



UNIVERSIDAD DE OVIEDO

ESCUELA POLITÉCNICA DE MIERES

MÁSTER EN TELEDETECCIÓN Y SISTEMAS DE INFORMACIÓN GEOGRÁFICA

**DEPARTAMENTO DE BIOLOGÍA DE ORGANISMOS Y SISTEMAS
ÁREA DE INGENIERÍA AGROFORESTAL**

TRABAJO FIN DE MÁSTER

MODELOS DE PREDICCIÓN DE ESTRUCTURA DE MASAS DE CASTAÑO EN EL NOROESTE PENINSULAR MEDIANTE DATOS MULTI-ESPECTRALES SENTINEL-2

AUTOR: JOSÉ CARLOS PÉREZ GIRÓN

TUTOR: PEDRO ÁLVAREZ ÁLVAREZ

COTUTOR: MARÍA CASTAÑO DÍAZ

JULIO, 2017



RESUMEN

Para caracterizar la estructura forestal de cualquier especie vegetal, se hace necesario responder a preguntas científicas, ecológicas y monitorear múltiples cambios forestales, respondiendo a específicamente a las características de esa especie en un hábitat y situación concreta. Esto implica un análisis continuo de la superficie forestal y hoy día es posible gracias a las técnicas de observación de la tierra y el uso de Sistemas de Información Geográfica (SIG).

En este TFM, se evalúa la capacidad de obtener información de la estructura forestal de las masas de castaño en Asturias y Galicia, a partir de datos procedentes del Cuarto Inventario Forestal Nacional (IFN4) e imágenes multiespectrales Sentinel-2, mediante la reflectividad en cada banda e índices de vegetación derivados. Posteriormente, se analizan estadísticamente los datos mediante Árboles de Clasificación y Regresión (CaRT) para obtener modelos predictivos de tipología de masa y de las variables biométricas relacionadas con esta.

Los resultados mostraron que el empleo de imágenes multiespectrales y datos de inventario no es suficiente para obtener información de la estructura y tipología de las masas de castaño, aunque en combinación con datos LiDAR podrían dar lugar a una mejora sustancial en la predicción, consiguiendo así abrir camino en el empleo de nuevos métodos en la investigación científica forestal y ecológica.



ABSTRACT

To characterize the forest structure of any plant species, it is necessary to answer to scientific and ecological questions and monitor multiple forest changes, responding specifically to the characteristics of this species in a specific habitat and situation. This implies a continuous analysis of the forest area and it is possible only thanks to Earth observation tools and the use of Geographic Information Systems (GIS).

This TFM, aims to evaluate the ability to obtain information from the forest structure of the chestnut in Asturias and Galicia with data from “*Cuarto Inventario Forestal Nacional (IFN4)*” and multispectral Sentinel-2 data, by means of reflectivity of each band and derived vegetation index. Subsequently, a statistical analysis is made using Classification and Regression Trees (CaRT) to obtain predictive models of mass typology and associated biometric variables.

The results showed that the use of multispectral images and inventory data is insufficient to obtain information on the structure and typology of the sweet chestnut, although in combination with LiDAR data may give rise to a substantial improvement in the prediction, thus making way for the use of new methods in scientific forest and ecological research.



ÍNDICE

RESUMEN	3
ABSTRACT.....	4
1 INTRODUCCIÓN Y OBJETIVOS.....	7
2 MATERIAL Y MÉTODOS.....	9
2.1 ÁREA DE ESTUDIO Y DATOS DE INVENTARIO	9
2.1.1 Características generales del castaño (<i>Castanea sativa</i> MILL.).....	9
2.1.2 Obtención de las parcelas.....	9
2.1.3 Inventario dasométrico previo y establecimiento de las tipologías	10
2.2 IMÁGENES SENTINEL-2	11
2.2.1 Adquisición de las imágenes.....	12
A. Level 1C	12
B. Level 2A	13
2.2.2 Imágenes seleccionadas.....	13
2.2.3 Correcciones de la imagen	15
2.2.4 Extracción de valores de reflectividad.....	17
2.3 ÍNDICES DE VEGETACIÓN	18
2.3.1 Fundamento teórico.....	18
2.3.2 Índices de vegetación empleados.....	20
2.4 ANÁLISIS ESTADÍSTICO.....	21
2.4.1 Depuración de los datos	21
2.4.2 Classification and Regression Trees (CaRT).....	21
2.4.3 Estimación del riesgo en el modelo	23
2.5 GENERACIÓN DE MAPAS PREDICTIVOS	23
3 RESULTADOS.....	25
4 DISCUSIÓN	28
5 CONCLUSIONES.....	30
6 BIBLIOGRAFÍA.....	31
7 ANEXOS	37
7.1 SCRIPT PARA PROCESADO EN BATCH DE LAS IMÁGENES	37
7.2 MAPAS PREDICTIVOS.....	38



ÍNDICE DE TABLAS

Tabla 1. Variables dasométricas disponibles para el estudio. Fuente: GIS-Forest	11
Tabla 2. Características espectrales y espaciales del sensor. Fuente: Drusch et al., (2012).....	12
Tabla 3. Imágenes Sentinel-2 adquiridas de verano de 2016 (VI6).....	14
Tabla 4. Imágenes Sentinel-2 adquiridas de primavera de 2017 (P17).	15
Tabla 5. Relación de índices de vegetación revisados y su nomenclatura.	20
Tabla 6. Índices calculados y relación de bandas "B" empleadas en el cálculo.	21
Tabla 7. Resultados del CaRT de los modelos pronosticados para las variables Dm, Dg, Ddom, G_ha_cas, Dg_cas y Por_cas.....	26

ÍNDICE DE FIGURAS

Figura 1. Muestreo del Inventario Forestal Nacional (IFN) con radio variable y fórmula de cálculo del FAC. Fuente: (Ruiz- Benito & García-Valdés, 2016).	10
Figura 2. Localización de las parcelas de estudio.	10
Figura 3. Descripción del proceso de clasificación de tipologías donde Pcs es el porcentaje, Ncs la densidad, Dgcs el diámetro medio cuadrático y Hcs la altura de los castaños, siendo H la altura de la parcela. Fuente: GIS-Forest.....	11
Figura 4. Procesado de las imágenes en estaciones de la ESA (Drusch et al., 2012).....	13
Figura 5. Rejilla de mosaicos mostrando el Tile 29TPH seleccionado en Google Earth. Fuente: Elaboración propia.	13
Figura 6. Flujo de procesos de Sen2Cor (Richter et al., 2012).....	16
Figura 7. Arriba: Imagen Sentinel-2 sin correcciones. Abajo: Imagen Sentinel-2 corregida de atmosfera y topografía.	16
Figura 8. Formato del .txt de coordenadas.	17
Figura 9. Extracción de valores de pixel con SNAP.	18
Figura 10. Firma espectral de la vegetación (Chuvieco, 2008).....	19
Figura 11. Partición de los nodos mediante CaRT.	22
Figura 12. Ejemplo de generación del mapa de predicción.....	24
Figura 13. Izq: CaRT para Dg. Der: CaRT para Dg_cas.....	27



1 INTRODUCCIÓN Y OBJETIVOS

La distribución de una determinada especie no es algo azaroso, ni permanente en el tiempo, sino determinada por la existencia de unos determinados factores ecológicos que satisfagan las necesidades de la especie y por las variaciones que sufren los mismos a lo largo del tiempo evolutivo (González, 2008).

Según datos del Mapa Forestal de España (MFE50) se puede hablar de unas 200.000 ha de masas en España donde la especie principal es el castaño de las cuales cabe destacar la presencia de estas masas en Asturias con unas 120.000 ha y seguido de Galicia con unas 60.000 ha.

Tras el abandono del campo debido el éxodo de los habitantes de las zonas rurales a las ciudades, muchas de estas masas, en especial los sotos, quedaron sin los cuidados culturales que recibían cuando eran aprovechadas para fruto o madera produciéndose una degradación y mezcla con otras especies (Álvarez-Álvarez *et al.*, 2000).

En la actualidad se ha intentado determinar en qué estado se encuentran estas masas mediante inventarios de campo, llegando a establecer diferentes niveles, pero esta labor tiene el inconveniente de ser una de las tareas más arduas y costosas (Alberdi *et al.*, 2016). Por ello se trata de recurrir a otros medios como la teledetección, con el fin de establecer relaciones entre los parámetros forestales y los datos obtenidos mediante esta técnica (McRoberts *et al.*, 2010).

El termino teledetección procedente del inglés (Remote Sensing) y no tiene una definición única empleada de forma habitual, de modo que son distintas las formas de conocerlo. Desde definiciones más generales, como en Lillesand *et al.*, (2014) donde se define como la ciencia y el arte de obtener información sobre un objeto, área o fenómeno a través del análisis de datos adquiridos por un aparato o artefacto que no está en contacto con este objeto, área o fenómeno, hasta más concretas como en Chuvieco, (2008) donde se define como aquella técnica que permite adquirir imágenes de la superficie terrestre desde sensores instalados en plataformas espaciales, asumiendo que entre la Tierra y el sensor existe una interacción energética ya sea reflexión de la energía solar o de un haz energético artificial, ya por emisión propia.

Se pueden destacar las siguientes ventajas de la teledetección espacial frente a los medios de observación más convencionales (Chuvieco, 2008):

- Cobertura global, repetitiva, panorámica y multiescala. Se ofrecen imágenes con una periodicidad determinada para un mismo sensor y además cubren toda la superficie terrestre, lo que favorece estudios a gran escala y prolongados en el tiempo. Además, la altura a la que van montados los sensores permiten capturar en una sola imagen grandes áreas de superficie, y estas dependiendo del sensor con un determinado nivel de detalle.



- Captura de información en regiones no visibles del espectro electromagnético. Los sensores empleados son capaces de capturar tipos de energía que no son perceptibles al ojo humano o incluso con cámaras convencionales.
- Formato digital y transmisión inmediata. Capturan las imágenes en formato digital, lo que favorece desde el tratamiento posterior de la imagen, con técnicas como el tratamiento digital de imágenes, a hacer que la transmisión de los datos capturados por el sensor se realice de forma automática y se puede disponer de esta información en un corto periodo de tiempo.

Debido a estas características que son propias del método, y principalmente al aumento de la disponibilidad de imágenes gratuitas capturas por sensores montados sobre satélite que existen en la actualidad, es posible el empleo de esta técnica como método complementario a los inventarios tradicionales.

En virtud de las necesidades del estudio, se establecen como principales objetivos los siguientes:

Objetivo 1. Estudio de la relación existente entre la estructura y tipología de las masas de castaño (*Castanea sativa Mill.*) determinada a partir de variables dasométricas del Cuarto Inventario Forestal Nacional (IFN4) en el Principado de Asturias y Galicia y los datos multiespectrales obtenidos de las imágenes de Sentinel-2 mediante la determinación de modelos de predicción ajustados.

Objetivo 2. Generación de cartografía continua a partir de los modelos pronosticados y de los datos Sentinel-2 que permita determinar la presencia de las diferentes estructuras y tipologías de las masas de castaño en la región de estudio.

2 MATERIAL Y MÉTODOS

2.1 ÁREA DE ESTUDIO Y DATOS DE INVENTARIO

2.1.1 CARACTERÍSTICAS GENERALES DEL CASTAÑO (*CASTANEA SATIVA MILL.*)

Castanea sativa M. es una especie perteneciente a la familia de las fagáceas. Considerada como autóctona en la península ibérica dadas las evidencias de registros de polen (Krebs *et al.*, 2004), y difundido su cultivo por los romanos hasta las áreas más occidentales de Europa, haciendo de esta especie una de las más importantes en la edad media (Conedera *et al.*, 2004).

Es una especie sensible a heladas tempranas y otoñales, que se desarrolla bien en estaciones con una temperatura media anual de 10-14°C, sin grandes variaciones. Requiere como mínimo de 700 mm de pluviometría anual, sin soportar la sequía estival, desarrollándose principalmente sobre suelos ricos en nutrientes, sin acumulación de sales y preferiblemente neutros o ácidos. En cuanto al temperamento, es una especie de media sombra, es decir, requiere de una cubierta que lo proteja en las primeras fases de su desarrollo (Álvarez-Álvarez *et al.*, 2000).

Es posible localizar masas de castaño de forma domesticada y silvestre. A las primeras se les conoce con el nombre de soutos, los cuales predominan en Galicia, mientras que en Asturias predomina la forma silvestre en monte bajo (Álvarez-Álvarez *et al.*, 2000).

2.1.2 OBTENCIÓN DE LAS PARCELAS

Se dispone de la base de datos del Cuarto Inventario Forestal Nacional (IFN4), el cual comenzó a mediados del año 2008, facilitada por el Banco de Datos de la Naturaleza, perteneciente al MAGRAMA, para las comunidades autónomas de Galicia y Principado de Asturias.

Las parcelas del IFN son parcelas permanentes de radio variable (Figura 1), significando esto que en el círculo de 5 m de radio se miden todos los pies mayores (diámetro igual o superior a 7,5 cm), en el de 10 m de radio sólo se miden los de la clase diamétrica 15 o mayor, en el de 15 m sólo los de clase diamétrica 25 o mayor y en la de 25 m de radio, sólo los de clase diamétrica 45 o mayor (Alberdi *et al.*, 2016; JUNTA DE CASTILLA Y LEÓN, 2014; Ruiz-Benito & García-Valdés, 2016).

Debido a esto, la conversión de los datos de la parcela a valores por hectárea se realiza mediante el correspondiente factor de expansión “FAC”, dando valores para dicho factor de 127, 32, 14 y 5 correspondientes con los radios anteriores.

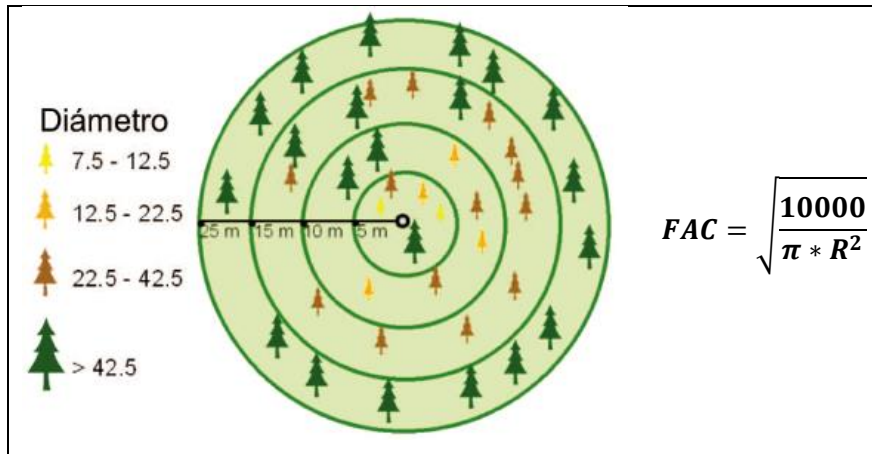


Figura 1. Muestreo del Inventario Forestal Nacional (IFN) con radio variable y fórmula de cálculo del FAC. Fuente: (Ruiz-Benito & García-Valdés, 2016).

Por lo tanto, a partir de las coordenadas XY se genera la capa de puntos con los datos correspondientes a cada parcela que posteriormente será procesada como se detalla en el punto 2.2.4 de este estudio. En este caso, solo se emplearon aquellas parcelas en que la especie principal es el castaño y su porcentaje de ocupación como especie principal supera el 50%, resultando en total 776 parcelas que cumplían estos requisitos. En la Figura 2 se muestra un mapa con la localización del total de parcelas estudiadas.

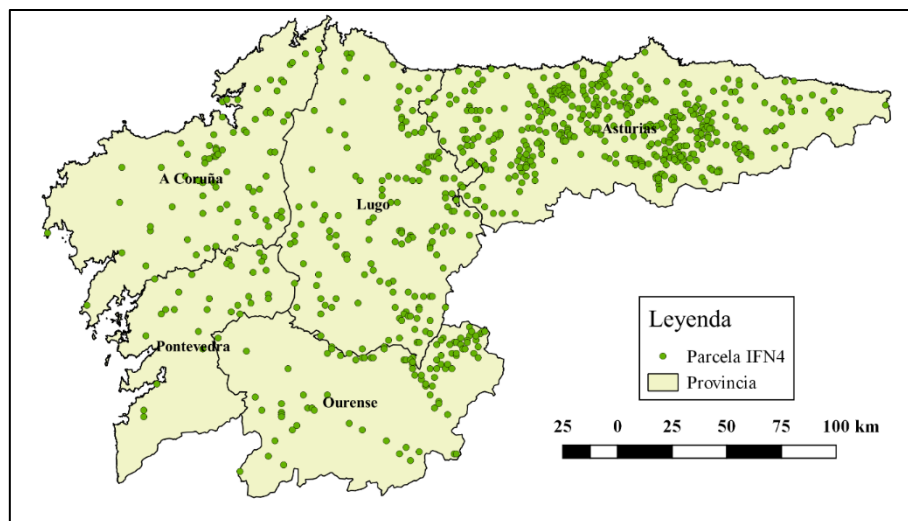


Figura 2. Localización de las parcelas de estudio.

2.1.3 INVENTARIO DASOMÉTRICO PREVIO Y ESTABLECIMIENTO DE LAS TIPOLOGÍAS

Previo a este estudio, en trabajos realizados por el grupo de investigación GIS-Forest pendientes de su publicación, se estudió la relación de existente entre las variables dasométricas y los diferentes tipos de estructuras forestales de las masas de castaño en el Noroeste Peninsular.

De este trabajo se aprovechará la información relativa a las tipologías de masas establecida (véase Figura 3) y las relaciones con los datos dasométricos recogidos en el IFN4 que se emplearon para establecer dichas tipologías (Tabla 1).

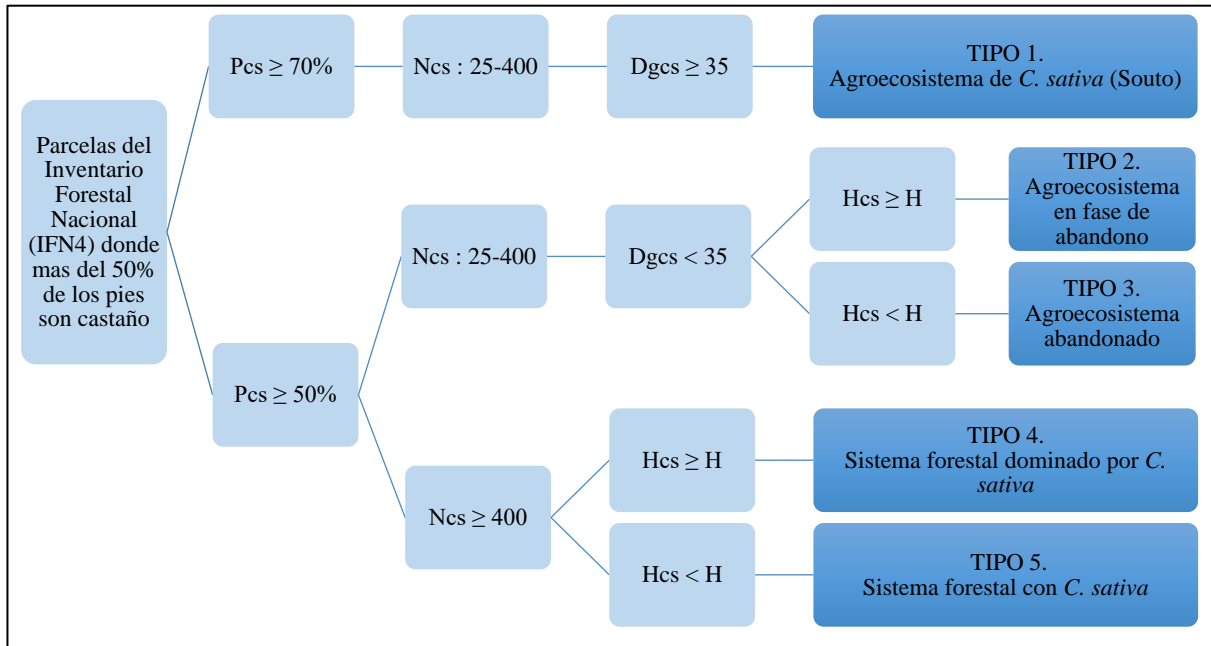


Figura 3. Descripción del proceso de clasificación de tipologías donde Pcs es el porcentaje, Ncs la densidad, Dgcs el diámetro medio cuadrático y Hcs la altura de los castaños, siendo H la altura de la parcela. Fuente: GIS-Forest.

Tabla 1. Variables dasométricas disponibles para el estudio. Fuente: GIS-Forest

Variable	Descripción de la variable
Provincia	Código de provincia
Estadillo	Nº de estadillo
Par_esta	Nº de parcela
N_ha	Número de pies por hectárea
Var_Ht	Varianza de la altura
G_ha	Área basimétrica por hectárea
Vcc_ha	Volumen con corteza por hectárea
Hm	Altura media
Dm	Diámetro medio
Dg	Diámetro medio cuadrático
hdom	Altura dominante
ddom	Diámetro dominante
N_ha_cas	Número de pies por hectárea (castaño)
G_ha_cas	Área basimétrica por hectárea (castaño)
Hm_cas	Altura media de (castaño)
Dg_cas	Diámetro medio cuadrático de (castaño)
por_casta	Porcentaje de castaño

2.2 IMÁGENES SENTINEL-2

La misión Sentinel-2 tiene como objetivos obtener imágenes que ayuden a observar los cambios terrestres de la Tierra dando continuidad a la serie de imágenes proporcionadas por los satélites LANDSAT y SPOT. Compuesta por dos satélites gemelos de órbita polar en la misma órbita, ambos

separados por un ángulo de 180° y equipados con un escáner multiespectral de 13 bandas que permite obtener información en el rango de los visibles e infrarrojos, permitiendo monitorizar los cambios en la tierra y en la vegetación, así como vigilar a nivel mundial el cambio climático, con una resolución espacial de 10, 20 y 60 m.

En la Tabla 2 se muestran las características en cuanto a resolución espectral y espacial del sensor.

Tabla 2. Características espectrales y espaciales del sensor. Fuente: Drusch *et al.*, (2012)

Sensor	Banda	Longitud de onda central (nm)	Ancho de banda (nm)	Resolución espacial (m)	Rango espectro
MSI (Multi Spectral Instrument)	1	443	20	60	Aerosol costero
	2	490	65	10	Azul
	3	560	35	10	Verde
	4	665	30	10	Rojo
	5	705	15	20	NIR
	6	740	15	20	NIR
	7	783	20	20	NIR
	8	842	115	10	NIR
	8a	865	20	20	NIR
	9	945	20	60	Vapor de Agua
	10	1380	30	60	SWIR- Cirrus
	11	1610	90	20	SWIR
12	2190	180	20	SWIR	

2.2.1 ADQUISICIÓN DE LAS IMÁGENES

Las imágenes son una compilación de “tiles” o mosaicos, en una determinada órbita. Estos mosaicos son la mínima partición indivisible que contiene la información de todas las longitudes de onda que el sensor es capaz de captar y tienen un tamaño de 100 x 100 km².

Estas son facilitadas de manera gratuita por la página web de la ESA (European Space Agency) para la misión Copérnico (<https://scihub.copernicus.eu/>), en la cual cualquier usuario previamente registrado puede seleccionar una zona deseada y descargar las imágenes mediante descarga directa. El nivel de procesado mínimo para la descarga es un “Level 1C”.

A. LEVEL 1C

El nivel de procesado ofrecido para la descarga es el 1C, el cual corresponde a una imagen dividida en mosaicos, de tamaño 100 x 100 km² (orto-rectificada) en proyección UTM/WGS84 y con un tamaño aproximado de 500 MB por mosaico. Las mediciones dadas por pixel son reflectividad Top of Atmosphere (TOA) junto con los parámetros para convertirlas en radiancia. El tamaño del pixel ha sido remuestreado con un GSD de tamaño fijo a valores de 10, 20 y 60 m. La precisión obtenida en el proceso de orto-rectificación está alrededor de un pixel (Clerc & Team, 2017; Drusch *et al.*, 2012; Vajsova, 2015). En la Figura 4 se muestra el procesado completo por parte de la estación de tratamiento de datos de la ESA.

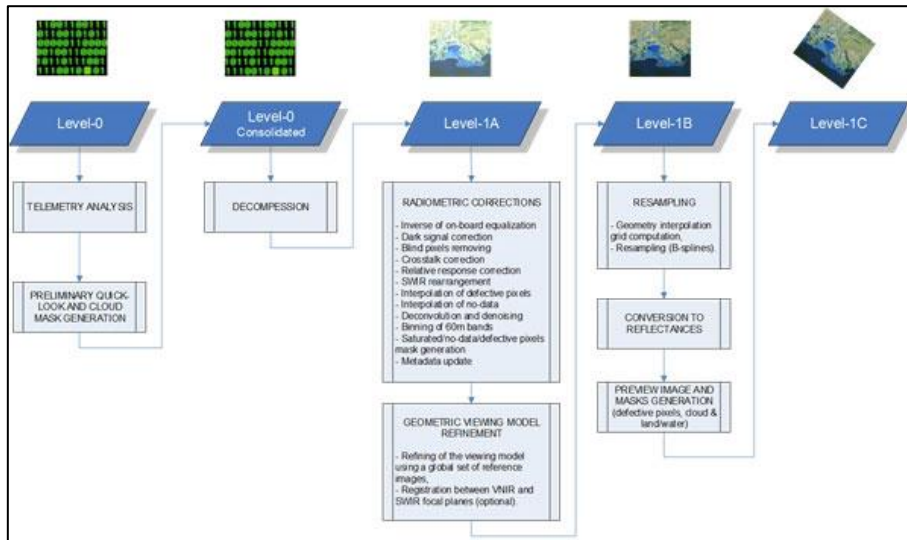


Figura 4. Procesado de las imágenes en estaciones de la ESA (Drusch et al., 2012)

B. LEVEL 2A

El nivel 2A proporciona imágenes de reflectividad Bottom of Atmosphere (BOA) derivadas de los productos Level-1C. Los productos de nivel 2A no son generados de forma automática por el sistema, sino que deben ser generados por el usuario mediante la herramienta Sentinel-2 Toolbox de SNAP.

2.2.2 IMÁGENES SELECCIONADAS

Para seleccionar los mosaicos del área de interés la ESA pone a disposición del usuario una rejilla en formato kml, visible en Google Earth, con la cual es posible determinar los nombres de los mosaicos que ocupan el área de estudio (Figura 5). Esta rejilla está disponible en:

https://sentinel.esa.int/documents/247904/1955685/S2A_OPER_GIP_TILPAR_MPC_20151209T095117_V20150622T000000_21000101T000000_B00.kml



Figura 5. Rejilla de mosaicos mostrando el Tile 29TPH seleccionado en Google Earth.

Fuente: Elaboración propia.

La elección de la época de las imágenes se realizó de acuerdo a criterios técnicos en cuanto a la corrección de imágenes, pues tras varias pruebas iniciales, en aquellas imágenes con un ángulo de elevación solar bajo la corrección topográfica era peor, mientras que, sin embargo, con ángulos de elevación superiores a 50° se daba sin problemas dicha corrección, por lo que se decide coger imágenes tomadas en época estival.

A pesar de que la toma de datos del IFN4 se realizó en 2012 y para la cual no estaba Sentinel-2 en funcionamiento, se decide emplear estas imágenes debido a la prometedora resolución espacial del sensor, teniendo en cuenta que la variación de la estructura de la masa es mínimo o despreciable en el período de desfase considerado (4 años). Las primeras imágenes que estaban a disposición eran de otoño de 2015, por lo que la presencia de datos con información de las hojas debía retrasarse hasta 2016, denominándolas como V16.

A continuación, en la Tabla 3 se muestran los datos relativos a las imágenes empleadas y que mosaicos se escogieron de cada una de ellas.

Tabla 3. Imágenes Sentinel-2 adquiridas de verano de 2016 (V16)

Imagen	Mosaico	Fecha de adquisición	Hora
S2A_OPER_PRD_MSIL1C_PDMC_20160710T015540_R037_V20160709T112403_20160709T112403.SAFE	29TNJ 29TPJ 29TQJ	09/07/2016	11:24:03
S2A_OPER_PRD_MSIL1C_PDMC_20160710T020205_R037_V20160709T112403_20160709T112403.SAFE	29TNH 29TNG 29TPH 29TPG 29TQH 29TQG	09/07/2016	11:24:03
S2A_OPER_PRD_MSIL1C_PDMC_20160716T184457_R137_V20160716T110923_20160716T110923.SAFE	30TUN	16/07/2016	11:09:23
S2A_OPER_PRD_MSIL1C_PDMC_20160716T184528_R137_V20160716T110923_20160716T110923.SAFE	30TUP	16/07/2016	11:09:23
S2A_OPER_PRD_MSIL1C_PDMC_20160802T093515_R080_V20160801T113323_20160801T113323.SAFE	29TMH 29TMG	01/08/2016	11:33:23

En segundo lugar, debido a la fenología del castaño, que hace que sea una de las especies forestales en las que más tarde brota la hoja (Furones-Pérez & Fernández-López, 2009), se decidió, coger una serie de imágenes de primavera, donde la reflectividad de las hojas fuese diferente a las demás especies.

Evaluando las imágenes disponibles, se decidió retrasar el estudio y esperar a que estuviesen disponibles las imágenes de la primavera de 2017, pues en los datos de 2016 la cantidad de nubes y el tamaño tan grande de los mosaicos hacia inservible la información.

Finalmente, las imágenes de primavera elegidas fueron las correspondientes a abril de 2017, cuando ya se había comprobado la brotación del castaño. En este caso, la ESA ya distribuía mosaicos

pequeños, con lo cual bastó con descargar cada uno por separado. Los datos relativos a los mosaicos de primavera empleados son los que se muestran en la Tabla 4.

Tabla 4. Imágenes Sentinel-2 adquiridas de primavera de 2017 (P17).

Imagen	Mosaico	Fecha de adquisición	Hora
S2A_MSIL1C_20170316T112101_N0204_R037_T29TNJ_20170316T112658.SAFE	29TNJ	16/03/2017	11:21:01
S2A_MSIL1C_20170316T112101_N0204_R037_T29TPJ_20170316T112658.SAFE	29TPJ	16/03/2017	11:21:01
S2A_MSIL1C_20170316T112101_N0204_R037_T29TQJ_20170316T112658.SAFE	29TQJ	16/03/2017	11:21:01
S2A_MSIL1C_20170319T113311_N0204_R080_T29TNH_20170319T113813.SAFE	29TNH	19/03/2017	11:33:11
S2A_MSIL1C_20170319T113311_N0204_R080_T29TNG_20170319T113813.SAFE	29TNG	19/03/2017	11:33:11
S2A_MSIL1C_20170316T112101_N0204_R037_T29TPH_20170316T112658.SAFE	29TPH	16/03/2017	11:21:01
S2A_MSIL1C_20170316T112101_N0204_R037_T29TPG_20170316T112658.SAFE	29TPG	16/03/2017	11:21:01
S2A_MSIL1C_20170316T112101_N0204_R037_T29TQH_20170316T112658.SAFE	29TQH	16/03/2017	11:21:01
S2A_MSIL1C_20170316T112101_N0204_R037_T30TUP_20170316T112658.SAFE	30TUP	16/03/2017	11:21:01

2.2.3 CORRECCIONES DE LA IMAGEN

Previamente al empleo de imágenes para el estudio de la teledetección las imágenes deben ser corregidas en caso de ser necesario tanto geoméricamente como radiométricamente. En este caso, las imágenes son ofrecidas por la ESA con un determinado nivel de procesamiento y corrección ya mencionado anteriormente (Figura 4), por lo que debido a la envergadura del proyecto se acepta la corrección geométrica por defecto como aceptable (1 pixel de error) y se procede a corregir radiométricamente las imágenes de atmosfera y topografía.

El procesado de las imágenes se ha llevado a cabo mediante el programa Sentinel Application Platform (SNAP), facilitado por la ESA para el procesado de imágenes Sentinel. Es una plataforma de código abierto GPLv3 (General Public License) por lo que su descarga y uso es gratuito. Disponible en: <http://step.esa.int/main/download/>. El proceso es prácticamente automatizado, pues por una parte el programa es capaz de realizar la corrección atmosférica y topográfica mediante datos tomados por el sensor, por lo que no hay que introducir datos externos, y por otra parte se automatiza el procesado de las imágenes mediante el desarrollo de un script programado en lenguaje de programación Python que ejecuta la aplicación desde consola de comandos y procesa las imágenes en lotes. El script se puede ver en el anexo 7.1 “Script para procesado en batch de las imágenes”.

Para la corrección atmosférica y topográfica se ejecuta el procedimiento Sen2Cor incluido en la extensión Sentinel-2 Toolbox desarrollada por (Müller-Wilm *et al.*, 2013) y cuyo algoritmo es descrito en (Richter *et al.*, 2012), y, que comparando con otros programas de corrección radiométrica como 6S,

FLAASH y DOS se obtuvo que los resultados obtenidos para píxeles de suelo desnudo y masas vegetales se comportan de forma similar en todos los programas, obteniendo resultados análogos (Lantzanakis *et al.*, 2017). En la Figura 6 se muestra el flujo de procesos que ejecuta Sen2Cor.

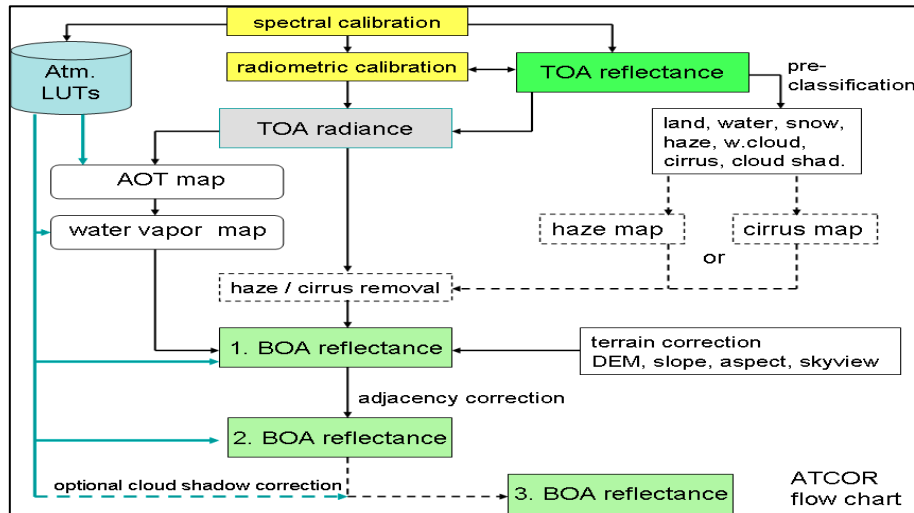


Figura 6. Flujo de procesos de Sen2Cor (Richter *et al.*, 2012)

Tras realizar las correcciones, se comprobaron las imágenes en polígonos de agua, viendo que su valor de reflectividad es bajo y constante tras corregir la imagen siguiendo el método descrito por Bukata *et al.*, (1983) y empleado en Recondo, (2002) con éxito. Además, se realizó una inspección visual de zonas montañosas para ver que efectivamente se había realizado bien el proceso (Figura 7).




Figura 7. Arriba: Imagen Sentinel-2 sin correcciones. Abajo: Imagen Sentinel-2 corregida de atmosfera y topografía.

2.2.4 EXTRACCIÓN DE VALORES DE REFLECTIVIDAD

Los datos de inventario IFN4 deben ser preparados para poder emplearlos en el programa SNAP, el cual pide como datos de entrada un fichero *.txt con los datos ordenados por un nombre y las coordenadas del punto en longitud y latitud.

De los datos ofrecidos por el IFN4 se extrae el valor FAC mínimo que corresponde con el máximo radio para cada parcela. Posteriormente estos datos son tratados con QGIS, realizando las siguientes operaciones:

1. *Proyección de cada parcela como un punto único, a partir de las coordenadas proyectadas, mediante la herramienta “Añadir capa de texto delimitado”.*
2. *“Buffer de distancia variable” en función del radio de parcela para crear una capa de polígonos con el área ocupada por cada parcela.*
3. *“Rasterizar” en función del nombre de la parcela, pues se pretende crear una capa ráster cuyas celdas contengan el nombre de la parcela a la que pertenecen, con un tamaño de celda de 10 m que es el tamaño de pixel de la imagen de la cual se va a obtener la reflectividad.*
4. *“Raster values to points” perteneciente a las herramientas de procesamiento de SAGA, con objeto de obtener el centroide de cada celda ráster que estaba inicialmente incluida dentro del área de la parcela.*
5. *Por último, se extraen las coordenadas en longitud y latitud y se exporta la tabla de atributos a un formato compatible con Excel.*

Una vez se dispone de esta información, se debe preparar en Excel la tabla para que solo queden las columnas correspondientes al nombre y a la longitud y latitud del punto, y será exportado en formato *.txt (MS-DOS), el cual queda según la Figura 8.

1	Name	Lon	Lat
2	323373	-8.20415205206	41.91801678410
3	323373	-8.20403147114	41.91801594830
4	323373	-8.20427151414	41.91810767910
5	323373	-8.20415093305	41.91810684340
6	323373	-8.20403035195	41.91810600750
7	323373	-8.20390977087	41.91810517160

Figura 8. Formato del .txt de coordenadas.

En cuanto a las imágenes, se remuestrearon todas a un tamaño de pixel de 10 m con el método de interpolación del vecino más próximo, ya que es necesario para poder extraer los valores de reflectividad con SNAP, pues no opera con imágenes multi-tamaño.

En el apartado Raster→Export→Extract pixel values, se añaden las imágenes corregidas y remuestreadas, se da un directorio de salida y un nombre al archivo, se añaden los puntos de los cuales se va a extraer datos mediante el archivo de texto creado anteriormente, y señalando únicamente el tic correspondiente a extraer valores de bandas (Figura 9), se ejecuta la aplicación, que generará un archivo de texto en el directorio indicado y con el nombre dado con los valores correspondientes a cada banda para cada uno de los puntos introducidos.

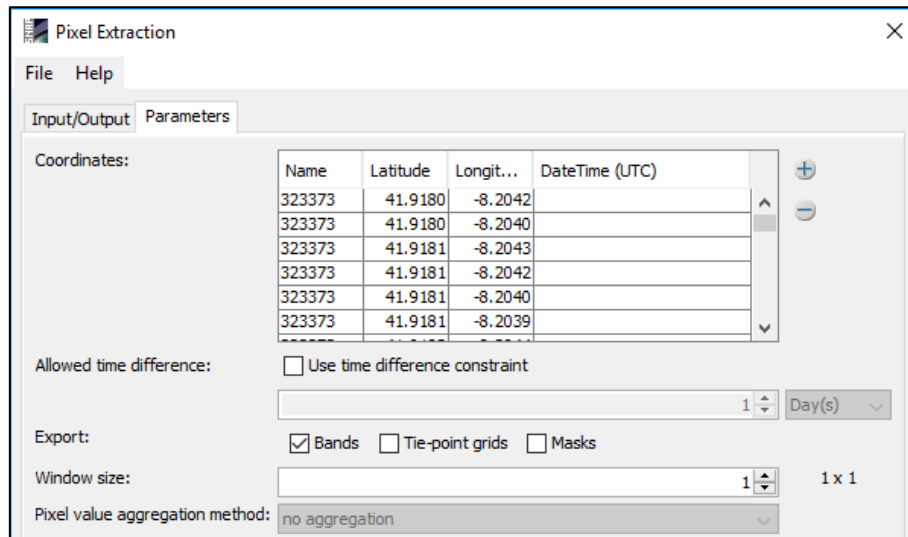


Figura 9. Extracción de valores de pixel con SNAP.

Por último, con dicha información, se resumieron los datos a valores por parcela según la media y la desviación típica y se creó una base de datos con la cual se procedió al cálculo de índices de vegetación y al análisis estadístico.

2.3 ÍNDICES DE VEGETACIÓN

2.3.1 FUNDAMENTO TEÓRICO

Uno de los fundamentos de la teledetección reside en una respuesta diferente de las distintas superficies a las diferentes longitudes de onda del espectro electromagnético. Según se puede observar en la Figura 10, si bien cada tipo de vegetación responde de distinta forma (Chuvieco, 2008), se cumplen unos parámetros generales, dados por una baja reflectividad en el visible, alta en el infrarrojo cercano (NIR) y baja con presencia de algunos picos en el infrarrojo de onda corta (SWIR) (Chuvieco, 2008).




Figura 10. Firma espectral de la vegetación (Chuvieco, 2008).

En concreto, la baja reflectividad en el visible, es debida al efecto absorbente de los pigmentos de la hoja (clorofilas, xantofilas y carotenos) (Gates *et al.*, 1965). La elevada reflectividad en el NIR es debida a la baja absorción de las clorofilas y a la estructura celular interna de la hoja y a partir de 1,4 μm , el efecto absorbente del agua es muy fuerte, por lo que se reduce la reflectividad drásticamente en el SWIR (Chuvieco, 2008).

Cabe destacar también el gran contraste entre la región del visible, concretamente en torno al rojo ($\lambda=0,6 \mu\text{m}$), y la del NIR, que da lugar a una pendiente acentuada que permite la obtención de una serie de índices de vegetación basados en este contraste, donde está representada más del 90% de la información espectral de la cubierta vegetal, por lo que son por lo general las bandas más empleadas para el cálculo de índices (Chuvieco, 2008; Major *et al.*, 1990; Sobrino, 2000).

Jackson *et al.*, (1983) define el índice de vegetación ideal como “*aquel particularmente sensible a la cubierta vegetal, insensible al brillo y color del suelo y poco afectado por las perturbaciones atmosféricas, los factores medioambientales y la geometría de iluminación y de observación*”. Posteriormente Sobrino (2000), define un índice de vegetación (IV) como “*un parámetro calculado a partir de los valores de reflectividad a distintas longitudes de onda y que pretende extraer la información relacionada con la vegetación minimizando la influencia de otros factores externos como las propiedades ópticas del suelo, la irradiancia solar, etc.*”.

Por lo tanto, los índices de vegetación constituyen una forma indirecta de medir diferentes parámetros o variables dasométricas de la vegetación mediante el empleo de datos espectrales obtenidos de imágenes tomadas por sensores remotos, siendo por tanto una idea que se adapta muy bien a la cuantificación de la vegetación en grandes áreas (Bannari *et al.*, 1995).

2.3.2 ÍNDICES DE VEGETACIÓN EMPLEADOS

Para determinar los índices a calcular, se realizó una revisión bibliográfica basada en estudios previos con objetivos similares, tanto de aquellos que usan el mismo sensor que se emplea en el presente proyecto como los que no lo hacen. Los índices revisados y sus denominaciones fueron los que se detallan en la Tabla 5.

Tabla 5. Relación de índices de vegetación revisados y su nomenclatura.

Índice	Abreviatura	Autor y fecha
Anthocyanin Reflectance Index I	ARI1	(Gitelson <i>et al.</i> , 2001)
Carotenoid Reflectance Index I	CRI1	(Gitelson <i>et al.</i> , 2002)
Difference Vegetation Index	DVI	(Tucker, 1979)
Enhanced Vegetation Index	EVI	(Huete <i>et al.</i> , 2002)
Green Normalized Difference Vegetation Index	GNDVI	(Gitelson <i>et al.</i> , 1996)
Inverted Red-Edge Chlorophyll Index	IRECI	(Frampton <i>et al.</i> , 2013)
Modified Soil Adjusted Vegetation Index	MSAVI2	(Qi <i>et al.</i> , 1994)
Moisture Stress Index	MSI	(Rock <i>et al.</i> , 1986)
Moisture Vegetation Index	MVI	(Ponzoni, 2001)
Normalized Difference Infrared Index	NDII	(Hardisky <i>et al.</i> , 1983)
Normalized Difference Vegetation Index	NDVI	(Rouse, 1973)
Red-Green Ratio	RGR	(Sims & Gamon, 2002)
Sentinel-2 Red-Edge Position	S2REP	(Frampton <i>et al.</i> , 2013)
Soil Adjusted Vegetation Index	SAVI	(Huete, 1988)
Standardized Vegetation Index	SVI	(Peters <i>et al.</i> , 2002)

En cuanto a estudios realizados con Landsat TM se encontró que en Cabacinha & de Castro, (2009) se empleó el NDVI, SAVI, EVI, MVI5 Y MVI7 para determinar relaciones con la diversidad florística y estructura forestal; Lu *et al.*, (2004) emplea los índices SVI, MSI, NDVI, NDII5, NDII7, SAVI Y MSAVI2, para determinar la correlación con variables dasométricas como área basimétrica o altura media; finalmente Freitas *et al.*, (2005) empleó el NDVI, MVI5 y MVI7 para determinar relaciones con la estructura forestal de bosques atlánticos lluviosos en Brasil.

En cuanto a la revisión bibliográfica de índices calculados a partir de imágenes Sentinel-2, los datos son más escasos al tratarse de una plataforma que lleva menor tiempo capturando datos. Destaca el empleo de los índices EVI y DVI como índices de mayor éxito entre otros muchos calculados para la determinación de crecimientos en volumen de masas forestales (Chrysafis *et al.*, 2017). En Majasalmi & Rautiainen, (2016) se emplea el S2REP para estimar variables biofísicas como el índice de área foliar (LAI). Este también es empleado junto con IRECI y NDVI en Frampton *et al.*, (2013), para el mismo propósito. Por último, en Hill, (2013) se emplean los índices NDVI, CRI1, ARI1, NDII y RGR como indicadores del estado de la vegetativo en pastizales y sabanas de Norte América.

Además de dicha revisión, se observó que debido a la gran cantidad de bandas en el NIR que tiene Sentinel-2, se emplea en algunos casos la B7 a pesar de tener originalmente menor resolución (Chrysafis *et al.*, 2017; Frampton *et al.*, 2013), por lo que se duplicará el cálculo de índices en aquellos en que sea necesario el empleo de dicha longitud de onda, dando lugar a un cálculo con la B7 y otro con

la B8 para el mismo índice. Esto da lugar a calcular un total de 12 índices de vegetación únicos (Tabla 6), es decir, sin contar duplicados por banda.

Tabla 6. Índices calculados y relación de bandas "B" empleadas en el cálculo.

Abreviatura	Fórmula	Sentinel-2 Bands
ARI1	$\left(\frac{1}{R_{550}}\right) - \left(\frac{1}{R_{700}}\right)$	$\left(\frac{1}{B3}\right) - \left(\frac{1}{B5}\right)$
CRI1	$\left(\frac{1}{R_{510}}\right) - \left(\frac{1}{R_{550}}\right)$	$\left(\frac{1}{B2}\right) - \left(\frac{1}{B3}\right)$
EVI	$G * \left(\frac{R_{NIR} - R_{RED}}{R_{NIR} + (C_1 * R_{RED} - C_2 * R_{BLUE}) + 1}\right)$	$2,5 * \left(\frac{B8 - B4}{B8 + (6 * B4 - 7,5 * B2) + 1}\right)$
GNDVI	$\frac{R_{NIR} - R_{GREEN}}{R_{NIR} + R_{GREEN}}$	$\frac{B8 - B3}{B8 + B3}$
IRECI	$\frac{R_{783} - R_{665}}{R_{783} + R_{665}}$	$\frac{B8 - B4}{B8 + B4}$
IRECI	$\frac{R_{705}}{R_{740}}$	$\frac{B5}{B6}$
MSAVI2	$\frac{2 * R_{NIR} + 1 - \sqrt{(2 * R_{NIR} + 1)^2 - 8 * (R_{NIR} - R_{RED})}}{2}$	$\frac{2 * B8 + 1 - \sqrt{(2 * B8 + 1)^2 - 8 * (B8 - B4)}}{2}$
MSI	$\frac{R_{1600}}{R_{820}}$	$\frac{B11}{B8}$
NDII	$\frac{R_{819} - R_{1649}}{R_{819} + R_{1649}}$	$\frac{B8 - B11}{B8 + B11}$
NDVI	$\frac{R_{803} - R_{681}}{R_{803} + R_{681}}$	$\frac{B8 - B4}{B8 + B4}$
RGR	$\frac{R_{600} - 699}{R_{500} - 599}$	$\frac{B4}{B3}$
S2REP	$705 + 35 * \left(\frac{\left(\frac{R_{783} + R_{665}}{2}\right) - R_{705}}{R_{740} - R_{705}}\right)$	$705 + 35 * \left(\frac{\left(\frac{B7 + B4}{2}\right) - B5}{B6 - B5}\right)$
SAVI	$\frac{R_{803} - R_{681}}{R_{803} + R_{681} + L} * (1 + L)$	$(B8 - B4)/(B8 + B4 + L) * (1 + L)$

2.4 ANÁLISIS ESTADÍSTICO

Se procedió a determinar las relaciones existentes entre los datos obtenidos mediante teledetección (reflectividad e índices) y los relacionados con la estructura de las masas de castaño obtenidos a partir del IFN4. Los análisis descritos fueron realizados con el software estadístico SPSS 23 (SPSS, 2016).

2.4.1 DEPURACIÓN DE LOS DATOS

Con objeto de no analizar datos de reflectividad correspondientes a las fracciones de suelo, agua o nubes se realizó un filtrado previo de la base de datos, eliminando del análisis aquellas parcelas en las cuales el valor del NDVI_8 era inferior o igual a 0,2. Con este valor se conseguía eliminar gran parte de los valores de reflectividad en zonas no deseadas, coincidiendo además con valores próximos a los recomendados en Holben, (1986).

2.4.2 CLASSIFICATION AND REGRESSION TREES (CART)

Los árboles de clasificación y regresión (CaRT) son un método no paramétrico desarrollado inicialmente por Breiman *et al.*, (1984) basado en la utilización de datos históricos y un número de clases

conocidas a priori para construir “árboles de decisiones”. Estos árboles de decisiones son empleados posteriormente para clasificar los nuevos datos (Gordon, 2013) y predecir modelos a partir de estos (Loh, 2011).

Los modelos se obtienen por divisiones repetitivas del espacio de datos y ajustando un modelo de predicción simple dentro de cada partición. Como resultado, las particiones resultantes pueden representarse gráficamente como un árbol de decisión (Loh, 2011). El procedimiento comienza partiendo el espacio de datos original en dos regiones diferentes, tratando de encontrar la división óptima de todas las variables sobre todos los puntos de rotura encontrados. Para cada una de las dos regiones creadas se volvería a repetir este proceso generando dos nuevas particiones por cada una generada anteriormente (Gordon, 2013).

Sea N_p el nodo parental y N_R, N_L , los respectivos nodos hijos derecha e izquierda del nodo parental. Considerando la muestra de entrenamiento como una matriz X con un número M de variables x_j y N observaciones. El árbol de clasificación se construye de acuerdo a la regla de la división, es decir, la regla que realiza la división de la muestra en partes más pequeñas (siempre dos) y con la máxima homogeneidad:




Figura 11. Partición de los nodos mediante CART.

Donde X_j es el valor de la variable y X_j^R es el mejor valor de variable en cuestión.

La máxima homogeneidad de los nodos hijos se define por la llamada función de impurezas $i(t)$. Puesto que la impureza del nodo padre N_p es constante para cualquiera de las divisiones posibles, la máxima homogeneidad de los nodos hijos izquierdo y derecho será equivalente a la maximización del cambio de la función de impurezas $i(t)$ (Timofeev, 2004). La función de impurezas empleada para partir la muestra en será la de GINI descrita en Breiman *et al.*, (1984).

Estas técnicas presentan ciertas ventajas para los problemas de teledetección debido a su rápida y fácil interpretación, mayor eficiencia con el tratamiento de gran cantidad de datos que las técnicas de regresión paramétricas, ya que no es necesaria la elección de antemano de las variables, pues identificará



las variables más significativas y elimina las no significativas (Friedl & Brodley, 1997; Gordon, 2013; Westreich *et al.*, 2010).

Como desventajas cabe destacar que cambios mínimos en la muestra de entrenamiento pueden dar lugar a arboles de decisión muy diferentes y que cada partición solo es debida a una variable (Timofeev, 2004).

Para realizar el CaRT con SPSS el procedimiento a seguir es el siguiente: Una vez cargada la base de datos en el programa, ir a “Analizar → Clasificar → Árbol”. En la ventana que aparece se debe elegir el método de crecimiento, que en nuestro caso es CRT, añadir la variable dependiente y las independientes. Por último, se definen los criterios para resultados, validación y ejecución del árbol.

2.4.3 ESTIMACIÓN DEL RIESGO EN EL MODELO

La idoneidad del modelo se evaluó mediante la estimación del riesgo descrita en (IBM, 2011), donde en el caso de que la variable dependiente sea de tipo escalar, dicha estimación de riesgo representará una medida de la varianza dentro de cada nodo, y por lo tanto no aporta mucha información al conjunto general. Por este motivo, son necesarios algunos pasos más para describir correctamente proporción de la varianza explicada por el modelo.

1. Si la varianza total es la varianza para las variables dependientes antes de tener en consideración a las variables independientes o, lo que es lo mismo, la varianza en el nodo raíz. Esta será igual al cuadrado de la desviación típica que se muestra en el nodo raíz.
2. La varianza dentro del nodo será el valor de la estimación de riesgo.
3. Del cociente entre la varianza dentro del nodo y la varianza total, se obtendrá la varianza no explicada, o lo que es lo mismo, la proporción de varianza debida al error.
4. Por último, la proporción de varianza explicada por el modelo corresponderá a la diferencia entre la unidad y la proporción de varianza debida al error.

2.5 GENERACIÓN DE MAPAS PREDICTIVOS

Una vez seleccionado el CaRT que muestra un mayor ajuste a la variable estudiada, se procedió a generar un mapa predictivo de la distribución de dicha variable mediante el uso del software SNAP. Haciendo uso de la calculadora de bandas (Band Maths) se generó una banda binaria para cada mosaico, en la que cada pixel queda evaluado como “Cero (0)” o “Uno (1)” según cumpla la condición establecida para pertenecer a un nodo determinado. Este método permite evaluar pixel a pixel la imagen con la condición introducida, obteniendo así datos continuos para toda el área de estudio.

Puesto que en las imágenes se tienen datos espectrales correspondientes a cubiertas que carecen de interés como agua, suelo o edificios, se realizaron pruebas con distintos índices de los calculados

anteriormente y se comprobó que realizando un filtrado con SAVI cuando este era superior a 0,2 se conseguía excluir prácticamente dichas cubiertas del área de estudio.

Como se observa en la Figura 12, donde se representa una parte de un mosaico tras el filtrado, el color negro corresponde con el valor “0”, es decir, no cumple las condiciones establecidas delimitando además el recorrido fluvial y la presencia de ciudades.

Una vez generadas estas bandas binarias para cada mosaico, mediante QGIS se maquetaron los mapas predictivos por provincias.

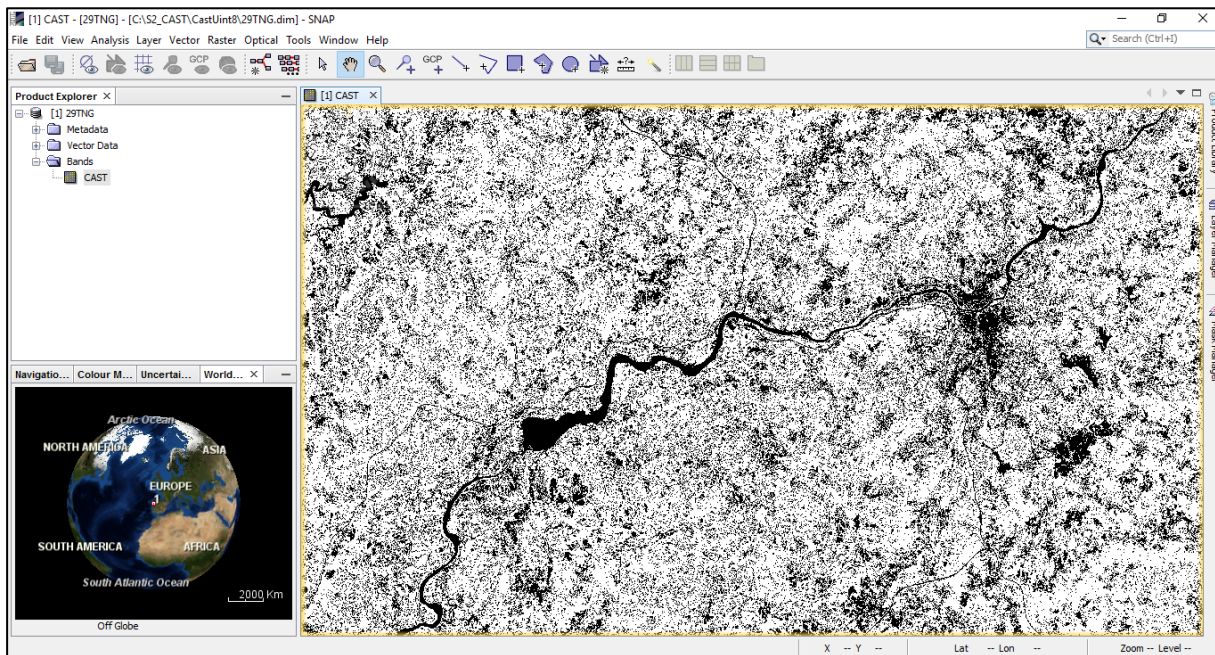


Figura 12. Ejemplo de generación del mapa de predicción.



3 RESULTADOS

Tras realizar el análisis estadístico con todas las variables dasométricas y tipológicas disponibles, se observó que no existía relación alguna de las variables espectrales con las tipológicas. En el caso de las variables dasométricas, aunque con una variabilidad explicada bastante baja si se encontraron algunas relaciones, según se muestran en la Tabla 7.



Tabla 7. Resultados del CaRT de los modelos pronosticados para las variables Dm, Dg, Ddom, G_ha_cas, Dg_cas y Por_cas.

Variable	R ²	Nodo	Media	Desviación estándar	N	%	Media pronosticada	Nodo padre	Variable independiente primaria		
									Variable	Mejora	Valores de división
Dm	0,115	0	25,826	17,754	763	100,0	25,826				
		1	21,996	11,890	388	50,9	21,996				≤ 0,005168
		2	29,788	21,563	375	49,1	29,788	0	V16SD_B4	15	> 0,005168
		3	18,542	8,930	187	24,5	18,542				≤ 0,005575
		4	25,210	13,337	201	26,3	25,210	1	P17SD_B4	6	> 0,005575
		5	33,914	24,146	241	31,6	33,914				≤ 0,563621
Dg	0,131	6	22,368	13,003	134	17,6	22,368	2	P17MN_IRECI_8	14	> 0,563621
		0	29,530	19,700	763	100,0	29,530				
		1	24,957	13,599	388	50,9	24,957				≤ 0,005168
		2	34,261	23,563	375	49,1	34,261	0	V16SD_B4	22	> 0,005168
		3	20,798	10,923	185	24,2	20,798				≤ 0,005481
		4	28,747	14,674	203	26,6	28,747	1	P17SD_B4	8	> 0,005481
Ddom	0,075	5	39,087	25,892	241	31,6	39,087				≤ 0,563621
		6	25,581	15,275	134	17,6	25,581	2	P17MN_IRECI_8	19	> 0,563621
		0	40,208	19,457	763	100,0	40,208				
		1	32,799	15,045	223	29,2	32,799				≤ 0,003297
		2	43,267	20,246	540	70,8	43,267	0	P17SD_B2	22	> 0,003297
		3	25,750	10,964	59	7,7	25,750				≤ 0,002085
G_ha_cas	0,062	4	35,336	15,526	164	21,5	35,336	1	V16SD_B3	7	> 0,002085
		0	22,775	19,997	763	100,0	22,775				
		1	11,940	12,802	86	11,3	11,940				≤ 0,002768
		2	24,151	20,330	677	88,7	24,151	0	P17SD_B4	13	> 0,002768
		3	33,024	26,590	81	10,6	33,024				≤ 0,199338
		4	22,945	19,036	596	78,1	22,945	2	P17MN_MSAVI2_8	10	> 0,199338
Dg_cas	0,127	0	29,142	21,229	763	100,0	29,142				
		1	24,318	15,041	388	50,9	24,318				≤ 0,005168
		2	34,133	25,200	375	49,1	34,133	0	V16SD_B4	25	> 0,005168
		3	17,667	10,343	127	16,6	17,667				≤ 0,004164
		4	27,555	15,898	261	34,2	27,555	1	P17SD_B4	10	> 0,004164
		5	39,101	27,269	241	31,6	39,101				≤ 0,563621
Por_cas	0,065	6	25,197	17,852	134	17,6	25,197	2	P17MN_IRECI_8	20	> 0,563621
		0	81,404	17,287	763	100,0	81,404				
		1	83,394	16,716	531	69,6	83,394				≤ 0,632129
		2	76,849	17,740	232	30,4	76,849	0	P17MN_GNDVI_7	9	> 0,632129
		3	85,063	16,127	404	52,9	85,063				≤ 11,927914
		4	78,084	17,497	127	16,6	78,084	1	V16MN_ARI1	6	> 11,927914
Por_cas	0,065	5	74,578	17,755	165	21,6	74,578				≤ 0,84296
		6	82,440	16,539	67	8,8	82,440	2	P17MN_NDVI_7	4	> 0,84296

En general, como se ya se ha anticipado, la variabilidad explicada con los modelos pronosticados obtenidos es bastante baja, siempre inferior al 15%, a pesar de que se disponía de una población muestral amplia, correspondiendo los resultados más favorables con las variables relacionadas con el diámetro medio cuadrático.

Atendiendo a estos modelos pronosticados, el primero para el diámetro medio cuadrático (Dg), explica un 13,08 % de la variabilidad, mientras que el correspondiente al diámetro medio cuadrático para el castaño (Dg_cas) explica el 12,75% de la variabilidad. En ambos casos, la estructura de nodos es similar, dos niveles completos y divididos por las mismas variables (Figura 13).

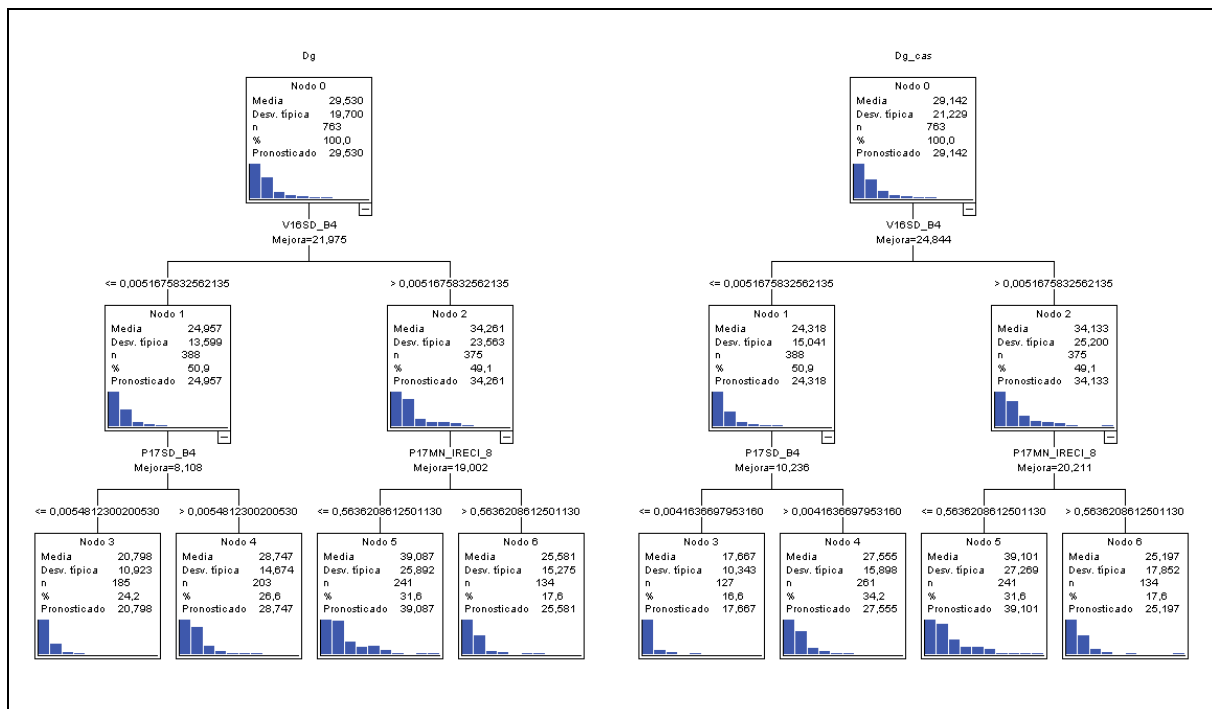


Figura 13. Izq: CaRT para Dg. Der: CaRT para Dg_cas.

En cuanto a las medias pronosticadas por los nodos terminales de cada árbol de decisión, en ambos casos los nodos 3,4, y 6 explican el mismo rango de valores, mientras que el nodo 5 destaca por ser el único que pronostica una media diferente, en torno a 40 cm, que corresponde con las tipologías 1 y 2.

A la vista de la similitud de resultados entre ambos CaRT y la diferencia mínima en la variabilidad explicada se decidió emplear el modelo pronosticado correspondiente al Dg_cas por su mayor proximidad a la especie objeto de estudio para la elaboración de los mapas predictivos. Además, debido a que los nodos 3,4 y 6 pronostican medias similares no es adecuado su uso, empleándose únicamente el camino al nodo 5 para delimitar las posibles zonas con existencia de las tipologías 1 y 2.



4 DISCUSIÓN

En el estudio de grandes áreas, los árboles de decisiones ofrecen modelos robustos, de fácil implementación y transparentes en sus operaciones (Hansen *et al.*, 2016), habiendo sido empleados exitosamente en estudios forestales con datos MODIS (Friedl *et al.*, 2002), Landsat 7 Enhanced Thematic Mapper Plus (ETM+) (Hansen *et al.*, 2013) y Sentinel-2 (Chrysafis *et al.*, 2017).

A la vista de los resultados obtenidos, los análisis estadísticos no paramétricos empleados no han determinado modelos robustos con los que sea posible predecir la estructura de las masas de castaño, mediante el empleo de reflectividad o índices de vegetación. En contra de estos resultados, estudios como el de Freitas *et al.*, (2005) si obtuvieron resultados satisfactorios en bosques atlánticos lluviosos de Brasil para determinar la estructura del bosque mediante teledetección empleando imágenes Landsat 7 ETM+.

Este desajuste puede ser debido a que la composición florística y estructural del bosque atlántico lluvioso de Brasil, caracterizado por masas densas y de hoja perenne, altamente diverso y con tres capas de cubierta arbórea (Mello *et al.*, 2003), no es similar al bosque atlántico objeto de este estudio, resultando de esto una dificultad para establecer patrones.

Las variables más influyentes en los modelos pronosticados resultaron ser las compuestas o derivadas de las bandas contenidas en el espectro correspondiente al rojo o al borde rojo (red edge), hecho que ya sugieren diferentes estudios previos (Frampton *et al.*, 2013; Hill, 2013; Vaglio-Laurin *et al.*, 2016), debido a la capacidad de esta región para detectar diferencias finas en los pigmentos de clorofila, pues un contenido alto en clorofila puede indicar mayor densidad de copas o estructuras forestales más complejas (Álvarez-Añorve *et al.*, 2008).

Además, se aprecia que las variables más decisivas en la partición de nodos suelen ser las bandas, y no los índices de vegetación derivados de estas, coincidiendo así con estudios previos donde se observó que la reflectividad original de las bandas está más relacionada con los parámetros forestales que los índices de vegetación (Chrysafis *et al.*, 2017; Lu *et al.*, 2004).

Al disponer de un tamaño de pixel de 10 metros, si la superficie ocupada por las copas son inferiores a esta, pueden darse problemas de identificación de especies, por lo que una de las causas de no encontrar resultados satisfactorios, podría ser la contaminación del pixel por especies trepadoras, epifitas o no estructurales dando lugar a confusión en la firma espectral característica de los árboles, como se ha demostrado en estudios llevados a cabo en bosques tropicales (Castro-Esau *et al.*, 2004; Kalacska *et al.*, 2007; Sánchez-Azofeifa & Castro-Esau, 2006).

Por último, son muchos los autores, tales como Asner *et al.*, (2012); Eitel *et al.*, (2016); Ota *et al.*, (2014); Saarela *et al.*, (2016), que recomiendan añadir la tecnología LiDAR a estudios de inventario



y estructurales por lo que probablemente los resultados de este estudio serían más explicativos si en lugar de haber empleado únicamente dos fuentes de datos, inventario tradicional y teledetección, se hubiese añadido una tercera fuente como LiDAR para obtener información vertical de la masa.



5 CONCLUSIONES

Tras la interpretación de los resultados obtenidos en el presente proyecto, en el que se han evaluado las relaciones existentes entre la información obtenida de datos multispectrales Sentinel-2 con la estructura y tipología de las masas de castaño, se ha llegado a una serie de conclusiones, entre las que cabe destacar:

Que no es posible obtener un modelo predictivo empleando imágenes Sentinel-2, para determinar la estructura de las masas de castaño mediante las tipologías establecidas en estudios anteriores a partir de variables dasométricas procedentes del IFN4.

En cuanto a las variables dasométricas relacionadas con la estructura de las masas de castaño, el mejor modelo pronosticado explica una variabilidad del 13,08 %, lo que se considera como muy baja, por lo que el empleo únicamente de la teledetección no es suficiente para determinar la estructura de las masas de castaño en Asturias y Galicia.

Las variables implicadas en la mayoría de los modelos son bandas o índices de vegetación que emplean reflectividad de las bandas que se encuentran en el rango del espectro electromagnético correspondiente al rojo (B4) o borde rojo (B5, B6, B7 y B8) para su cálculo. Además, se observa que la B8 tiene mayor influencia en los modelos que la B7, lo que podría ser suficiente para descartar su empleo y simplificar cálculos.

Que el empleo de la teledetección va íntimamente ligado a la tecnología LiDAR para determinar la estructura de las masas de castaño, el primero ofrece información horizontal de la masa, mientras que el segundo ofrece información vertical complementándose el uno al otro. De este modo, al tratarse de una misma especie de la que se pretenden desgranar diferentes estados evolutivos (tipologías), la información horizontal obtenida de la teledetección debe ser homogénea dentro de un rango determinado, mientras que la información vertical debe variar abarcando todos los casos posibles existentes en la masa.



6 BIBLIOGRAFÍA

- Alberdi, I., Sandoval, V., Condes, S., Cañellas, I., & Vallejo, R. (2016). El Inventario Forestal Nacional español, una herramienta para el conocimiento, la gestión y la conservación de los ecosistemas forestales arbolados. *Ecosistemas*, 25(3), 88–97. <http://doi.org/10.7818/ECOS.2016.25-3.10>
- Alvarez-Añorve, M., Quesada, M., & Barrera, E. de la. (2008). Remote Sensing and Plant Functional Groups: Physiology, Ecology, and Spectroscopy in Tropical Systems Mariana. *Spectroscopy*, 27–45.
- Álvarez Álvarez, P., Barrio, M., Castedo, F., Díaz Varela, R. a., Fernández, J. ., Mansilla, P., ... Salinero, M. (2000). *Manual de selvicultura del castaño en Galicia*.
- Asner, G. P., Clark, J. K., Mascaro, J., Galindo García, G. A., Chadwick, K. D., Navarrete Encinales, D. A., ... Ordóñez, M. F. (2012). High-resolution mapping of forest carbon stocks in the Colombian Amazon. *Biogeosciences*, 9(7), 2683–2696. <http://doi.org/10.5194/bg-9-2683-2012>
- Bannari, A., Morin, D., Bonn, F., & Huete, A. R. (1995). A review of vegetation indices. *Remote Sensing Reviews*, 13(1), 95–120. <http://doi.org/10.1080/02757259509532298>
- Bukata, R. P., Bruton, J. E., & Jerome, J. H. (1983). Use of chromaticity in remote measurements of water quality. *Remote Sensing of Environment*, 13(2), 161–177. [http://doi.org/10.1016/0034-4257\(83\)90020-2](http://doi.org/10.1016/0034-4257(83)90020-2)
- Cabacinha, C. D., & de Castro, S. S. (2009). Relationships between floristic diversity and vegetation indices, forest structure and landscape metrics of fragments in Brazilian Cerrado. *Forest Ecology and Management*, 257(10), 2157–2165. <http://doi.org/10.1016/j.foreco.2009.02.030>
- Castro-Esau, K. L., Sánchez-Azofeifa, G. A., & Caelli, T. (2004). Discrimination of lianas and trees with leaf-level hyperspectral data. *Remote Sensing of Environment*, 90(3), 353–372. <http://doi.org/10.1016/j.rse.2004.01.013>
- Chrysafis, I., Mallinis, G., Siachalou, S., & Patias, P. (2017). Assessing the relationships between growing stock volume and Sentinel-2 imagery in a Mediterranean forest ecosystem. *Remote Sensing Letters*, 8(6), 508–517. <http://doi.org/10.1080/2150704X.2017.1295479>
- Chuvieco, E. (2008). *Teledetección ambiental: La observación de la Tierra desde el Espacio*. Ariel Ciencia (Vol. 3).
- Clerc, S., & Team, M. (2017). Data Quality Report. *European Space Agency, (Special Publication) ESA SP*.
- Conedera, M., Krebs, P., Tinner, W., Pradella, M., & Torriani, D. (2004). The cultivation of *Castanea*



- sativa (Mill.) in Europe, from its origin to its diffusion on a continental scale. *Vegetation History and Archaeobotany*, 13(3), 161–179. <http://doi.org/10.1007/s00334-004-0038-7>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., ... Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25–36. <http://doi.org/10.1016/j.rse.2011.11.026>
- Eitel, J. U. H., Höfle, B., Vierling, L. A., Abellán, A., Asner, G. P., Deems, J. S., ... Vierling, K. T. (2016). Beyond 3-D: The new spectrum of lidar applications for earth and ecological sciences. *Remote Sensing of Environment*, 186, 372–392. <http://doi.org/10.1016/j.rse.2016.08.018>
- Frampton, W. J., Dash, J., Watmough, G., & Milton, E. J. (2013). Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 82, 83–92. <http://doi.org/10.1016/j.isprsjprs.2013.04.007>
- Freitas, S. R., Mello, M. C. S., & Cruz, C. B. M. (2005). Relationships between forest structure and vegetation indices in Atlantic Rainforest. *Forest Ecology and Management*, 218(1–3), 353–362. <http://doi.org/10.1016/j.foreco.2005.08.036>
- Friedl, M. a. M. A., & Brodley, C. E. C. E. (1997). Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment*, 61(3), 399–409. [http://doi.org/10.1016/S0034-4257\(97\)00049-7](http://doi.org/10.1016/S0034-4257(97)00049-7)
- Friedl, M. A., McIver, D. K., Hodges, J. C. F., Zhang, X. Y., Muchoney, D., Strahler, A. H., ... Schaaf, C. (2002). Global land cover mapping from MODIS: Algorithms and early results. *Remote Sensing of Environment*, 83(1–2), 287–302. [http://doi.org/10.1016/S0034-4257\(02\)00078-0](http://doi.org/10.1016/S0034-4257(02)00078-0)
- Furones-Pérez, P., & Fernández-López, J. (2009). Morphological and phenological description of 38 sweet chestnut cultivars (*Castanea sativa* Miller) in a contemporary collection. *Spanish Journal of Agricultural Research*, 7(4), 829–843.
- Gates, D. M., Keegan, H. J., Schleter, J. C., & Weidner, V. R. (1965). Spectral Properties of Plants. *Applied Optics*, 4(1), 11. <http://doi.org/10.1364/AO.4.000011>
- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3), 289–298. [http://doi.org/10.1016/S0034-4257\(96\)00072-7](http://doi.org/10.1016/S0034-4257(96)00072-7)
- Gitelson, A. A., Merzlyak, M. N., & Chivkunova, O. B. (2001). Optical Properties and Nondestructive Estimation of Anthocyanin Content in Plant Leaves. *Photochemistry and Photobiology*, 74(1), 38–45. [http://doi.org/10.1562/0031-8655\(2001\)](http://doi.org/10.1562/0031-8655(2001))
- Gitelson, A. a, Zur, Y., Chivkunova, O. B., & Merzlyak, M. N. (2002). Assessing carotenoid content in



- plant leaves with reflectance spectroscopy. *Photochemistry and Photobiology*, 75(3), 272–281. [http://doi.org/10.1562/0031-8655\(2002\)0750272ACCIPL2.0.CO2](http://doi.org/10.1562/0031-8655(2002)0750272ACCIPL2.0.CO2)
- González, J. (2008). Plantas alóctonas invasoras en el Principado de Asturias, 190.
- Gordon, L. (2013). Using Classification and Regression Trees (CART) in SAS For Applications in Public Health. *SAS Global Forum*, (Gordon 2010), 1–8.
- Hansen, M. C., Potapov, P. V., Goetz, S. J., Turubanova, S., Tyukavina, A., Krylov, A., ... Egorov, A. (2016). Mapping tree height distributions in Sub-Saharan Africa using Landsat 7 and 8 data. *Remote Sensing of Environment*, 185, 221–232. <http://doi.org/10.1016/j.rse.2016.02.023>
- Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., ... Townshend, J. R. G. (2013). High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science*, 342(6160), 850–853. <http://doi.org/10.1126/science.1244693>
- Hardisky, M. A., & Klemas, V. (1983). The influence of soil salinity, growth form, and leaf moisture on the spectral reflectances of *Spartina alterniflora* canopies. *Photogrammetric Engineering and Remote Sensing*, 49(1), 77–83.
- Hill, M. J. (2013). Vegetation index suites as indicators of vegetation state in grassland and savanna: An analysis with simulated SENTINEL 2 data for a North American transect. *Remote Sensing of Environment*, 137, 94–111. <http://doi.org/10.1016/j.rse.2013.06.004>
- Holben, B. N. (1986). Characteristics of maximum-value composite images from temporal AVHRR data. *International Journal of Remote Sensing*, 7(11), 1417–1434. <http://doi.org/10.1080/01431168608948945>
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83, 195–213. [http://doi.org/10.1016/S0034-4257\(02\)00096-2](http://doi.org/10.1016/S0034-4257(02)00096-2)
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [http://doi.org/10.1016/0034-4257\(88\)90106-X](http://doi.org/10.1016/0034-4257(88)90106-X)
- IBM. (2011). IBM SPSS Decision Trees 20.
- Jackson, R. D., Slater, P. N., & Pinter, P. J. (1983). Discrimination of growth and water stress in wheat by various vegetation indices through clear and turbid atmospheres. *Remote Sensing of Environment*, 13(3), 187–208. [http://doi.org/10.1016/0034-4257\(83\)90039-1](http://doi.org/10.1016/0034-4257(83)90039-1)
- JUNTA DE CASTILLA Y LEÓN. (2014). Metodología empleada para el estudio de los crecimientos de madera y biomasa forestal en Castilla y León.



- Kalacska, M., Sanchez-Azofeifa, G. A., Rivard, B., Caelli, T., White, H. P., & Calvo-Alvarado, J. C. (2007). Ecological fingerprinting of ecosystem succession: Estimating secondary tropical dry forest structure and diversity using imaging spectroscopy. *Remote Sensing of Environment*, 108(1), 82–96. <http://doi.org/10.1016/j.rse.2006.11.007>
- Krebs, P., Conedera, M., Pradella, M., Torriani, D., Felber, M., & Tinner, W. (2004). Quaternary refugia of the sweet chestnut (*Castanea sativa* Mill.): An extended palynological approach. *Vegetation History and Archaeobotany*, 13(3), 145–160. <http://doi.org/10.1007/s00334-004-0041-z>
- Lantzanakis, G., Mitraka, Z., & Chrysoulakis, N. (2017). Comparison of Physically and Image Based Atmospheric Correction Methods for Sentinel-2 Satellite Imagery. *Perspectives on Atmospheric Sciences*, (January 2017), 255–261. http://doi.org/10.1007/978-3-319-35095-0_36
- Lillesand, T., Kiefer, R., & Chipman, J. (2014). Remote sensing and image interpretation. (pp. 1-21-391).
- Loh, W.-Y. (2011). Classification and regression trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1(1), 14–23. <http://doi.org/10.1002/widm.8>
- Lu, D., Mausel, P., Brondízio, E., & Moran, E. (2004). Relationships between forest stand parameters and Landsat TM spectral responses in the Brazilian Amazon Basin. *Forest Ecology and Management*, 198(1–3), 149–167. <http://doi.org/10.1016/j.foreco.2004.03.048>
- Majasalmi, T., & Rautiainen, M. (2016). The potential of Sentinel-2 data for estimating biophysical variables in a boreal forest: a simulation study. *Remote Sensing Letters*, 7(5), 427–436. <http://doi.org/10.1080/2150704X.2016.1149251>
- Major, D. J., Baret, F., & Guyot, G. (1990). A ratio vegetation index adjusted for soil brightness. *International Journal of Remote Sensing*, 11(5), 727–740. <http://doi.org/10.1080/01431169008955053>
- McRoberts, R. E., Tomppo, E. O., & Næsset, E. (2010). Advances and emerging issues in national forest inventories. *Scandinavian Journal of Forest Research*, 25(4), 368–381. <http://doi.org/10.1080/02827581.2010.496739>
- Mello, M., Freitas, S., & Cerqueira, R. (2003). Estrutura da vegetação em fragmentos florestais de Mata Atlântica com base no sensoriamento remoto. *VI Congresso de Ecologia Do Brasil*.
- Müller-Wilm, U., Louis, J., Richter, R., Gascon, F., & Niezette, M. (2013). Sentinel-2 Level 2a Prototype Processor : Architecture , Algorithms and First Results. *ESA Living Planet Symposium 2013, Edinburgh, UK*, (November 2016).
- Ota, T., Ahmed, O. S., Franklin, S. E., Wulder, M. A., Kajisa, T., Mizoue, N., ... Vuthy, M. (2014).



- Estimation of airborne Lidar-derived tropical forest canopy height using landsat time series in Cambodia. *Remote Sensing*, 6(11), 10750–10772. <http://doi.org/10.3390/rs61110750>
- Peters, A. J., WalterShea, E. A., LeL JI, A. V., Hayes, M., & Svoboda, M. D. (2002). Drought monitoring with NDVI-based standardized vegetation index. *American Society for Photogrammetry and Remote Sensing*, 68(1), 71–75.
- Ponzoni, F. (2001). Spectral behavior of vegetation. *Remote Sensing: Reflectance of Natural Objects.*, 57–199.
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119–126. [http://doi.org/10.1016/0034-4257\(94\)90134-1](http://doi.org/10.1016/0034-4257(94)90134-1)
- Recondo, C. (2002). Cartografía de zonas quemadas en Asturias durante el período 1991-2001 a partir de imágenes Landsat-TM. *Revista de Teledetección*, 47–55.
- Richter, R., Louis, J., & Berthelot, B. . (2012). Sentinel-2 MSI – Level 2A Products Algorithm Theoretical Basis Document. *European Space Agency, (Special Publication) ESA SP*, 49(0), 1–72.
- Rock, B. N., Vogelmann, J. E., Williams, D. L., Vogelmann, A. F., & Hoshizaki, T. (1986). Remote detection of forest damage.pdf. *BioScience*.
- Rouse, J. W. (1973). MONITORING THE VERNAL ADVANCEMENT AND RETROGRADATION (GREEN WAVE EFFECT) OF NATURAL VEGETATION (MMC. *NASA/GSFCT Type III Final Report, Greenbelt, MD, USA*.
- Ruiz-Benito, P., & García-Valdés, R. (2016). Inventarios forestales para el estudio de patrones y procesos en Ecología. *Ecosistemas*, 25(3), 1–5. <http://doi.org/10.7818/ECOS.2016.25-3.01>
- Saarela, S., Holm, S., Grafström, A., Schnell, S., Næsset, E., Gregoire, T. G., ... Ståhl, G. (2016). Hierarchical model-based inference for forest inventory utilizing three sources of information. *Annals of Forest Science*, (1432). <http://doi.org/10.1007/s13595-016-0590-1>
- Sánchez-Azofeifa, G. A., & Castro-Esau, K. (2006). Canopy observations on the hyperspectral properties of a community of tropical dry forest lianas and their host trees. *International Journal of Remote Sensing*, 27(10), 2101–2109. <http://doi.org/10.1080/01431160500444749>
- Sims, D. A., & Gamon, J. A. (2002). Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 81(2–3), 337–354. [http://doi.org/10.1016/S0034-4257\(02\)00010-X](http://doi.org/10.1016/S0034-4257(02)00010-X)
- Sobrino, J. A. (2000). *Teledetección*. Universitat de València.



SPSS, I. B. M. (2016). IBM SPSS statistics for Windows, version 23.0. In *New York: IBM Corp.*

Timofeev, R. (2004). Classification and Regression Trees (CART) Theory and Applications. *Journal of Neurosurgery*. <http://doi.org/10.3171/jns.1995.82.5.0764>

Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [http://doi.org/10.1016/0034-4257\(79\)90013-0](http://doi.org/10.1016/0034-4257(79)90013-0)

Vaglio Laurin, G., Puletti, N., Hawthorne, W., Liesenberg, V., Corona, P., Papale, D., ... Valentini, R. (2016). Discrimination of tropical forest types, dominant species, and mapping of functional guilds by hyperspectral and simulated multispectral Sentinel-2 data. *Remote Sensing of Environment*, 176(February), 163–176. <http://doi.org/10.1016/j.rse.2016.01.017>

Vajsova, B. (2015). New sensors benchmark report on Sentinel-2A. *Joint Research Centre*.

Westreich, D., Lessler, J., & Funk, M. J. (2010). Propensity score estimation: neural networks, support vector machines, decision trees (CART), and meta-classifiers as alternatives to logistic regression. *Journal of Clinical Epidemiology*, 63(8), 826–833. <http://doi.org/10.1016/j.jclinepi.2009.11.020>

PÁGINAS WEB CONSULTADAS

- Base de datos de índices para teledetección. (2017). Disponible en: http://www.indexdatabase.de/db/is.php?sensor_id=96 [Consultado: 20 febrero 2017].
- Centro Nacional de Información Geográfica. (2016). Disponible en: <http://centrodedescargas.cnig.es/CentroDescargas/inicio.do#> [Consultado: 17 noviembre 2016].
- Contacto con el Banco de Datos de la Naturaleza. (2017). Disponible en: <http://www.mapama.gob.es/es/biodiversidad/servicios/banco-datos-naturaleza/contacto-banco-datos-naturaleza/> [Consultado: 20 noviembre 2016]
- Copernicus Open Access Hub. (2017). Disponible en: <https://scihub.copernicus.eu/> [Consultado: 17 noviembre 2016].
- Descarga de SNAP. (2017). Disponible en: <http://step.esa.int/main/download/> [Consultado: 17 noviembre 2016].
- Malla de mosaicos Sentinel-2 en formato kml. (2017) Disponible en: https://sentinel.esa.int/documents/247904/1955685/S2A_OPER_GIP_TILPAR_MPC_201512_09T095117_V20150622T000000_21000101T000000_B00.kml [Consultado: 17 noviembre 2016].
- Mapa Forestal de España 50. (2017). Disponible en: <http://www.mapama.gob.es/es/biodiversidad/servicios/banco-datos-naturaleza/informacion-disponible/mfe50.aspx> [Consultado: 20 noviembre 2016]



7 ANEXOS

7.1 SCRIPT PARA PROCESADO EN BATCH DE LAS IMÁGENES

```
1. # Correccion de imagenes Sentinel-2 mediante proceso en batch con SNAP
2. # Jose Carlos Perez Giron 2017
3.
4. import os
5.
6. # LECTURA DE IMAGENES
7. carpeta="ruta de la carpeta"
8. lista_de_nombres=os.listdir(carpeta)
9.
10. # FICHERO DE SALIDA
11. rutafiletero="ruta del fichero de salida(.txt)"
12. filetero=open(rutafiletero,"w")
13. contador=0
14. procesadas=0
15.
16. # CONTEO DE IMAGENES A PROCESAR
17. for nombre_de_fichero in lista_de_nombres:
18.     if nombre_de_fichero.split("_")[3]=="MSIL1C" or
19.        nombre_de_fichero.split("_")[1]=="MSIL1C":
20.         contador=contador+1
21.
22. # PROCESADO DE LAS IMAGENES
23. for nombre_de_fichero in lista_de_nombres:
24.     if nombre_de_fichero.split("_")[3]=="MSIL1C" or
25.        nombre_de_fichero.split("_")[1]=="MSIL1C":
26.         comando="L2A_Process --resolution 10 "+carpeta+nombre_de_fichero
27.         procesadas=procesadas+1
28.         print "PROCESANDO LA IMAGEN (" ,procesadas," DE " ,contador,")
29.         ",nombre_de_fichero,"\n"
30.         os.system (comando)
31.         filetero.write(nombre_de_fichero+"\n")
32.
33. # FIN DEL PROGRAMA, GUARDADO DE FICHEROS
34. filetero.close()
35. print "Final del programa, puedes ver el reporte de las imagenes procesadas
36.     en la carpeta indicada"
```

7.2 MAPAS PREDICTIVOS

