



ESCUELA DE INGENIERÍA AGRARIA Y FORESTAL

TRABAJO FIN DE MÁSTER

**MÁSTER UNIVERSITARIO EN GEOINFORMÁTICA PARA LA GESTIÓN DE LOS
RECURSOS NATURALES**

**ANÁLISIS DE DETECCIÓN DE CAMBIOS UTILIZANDO IMÁGENES SATÉLITE
MULTITEMPORALES SENTINEL 2 Y SU INTEGRACIÓN EN LA GENERACIÓN
DE MAPAS DE COMBUSTIBLES A ESCALA MUNICIPAL**

**CHANGE DETECTION ANALYSIS USING SENTINEL 2 MULTITEMPORAL
SATELLITE IMAGERY AND ITS INTEGRATION FOR FUEL MAPPING AT
MUNICIPAL SCALE**

Dimas Pereira Obaya

Tutora: María Flor Álvarez Taboada

Cotutora: Sandra Sánchez García (CETEMAS)

Ponferrada, septiembre de 2020

RESUMEN

La cartografía de Modelos de Combustibles es una herramienta clave en los procesos de toma de decisiones para la prevención y defensa frente a los incendios forestales. Siendo por tanto necesario mantenerla actualizada para describir de la forma más fiable posible la realidad; aunque esta tarea es complicada debido a los constante cambios en las coberturas del suelo.

Los objetivos planteados en este trabajo son tres: (1) Cartografía de cuatro grandes tipos de combustibles en base a diferencias espectrales, empleando imágenes de satélite y software libre, (2) Cartografía de áreas quemadas a partir de un análisis multitemporal de imágenes satélite, empleando una plataforma web para el procesamiento geoespacial, y (3) Evaluación de la metodología propuesta para actualizar el mapa de combustibles actual de forma semi-automática.

Los procesos seguidos se han dividido en dos bloques: cartografía de cuatro tipos de combustibles y de zonas quemadas, en los que aunque planteando un tipo de análisis distinto se comparten varios pasos. Para generar la cartografía de los cuatro tipos de vegetación se llevó a cabo un análisis basado en objetos (OAA) u *Object Based Analysis* (OBIA) sobre una colección multitemporal de imágenes Satélite Sentinel 2 MSI. El primer paso consistió en la adquisición y el procesado de las imágenes, que posteriormente fueron segmentadas para generar la base de datos necesaria para llevar a cabo la clasificación automática supervisada final. Para general la cartografía de áreas quemadas, se empleó una serie temporal de imágenes Sentinel 2 MSI. En este caso se llevó a cabo la adquisición y el procesado de las imágenes y posteriormente se efectuó directamente el proceso de clasificación, ya que al plantear un análisis a nivel de píxel la base de datos de referencia se creó sin llevar a cabo la segmentación de las imágenes.

Los resultados obtenidos demuestran la posibilidad de identificar diferentes coberturas de forma fiable en base a la información que ofrecen las imágenes multiespectrales Sentinel 2 MSI. La clasificación de los grupos de combustibles alcanzó una exactitud global del 87,01 %, mientras el valor de la exactitud global de clasificación de áreas quemadas es 98, 28 %.

La metodología empleada en este trabajo, que se basa en el uso sensores remotos pasivos en la combinación de diferentes softwares libres y comerciales, permite actualizar la cartografía existente y por tanto disponer de herramientas con información actualizada, muy apreciadas en tareas de planificación de la gestión y defensa de los incendios forestales.

Palabras clave: modelos de combustibles, zonas quemadas, actualización, semi-automática, Sentinel 2 MSI, OBIA, Segmentación.

ABSTRACT

Fuel Model Mapping is a key tool in decision-making processes for forest fire prevention and defense. It is therefore necessary to keep it up to date to describe reality as reliably as possible; although this task is complicated due to constant changes in soil cover.

The objectives set out in this work are three: (1) Mapping of four large types of fuels based on spectral differences, using satellite images and free software, (2) Mapping areas burned from a multitemporal analysis of satellite images, using a web platform for geospatial processing, and (3) Evaluation of the proposed methodology for updating the current fuel map semi-automatically.

The following processes have been divided into two blocks: mapping of four types of fuels and burnt areas, in which, although a different type of analysis proposes, several steps are shared. To map the four vegetation types, an Object Based Analysis (OBIA) was performed on a multitemporal collection of Sentinel 2 MSI Satellite images. The first step was the acquisition and processing of the images, which were subsequently segmented to generate the database needed to perform the final supervised automatic classification. To general the mapping of burnt areas, a temporary series of Sentinel 2 MSI images was used. In this case, the acquisition and processing of the images was carried out and subsequently the classification process was carried out directly, since when considering a pixel-level analysis the reference database was created without segmenting the images.

The results obtained demonstrate the possibility of identifying different coverages reliably based on the information provided by Sentinel 2 MSI multispectral images. The classification of fuel groups achieved an overall accuracy of 87.01%, while the overall accuracy value of burned area classification is 98.28%.

The methodology used in this work, which is based on the use of passive remote sensors in the combination of different free and commercial software, allows to update the existing mapping. And therefore, have tools with up-to-date information highly appreciated in planning the management and defense of forest fires.

Keywords: fuel models, burned zones, upgrade, semi-automatic, Sentinel 2 MSI, OBIA, Segmentation.

ÍNDICE

Resumen	I
Abstract	II
1 Introducción.....	1
2 Objetivos	5
3 Área de estudio.....	6
4 Material Y MÉTODOS	7
4.1 Material	7
4.1.1 Imágenes de Sentinel 2 MSI.....	7
4.1.2 Base de datos de referencia de cubiertas del suelo	10
4.1.3 Base de datos de referencia de áreas quemadas.....	13
4.1.4 RStudio	16
4.1.5 eCognition Essentials	17
4.1.6 ArcMap.....	17
4.1.7 Google Earth Engine (GEE).....	17
4.2 Métodos	17
4.2.1 Cartografiado de cubiertas vegetales mediante clasificación de las imágenes	17
4.2.2 Cartografiado de las zonas quemadas.....	24
5 Resultados	27
5.1 Cartografía de cuatro tipos de combustibles en base a diferencias espectrales, empleando imágenes de satélite y software libre	27
5.1.1 Selección de variables	27
5.1.2 Evaluación de la clasificación	29
5.2 Cartografía de áreas quemadas a partir de un análisis multitemporal de imágenes satélite empleando una plataforma de procesamiento geoespacial	35
5.2.1 Importancia de las variables	35
5.2.2 Evaluación de la clasificación	36

5.3	Metodología para actualizar de forma semi-automática los mapas de combustibles generados por el CETEMAS en el año 2017, a escala municipal	41
6	Discusión.....	43
6.1	Cartografía de cuatro tipos de combustibles en base a diferencias espectrales, empleando imágenes de satélite y software libre	43
6.2	Cartografía de áreas quemadas a partir de un análisis multitemporal de imágenes satélite empleando una plataforma de procesamiento geoespacial	44
6.3	Metodología para actualizar de forma semi-automática los mapas de combustibles generados por el CETEMAS en el año 2017, a escala municipal	45
7	Conclusiones y futuras líneas de trabajo	47
7.1	Conclusiones	47
7.1.1	Cartografía de cuatro tipos de combustibles en base a diferencias espectrales, empleando imágenes de satélite y software libre	47
7.1.2	Cartografía de áreas quemadas a partir de un análisis multitemporal de imágenes satélite empleando una plataforma de procesamiento geoespacial.....	47
7.1.3	Metodología para actualizar de forma semi-automática los mapas de combustibles generados por el CETEMAS en el año 2017, a escala municipal	47
7.2	Futuras líneas de trabajo.....	48
8	Bibliografía.....	49
	Anexos.....	55
	Anexo 1: Mapa de los tipos de coberturas del suelo del concejo de Tineo (Asturias)	55
	Anexo 2: Script en diseñado en RStudio para el procesado de las imágenes Sentinel 2.....	56
	Anexo 3: Estadísticos como tabla.....	64
	Anexo 4: Unión por ID.....	64
	Anexo 5: Listado de variables empleadas en la clasificación de los grupos de vegetación.	65
	Anexo 6: Script para llevar a cabo la clasificación supervisada en RStudio	68
	Anexo 7: Clasificación de zonas en la plataforma GEE.....	69
	Anexo 8: Cartografía de combustibles del concejo de Tineo (Asturias)	73
	Anexo 9: Cartografía de áreas quemadas en el concejo de Tineo (Asturias) durante la temporada invernal de incendios.....	74

ÍNDICE DE TABLAS

Tabla 1.1. Ejemplos del sobre el uso de los sensores remotos en el mapeo de combustibles forestales en España. Fuente: Elaboración propia.	5
Tabla 4.1. Características básicas de los productos de los sensores Sentinel 2 MSI y Landsat 8 OLI	8
Tabla 4.2. Resumen de las imágenes multiespectrales Sentinel 2 MSI seleccionadas. Fuente: Elaboración propia.	9
Tabla 4.3. Imágenes Sentinel 2 empleadas en el mapeo de las zonas quemadas en Tineo en 2020. Fuente: Elaboración propia.	10
Tabla 4.4. Parcelas de referencia cuya cobertura fue identificada mediante a trabajos de campo. Fuente: Elaboración propia.	11
Tabla 4.5. Información de base para clasificar las parcelas generadas de forma aleatoria. Fuente: Elaboración propia.	12
Tabla 4.6. Parcelas generadas de forma aleatoria y fotointerpretadas. Fuente: Elaboración propia.	12
Tabla 4.7. Parcelas de referencia para la clasificación de áreas quemadas.	16
Tabla 4.8. Leyenda para el cartografiado de cuatro grandes grupos de combustibles. Fuente: Elaboración propia en base a la clasificación de la Fotoguía de Combustibles de Galicia (Arellano <i>et al.</i> , 2017).	19
Tabla 4.9. Bandas e índices espectrales derivados de cada una de las imágenes Sentinel 2 MSI. Fuente: Elaboración propia.	21
Tabla 4.10. Asignación del código a 8 variables a modo de ejemplo. Fuente: Elaboración propia.	21
Tabla 4.11. Número de parcelas empleadas como referencia en el proceso de clasificación... ..	22
Tabla 4.12. Bandas espectrales de la imagen Sentinel 2 MSI del 4 de abril de 2020 empleadas como variables en la base de referencia. Fuente: Elaboración propia.	26
Tabla 5.1. Exactitud global de la clasificación de combustibles según el espacio de entidades empleado (valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad). Fuente: Elaboración propia.	30

Tabla 5.2. Matriz de confusión de la clasificación de combustibles generada partir del análisis multitemporal, y valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad de la exactitud global, del productor y del usuario. Fuente: Elaboración propia.	32
Tabla 5.3. Superficies de cada una de clases identificadas en el cartografiado de cuatro grandes grupos de combustibles. Fuente: Elaboración propia.....	33
Tabla 5.4. Exactitud global de la clasificación de áreas quemadas (valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad). Fuente: Elaboración propia.	36
Tabla 5.5. Superficie afectada por algún incendio forestal en Tineo entre el día 1 de enero de 2020 y el 4 de abril de 2020. Fuente: Elaboración propia.....	36
Tabla 5.6. Matriz de confusión de la clasificación de áreas quemadas, y valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad de la exactitud global, del productor y del usuario. Fuente: Elaboración propia.....	38

ÍNDICE DE FIGURAS

Figura 1.1. Distribución espacial del número de incendios en Asturias (2006-2018). Fuente: Elaboración propia a partir de la EPLIFA del Gobierno del Principado de Asturias (2020).	2
Figura 1.2. Distribución espacial de la superficie quemada en Asturias (2006- 2018). Fuente: Elaboración propia a partir de la EPLIFA del Gobierno del Principado de Asturias (2020).	2
Figura 1.3. Comparación de la resolución espacial, espectral y temporal de diferentes satélites con sensores espectrales. Fuente: Elaboración propia a partir de Lechner <i>et al.</i> (2020).....	4
Figura 3.1. Localización del concejo Tineo en el Principado de Asturias. Fuente: Elaboración propia.....	6
Figura 4.1. Flujo de procesos global. Fuente: Elaboración propia.	7
Figura 4.2. Representación gráfica de la resolución espectral frente a la resolución espacial del sensor MSI de los satélites Sentinel 2. Fuente: Elaboración propia a partir de Drusch <i>et al.</i> (2012).....	8
Figura 4.3. Localización geográfica de las parcelas del IFN4 y del CETEMAS en el concejo de Tineo. Fuente: Elaboración propia.	11
Figura 4.4. Localización geográfica de las parcelas clasificadas mediante fotointerpretación. Fuente: Elaboración propia.	13
Figura 4.5. Composición en falso color (infrarrojo de onda corta, infrarrojo cercano y rojo) de la imagen del 4 de abril de 2020 en GEE. Fuente: Elaboración propia.....	14

Figura 4.6. Diferencia entre el índice <i>Normalized Burn Ratio</i> (NBR) de la imagen del inicio y del fin del período de incendios (dNBR). En color más claro se localizan las zonas quemadas. Fuente: elaboración propia.	15
Figura 4.7. Distribución espacial de las parcelas de referencia para la clasificación de áreas quemadas.	16
Figura 4.8. Flujo de procesos seguido en la clasificación de imágenes Sentinel 2 MSI planteando un OBIA.	18
Figura 4.9. Representación de los puntos de referencia sobre los segmentos y una ortofotografía del PNOA (2017). Fuente: Elaboración propia.	23
Figura 4.10. Flujo de procesos seguido para la generación de una cartografía áreas quemadas en Tineo (2020).	25
Figura 5.1. Variables más importantes en base al Decrecimiento Medio de Gini (MDG). Fuente: Elaboración propia.	28
Figura 5.2. Variables más importantes a la hora de distinguir entre clases según el Decrecimiento Medio de Gini (MDG). Fuente: Elaboración propia.	29
Figura 5.3. Recorte de 2 km x 2 km del mapa de cuatro grandes grupos de combustibles. Fuente: Elaboración propia.	34
Figura 5.4. Recorte de 5 km x 5 km del mapa de cuatro grandes grupos de combustibles. Fuente: Elaboración propia.	35
Figura 5.5. Importancia relativa de cada una de las bandas espectrales empleadas en la clasificación. Fuente: Elaboración propia.	36
Figura 5.6. Incendios identificados en ambas clasificaciones. Fuente: Elaboración propia.	39
Figura 5.7. Incendios identificados en clasificación y no en la capa de áreas quemadas del EFFIS. Fuente: Elaboración propia.	39
Figura 5.8. Incendio erróneamente clasificado, pues ocurrió en el año 2019 no durante el período de análisis. Fuente: Elaboración propia.	40
Figura 5.9. Parcelas agrícolas erróneamente identificadas como incendios durante la clasificación. Fuente: Elaboración propia.	40
Figura 5.10. Esquema de integración entre los distintos flujos de trabajo y la generación de las distintas capas cartográficas. Fuente: Elaboración propia.	42

1 INTRODUCCIÓN

En los últimos años los grandes incendios forestales se han convertido en una de las principales perturbaciones a escala global (Leblon *et al.*, 2012). Además, los cambios en los patrones meteorológicos que ha provocado el cambio climático, así como la modificación de los usos del suelo como consecuencia del abandono de las zonas rurales, han generado una situación en la que se favorece la propagación de los incendios forestales (Molina *et al.*, 2019; Halofsky *et al.*, 2020).

En España los incendios forestales perturban el medio de forma constante en el tiempo, y en todo el territorio, aunque desde que se recogen datos en este campo se observa una distribución espacial bastante localizada en el noroeste peninsular, donde la mayoría de los siniestros son provocados de forma intencionada (Ministerio de Agricultura, Pesca y Alimentación, 2019). En base a la información recopilada en el Avance Informativo sobre los Incendios Forestales en España, elaborado por el Ministerio para la Transición Ecológica y Reto Demográfico (2020), parece que esta tendencia continúa, siendo la zona del noroeste la más afectada. Hasta el momento los incendios que han afectado a las provincias de León y Zamora y las Comunidades Autónomas de Galicia y Asturias suponen un 52 % del total de siniestros y un 63 % del total de la superficie forestal arbolada quemada en lo que va del año 2020.

La “Estrategia integral de prevención y lucha contra los incendios forestales en Asturias” o EPLIFA (2020-2025), recoge que desde 2005 hasta 2018 en Asturias se registraron un total de 22.269 incendios (Figura 1.1) que afectaron a 141.795 ha (Figura 1.2), de las que solo el 15,8 % se corresponde con vegetación arbolada, es decir, son los estratos de vegetación arbustiva los que sufren más perturbaciones. Cabe destacar que, en cuanto al número de incendios, los concejos más afectados pertenecen a la mitad oriental, donde se concentró el 66 % del total, mientras que los concejos de interior de occidente acumulan el 54,2 % de la superficie quemada.

Los incendios forestales en Asturias muestran un claro carácter estacional tanto en número de siniestros como en términos de superficie que, a diferencia del ámbito mediterráneo (de marcado carácter estival) se concentran en dos periodos. Por un lado, el más intenso que coincide con el final del invierno y el principio de la primavera, y otro que se distribuye entre los meses julio y octubre. A partir de los datos recogidos durante la serie 2005-2018 se puede concluir que el momento más crítico se distribuye entre la segunda quincena de febrero y la primera de abril, concentrándose en estos dos meses el 43,2 % del total de los siniestros y el 52 % de la superficie afectada (Gobierno del Principado de Asturias, 2020).



Figura 1.1. Distribución espacial del número de incendios en Asturias (2006-2018). Fuente: Elaboración propia a partir de la EPLIFA del Gobierno del Principado de Asturias (2020).




Figura 1.2. Distribución espacial de la superficie quemada en Asturias (2006- 2018). Fuente: Elaboración propia a partir de la EPLIFA del Gobierno del Principado de Asturias (2020).

En este contexto, es clave disponer de herramientas precisas que provean información espacialmente explícita sobre las características de los combustibles forestales (Szapkowski y Jensen, 2019), y que puedan ser empleadas en la gestión de los trabajos de prevención, defensa y recuperación (Chuvieco y Kasischke, 2007).

En esta línea, la Fundación Centro Tecnológico Forestal y de la Madera (CETEMAS) colabora con la Consejería de Medio Rural y Recursos Naturales y el Servicio de Emergencias del Principado de Asturias, en el desarrollo de una herramienta que permita generar y actualizar de forma semiautomática cartografía relacionada con los combustibles forestales presentes en el entorno asturiano, a partir de datos recogidos con sensores remotos. Para ello, en el marco de un Proyecto europeo Interreg-Sudoe denominado PLURIFOR (2016-2019) “Planes de Gestión de riesgos transnacionales para los espacios

rurales forestales sensibles a los riesgos bióticos y abióticos”, dentro del Plan Riesgo de Incendios Forestales Sánchez García *et al.* (2019) trabajaron en la asignación de los distintos modelos de combustibles descritos en la Fotoguía de Modelos de Combustibles de Galicia desarrollada por (Arellano *et al.*, 2017), a partir de datos del Mapa Forestal de España (DGDRPF, 2012) y los datos del PNOA-LiDAR. Una vez establecida dicha metodología para su reproducción y escalado por concejos a toda la región, se sigue trabajando en la mejora de precisión de los resultados empleando datos LiDAR con una mayor densidad de puntos o bien combinándolos con la información espectral que ofrecen los sensores remotos pasivos. Todo ello, condicionado por las características de las fuentes de información y sus períodos de actualización y publicación.

Por una parte, los sensores remotos activos emiten radiación y miden su señal de retorno, mientras que los sensores pasivos miden la radiación reflejada por los objetos tras la incidencia de radiación procedente de una fuente externa (Tempfli *et al.*, 2009). Los fundamentos del funcionamiento de ambos tipos de sensores condicionan sus aplicaciones en la gestión forestal. Mientras que los sensores activos son realmente útiles en la representación tridimensional de la estructura de las masas, el uso de los sensores ópticos debe orientarse a la identificación de coberturas o a los análisis de detección de cambios (Fassnacht *et al.*, 2016; White *et al.*, 2016).

En todo caso, ante la cantidad de información disponible actualmente hay que analizar la resolución espectral, espacial y temporal, así como el coste de adquisición de aquellos sensores que se adapten al objetivo perseguido (Labrador García *et al.*, 2012). En concreto, la resolución espectral que Janssen y Bakker (2004) definen como el número de bandas del espectro electromagnético que un sensor es capaz de capturar, será el factor limitante a la hora de plantear una clasificación, es decir, al utilizar la información espectral para asignar una clase a cada píxel u objeto de la imagen (Tempfli *et al.*, 2009; Hennessy *et al.*, 2020).

Por otro lado, la resolución espacial hace referencia al elemento de menor tamaño que el sensor puede detectar (Liang *et al.*, 2012). Los avances en la tecnología de los sensores espectrales permiten disponer de sensores del alta resolución espacial (10 - 20 m/píxel) y de muy alta resolución (< 10 m/píxel), pasando así de trabajar con varios objetos por píxel a trabajar con objetos formados por varios píxeles (White *et al.*, 2016). De esta forma se puede plantear lo que se conoce como análisis orientado a objetos (AOO) u *Object Based Image Analysis* (OBIA), que consiste en identificar dentro de una imagen aquellos grupos de píxeles vecinos que representan un objeto de la realidad, y usar sus características espectrales, texturales y geométricas para clasificar la escena (Kucharczyk *et al.*, 2020). Frente a los análisis a nivel de píxel, en paisajes fragmentados y heterogéneos los OBIA permiten reducir la variabilidad espectral (Fassnacht *et al.*, 2016), además de reducir en las clasificaciones el llamado efecto “sal y pimienta” (Blaschke, 2010), es decir, la aparición de píxeles asociados a una clase aislados y rodeados por otra clase.

En cuanto a la resolución temporal (frecuencia con que los datos son recopilados) se debe resaltar su relevancia en situaciones en las que la climatología dificulta la adquisición de imágenes libres de nubes y con buenas condiciones de iluminación (Drusch *et al.*, 2012).

Como se puede ver en la Figura 1.3. Comparación de la resolución espacial, espectral y temporal de diferentes satélites con sensores espectrales. Fuente: Elaboración propia a partir de Lechner *et al.* (2020). es difícil que un sensor tenga una muy alta resolución espacial, espectral y temporal, ya que conforme aumenta la resolución espacial disminuye la resolución espectral y temporal, salvo en el caso de las plataformas de pago que logran trabajar con frecuencias diarias, puesto que son sensores orientables. Además, la resolución espacial está inversamente relacionada con el campo de visión, esto significa que los sensores de muy alta resolución abarcan áreas menos extensas que los sensores de la alta resolución. En base esto, en última instancia será el objetivo del trabajo, la escala (local o regional) y el coste de adquisición los que condicionen la selección final de las imágenes a utilizar.

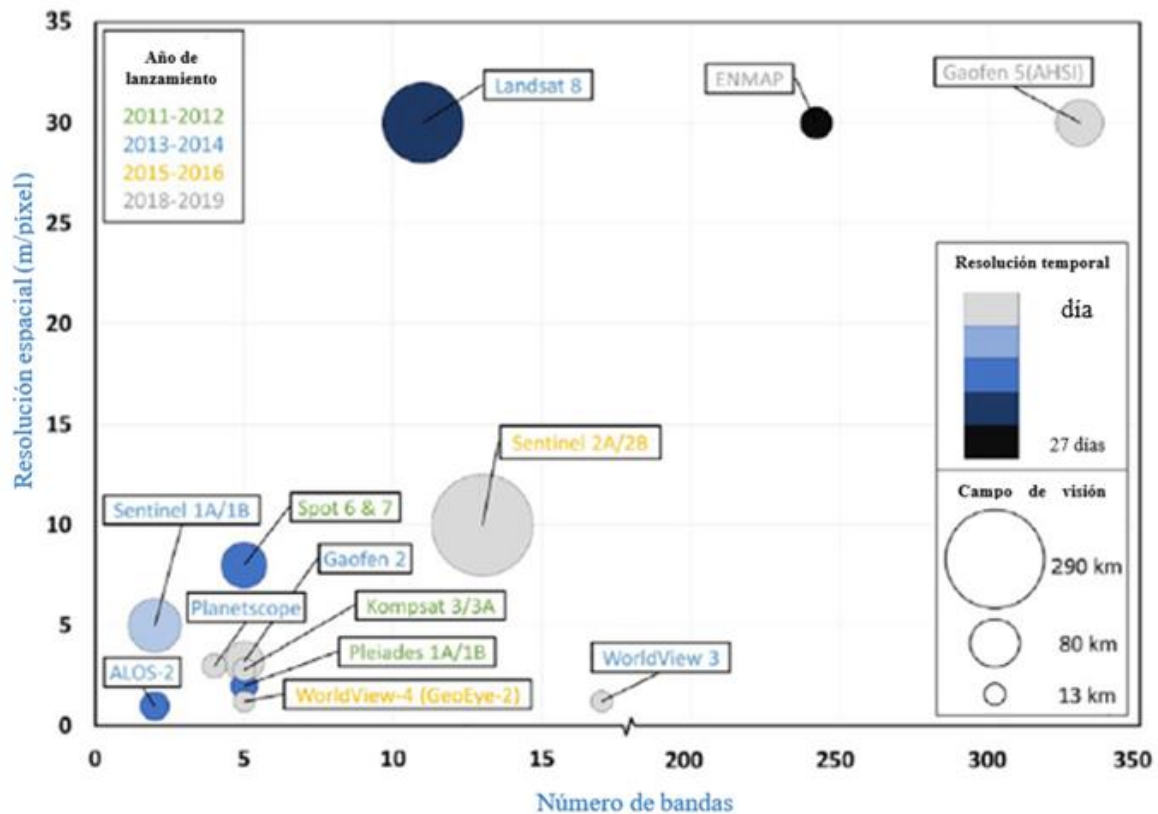


Figura 1.3. Comparación de la resolución espacial, espectral y temporal de diferentes satélites con sensores espectrales. Fuente: Elaboración propia a partir de Lechner *et al.* (2020).

Los sensores remotos son una fuente de información realmente útil en la gestión forestal, y una de sus aplicaciones es la evaluación de incendios (Gómez *et al.*, 2019). Prueba de ello es la revisión bibliográfica realizada en este trabajo, que ha permitido comprobar que en España se han planteado diferentes trabajos orientados al mapeo de combustibles a partir de sensores remotos activos y pasivos

(Tabla 1.1. Ejemplos del sobre el uso de los sensores remotos en el mapeo de combustibles forestales en España. Fuente: Elaboración propia.). Entre ellos destacan los de García *et al.* (2011) y Marino *et al.* (2016), ambos combinan los datos multispectrales y datos LiDAR. Además, siguen la misma metodología para generar una cartografía de combustibles, planteando primero una clasificación de tipos de vegetación sobre imágenes multispectrales, y empleando posteriormente métricas LiDAR para diferenciar tipos de combustibles.

Tabla 1.1. Ejemplos del sobre el uso de los sensores remotos en el mapeo de combustibles forestales en España. Fuente: Elaboración propia.

Referencia	Tipo de Sensor/Sensores	Técnica
(Arroyo <i>et al.</i> , 2006)	QuickBird-2	Mapa de combustibles (OBIA)
(García <i>et al.</i> , 2011)	ATM + LiDAR (1,5-6 pulsos/m ²)	Clasificación de tipos de vegetación; Identificar modelos de combustibles
(Marino <i>et al.</i> , 2016)	Landsat 8 OLI + LiDAR (1 pulso/m ²)	Clasificación de tipos de vegetación; Identificar modelos de combustibles
(Alonso-Benito <i>et al.</i> , 2016)	WorldView-2 + LiDAR (2,43 pulsos/m ²)	Mapa de combustibles (OBIA)

Estos trabajos demuestran las capacidades de los sensores remotos a la hora de generar mapas de coberturas e identificar tipos de combustibles. Sumado a ello, la tendencia actual de permitir acceder de forma libre a gran cantidad de información ya procesada, lista para su uso en la nube como en el caso de la plataforma *Google Earth Engine* (GEE), o bien su descarga para su integración en los sistemas de información geográfica (SIG), han permitido generalizar el uso de sensores remotos pasivos como Landsat 8 OLI o Sentinel 2 MSI en la gestión forestal (Lechner *et al.*, 2020).

2 OBJETIVOS

El objetivo de este trabajo es diseñar una metodología que permita actualizar de forma semi-automática los mapas de combustibles generados por el CETEMAS en el año 2017, a escala de municipio, reduciendo las limitaciones que supone depender de la publicación de los datos de Inventario Forestal Nacional y del PNOA-LiDAR.

Se plantean entonces tres hitos para alcanzar el objetivo final:

- a. Cartografía de cuatro grandes tipos de combustibles en base a diferencias espectrales, empleando imágenes de satélite y software libre.
- b. Cartografía de áreas quemadas a partir de un análisis multitemporal de imágenes satélite empleando una plataforma web para el procesamiento geoespacial.
- c. Evaluación de la metodología propuesta para actualizar el mapa de combustibles actual de forma semi-automática.

3 ÁREA DE ESTUDIO

La metodología presentada en este trabajo se ha aplicado en el concejo de Tineo (Asturias), ubicado en el suroccidente el Principado de Asturias (Figura 3.1). Abarca una extensión de 540,8 km² en la que el punto más bajo ronda los 160 m.s.n.m y el más alto alcanza los 1530 m.s.n.m. El Mapa Forestal del Año 2012 (ver Anexo 1: Mapa de los tipos de coberturas del suelo del concejo de Tineo (Asturias)) muestra que los usos y cubiertas del suelo siguen un patrón espacial muy marcado: en el centro del concejo se concentran las tierras asociadas a la agricultura, que se combinan también con masas forestales naturales y artificiales, mientras que en los extremos este y oeste el principal tipo de cobertura presente son las coberturas de matorral.

La elección de este Concejo como área de estudio viene dada por la variedad de cubiertas del suelo y modelos de combustibles presentes (según los datos del MFE del años 2012 (DGDRPF, 2012) el 58,82 % del territorio de Tineo se trata de superficie forestal y alrededor del 29 % está dedicado a la explotación agrícola), así como por su extensión (es el segundo municipio más grande de Asturias), y porque además pertenece a la comarca de Lluvia, que fue la tercera comarca más afectada por los incendios entre los años 2005 y 2018 según los datos de la EPLIFA (Gobierno del Principado de Asturias, 2020). Además, para esta zona se contaba con información relevante recogida en parcelas de muestro de la Fundación CETEMAS, lo que facilitaba los trabajos de entrenamiento y validación del proceso a desempeñar. Se tuvo también en cuenta la disponibilidad de imágenes libres de nubes para las fechas de estudio, mientras que en otros concejos del suroccidente como Cangas del Narcea la cobertura nubosa no permitía disponer de condiciones adecuadas para el procesado.

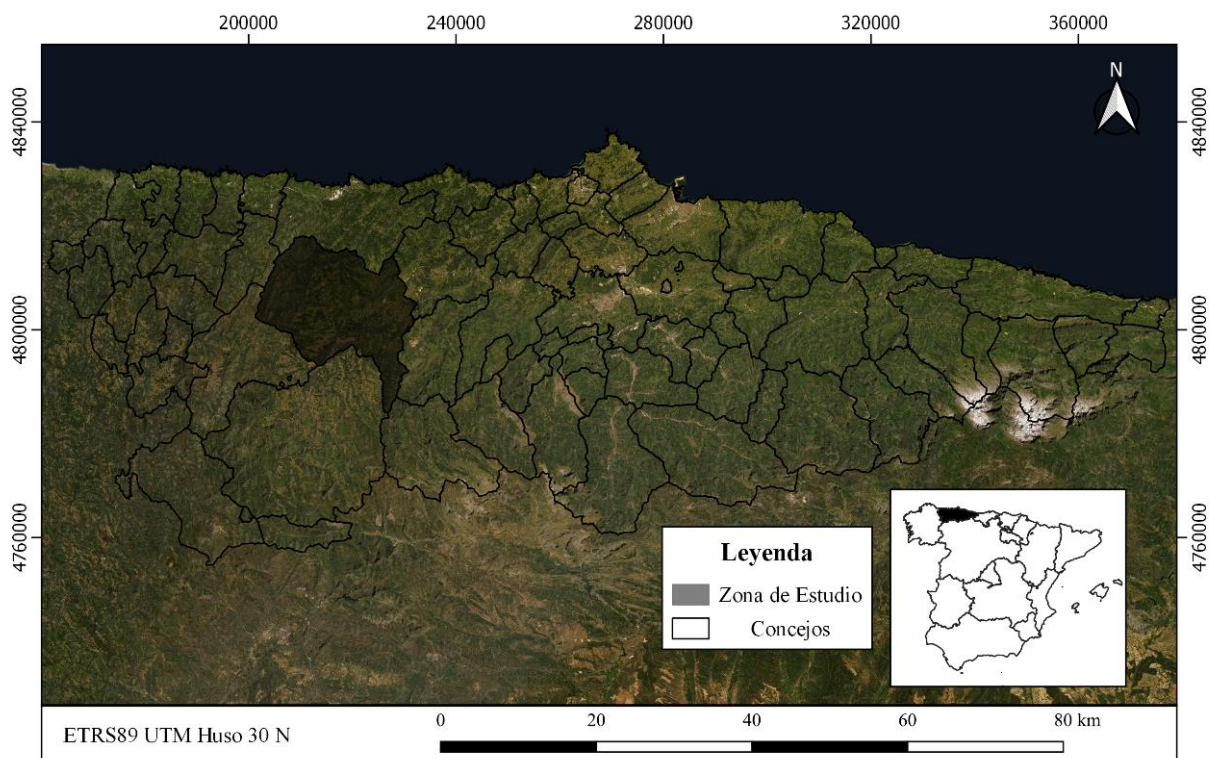


Figura 3.1. Localización del concejo Tineo en el Principado de Asturias. Fuente: Elaboración propia.

4 MATERIAL Y MÉTODOS

Este trabajo se basa en el uso de imágenes satélite Sentinel 2 MSI, para desarrollar dos clasificaciones supervisadas, una siguiendo un análisis orientado a objetos (OBIA) que permita generar una cartografía de cubiertas vegetales, y otra mediante un análisis planteado a nivel de píxel para generar una cartografía de áreas quemadas. Con el flujo de procesos que recoge la Figura 4.1 se pretende resumir todo el trabajo, que se explica a lo largo del presente capítulo.

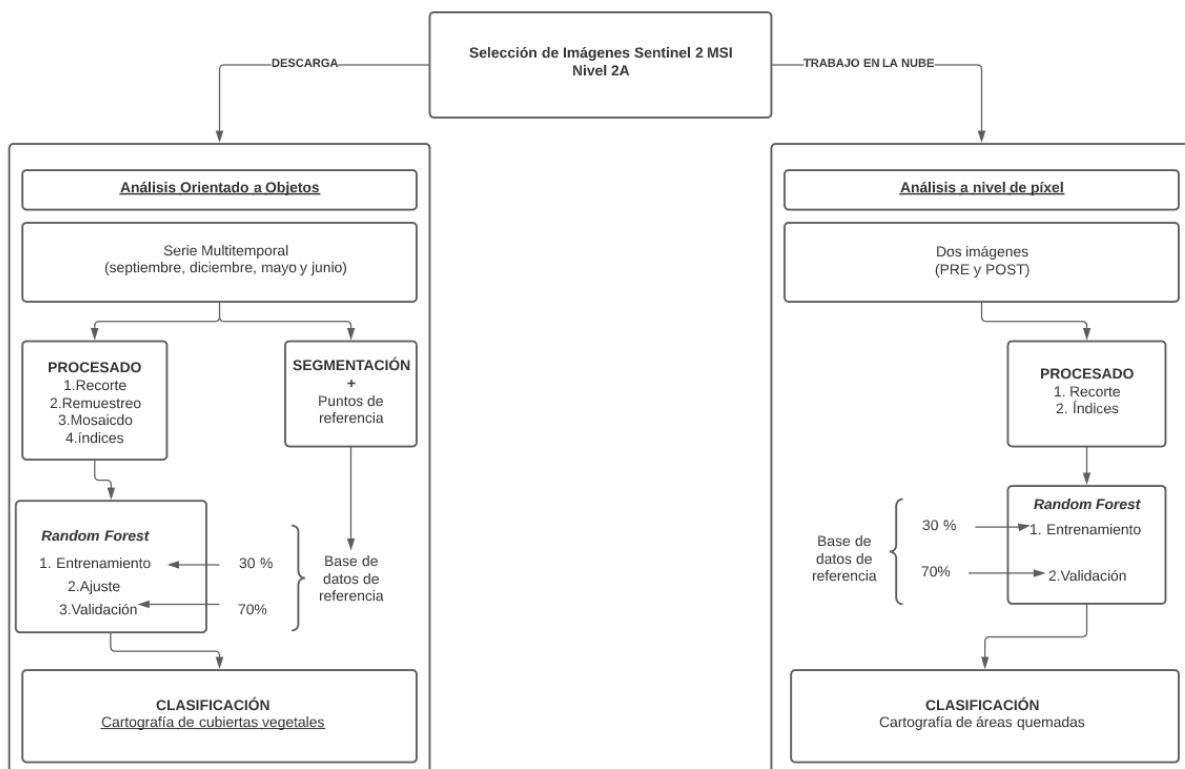


Figura 4.1. Flujo de procesos global. Fuente: Elaboración propia.

4.1 Material

En el presente apartado se detallan los datos de partida empleados, así como los programas informáticos empleados para su procesado.

4.1.1 *Imágenes de Sentinel 2 MSI*

Los sensores remotos Landsat 8 OLI y Sentinel 2 MSI son sensores remotos multiespectrales cuyo uso está muy generalizado. La Tabla 4.1. Características básicas de los productos de los sensores Sentinel 2 MSI y Landsat 8 OLI . recoge las características de los productos generados por ambos. Esta comparativa permite concluir que la opción más adecuada para disponer de datos espacial y espectralmente precisos y actualizados en la zona de estudio es la constelación Sentinel 2, ya que los

satélites S2 A y S2 B realizan barridos con un ancho de campo de visión de 290 km y su combinación permite trabajar con una resolución temporal de cinco días (Drusch *et al.*, 2012).

Tabla 4.1. Características básicas de los productos de los sensores Sentinel 2 MSI y Landsat 8 OLI .

Sensor	Número de bandas	Región del espectro	Resolución espacial (m/píxel)	Campo de visión	Referencia
Sentinel 2 MSI	13	Azul costero, Azul, Verde, Rojo, Infrarrojo cercano (NIR) I y II, Borde rojo I,II y III, Cirros e Infrarrojo de onda corta (SWIR) I y II	10 m (Visible y Infrarrojo cercano I); 20 (Borde rojo, NIR II y SWIR I y II); 60m (Azul costero y Cirros)	290	https://earth.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument
Landsat 8 OLI	9	Azul costero, Azul, Verde, Rojo, NIR y SWIR I y II, Pancromático y Cirros	15 (Pancromático); 30 m (el resto de bandas)	185	https://www.usgs.gov/media/images/landsat-8-band-designations

Ambos satélites tienen implementado el sensor *Multispectral Instrument* (MSI) que les permite capturar 13 bandas, que se corresponden con longitudes de onda de entre 400 y 2300 nm del espectro electromagnético, y cuya resolución espacial varía entre los 10m/píxel y los 60m/píxel (Drusch *et al.*, 2012) (Figura 4.2).

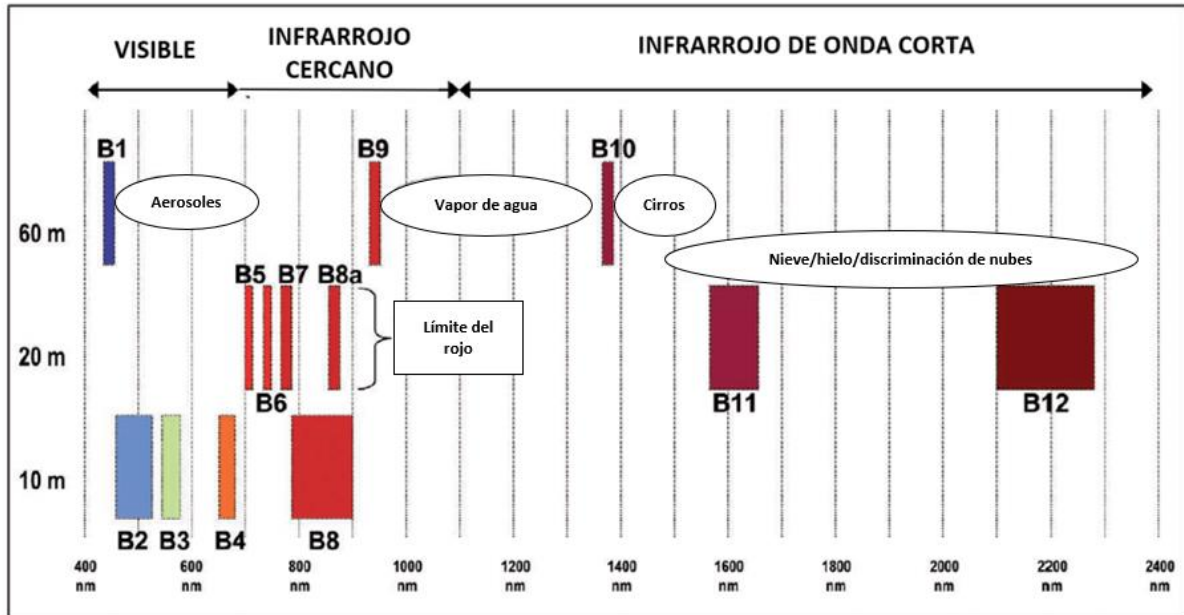


Figura 4.2. Representación gráfica de la resolución espectral frente a la resolución espacial del sensor MSI de los satélites Sentinel 2. Fuente: Elaboración propia a partir de Drusch *et al.* (2012).

4.1.1.1 Imágenes para el cartografiado de cubiertas vegetales

La selección de las imágenes comenzó en la aplicación *Sentinelhub Playground* (<https://apps.sentinel-hub.com/sentinel-playground/>), que permite parametrizar las búsquedas en base a diferentes criterios (fecha, lugar, porcentaje de cobertura de nubes y nivel de preprocesado de las

imágenes). Para mejorar la discriminación de las coberturas se puede recurrir a la variaciones que los cambios fenológicos producen en sus rasgos espectrales (Lausch *et al.*, 2016; Hościło and Lewandowska, 2019), por lo que se buscaron imágenes libres de nubes que coincidieran con cada una de las cuatro estaciones entre septiembre de 2019 y junio de 2020.

Al plantear un análisis multitemporal es importante trabajar con imágenes en las que se haya reducido e incluso eliminado la influencia de la atmósfera (Stoffels *et al.*, 2015). Por ello una vez elegidas las imágenes, desde el portal *Copernicus Open Access Hub* (<https://scihub.copernicus.eu/>) se descargaron con nivel 2A de preprocesado, es decir, corregidas atmosféricamente y con valores de reflectancia en la parte inferior de la atmósfera (*Bottom Of Atmosphere*, BOA). Para abarcar la totalidad del área de estudio, fue necesario utilizar cuatro cuadrículas (*tiles*) Sentinel para cada fecha (29TPJ, 29TPH, 29TQJ y 29TQH), lo que generó una colección de 16 imágenes (Tabla 4.2. Resumen de las imágenes multiespectrales Sentinel 2 MSI seleccionadas. Fuente: Elaboración propia.). Todas ellas son imágenes corregidas geométricamente y con sistema de referencia de coordenadas WGS 84 UTM Huso 29. Las imágenes de septiembre, diciembre y mayo fueron capturadas por el satélite S2-A, mientras que la correspondiente a junio fue adquirida por el satélite S2-B, en cualquier caso, todas fueron capturadas el sensor *Multispectral Instrument* (MSI).

Tabla 4.2. Resumen de las imágenes multiespectrales Sentinel 2 MSI seleccionadas. Fuente: Elaboración propia.

Momento	Satélite		Tile	Código
	S2	Fecha		
Transición Verano-Otoño	A	12/09/2019	TPJ	S2A_MSIL2A_20190912T112111_N0213_R037_T29TPJ
	A		TPH	S2A_MSIL2A_20190912T112111_N0213_R037_T29TPH
	A		TQJ	S2A_MSIL2A_20190912T112111_N0213_R037_T29TQJ
	A		TQH	S2A_MSIL2A_20190912T112111_N0213_R037_T29TQH
Invierno	A	31/12/2019	TPJ	S2A_MSIL2A_20191231T112451_N0213_R037_T29TPJ
	A		TPH	S2A_MSIL2A_20191231T112451_N0213_R037_T29TPH
	A		TQJ	S2A_MSIL2A_20191231T112451_N0213_R037_T29TQJ
	A		TQH	S2A_MSIL2A_20191231T112451_N0213_R037_T29TQH
Primavera	A	28/05/2020	TPJ	S2A_MSIL2A_20200529T112121_N0214_R037_T29TPJ
	A		TPH	S2A_MSIL2A_20200529T112121_N0214_R037_T29TPH
	A		TQJ	S2A_MSIL2A_20200529T112121_N0214_R037_T29TQJ
	A		TQH	S2A_MSIL2A_20200529T112121_N0214_R037_T29TQH
Verano	B	23/06/2020	TPJ	S2B_MSIL2A_20200623T112119_N0214_R037_T29TPJ
	B		TPH	S2B_MSIL2A_20200623T112119_N0214_R037_T29TPH
	B		TQJ	S2B_MSIL2A_20200623T112119_N0214_R037_T29TQJ
	B		TQH	S2B_MSIL2A_20200623T112119_N0214_R037_T29TQH

4.1.1.2 Imágenes para el cartografiado de áreas quemadas

En el Principado de Asturias la época más crítica en cuanto al número de incendios y superficie quemada se concentra entre los meses finales del invierno (EPLIFA, 2020). Como se decidió utilizar el índice dNBR (Botella-Martínez y Fernández-Manso, 2017) para localizar las áreas quemadas, y este

requiere el empleo de una imagen pre incendio y otra post incendio, fue necesario localizar dos imágenes libres de nubes para asociar al inicio y fin de este período, respectivamente. Normalmente el ciclo en el que los incendios son recurrentes comienza la segunda quincena de febrero y se extiende hasta la primera quincena de abril, coincidente con periodos con alta nubosidad. A pesar de la alta frecuencia de captura de la constelación Sentinel 2 las condiciones climatológicas condicionaron la tarea de selección, decidiendo trabajar finalmente con una imagen del 31 de diciembre de 2019 y un del 5 de abril de 2020 (Tabla 4.3. Imágenes Sentinel 2 empleadas en el mapeo de las zonas quemadas en Tineo en 2020. Fuente: Elaboración propia.).

Al trabajar en la plataforma *Google Earth Engine* (GEE) no fue necesario descargar las imágenes, si no que se trabajó con la colección de imágenes Sentinel 2 que está disponible en el catálogo de GEE. Al usar una serie de dos imágenes se empleó la colección “COPERNICUS/S2_SR” que recoge las imágenes Sentinel 2 con nivel 2A de preprocesado, es decir, corregidas atmosféricamente y con valores de reflectancia en la parte inferior de la atmósfera (*Bottom Of Atmosphere*, BOA). Como ya se indica en el subapartado 4.1.1.1 para cubrir toda la superficie del concejo de Tineo hay que trabajar con cuatro cuadrículas para cada escena, es decir, se empleó una colección formada por 8 imágenes (Tabla 4.3. Imágenes Sentinel 2 empleadas en el mapeo de las zonas quemadas en Tineo en 2020. Fuente: Elaboración propia.), que tienen asociado el sistema de referencia de coordenadas geográficas WGS 84, ya que es el sistema que la plataforma GEE emplea por defecto.

Tabla 4.3. Imágenes Sentinel 2 empleadas en el mapeo de las zonas quemadas en Tineo en 2020. Fuente: Elaboración propia.

Momento	Satélite S2	Fecha	Código
Inicio	A	31/12/2019	S2A_MSIL2A_20190912T112111_N0213_R037_T29TPJ
			S2A_MSIL2A_20190912T112111_N0213_R037_T29TPH
			S2A_MSIL2A_20190912T112111_N0213_R037_T29TQJ
			S2A_MSIL2A_20190912T112111_N0213_R037_T29TQH
Fin	B	04/04/2020	S2B_MSIL2A_20200404T112109_N0214_R037_T29TPJ
			S2B_MSIL2A_20200404T112109_N0214_R037_T29TPH
			S2B_MSIL2A_20200404T112109_N0214_R037_T29TQJ
			S2B_MSIL2A_20200404T112109_N0214_R037_T29TQH

4.1.2 Base de datos de referencia de cubiertas del suelo

Al plantear una clasificación de coberturas es necesario disponer de una base de datos que sirva tanto para el entrenamiento como para la validación del modelo clasificador. En este caso se tomaron por un lado una serie de parcelas cuya clase de cobertura fue identificada en campo durante el Cuarto Inventario Forestal Nacional (IFN₄) (DGDRPF, 2012) y otras sobre las que ha trabajado el CETEMAS, además de un conjunto de puntos generados a partir de un muestreo aleatorio sobre el concejo de Tineo que han sido clasificados mediante fotointerpretación.

En el caso del trabajo de campo del IFN₄ y del CETEMAS la identificación de las coberturas se hizo de forma similar, empleando parcelas de 15 metros de radio. En total conforman un grupo de 67 parcelas que representan principalmente formaciones de coníferas y frondosas (Tabla 4.4). Ambos conjuntos fueron referenciados según el sistema de referencia de coordenadas (SRC) ETRS 89 UTM Huso 30. La **¡Error! No se encuentra el origen de la referencia.** representa su distribución espacial empleando este SRC.

Tabla 4.4. Parcelas de referencia cuya cobertura fue identificada mediante a trabajos de campo. Fuente: Elaboración propia.

Conjunto	Fecha	Cobertura	Número
IFN ₄	2009-2010	Coníferas	38
		Frondosas	3
CETEMAS	2015-2019	Coníferas	3
		Frondosas	23

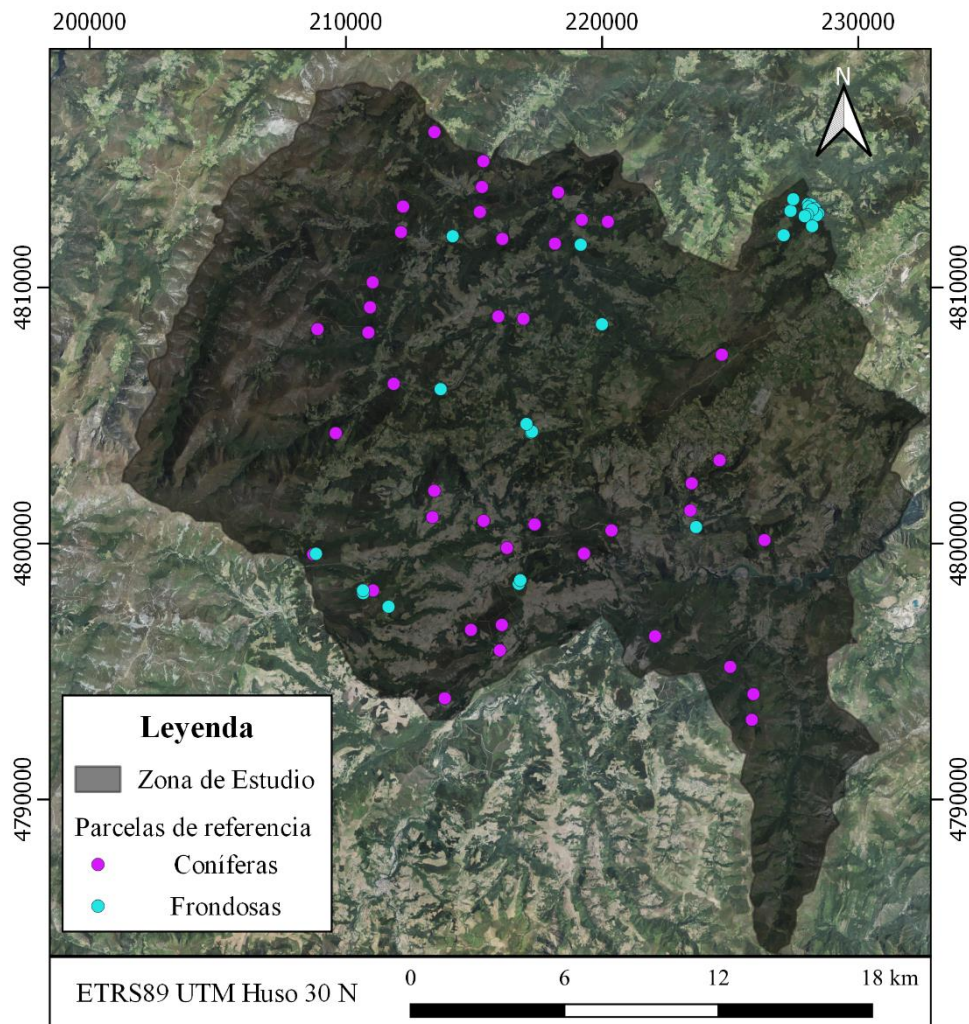


Figura 4.3. Localización geográfica de las parcelas del IFN4 y del CETEMAS en el concejo de Tineo. Fuente: Elaboración propia.

En cuanto a la tercera fuente de datos, para clasificar las parcelas generadas en el muestreo aleatorio se tomaron como referencia para la fotointerpretación los conjuntos de datos recogidos en la Tabla 4.5, que se corresponden con el servicio de mapas web (WMS) de las ortofotos PNOA de máxima actualidad, los perímetros de los incendios ocurridos en Tineo en 2018 y 2019 suministrados por el Servicio de Emergencias del Principado de Asturias (SEPA) y las combinaciones en color verdadero de las imágenes satélite Sentinel 2 MSI recogidas en el subapartado 4.1.1.1.

Tabla 4.5. Información de base para clasificar las parcelas generadas de forma aleatoria. Fuente: Elaboración propia.

Conjunto de datos	Fecha	Tipo	Referencia
Ortofoto PNOA Máxima Actualidad	2017	WMS	(https://www.ign.es/wms-inspire/pnoa-ma?request=GetCapabilities&service=WMS) Servicio de Emergencias del Principado de Asturias (SEPA)
Perímetros incendios de Tineo	2018-2019	vectorial	
Imágenes satélite Sentinel 2 MSI	2019-2020	Ráster multi-banda	Subapartado 4.1.1.1

Se trató de que el tamaño de las clases fuera equilibrado, con el objetivo de evitar un desajuste que provocase elevadas exactitudes en clase más representadas y peores resultados en las clases con menos peso (Wessel *et al.*, 2018). Como se ve en la Tabla 4.6 se trabajó con un total de 301 parcelas distribuidas a lo largo del concejo de Tineo (**¡Error! No se encuentra el origen de la referencia.**) empleando como sistema de referencia de coordenadas el SRC ETRS 89 UTM Huso 30. En este caso, además de las clases “Coníferas” y “Frondosas”, se incluyeron las clases “Herbazal” y “Matorral” (los otros dos grandes grupos de vegetación presentes), así como las clases “Infraestructuras” y “Resto”, que aunque no son objeto de la clasificación, son necesarias para poder aplicar el algoritmo clasificador con éxito, puesto que la leyenda debe ser exhaustiva e incluir todas las clases presentes.

Tabla 4.6. Parcelas generadas de forma aleatoria y fotointerpretadas. Fuente: Elaboración propia.

Conjunto	Cobertura	Número
Parcelas fotointerpretadas	Coníferas	28
	Frondosas	64
	Herbazal	62
	Matorral	71
	Infraestructuras	22
	Resto de coberturas	54

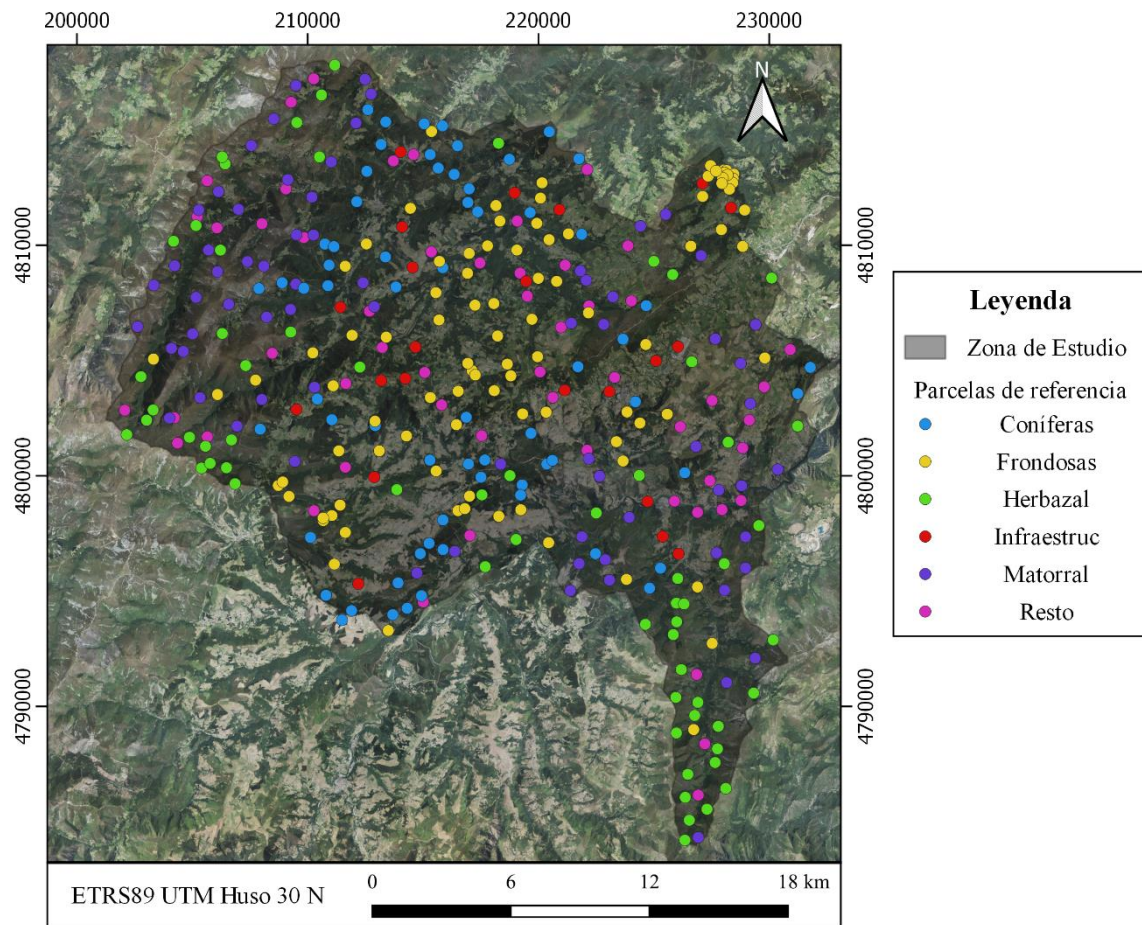


Figura 4.4. Localización geográfica de las parcelas clasificadas mediante fotointerpretación. Fuente: Elaboración propia.

4.1.3 Base de datos de referencia de áreas quemadas

Las parcelas de referencia empleadas para la identificación de áreas quemadas se generaron en Google Earth Engine (GEE), mediante fotointerpretación y tomando como apoyo una composición en falso color (infrarrojo de onda corta, infrarrojo cercano y rojo) de la imagen del 4 de abril de 2020 (**¡Error! No se encuentra el origen de la referencia.**), así como la diferencia en entre el índice *Normalized Burn Ratio* (NBR) (Key y Benson, 2006) de la imagen del inicio y del fin del período de incendios (dNBR), que se representa en la **¡Error! No se encuentra el origen de la referencia.**




Figura 4.5. Composición en falso color (infrarrojo de onda corta, infrarrojo cercano y rojo) de la imagen del 4 de abril de 2020 en GEE. Fuente: Elaboración propia.




Figura 4.6. Diferencia entre el índice *Normalized Burn Ratio* (NBR) de la imagen del inicio y del fin del período de incendios (dNBR). En color más claro se localizan las zonas quemadas. Fuente: elaboración propia.

Se generó un conjunto formado por 12 parcelas para la clase quemado, con un total de 48 píxeles de 10 m x 10 m y 38 parcelas para la clase no quemado (224 píxeles) (Tabla 4.7). Este conjunto de 50 parcelas al haber sido generado en la GEE tiene asociado como sistema de coordenadas las geográficas y como sistema de referencia WGS 84, pues es con el que se trabaja por defecto en la plataforma. En cualquier caso, para su representar su distribución en el concejo de Tineo (Figura 4.7. Distribución espacial de las parcelas de referencia para la clasificación de áreas quemadas.) se exportaron y transformaron al SRC ETRS 89 UTM Huso 30.

Tabla 4.7. Parcelas de referencia para la clasificación de áreas quemadas.

Clase	Número de parcelas	Número de píxeles
Quemado	12	48
No quemado	40	224

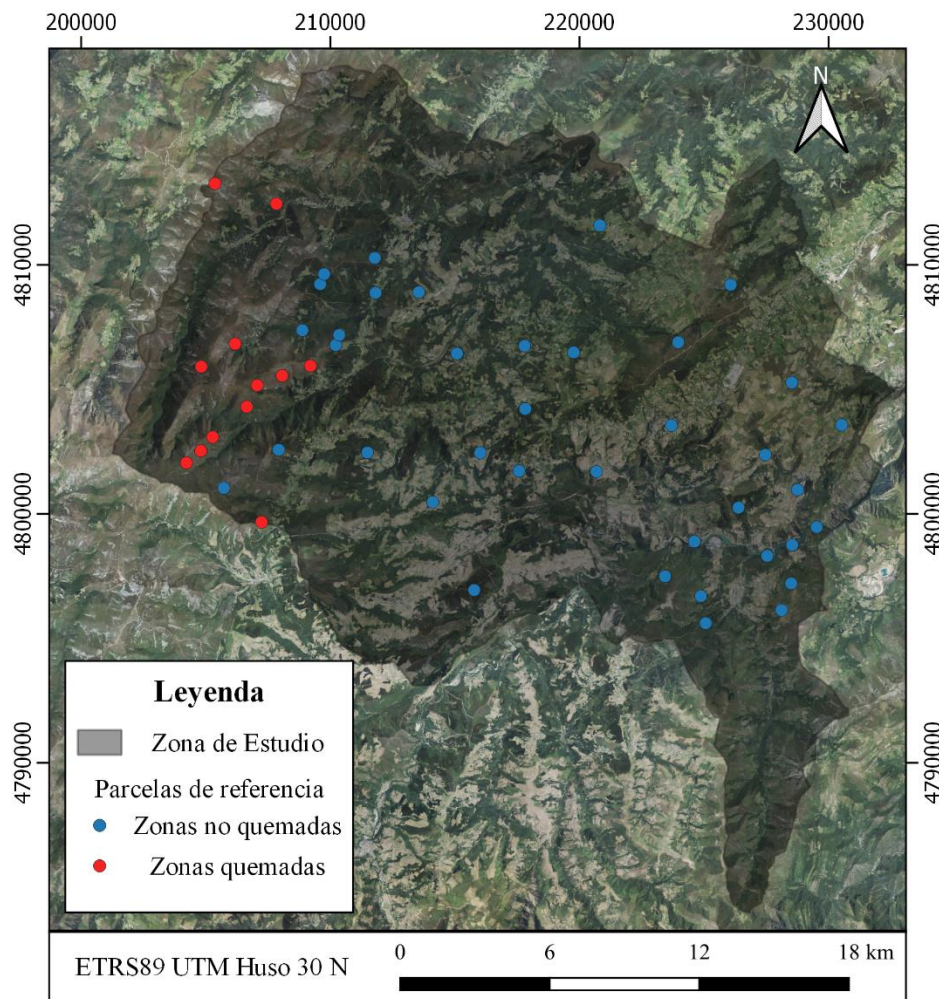


Figura 4.7. Distribución espacial de las parcelas de referencia para la clasificación de áreas quemadas.

4.1.4 RStudio

Se empleó la versión 4.0.2 del software de análisis estadístico RStudio (RStudio Team, 2020), con el objetivo de poder repetir los procesos con otros conjuntos de datos. R se trata de un plataforma libre cuyo núcleo principal, está orientado a la computación gráfica y estadística, aunque gracias al continuo desarrollo por parte de la Comprehensive R Archive Network (CRAN) existen números paquetes orientados a al análisis de datos espaciales (Bivand *et al.*, 2008; Pebesma *et al.*, 2012).

4.1.5 *eCognition Essentials*

El software comercial Essentials de eCognition 1.3.1 (Trimble, Inc, 2016), es una herramienta orientada al mapeo de coberturas del suelo y la detección de cambios. En este caso se utilizó debido a su potencial para segmentar las imágenes satélites de alta resolución espacial, ya que la segmentación es una tarea clave en el flujo de procesos de un análisis orientado a objetos (Kucharczyk *et al.*, 2020).

4.1.6 *ArcMap*

Se empleó el software de ESRI ArcMap en su versión 10.7.1 (ESRI, 2019) para generar flujos de procesos actualizables y reproducibles (ESRI, 2000), ya que tiene implementado el *Model Builder*.

4.1.7 *Google Earth Engine (GEE)*

Google Earth Engine es una plataforma orientada al análisis geoespacial que recoge en la nube un amplio catálogo de datos de libre acceso, así como un servicio de computación, que reduce los costes tecnológicos derivados del almacenamiento y procesado de grandes conjuntos de datos (Tamiminia *et al.*, 2020). La interfaz de programación de aplicaciones permite acceder a las diferentes colecciones de datos, incorporar datos del propio usuario y analizarlos mediante a los lenguajes Java o Python usando una amplia librería de operadores. A su vez el entorno de desarrollo integrado (IDE) hace posible la visualización de los resultados (Gorelick *et al.*, 2017). Se empleó para comprobar las prestaciones que presenta la plataforma, a la hora realizar clasificaciones a partir de imágenes de satélite utilizando los catálogos de datos y algoritmo implementados en la nube.

4.2 **Métodos**

En este apartado se explican los pasos necesarios para poder seguir el flujo de procesos recogido en la Figura 4.8. Flujo de procesos seguido en la clasificación de imágenes Sentinel 2 MSI planteando un OBIA. Aunque el método de análisis empleado en cada clasificación es distinto, en ambas se puede dividir el proceso en cuatro bloques: partiendo con el procesado de las imágenes multiespectrales, el siguiente paso consistió en generar la base de datos de entrenamiento y validación; seguidamente se entrenó y se ajustó el algoritmo clasificador, para cerrar el proceso con la clasificación final y validación.

4.2.1 *Cartografiado de cubiertas vegetales mediante clasificación de las imágenes*

Se ha planteado una clasificación de coberturas a partir de una serie multitemporal de imágenes Sentinel 2. Para ello, se trabajó mediante OBIA tomando como base el proceso que plantean Kucharczyk *et al.* (2020). En la Figura 4.8 se puede ver el flujo de procesos seguido durante el trabajo: adquisición y procesado de las imágenes Sentinel 2, segmentación para crear la base de datos de referencia, que permita entrenar, validar el algoritmo clasificador, y finalmente, la clasificación de los objetos de la imagen.

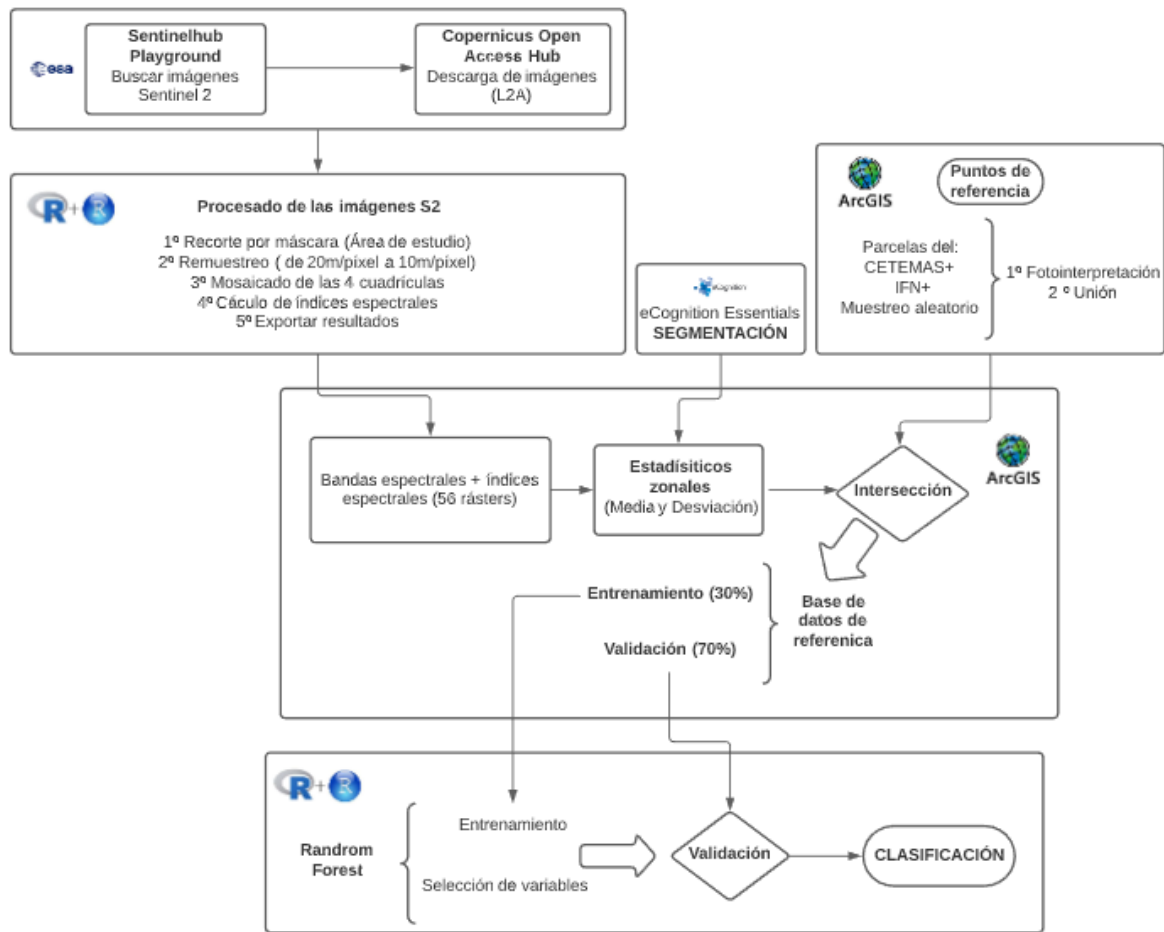


Figura 4.8. Flujo de procesos seguido en la clasificación de imágenes Sentinel 2 MSI planteando un OBIA.

4.2.1.1 Definición de las agrupaciones de cobertura vegetal

A la hora de plantear una clasificación de tipos de vegetación a partir de imágenes generadas por sensores remotos pasivos, hay que tener en cuenta que la mayoría de los modelos de combustibles normalmente están relacionados con estructura de las masas y por tanto las limitaciones de sensores ópticos condicionarán los tipos que se puedan diferenciar.

Los sensores espectrales no pueden atravesar a la cubierta vegetal, y además la reflectancia no muestra una relación directa con métricas relacionadas con la estratificación vertical de la vegetación, como puede ser la altura (Arroyo *et al.*, 2008). Se tiene entonces que plantear tipos o grupos de vegetación que puedan ser diferenciados en función de su firma espectral.

En base a las capacidades de las imágenes satélite y atendiendo a la clasificación recogía en la Fotoguía de Combustibles de Galicia (Arellano *et al.*, 2017), se plantea la leyenda que recoge la formada por una clase asociada a las infraestructuras, otra que englobe el resto de coberturas, además cuatro tipos de combustibles: Herbazales (pastizales y helechales), Matorrales, Coníferas y Frondosas.

Tabla 4.8. Leyenda para el cartografiado de cuatro grandes grupos de combustibles. Fuente: Elaboración propia en base a la clasificación de la Fotoguía de Combustibles de Galicia (Arellano *et al.*, 2017)

Tipo de cobertura	Descripción
Fronosas Coníferas	Masas naturales (<i>Castanea sativa</i> , <i>Betula pubescens</i> , <i>Quercus pyrenaica</i> y <i>Q robur</i>) y masas artificiales (<i>Eucalyptus globulus</i>)
Matorral Herbazal	Masas del género <i>Pinus</i> (incluyendo repobalaciones) Estratos de vegetación leñosa de porte arbustivo; arbolado disperso con predominio del matorral Pastizales y Helechales
Infraestructuras	Núcleos urbanos
Resto de coberturas	Masas de agua; Roquedos; Zonas agrícolas y las no incluidas en las anteriores

4.2.1.2 Procesamiento de las imágenes: remuestreo, unión y cálculo de índices

A partir de las cuatro cuadrículas descargadas para cada fecha se generó un mosaico que permita disponer de imágenes satélite del Concejo de Tineo, utilizando para ello nueve de las 13 bandas disponibles (Azul, Verde, Rojo, tres bandas del Borde Rojo (Límite del Rojo), infrarrojo cercano y dos bandas del infrarrojo de onda corta). Para ello se preparó en RStudio un script de manera que el proceso pueda reproducirse con cualquier imagen de forma más o menos automática, dicho script aparece recogido en el Anexo 2: Script en diseñado en RStudio para el procesado de las imágenes Sentinel 2.

En un principio, se aplicó sobre las bandas espectrales de cada cuadrícula un recorte por máscara para centrarse en el área de estudio y además reducir los tiempos de procesado. Para poder unir las imágenes y hacer el cálculo de índices espectrales todas las bandas deben tener la misma resolución, así que tras el recorte fue necesario aplicar un remuestreo en el caso de las tres bandas del límite del rojo y las dos bandas del infrarrojo de onda corta, que cuentan con una resolución espacial de 20 m/píxel. De esta forma y tras haber empleado el método del vecino más próximo se dispuso de todas las bandas a una resolución espacial de 10 m/píxel. A continuación, para no ejecutar la unión de cada una de las bandas por separado, estas se apilaron para hacer el mosaicado directamente sobre los grupos de bandas (*stacks*).

El siguiente paso consistió en calcular a partir de las bandas del verde (B3), del rojo (B4), de la primera banda del borde rojo (B5), del NIR (B8) y de las dos bandas del SWIR (B11 y B12) cinco índices espectrales. Se calculó el *Normalized Difference Vegetation Index* (1), que aunque es el índice de vegetación más utilizado es algo sensible al ruido, y por ello y en base a las indicaciones ofrecidas por García *et al.* (2011) y Marino *et al.*, (2016), para mejorar la capacidad de discriminación entre coberturas, se calcularon los índices *Soil adjusted Vegetation Index* (2) y *Normalized Difference Infared Index* (3). Además se calcularon el *Anthocyanin Reflectance Index* I (4) y II (5) debido a que permiten mejorar la discriminación entre las clases de matorral y herbazal, ya que usar el nivel de antocianinas contribuye a diferenciar entre ambos estratos (Bayle *et al.*, 2019).

$$(1) \text{NDVI} = \frac{\text{NIR}-R}{\text{NIR}+R}$$

$$(2) \text{SAVI} = \frac{\text{NIR}-R}{\text{NIR}+R+L} \times (1+L) \quad (L = 0.5)$$

$$(3) \text{NDII} = \frac{\text{NIR}-\text{SWIR1}}{\text{NIR}+\text{SWIR1}}$$

$$(4) \text{ARI I} = \frac{1}{G} - \frac{1}{RE}$$

$$(5) \text{ARI II} = \left(\frac{1}{G} - \frac{1}{RE} \right) \times \text{NIR}$$

Para cada una de las fechas se obtuvieron un total quince archivos ráster, que se corresponden con nueve bandas espectrales, cinco índices espectrales y un apilado de todas ellas.

4.2.1.3 Segmentación

La segmentación es un proceso clave en los análisis de imágenes orientados a objetos, que consiste en identificar objetos de la realidad en un imagen (Blaschke *et al.*, 2014). Al igual que en los análisis basados en píxeles se tiene en cuenta la información espectral de cada uno de ellos, pero además al trabajar con imágenes de alta resolución espacial se usan las características espectrales, texturales y geométricas de los objetos (Hossain y Chen, 2019).

Los métodos de segmentación pueden dividirse en dos grupos en función de los criterios empleados, así los basados en píxeles segmentan a partir de umbrales sobre las características, mientras que los basados en bordes y en regiones emplean la similitud y discontinuidad entre los objetos. Además según el punto de partida, se pueden diferenciar entre los métodos de división y unión que toman la imagen como semillas o los métodos de crecimiento y unión que toman como semilla un píxel (Hossain y Chen, 2019).

En este caso se trabajó con el software comercial de Trimble eCognition Essential (Trimble, Inc, 2016), en el que viene implementado el algoritmo *Multiresolution Segmentation* que trabaja de forma no supervisada y de forma iterativa a partir de un píxel semilla. Además, sigue los criterios de los métodos basados en regiones y en bordes, así que va agrupando píxeles adyacentes con características similares hasta identificar un cambio brusco lo que supone el cierre del segmento. Aunque esta combinación lo hace menos sensible al ruido, resulta difícil encontrar la parametrización óptima (Hossain y Chen, 2019; Kucharczyk *et al.*, 2020), sobre todo el parámetro de escala ya que también depende de la extensión del área de estudio (Ma *et al.*, 2017).

En el software eCognition Essentials el número de bandas a usar en la segmentación está limitado a doce así que se usaron las bandas verde, azul, rojo, Infrarrojo, las dos bandas del infrarrojo de onda corta y los cinco índices espectrales correspondientes a la imagen del 23 de junio de 2020. Además es necesario indicar los valores de los parámetros de escala para controlar la segmentación excesiva

y por defecto (Kucharczyk *et al.*, 2020), y los parámetros de color y forma ya que en conjunto son clave a la hora de diferenciar zonas con valores espectrales muy similares (Drăguț *et al.*, 2010). Así que tras varios intentos se decidió usar unos valores de 50 para la escala y de 0,5 para el color y la forma, ya que visualmente se apreciaban segmentos más homogéneos y ajustados a la realidad.

4.2.1.4 Extracción de estadísticos

El software eCognition Essentials no permite generar los estadísticos asociados a cada uno de los objetos en base a la información espectral. Por ello, una vez segmentada la escena, en el entorno de ArcGIS (ESRI, 2019) y con la herramienta *Model Builder* se diseñaron dos modelos, ambos recogidos en los Anexo 3: Estadísticos como tabla y Anexo 4: Unión por ID respectivamente. El primero con la ayuda de la figura del iterador de rásteres y empleando la herramienta “estadísticos zonales en forma de tabla”, permite extraer la media y la desviación estándar los valores espectrales de cada uno de los objetos que forman la imagen (empleando por cada imagen las nueve bandas y los 5 índices que se recogen en la Tabla 4.9. Bandas e índices espectrales derivados de cada una de las imágenes Sentinel 2 MSI. Fuente: Elaboración propia.). Mientras que el segundo llamado “Unión por ID” genera una base de datos formada por 42,478 segmentos y 112 variables (28 por cada escena), ya que recoge los estadísticos de toda la serie temporal.

Tabla 4.9. Bandas e índices espectrales derivados de cada una de las imágenes Sentinel 2 MSI. Fuente: Elaboración propia.

Variables	
Bandas espectrales	Azul (B01), Verde (B02), Rojo(B03), Borde rojo (B05, B06, B07), NIR(B08), SWIR (B11 y B12)
Índices espectrales	ARI I, ARI II, NDII, NDVI y SAVI

Para identificar las 112 variables se creó un código basado en el mes de la imagen, el estadístico y la banda o índice espectral correspondientes (Mes_Estadístico_Banda/índice). En la Tabla 4.10. Asignación del código a 8 variables a modo de ejemplo. Fuente: Elaboración propia. se recogen 8 de las variables, de forma que se ejemplifique la asignación del código a cada una de ellas. En el Anexo 5: Listado de variables empeladas en la clasificación de los grupos de vegetación. se recogen por separado todas las variables, agrupadas en función del mes de las imágenes Sentinel 2 MSI empeladas en el análisis.

Tabla 4.10. Asignación del código a 8 variables a modo de ejemplo. Fuente: Elaboración propia.

Mes de la escena	Estadístico	Banda/índice espectral	Código
Septiembre (S)	Media (M)	B02	S_M_B02
	Desviación estándar (ST)	B02	S_ST_B02
Diciembre (D)	Media (M)	B03	D_M_B03
	Desviación estándar (ST)	B03	D_ST_B03
Mayo (M)	Media (M)	NDVI	M_M_NDVI
	Desviación estándar (ST)	NDVI	M_ST_NDVI

Junio(J)	Media (M)	SAVI	J_M_SAVI
	Desviación estándar (ST)	SAVI	J_ST_SAVI

4.2.1.5 Clasificación

Una clasificación orientada a objetos consiste en identificar la clase a la que pertenecen cada uno de los elementos identificados en la imagen durante el proceso de segmentación. En este caso, además de forma supervisada lo que significa que es necesario entrenar al algoritmo clasificador en base a una serie de parcelas de referencia (Kucharczyk *et al.*, 2020).

A la hora de plantear un OBIA para clasificar imágenes satélites son muchos los algoritmos de aprendizaje automático disponibles. Uno cuyo uso está más generalizado es el algoritmo no paramétrico *Random Forest*, consiste en una serie árboles de decisión en los que tanto el conjunto de datos de entrenamiento como las variables empleadas se seleccionan de forma aleatoria en cada iteración (Breiman, 2001). Esta densa red de árboles de decisión permite al algoritmo reducir los efectos del sobre entrenamiento y la influencia de los valores extremos (Belgiu and Drăguț, 2016). Por todo ello, se decidió utilizarlo en este análisis.

4.2.1.6 Base de datos de entrenamiento y validación

Para generar la base de datos de referencia se unieron las parcelas del IFN₄, del CETEMAS y las parcelas generadas en el muestro aleatorio, dando lugar a un conjunto de 368 parcelas (Tabla 4.11. Número de parcelas empleadas como referencia en el proceso de clasificación.). El siguiente paso consistió en comprobar que cada una de estas parcelas se ubicaba en un único objeto de la imagen (Figura 4.9. Representación de los puntos de referencia sobre los segmentos y una ortofotografía del PNOA (2017). Fuente: Elaboración propia.) y que era homogénea espectralmente.

Tabla 4.11. Número de parcelas empleadas como referencia en el proceso de clasificación.

Tipo de cobertura	Número
Frondosas	94
Coníferas	62
Herbazales	62
Infraestructuras	22
Matorral	71
Resto de coberturas	54
Total	368




Figura 4.9. Representación de los puntos de referencia sobre los segmentos y una ortofotografía del PNOA (2017). Fuente: Elaboración propia.

Finalmente, todos ellos fueron intersecados con los estadísticos de cada uno de los 42,478 objetos de la imagen, dando lugar a una base de datos en la que cada segmento tiene asociadas sus características espectrales. Parte de esta base de referencia se empleó para entrenar y parte para validar, tal y como se describe en los apartados siguientes.

4.2.1.7 Ajuste del modelo y clasificación

El proceso de entrenamiento, ajuste y clasificación del algoritmo no paramétrico *RandomForest* se desarrolló al completo en RStudio (RStudio Team, 2020) utilizando el paquete *randomForest* (Liaw y Wiener, 2002). Todo este proceso puede verse en el script recogido en el Anexo 6: Script para llevar a cabo la clasificación supervisada en RStudio. Se comenzó con la división aleatoria de la base de datos verdad terreno en dos subconjuntos, para emplear un 30% en el entrenamiento del algoritmo y un 70% en la validación, es decir, 114 y 254 parcelas respectivamente.

Se decidió comprobar cómo se alcanzarían resultados más exactos, si empleando la información de la serie temporal en conjunto o con las imágenes por separado. Como criterio de comparación se emplearon las exactitudes globales obtenidas en cada situación, decidiendo finalmente realizar un análisis multitemporal.

En cada iteración el *Random Forest* utiliza diferentes variables, y trabajar con todas las variables implicaba que en cada iteración el algoritmo debía seleccionar entre 112 variables, por ello se realizó una selección de variables. Para ello se tomó como referencia el Decrecimiento de Gini o *Mean Decrease Gini* (MDG), que se trata de un estadístico que estima la importancia en función de la exactitud

de cada variable en el proceso de clasificación, así como del número de veces que el modelo recurre a ella (Menze *et al.*, 2009).

4.2.1.8 Evaluación de la clasificación

Para poder valorar la exactitud del modelo se clasificaron los 254 puntos reservados para el proceso de validación. De esta forma, y en función de los valores reales y los valores predichos se generó la matriz de confusión y se calcularon la exactitud de cada clase y la global, ya que es lo más apropiado para valorar la exactitud de mapas categóricos generados a partir de la clasificación de imágenes (Foody, 2020). Además, se estimaron los intervalos de confianza al 95 % de probabilidad a partir del método Wald ajustado (Sauro y Lewis, 2005), pues son muy útiles en la interpretación y comparación de los resultados (Foody, 2009).

4.2.2 Cartografiado de las zonas quemadas

Se generó una cartografía de las zonas quemadas en el Concejo de Tineo durante los tres primeros meses del año 2020, utilizando imágenes de la constelación de satélites Sentinel 2. Tomando como base la diferencia entre el *Normalized Burn Ratio* del momento inicial y final de la serie temporal (*dNBR*) se creó a partir de un análisis visual una base de referencia descrita en el apartado de “Material”. Finalmente, ese conjunto de puntos verdad terreno se combinó para el ajuste, validación y ejecución del algoritmo *Random Forest*, como se puede ver en el flujo de procesos que recoge la Figura 4.10. Flujo de procesos seguido para la generación de una cartografía de áreas quemadas en Tineo (2020). Todo el proceso se realizó en un script (Anexo 7: Clasificación de zonas en la plataforma GEE) diseñado en el entorno de *Google Earth Engine* (GEE).

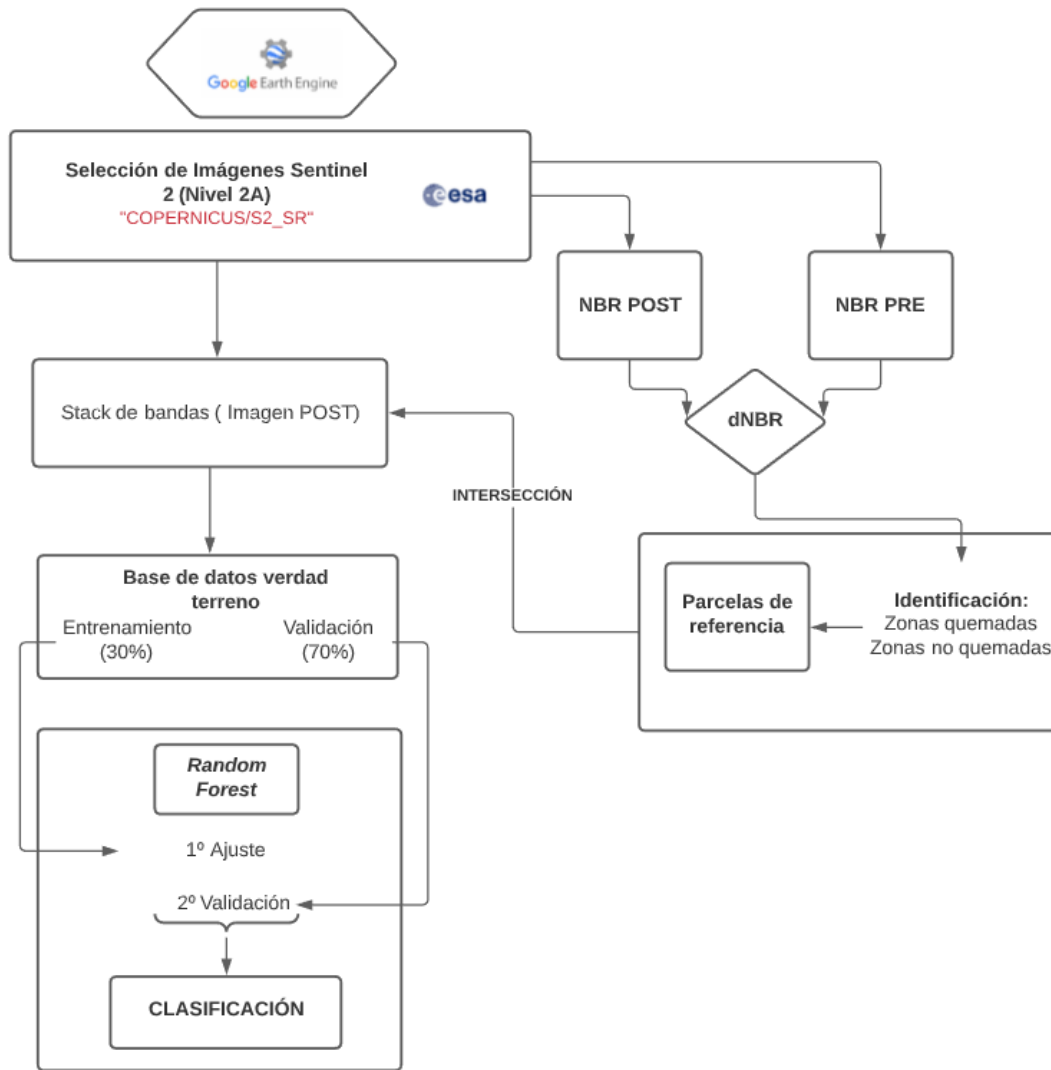


Figura 4.10. Flujo de procesos seguido para la generación de una cartografía áreas quemadas en Tineo (2020).

4.2.2.1 Procesado de las imágenes

Tras seleccionar la colección de imágenes se hizo un filtrado por fecha e indicando los límites del área de estudio. De esta forma se seleccionaron las imágenes de diciembre (31/12/2019) y de abril (04/04/2020), y seguidamente se mosaicaron las cuatro cuadrículas de cada escena (29TPJ, 29TPH, 29TQJ y 29TQH) y se recortaron por máscara.

El *Normalized Burn Ratio* (NBR) es una diferencia normalizada entre el infrarrojo cercano y el infrarrojo de onda corta como se puede ver en la ecuación (6). El uso de estas bandas del espectro permite detectar cambios en la materia vegetal viva, en el contenido de humedad y en las condiciones del suelo (Miller y Thode, 2007). Por ello su uso se ha generalizado en la identificación y delimitación de áreas quemadas así como en la estimación de la severidad (Botella-Martínez y Fernández-Manso, 2017). En este caso se empleó para calcular para cada píxel de la imagen la diferencia del NBR al inicio y al final del período de incendios. Valores elevados del dNBR indican que se ha producido una perturbación.

$$NBR = \frac{NIR-SWIR}{NIR+SWIR} \quad (6)$$

$$dNBR = NBR_{PRE} - NBR_{POST} \quad (7)$$

4.2.2.2 Clasificación

El mapeo de zonas quemadas en el Concejo de Tineo durante los primeros meses del año 2020 se consiguió a partir de una clasificación a nivel de píxel, generada con el algoritmo *Random Forest* a partir de información espectral ofrecida por una imagen Sentinel 2 del día 4 de abril.

De las trece bandas del espectro electromagnético que captura el sensor MSI de los satélites Sentinel 2, se usaron nueve de ellas como variables independientes en la clasificación. Es decir, se extrajeron para cada parcela el valor de reflectancia las bandas espectrales del Azul, verde, rojo, borde rojo (tres bandas), infrarrojo cercano e infrarrojo de onda (dos bandas) asociada la imagen del 4 de abril de 2020 (Tabla 4.12. Bandas espectrales de la imagen Sentinel 2 MSI del 4 de abril de 2020 empeladas como variables en la base de referencia. Fuente: Elaboración propia.).

Tabla 4.12. Bandas espectrales de la imagen Sentinel 2 MSI del 4 de abril de 2020 empeladas como variables en la base de referencia. Fuente: Elaboración propia.

Espacio de entidades	Variables
Imagen del 4 de abril de 2020	Azul (B01), Verde (B02), Rojo(B03), Borde rojo (B05, B06, B07), NIR(B08), SWIR (B11 y B12)

4.2.2.3 Entrenamiento del modelo

El proceso de entrenamiento del algoritmo *Random Forest* y la clasificación se desarrolló al completo en la plataforma GEE, empleando la librería “*ee.Classifier*” implementada en la interfaz de programación de aplicaciones.

El primer paso consistió en dividir de forma aleatoria la base de datos de referencia en dos subconjuntos, un 30% se empleó en el entrenamiento y un 70% validación del modelo. Seguidamente, se entrenó un modelo *Random Forest* con 500 iteraciones, tomando como referencia un total 276 píxeles. Cabe destacar que es necesario fijar una semilla para el submuestreo que hace el algoritmo, ya que en caso contrario el resultado sería distinto tras cada ejecución.

Se trabajó con un total de nueve variables asociadas a la imagen Sentinel 2 MSI del día 4 de abril de 2020, en cada iteración el *Random Forest* selecciona de entre esas variables un subconjunto diferente. Finalmente, se decidió valorar la importancia de cada una de las variables en el modelo, en este caso no pudo calcularse el Decrecimiento Medio de Gini (MDG), pero recurriendo a la opción “*ee.Classifier.setOutputMode*”, se calculó la importancia de cada una de ellas en función de la probabilidad de que la clasificación final sea correcta (Google Developers, 2020).

4.2.2.4 Validación y ejecución del modelo

Una vez el modelo ha sido entrenado es necesario validarlo. Para ello se ejecutó el algoritmo sobre el subconjunto de validación (634 píxeles), y se comprobó el grado de acierto del clasificador tomando como referencia la clase asignada por fotointerpretación a cada punto de validación. Posteriormente se calcularon la matriz de confusión, la precisión global del modelo y sus intervalos de confianza por el método Wald ajustado para una probabilidad del 95 % (Sauro y Lewis, 2005).

El Sistema europeo de incendios forestales (EFFIS) emplea imágenes del satélite MODIS de 250 metros de resolución, para actualizar de forma diaria una cartografía de áreas quemadas del continente europeo y la región mediterránea (EFFIS, 2020). Desde el visor de la situación actual del EFFIS (https://effis.jrc.ec.europa.eu/static/effis_current_situation/public/index.html) se descargaron los perímetros de los incendios detectados durante el período de estudio (entre enero y abril de 2020).

La capa de áreas quemadas del EFFIS se empleó para comprobar si la clasificación generada a partir de las imágenes Sentinel 2 MSI detectaba los incendios registrados a partir de los datos MODIS. Teniendo en cuenta que la resolución espacial de los datos MODIS es de 250 m y que el error mínimo asociado una clasificación es de 2 píxeles x 2 píxeles (Tobler, 1987), se llevó a cabo ArcMAP (ESRI, 2019) un análisis de proximidad de 500 metros sobre cada uno de los incendios detectados por la módulo de análisis rápido del EFFIS, y así estimar el error de omisión de la clasificación generada en GEE.

5 RESULTADOS

5.1 Cartografía de cuatro tipos de combustibles en base a diferencias espectrales, empleando imágenes de satélite y software libre

5.1.1 Selección de variables

Con este análisis multitemporal orientado a objetos se clasificaron cuatro grandes grupos de combustible, empleando como datos de partida 112 variables independientes derivadas de las imágenes Sentinel 2 MSI.

La Figura 5.1. Variables más importantes en base al Decrecimiento Medio de Gini (MDG). Fuente: Elaboración propia. muestra las 22 variables con un mayor valor del índice de Decrecimiento Medio de Gini (*Mean Decrease Gini*, MDG). A nivel global las variables más importantes se correspondieron con los valores medios del índice NDVI del mes de mayo (M_M_NDVI), de los índices ARI y ARI II de los meses de mayo y septiembre (M_M_ARI, S_M_ARI, M_M_ARI_II y S_M_ARI_II). Seguidos por los valores medios de la banda verde del mes de mayo (M_M_B03), de las bandas roja y verde del mes de septiembre (S_M_B04 y S_M_B03), el valor medio del índice SAVI del mes de diciembre (D_M_SAVI) y el valor medio de la primera banda infrarrojo de onda corta del mes de mayo (M_M_B11). En general las variables derivadas de las imágenes de septiembre y mayo se identificaron como más relevantes, con la excepción del índice SAVI del mes de diciembre (novenno en la lista de variables).




Figura 5.1. Variables más importantes en base al Decrecimiento Medio de Gini (MDG). Fuente: Elaboración propia.

Por otro lado, la Figura 5.2. Variables más importantes a la hora de distinguir entre clases según el Decrecimiento Medio de Gini (MDG). Fuente: Elaboración propia. recoge las variables más importantes a la hora de identificar cada uno de los grandes grupos de combustibles. En los grupos de combustibles arbóreos (coníferas y frondosas) priman los variables derivadas de las imágenes de mayo y septiembre, con la presencia en menor medida de variables derivadas de las imágenes de junio. En el caso del matorral resultaron más relevantes las variables derivadas de las imágenes de septiembre y mayo, mientras que para el grupo herbazal la mayor importancia es para el índice SAVI de diciembre y variables de septiembre y mayo (DMG D_M_SAVI, S_M y M_M). En todos los casos el mayor poder discriminante se corresponde con índices de vegetación, no con bandas espectrales. Aunque como norma general muestran una mayor importancia las variables los valores medios de las variables, cabe destacar el peso de la desviación estándar del índice ARI II tanto en las frondosas como en el grupo de los matorrales (S_ST_ARI_II), lo que indica la utilidad de este estadístico para la discriminación entre ellas.

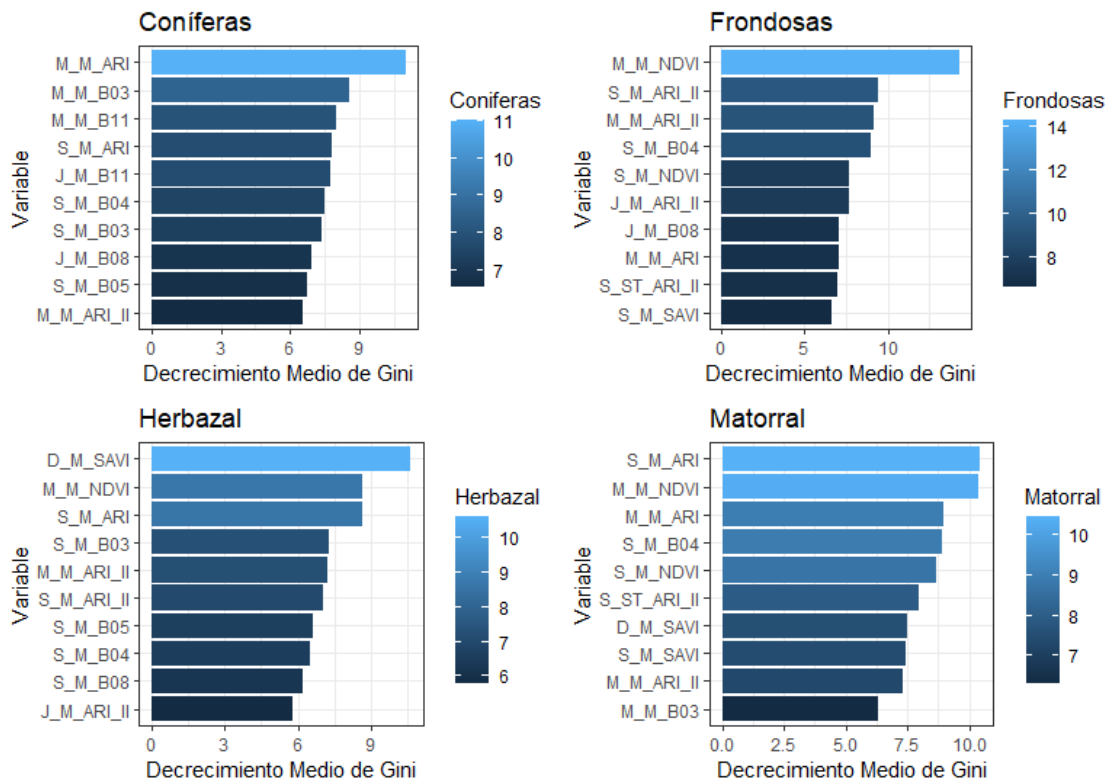


Figura 5.2. Variables más importantes a la hora de distinguir entre clases según el Decrecimiento Medio de Gini (MDG). Fuente: Elaboración propia.

5.1.2 Evaluación de la clasificación

Al trabajar con las imágenes de septiembre, diciembre, mayo y junio por separado, la exactitud global de la clasificación fue del 83,46 %, 68,5 %, 51,57 % y 52,76 % respectivamente (Tabla 5.1. Exactitud global de la clasificación de combustibles según el espacio de entidades empleado (valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad). Fuente: Elaboración propia.). Resultados que parecen coincidir con la importancia de las variables recogidas en el apartado anterior 5.1.1, en el que se observaba que las variables del mes de septiembre eran la que tenía un mayor peso. El empleo de la información espectral de las cuatro imágenes de forma conjunta permitió generar una clasificación con una exactitud global del 84,25% como se puede ver en la Tabla 5.1, al mejorar la discriminación entre clases gracias al uso de métricas recogidas en otros momentos del año, aunque teniendo en cuenta los intervalos de confianza, la diferencia en la exactitud global no es significativa. Sí se produce un incremento significativo de la exactitud global al reducir el número de variables del análisis multitemporal empleadas en el modelo a las 22 más importantes, obteniéndose una fiabilidad global del 87,01 %, lo que supone una mejora de casi 3 puntos porcentuales (Tabla 5.1. Exactitud global de la clasificación de combustibles según el espacio de entidades empleado (valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad). Fuente: Elaboración propia.).

Tabla 5.1. Exactitud global de la clasificación de combustibles según el espacio de entidades empleado (valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad). Fuente: Elaboración propia.

Espacio de entidades	VARIABLES EMPLEADAS	Exactitud global (%)
a	Media y desviación típica de las bandas Azul, Verde, Rojo, Borde Rojo, NIR, SWIR y los índices ARI, ARI II, NDII, NDVI y SAVI del mes de septiembre (28)	83,46 (78,78 - 87,55)
b	Media y desviación típica de las bandas Azul, Verde, Rojo, Borde Rojo, NIR, SWIR y los índices ARI, ARI II, NDII, NDVI y SAVI del mes de diciembre (28)	68,5 (62,55 - 73,91)
c	Media y desviación típica de las bandas Azul, Verde, Rojo, Borde Rojo, NIR, SWIR y los índices ARI, ARI II, NDII, NDVI y SAVI del mes de mayo (28)	51,57 (45,45 - 57,65)
d	Media y desviación típica de las bandas Azul, Verde, Rojo, Borde Rojo, NIR, SWIR y los índices ARI, ARI II, NDII, NDVI y SAVI del mes de junio (28)	52,76 (46,62 - 58,81)
e= (a +b+c+d)	Media y desviación típica de las bandas Azul, Verde, Rojo, Borde Rojo, NIR, SWIR y los índices ARI, ARI II, NDII,NDVI,y SAVI de todas las escenas (112)	84,25 (79,24 - 88,25)

Con el objetivo de evaluar los resultados de la clasificación final con 22 variables, se generó la matriz de confusión empleando los datos de referencia y las predicciones del algoritmo *Random Forest* (**¡Error! No se encuentra el origen de la referencia..2**). El valor más probable de exactitud del productor, del usuario y global aparece acompañado del intervalo de confianza de Wald ajustado al 95% de probabilidad.

El valor más probable de la exactitud global de la clasificación es de 87,01%, mientras que la exactitud del productor como la del usuario adquieren los valores más altos al identificar las clases de Coníferas y Frondosas, superando en ambos casos el 89 %. Por contra, los peores datos se asocian a la clase Herbazal en el caso de la exactitud del productor y a la clase infraestructuras en el caso de la exactitud del usuario, siendo el valor más probable 77,78 % y 73,33 % respectivamente. Esta diferencia entre la exactitud alcanzada al trabajar con los grupos de vegetación arbóreas (Coníferas y Frondosas) y de vegetación arbustiva (Herbazales y Matorrales) se debe principalmente a la estructura y distribución, siendo en los primero más extensa y homogénea, así como a la base de datos de referencia, donde se demuestra que los trabajos de campo son una fuente más fiable que las parcelas fotointerpretadas.

Por otro lado, las mayores tasas de confusión se producen al identificar la clase Herbazal. El modelo comete un error de omisión del 22,22 % (12,36 % – 36,45 %), siendo el principal causante de este error la similitud existente entre los pastizales incluidos en la clase herbazal, y algunas de las coberturas incluidas en la clase resto de coberturas, como pueden ser los prados de uso agrícola. Al diferenciar entre los estratos de matorral y de herbazal se comete un error de omisión del 15,19 % (3,10 % - 43,36%). Este error, aunque asumible debe reducirse en próximos trabajos ya que las áreas cubiertas por matorral son las que se ven principalmente afectadas en los incendios del Principado de Asturias.

Parece que el modelo encuentra dificultades al diferenciar entre las clases que no pertenecen a los cuatro grandes grupos de combustibles, es decir, la clase infraestructuras y resto de coberturas. Lo que puede deberse principalmente al grado de similitud espectral existente entre los roquedos con escasa vegetación (dentro de la clase resto de coberturas) y las zonas urbanas recogidas en la clase infraestructuras.

Tabla 5.2. Matriz de confusión de la clasificación de combustibles generada partir del análisis multitemporal, y valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad de la exactitud global, del productor y del usuario. Fuente: Elaboración propia.

	Referencia							Exactitud del usuario (%)	Error de comisión (%)	
	Coníferas	Fronosas	Herbazal	Infraestructuras	Matorral	Resto	Total			
Clasificación	Coníferas	43	1	0	0	1	0	45	95,00 (84,35 - 99,59)	5,00 (0,41 - 7,62)
	Fronosas	4	60	1	0	0	0	65	92,31 (82,82 - 97,05)	7,69 (2,95 - 17,16)
	Herbazal	0	0	35	0	7	1	43	81,40 (67,12 - 90,52)	18,60 (9,48 - 32,88)
	Infraestructuras	0	0	0	11	0	4	15	73,33 (47,62 - 89,54)	26,67 (10,46 - 52,38)
	Matorral	1	1	2	0	44	1	49	89,80 (77,81 - 96,00)	10,20 (4,00 - 22,19)
	Resto	0	0	7	2	0	28	37	75,68 (59,69 - 86,83)	24,32 (13,17 - 40,31)
	Total	48	62	45	13	52	34	254		5,00
	89,58	96,77	77,78	84,61	84,61	82,35				
Exactitud del productor (%)	(77,39 - 95,91)	(88,33 - 99,76)	(63,55 - 87,64)	(56,54 - 96,90)	(72,21 - 92,26)	(66,11 - 92,03)				
	10,42	3,23	22,22	15,39	15,19	17,65				
Error de omisión (%)	(4,09 - 22,61)	(0,25 - 12,03)	(12,36 - 36,45)	(3,10 - 43,36)	(7,74 - 27,79)	(7,97 - 33,89)				
								87,01		
							Exactitud global (%)	(82,28 - 90,63)		

Tras haber analizado los resultados obtenidos durante la validación del modelo, se generó la cartografía de grandes grupos de combustibles. Las figuras Figura 5.3. Recorte de 2 km x 2 km del mapa de cuatro grandes grupos de combustibles. Fuente: Elaboración propia. Figura 5.4 representan dos zonas de aproximadamente 2 km x 2 km representativas del concejo de Tineo, mientras que el mapa de todo el concejo se recoge en el Anexo 8: Cartografía de combustibles del concejo de Tineo (Asturias) . Además, se calcularon las superficies de cada una de las seis clases identificadas y recogieron en la Tabla 5.3 .

Tabla 5.3. Superficies de cada una de clases identificadas en el cartografiado de cuatro grandes grupos de combustibles. Fuente: Elaboración propia.

Clase	Superficie (ha)	Superficie total (%)
Frondosas	167,15	30,9
Matorral	132,25	24,45
Resto	106,44	19,68
Herbazal	79,75	14,75
Coníferas	48,77	9,02
Infraestructuras	6,46	1,2

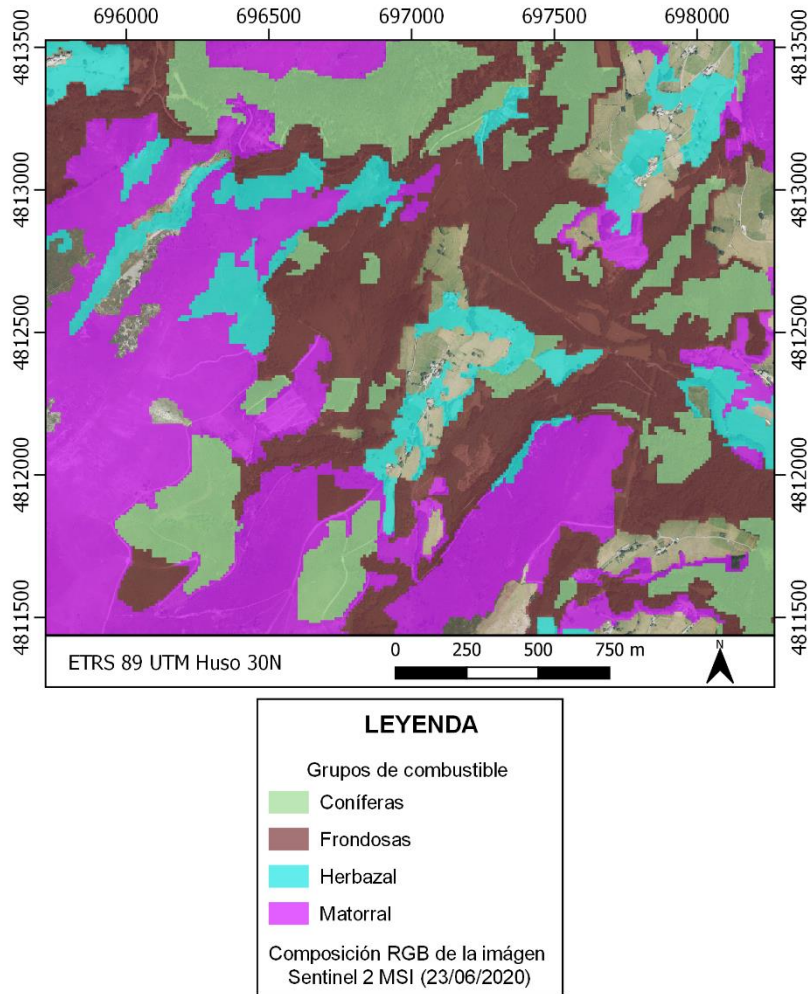


Figura 5.3. Recorte de 2 km x 2 km del mapa de cuatro grandes grupos de combustibles. Fuente: Elaboración propia.

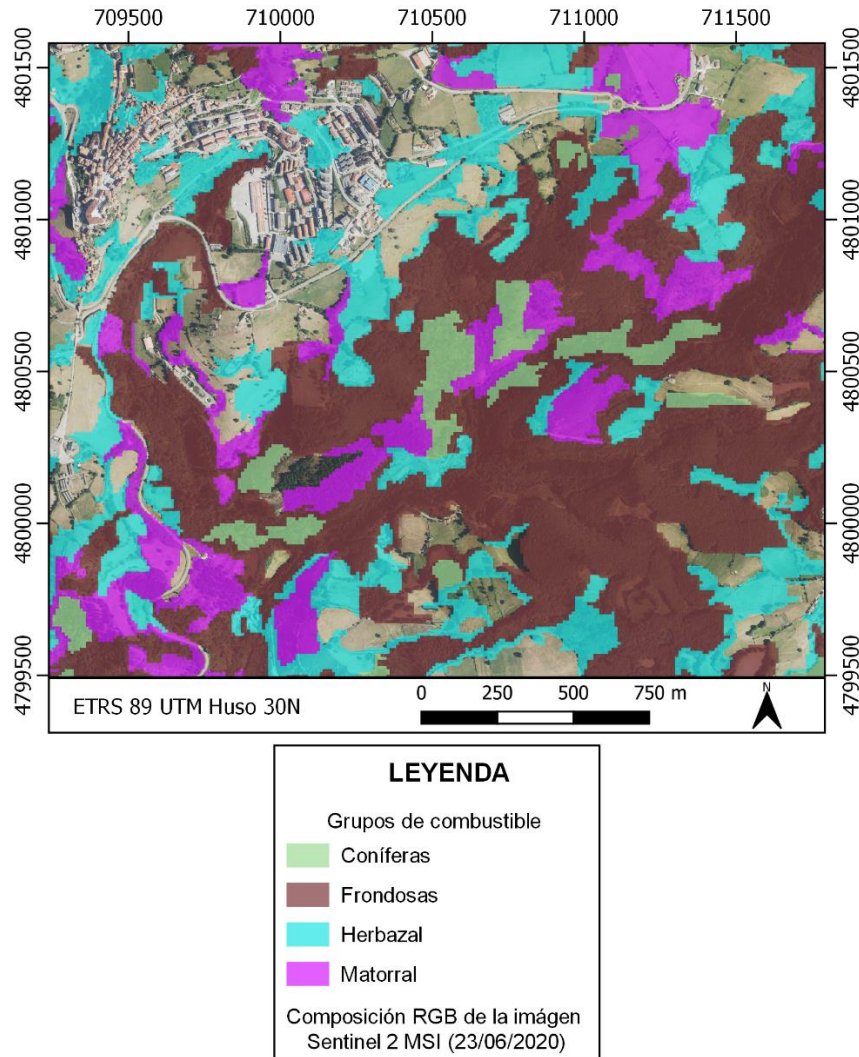


Figura 5.4. Recorte de 2 km x 2 km del mapa de cuatro grados grupos de combustibles. Fuente: Elaboración propia.

5.2 Cartografía de áreas quemadas a partir de un análisis multitemporal de imágenes satélite empleando una plataforma de procesamiento geoespacial

5.2.1 *Importancia de las variables*

Tras el entrenamiento del modelo empleando nueve variables (Tabla 5.4) con la información espectral de la imagen del día 4 de abril de 2020, la clasificación final alcanzó una exactitud global del 97,90% (Intervalo de confianza de Wald ajustado: 96,90 % - 99,07%).

Como se puede ver en la Figura 5.5. Importancia relativa de cada una de las bandas espectrales empleadas en la clasificación. Fuente: Elaboración propia. que representa la importancia de cada variable en función de la probabilidad de que al usar el resultado de clasificación sea correcto. Se puede observar que, de las nueve bandas espectrales empleadas, las más importantes coinciden con las bandas del borde rojo (B6 y B7), del infrarrojo cercano (B8) y con la segunda banda del infrarrojo de onda corta (B12). La importancia de estas bandas se debe a que sus niveles de reflectancia aumentan al reducirse la presencia de vegetación y el contenido humedad (Miller y Thode, 2007).

Tabla 5.4. Exactitud global de la clasificación de áreas quemadas (valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad). Fuente: Elaboración propia.

Espacio de entidades	Variables empleadas	Exactitud global (%)
Imagen del 4 de abril de 2020	Azul (B01), Verde (B02), Rojo(B03), Borde rojo (B05, B06, B07), NIR(B08), SWIR (B11 y B12)	97,90% (96,90 %-99,07%)




Figura 5.5.Importancia relativa de cada una de las bandas espectrales empleadas en la clasificación. Fuente:Elabotación propia.

5.2.2 Evaluación de la clasificación

Se evaluó la exactitud de la clasificación empleando para ello la matriz de confusión que se recoge en la Tabla 5.5, en la que las exactitudes vienen acompañadas por sus intervalos de confianza de Wald ajustado al 95% de probabilidad. Dicha tabla permite conocer la exactitud tanto del productor como del usuario que en ningún caso es inferior al 90,51 % (83,67 % - 94,77%). A pesar de estos niveles de exactitud, se comete un error de comisión del 2,56 % al predecir como zona quemada 11 píxeles que en realidad pertenecen a la clase zona no quemada. La clasificación, como se puede ver en la Tabla 5.5. Superficie afectada por algún incendio forestal en Tineo entre el día 1 de enero de 2020 y el 4 de abril de 2020. Fuente: Elaboración propia permitió estimar un área quemada de 814,54 ha durante los 3 primeros meses del año en el concejo de Tineo.

Tabla 5.5. Superficie afectada por algún incendio forestal en Tineo entre el día 1 de enero de 2020 y el 4 de abril de 2020. Fuente: Elaboración propia


Clase	Superficie (ha)
Quemado	814,54
No quemado	54165,46

Atendiendo a la capa de áreas quemadas ofrecida por el EFFIS, entre el día 1 de enero de 2020 y el día 4 de abril de 2020 fueron seis los incendios producidos en Tineo cuya superficie superó las 6,25 ha. Tras clasificar la totalidad de la escena se identificaron un total de 535 áreas quemadas, de las que 341 coinciden con el área de proximidad realizado sobre cada uno de los seis incendios detectados por el módulo de evaluación rápida de daños del EFFIS. Esto significa que no existe error de omisión asociado a la clasificación, pues todos los incendios identificados por EFFIS fueron detectados.

Una vez clasificada la totalidad de la imagen, la fotointerpretación permite analizar los cuatro escenarios posibles. El primero de ellos, es que ambas cartografías identifiquen un incendio (Figura 5.6. Incendios identificados en ambas clasificaciones. Fuente: Elaboración propia.). En el segundo escenario, debido a la diferencia entre la resolución espacial de los sensores MODIS y Sentinel 2 MSI, es posible que incendios con superficies inferiores a las 30 ha solo sean detectado con las imágenes Sentinel 2 (Figura 5.7). Por otro lado, las otras dos situaciones recogidas en las Figuras Figura 5.8 y Figura 5.9 suponen un error de comisión, es decir, se identifican como quemadas zonas en las que no se ha producido ningún incendio. La primera es debe a la perturbación producida por un incendio ocurrido en el año 2019, mientras que en la segunda se les asigna la categoría de áreas quemadas a varias parcelas agrícola en las que la cobertura vegetal ha sido eliminada (recolección) o bien reducida (siega). Además en el Anexo 9: Cartografía de áreas quemadas en el concejo de Tineo (Asturias) durante la temporada invernal de incendios se recoge el mapa de incendios identificados en todo el concejo de Tineo.

Tabla 5.6. Matriz de confusión de la clasificación de áreas quemadas, y valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad de la exactitud global, del productor y del usuario. Fuente: Elaboración propia.

	Referencia			Exactitud del usuario (%)	Error de comisión (%)
	Zona quemada	Zona no quemada	Total		
Clasificación	Zona quemada	522	11	533	97,34 (96,30 - 98,89)
	Zona no quemada	0	105	105	100 (96,98 - 100,00)
	Total	522	116	638	
		100	90,51		2,66 (1,11 - 3,70)
Exactitud del productor (%)	(99,38 - 100,00)	(83,67 - 94,77)			
Error de omisión (%)	0 (0,00 - 0,62)	9,49 (5,23 - 16,33)			
					98,28 (96,90 - 99,07)
				Exactitud global (%)	



LEYENDA




-  Perímetros delimitados
 -  Análisis de proximidad sobre los incendios MODIS
- Composición RGB imagen Sentinel 2 MSI (23/06/2020)

Figura 5.6. Incendios identificados en ambas clasificaciones. Fuente: Elaboración propia.



LEYENDA



-  Perímetros delimitados
- Composición RGB imagen Sentinel 2 MSI (23/06/2020)

Figura 5.7. Incendios identificados en clasificación y no en la capa de áreas quemadas del EFFIS. Fuente: Elaboración propia.



LEYENDA




-  Perímetros delimitados
 -  Incendio de Fontalba (2019)
- Composición RGB imagen Sentinel 2 MSI (23/06/2020)

Figura 5.8. Incendio erróneamente clasificado, pues ocurrió en el año 2019 no durante el período de análisis. Fuente: Elaboración propia.



LEYENDA


-  Perímetros delimitados
- Composición RGB imagen Sentinel 2 MSI (23/06/2020)

Figura 5.9. Parcelas agrícolas erróneamente identificadas como incendios durante la clasificación. Fuente: Elaboración propia.

5.3 Metodología para actualizar de forma semi-automática los mapas de combustibles generados por el CETEMAS en el año 2017, a escala municipal

Los resultados obtenidos en este trabajo que se recogen en los apartados 5.1 (cartografía de grupos de combustibles) y 5.2 (cartografía de áreas quemadas) demuestran que estos productos generados a partir del uso de imágenes Sentinel 2 MSI pueden ser parte de una metodología que permita actualizar de forma semi-automática cartografías ya existentes. El uso de datos de sensores pasivos como Sentinel 2 MSI permite generar información actualizada incluso semanalmente, siempre y cuando la cobertura de nubes lo permita.

Teniendo en cuenta alguno de los usos prácticos que se le puede llegar a dar a este tipo de cartografía en materia de prevención y extensión de incendios forestales, la identificación de grandes grupos (conífera, frondosa, matorral, pastizal), tiene gran importancia ya que se está priorizando que sea información actualizada para confirmar el tipo estructural de cobertura forestal y ser considerado junto con el resto de cartografía temática, para llevar a cabo un posible análisis de detección de cambios y reasignación del modelo de combustible o agrupación en su caso.

De esta manera, como se puede ver en la Figura 5.10, para el proceso de integración de estas capas cartográficas en la herramienta de actualización, será necesario llevar a cabo una intersección entre la cartografía de modelos de combustibles existente y los productos generados en el presente trabajo. Posteriormente se debe incorporar sobre la herramienta descrita por Sánchez García et al.(2019), una parte sobre el algoritmo condicional en lenguaje Python, que permita el desarrollo de un análisis de detección de cambios. Con ello, se podrá identificar y mantener el modelo de combustible designado anteriormente o reasignar el grupo en base a la reciente información recabada.

Siguiendo esta metodología se podrá disponer de una herramienta útil en las tareas de planificación y defensa contra incendios, que además estará actualizada y se ajustará a la realidad.

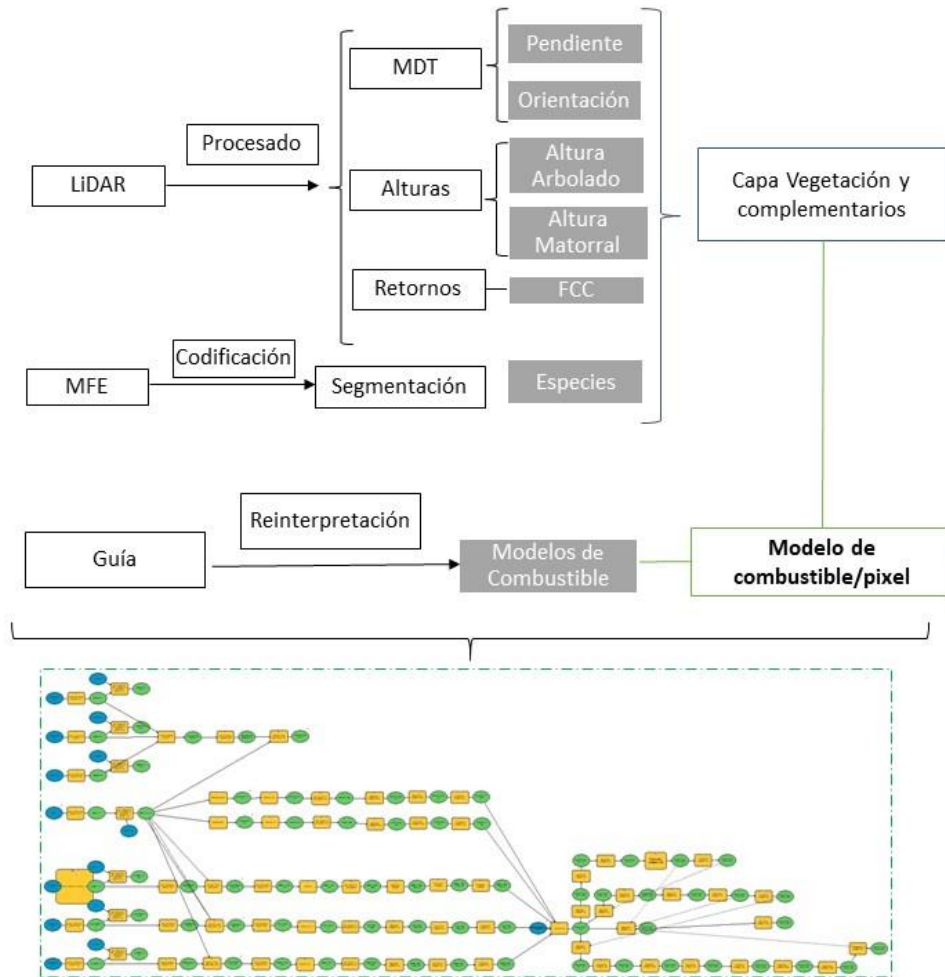
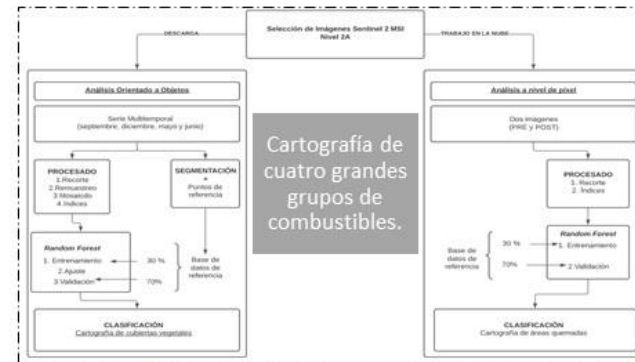


Figura 4.8. Flujo de procesos seguido en la clasificación de imágenes Sentinel2 MSI planteando un OBIA



Modelo de combustible/pixel ACTUALIZADO

Figura 4.11. Flujo de procesos seguido para la generación de una cartografía áreas quemadas en Tineo (2020).

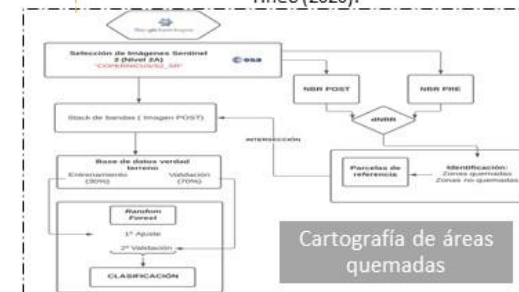


Figura 5.10. Esquema de integración entre los distintos flujos de trabajo y la generación de las distintas capas cartográficas. Fuente: Elaboración propia

6 DISCUSIÓN

6.1 Cartografía de cuatro tipos de combustibles en base a diferencias espectrales, empleando imágenes de satélite y software libre

Uno de los principales objetivos de este trabajo fue plantear una clasificación orientada a objetos con el algoritmo *Random Forest* a partir de una serie multitemporal de imágenes Sentinel 2. Como se demuestra con la Tabla 5.1. Exactitud global de la clasificación de combustibles según el espacio de entidades empleado (valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad). Fuente: Elaboración propia., el uso de información espectral asociada a diferentes etapas fenológicas permite mejorar la discriminación entre las coberturas vegetales (Gómez *et al.*, 2016; Zeng *et al.*, 2020).

Con el mismo objetivo y utilizando el algoritmo *Random Forest* para identificar tipos de vegetación asociados a grandes grupos de combustibles, Marino *et al.* (2016) recurren al uso de imágenes Landsat 8 y finalmente obtienen una exactitud global del 81%. En este trabajo empleando el mismo algoritmo se obtuvo una clasificación con una exactitud global asociada del 87.01 %. Immitzer *et al.* (2019) aunque no con el mismo objetivo, plantean un OBIA en el que tras la segmentación de la imagen con el algoritmo *Random Forest* logran al igual que en este trabajo identificar seis tipos de coberturas del suelo, pero con una exactitud del 96,2 %. Estos resultados demuestran que tanto el planteamiento de los OBIA sobre una serie multitemporal de imágenes multiespectrales de alta resolución espacial tiene capacidad suficiente permiten generar clasificaciones fiables.

Analizando las diferentes variables empleadas en el ajuste y entrenamiento del algoritmo clasificador (Figura 5.1 y Figura 5.2), se coincide con Immitzer *et al.* (2019) en que las bandas espectrales del rojo, infrarrojo cercano e infrarrojo de onda corta son las más relevantes. Además, cada destacar la importancia del infrarrojo cercano al distinguir entre las clases de coníferas y frondosas. En el caso de los índices de espectrales, parece que combinar varias bandas del espectro electromagnético realmente facilita la diferencia entre clases de cobertura (Zeng *et al.*, 2020). El SAVI incluido en el análisis al ser menos sensible que el NDVI al ruido provocado por la mezcla de firmas espectrales (Marino *et al.*, 2016), parece tomar cierta importancia en la clasificación tanto a nivel global como a nivel de clase. Por otro lado el índice ARI basado en las bandas del borde rojo, elegido con el objetivo de facilitar la identificación de los estratos de matorral (Bayle *et al.*, 2019), ha cumplido sobre todo al diferencia matorral de masas de frondosas.

Teniendo en cuentas estas indicaciones y en base a los resultados asociados la clasificación final (Tabla 5.2. Matriz de confusión de la clasificación de combustibles generada partir del análisis multitemporal, y valor más probable e intervalo de confianza de Wald ajustado al 95 % de probabilidad de la exactitud global, del productor y del usuario. Fuente: Elaboración propia.) se puede confirmar el

potencial del uso de imágenes Sentinel 2 MSI para desarrollar un análisis multitemporal que permita generar una cartografía de combustibles fiable a nivel local, y por tanto puede emplearse en cartografías ya existentes. Aunque sin olvidar las limitaciones a la hora de diferenciar entre las clases más estratificadas y heterogéneas (Herbazal y Matorral). Para resolver estos problemas se debería disponer de una red de parcelas de campo más densa y representativa, que reduzca el error asociado a las tareas de fotointerpretación.

A lo largo de este trabajo se ha combinado tanto softwares comerciales como libres. El procesamiento de las imágenes Sentinel 2 MSI se llevó a cabo en el software libre RStudio (RStudio Team, 2020), a partir del diseño de un script (Anexo 2: Script en diseñado en RStudio para el procesado de las imágenes Sentinel 2) se puede reproducir el flujo de trabajo con cada una de las cuatro escenas empeladas en el análisis. En el caso de la segmentación, fue necesario recurrir al software eCognition Essentials (Trimble, Inc, 2016), para poder trabajar con el algoritmo *Multiresolution Segmentation*, cuyo resultados no se pueden alcanzar con otros softwares libres. A la hora extraer los estadísticos espectrales tras comenzar a trabajar en RStudio, la cantidad de tiempo de procesado empelado sin resultados obligó a utilizar el software comercial ArcMap (ESRI, 2019). Finalmente, los paquetes de análisis estadístico (“randomForest” y “Caret”) implementados en RStudio permitieron usar el modelo no paramétrico *Random Forest* para generar la clasificación final. Coincidiendo con Bivand *et al.*, (2008) y Pebesma *et al.* (2012) se puede afirmar el potencial del software libre al permitir crear flujo de procesos reproducibles, reducir los tiempos de procesado en alguna tareas y la fácil exportación de los resultados, aunque en este caso se confirma la necesidad de combinar diferentes softwares para obtener buenos resultados.

6.2 Cartografía de áreas quemadas a partir de un análisis multitemporal de imágenes satélite empleando una plataforma de procesamiento geoespacial

Respecto al mapa de zonas quemadas durante los primeros tres meses del año 2020, realizada en la plataforma Google Earth Engine (GEE) mediante a una clasificación a nivel de píxel con el algoritmo *Random Forest* sobre una imagen Sentinel 2, también Anaya *et al.* (2018) recurren a GEE para identificar zonas quemadas a partir de imágenes Landsat 5 y 8, basándose en umbrales del índice dNBR para la clasificación. Aunque se siguen metodologías distintas ambos trabajos confirman la funcionalidad de GEE, que al disponer de amplias colecciones de imágenes satélite y al permitir el acceso a diferentes algoritmos mediante a la interfaz de programación de aplicaciones permiten el desarrollo de este tipo de análisis (Gorelick *et al.*, 2017).

La clasificación de zonas quemadas y no quemadas obtenida presenta una exactitud global del 98,28 %, superior a las recogidas en el trabajo de Ngadze *et al.* (2020) que alcanzan valores del 86 % y 89 % empleando también el algoritmo *Random Forest* para clasificar a partir de imágenes Sentinel 2 MSI. Además, si se atiende a la importancia de cada una de las bandas del espectro electromagnético

(**Error! No se encuentra el origen de la referencia.**), ambos trabajos coinciden en que las bandas 2 y 3 del borde rojo y la banda del infrarrojo cercano son clave en la identificación de las zonas quemadas. Huang *et al.* (2016) usan los datos del sensor MSI y también destacan la importancia de las bandas del borde rojo, del infrarrojo cercano y del infrarrojo de onda corta con las que obtienen una exactitud global superior al 80 %, frente a las bandas del espectro visible que apenas tienen peso en la discriminación. Los resultados que se obtenidos en los tres trabajos confirman las capacidades de uso de las imágenes Sentinel 2 MSI en la identificación de áreas quemadas.

Por otro lado, si se comparan los resultados con la cartografía de áreas quemadas elaborada por el EFFIS a partir de imágenes MODIS, se puede afirmar que ambos productos son fiables a la hora de localizar zonas en la que se ha producido un incendio. El módulo de análisis rápido de daños del EFFIS condicionado por la resolución espacial de 250 metros de las imágenes MODIS sólo detecta incendios superiores a la 6,2 ha, y difícilmente los de menos de 30 ha. En cualquier caso, la cartografía recogida por el EFFIS logra identificar entre el 70 y 80 % de todos los incendios producidos en el marco europeo (EFFIS, 2020). Trabajar con imágenes de alta resolución espacial como las Sentinel 2 (10 – 20 m/píxel) permite delimitar de forma más precisa el perímetro de los incendios, y con ello obtener valores de superficies quemadas más ajustados a la realidad.

Tras el análisis de los resultados de la validación de la clasificación (Tabla 5.6) se puede afirmar que las imágenes Sentinel 2 MSI son una herramienta útil y fiable para usar en la identificación y delimitación de áreas quemadas a escala local. La principal limitación de este producto, el error de comisión asociado al identificar como incendios zonas agrícolas (prados recién segados y tierras sin cobertura tras la recolección) e incendios de años pasado. Este último error se podría minimizar haciendo un análisis multitemporal que incluya en una imagen correspondiente con el inicio del periodo de estudio.

Aunque el uso de la plataforma Google Earth Engine supuso la posibilidad de trabajar en la nube, reduciendo de forma notable las tareas derivadas de la descarga y el procesado y almacenamiento de las imágenes satélite (Tamimnia *et al.*, 2020), no fue posible utilizar los segmentos generados en eCognition Essentials, ya que, debido al tamaño de la capa GEE no permitió usarla y por tanto no se pudo desarrollar un OBIA. A pesar de ello, se puede afirmar que gracias a la amplia colección de datos y algoritmos disponibles es posible llevar a cabo clasificaciones a nivel de píxel fiables y de forma rápida, siempre y cuando los conjuntos de datos que se usen no sean demasiado grandes.

6.3 Metodología para actualizar de forma semi-automática los mapas de combustibles generados por el CETEMAS en el año 2017, a escala municipal

En base a los resultados obtenidos en este trabajo, se puede afirmar que es posible plantear una metodología orientada a actualizar al menos de forma anual la cartografía de combustibles existente a escala municipal en Asturias. De esta forma se reducirían las limitaciones que supone depender la una

publicación periódica como la del Mapa Forestal Nacional y la de los datos del PNOA-LIDAR para llevar a cabo una actualización.

7 CONCLUSIONES Y FUTURAS LÍNEAS DE TRABAJO

7.1 Conclusiones

A continuación, se detallan las conclusiones obtenidas en este trabajo:

7.1.1 *Cartografía de cuatro tipos de combustibles en base a diferencias espectrales, empleando imágenes de satélite y software libre*

Los resultados asociados a la clasificación de cuatro grupos de combustible demuestran, la capacidad del análisis orientado a objetos al plantear una clasificación de coberturas, además de la funcionalidad de las imágenes Sentinel 2 MSI para crear colecciones multitemporales que permiten emplear las variaciones espectrales que los cambios fenológicos producen en las coberturas para su mejor identificación. Dadas las exactitudes alcanzadas, se pudo confirmar que se obtienen mejores resultados al trabajar con masas homogéneas y extensas, y que ante clases fragmentadas y con una mayor mezcla espectral se debe aumentar el tamaño de la base de datos de referencia

Por otro lado, la posibilidad de poder usar los paquetes de análisis estadístico y espacial desarrollados por la *Comprehensive R Archive Network* (CRAN), ha permitido desarrollar parte del proceso en RStudio. El uso de dicho software libre, supone una oportunidad a la hora de diseñar scripts reproducibles en el procesado de imágenes satélite, sobre todo a la hora de trabajar con algoritmos de clasificación, debido principalmente a los numerosos algoritmos disponibles y al eficiente manejo de las bases de datos en dicho entorno.

7.1.2 *Cartografía de áreas quemadas a partir de un análisis multitemporal de imágenes satélite empleando una plataforma de procesamiento geoespacial*

Este trabajo permite confirmar la utilidad de las imágenes satélite Sentinel 2 MSI para identificar y delimitar áreas quemadas. En los resultados obtenidos se observa el llamado efecto “sal y pimienta”, la principal limitación de los análisis a nivel de píxel en comparación con los OBIA. Se ha demostrado que la plataforma GEE es una gran fuente de datos gracias a su amplio catálogo de colecciones, y que, a pesar de los diferentes herramientas y algoritmo disponibles en la interfaz de programación de aplicaciones, su uso en el análisis geoespacial está limitado si es necesario importar conjuntos de datos desde fuera de la plataforma.

7.1.3 *Metodología para actualizar de forma semi-automática los mapas de combustibles generados por el CETEMAS en el año 2017, a escala municipal*

La cartografía generada a partir de datos satélite espectrales de libre acceso con una alta resolución espacial (10 m/píxel) y temporal (5 días), demuestra que es posible diseñar una metodología orientada a la actualización semi-automática de los mapas de combustible existentes. Debido a que el uso de los sensores espectrales no permite identificar todos los modelos de combustible presentes en la cartografía actual, se debe plantear un análisis de detección de cambios a nivel de grupos de combustible

para llevar a cabo la actualización. Esta metodología reduce el problema que supone depender de la publicación periódica de datos como el Mapa Forestal Español y los datos del PNOA-LIDAR y permite ajustar a la realidad las herramientas existentes en la gestión y defensa frente a los incendios forestales.

7.2 **Futuras líneas de trabajo**

A continuación, se resaltan algunos aspectos que se podrían tener en cuenta para mejorar y dar una posible continuidad a este trabajo:

- Se debería llevar a cabo la actualización del mapa de combustibles para el concejo de Tineo, así como su análisis detallado y evaluación respecto a otras experiencias y puntos de vista para su posible uso práctico.
- Se debería analizar la posibilidad de disponer de una red de parcelas de campo más densa, sobre todo para algunas clases concretas, en la que se trabajase de forma cíclica, de modo que se pueda disponer una mayor base de datos de referencia y que, además reduzca el error asociado a la fotointerpretación.
- Sería recomendable generar la cartografía de áreas quemadas siguiendo un análisis orientado a objetos, que permita comparar los resultados obtenidos con el análisis a nivel píxel desarrollado en la plataforma GEE. De esta manera, comprobar la robustez de los resultados obtenidos, y que pueda ratificarse su utilidad y eficiencia.

8 BIBLIOGRAFÍA

Alonso-Benito, A., Arroyo, L., Arbelo, M. and Hernández-Leal, P. (2016) "Fusion of WorldView-2 and LiDAR Data to Map Fuel Types in the Canary Islands", *Remote Sensing*, 8(8), p. 669. doi:10.3390/rs8080669.

Anaya, J. A., Sione, W. F. and Rodríguez-Montellano, A. M. (2018) "Identificación de áreas quemadas mediante el análisis de series de tiempo en el ámbito de computación en la nube", *Revista de Teledetección*, (51), p. 61. doi:10.4995/raet.2018.8618.

Arellano, S., Vega, J. A., Ruíz, A. D., Arellano, A., Álvarez, J. G., Vega, D. J. and Pérez, E. (2017) *Foto-guía de combustibles forestales de Galicia y comportamiento del fuego asociado*. Santiago de Compostela: Andavira.

Arroyo, L. A., Healey, S. P., Cohen, W. B., Cocero, D. and Manzanera, J. A. (2006) "Using object-oriented classification and high-resolution imagery to map fuel types in a Mediterranean region: LOCAL-SCALE FUEL MAP", *Journal of Geophysical Research: Biogeosciences*, 111(G4). doi:10.1029/2005JG000120.

Arroyo, L. A., Pascual, C. and Manzanera, J. A. (2008) "Fire models and methods to map fuel types: The role of remote sensing", *Forest Ecology and Management*, 256(6), pp. 1239–1252. doi:10.1016/j.foreco.2008.06.048.

Bayle, A., Carlson, B., Thierion, V., Isenmann, M. and Choler, P. (2019) "Improved Mapping of Mountain Shrublands Using the Sentinel-2 Red-Edge Band", *Remote Sensing*, 11(23), p. 2807. doi:10.3390/rs11232807.

Belgiu, M. and Drăguț, L. (2016) "Random forest in remote sensing: A review of applications and future directions", *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, pp. 24–31. doi:10.1016/j.isprsjprs.2016.01.011.

Bivand, R., Pebesma, E. and Gómez-Rubio, V. (2008) *Applied Spatial Data Analysis with R*. New York, NY: Springer New York. doi:10.1007/978-0-387-78171-6.

Blaschke, T. (2010) "Object based image analysis for remote sensing", *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), pp. 2–16. doi:10.1016/j.isprsjprs.2009.06.004.

Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Queiroz Feitosa, R., van der Meer, F., van der Werff, H., van Coillie, F. and Tiede, D. (2014) "Geographic Object-Based Image Analysis – Towards a new paradigm", *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, pp. 180–191. doi:10.1016/j.isprsjprs.2013.09.014.

- Botella-Martínez, M. A. and Fernández-Manso, A. (2017) "Estudio de la severidad post-incendio en la Comunidad Valenciana comparando los índices dNBR, RdNBR y RBR a partir de imágenes Landsat 8", *Revista de Teledetección*, (49), p. 33. doi:10.4995/raet.2017.7095.
- Breiman, L. (2001) "Random Forests", *Machine Learning*, 45(1), pp. 5–32. doi:10.1023/A:1010933404324.
- Chuvieco, E. and Kasischke, E. S. (2007) "Remote sensing information for fire management and fire effects assessment", *Journal of Geophysical Research*, 112(G1), p. G01S90. doi:10.1029/2006JG000230.
- DGDRPF (2012) *Principado de Asturias. Cuarto Inventario Forestal Nacional*. Madrid: Ministerio de Agricultura, Alimentación y Medio Ambiente.
- Drăguț, L., Tiede, D. and Levick, S. R. (2010) "ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data", *International Journal of Geographical Information Science*, 24(6), pp. 859–871. doi:10.1080/13658810903174803.
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F. and Bargellini, P. (2012) "Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services", *Remote Sensing of Environment*, 120, pp. 25–36. doi:10.1016/j.rse.2011.11.026.
- EFFIS (2020) "User Guide to EFFIS applications". Available at: https://effis.jrc.ec.europa.eu/static/effis_current_situation/public/static/userguides/userguide.pdf.
- ESRI (2000) *ModelBuilder for ArcView Spatial Analyst 2*. California,US: Environmental Systems Research Institute.
- ESRI (2019) *ArcMap 10.7.1*. Redlands, CA: Environmental Systems Research Institute. Available at: <https://support.esri.com/es/products/desktop/arcgis-desktop/arcmap/10-7>.
- Fassnacht, F. E., Latifi, H., Stereńczak, K., Modzelewska, A., Lefsky, M., Waser, L. T., Straub, C. and Ghosh, A. (2016) "Review of studies on tree species classification from remotely sensed data", *Remote Sensing of Environment*, 186, pp. 64–87. doi:10.1016/j.rse.2016.08.013.
- Foody, G. M. (2009) "Classification accuracy comparison: Hypothesis tests and the use of confidence intervals in evaluations of difference, equivalence and non-inferiority", *Remote Sensing of Environment*, 113(8), pp. 1658–1663. doi:10.1016/j.rse.2009.03.014.
- Foody, G. M. (2020) "Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification", *Remote Sensing of Environment*, 239, p. 111630. doi:10.1016/j.rse.2019.111630.

- García, M., Riaño, D., Chuvieco, E., Salas, J. and Danson, F. M. (2011) "Multispectral and LiDAR data fusion for fuel type mapping using Support Vector Machine and decision rules", *Remote Sensing of Environment*, 115(6), pp. 1369–1379. doi:10.1016/j.rse.2011.01.017.
- Gobierno del Principado de Asturias (2020) *Estrategia integral de prevención y lucha contra los incendios forestales en Asturias (2020-2025)*. Asturias: Gobierno del Principado de Asturias.
- Gómez, C., Alejandro, P., Hermosilla, T., Montes, F., Pascual, C., Ruiz, L. A., Álvarez-Taboada, F., Tanase, M. and Valbuena, R. (2019) "Remote sensing for the Spanish forests in the 21st century: a review of advances, needs, and opportunities", *Forest Systems*, 28(1), p. eR001. doi:10.5424/fs/2019281-14221.
- Gómez, C., White, J. C. and Wulder, M. A. (2016) "Optical remotely sensed time series data for land cover classification: A review", *ISPRS Journal of Photogrammetry and Remote Sensing*, 116, pp. 55–72. doi:10.1016/j.isprsjprs.2016.03.008.
- Google Developers (2020) "Google Earth Engine Developers Guide".
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D. and Moore, R. (2017) "Google Earth Engine: Planetary-scale geospatial analysis for everyone", *Remote Sensing of Environment*, 202, pp. 18–27. doi:10.1016/j.rse.2017.06.031.
- Halofsky, J. E., Peterson, D. L. and Harvey, B. J. (2020) "Changing wildfire, changing forests: the effects of climate change on fire regimes and vegetation in the Pacific Northwest, USA", *Fire Ecology*, 16(1), p. 4. doi:10.1186/s42408-019-0062-8.
- Hennessy, A., Clarke, K. and Lewis, M. (2020) "Hyperspectral Classification of Plants: A Review of Waveband Selection Generalisability", *Remote Sensing*, 12(1), p. 113. doi:10.3390/rs12010113.
- Hościło, A. and Lewandowska, A. (2019) "Mapping Forest Type and Tree Species on a Regional Scale Using Multi-Temporal Sentinel-2 Data", *Remote Sensing*, 11(8), p. 929. doi:10.3390/rs11080929.
- Hossain, M. D. and Chen, D. (2019) "Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective", *ISPRS Journal of Photogrammetry and Remote Sensing*, 150, pp. 115–134. doi:10.1016/j.isprsjprs.2019.02.009.
- Huang, H., Roy, D., Boschetti, L., Zhang, H., Yan, L., Kumar, S., Gomez-Dans, J. and Li, J. (2016) "Separability Analysis of Sentinel-2A Multi-Spectral Instrument (MSI) Data for Burned Area Discrimination", *Remote Sensing*, 8(10), p. 873. doi:10.3390/rs8100873.
- Immitzer, M., Neuwirth, M., Böck, S., Brenner, H., Vuolo, F. and Atzberger, C. (2019) "Optimal Input Features for Tree Species Classification in Central Europe Based on Multi-Temporal Sentinel-2 Data", *Remote Sensing*, 11(22), p. 2599. doi:10.3390/rs11222599.

- Janssen, L. L. F. and Bakker, W. H. (2004) "Chapter 3: Sensors and platforms", in *Principles of Remote Sensing*. Enschede, The Netherlands: The International Institute for Geo-Information Science and Earth Observation (ITC), pp. 43–57.
- Key, C. H. and Benson, N. C. (2006) "Landscape Assessment (LA)", p. 56.
- Kucharczyk, M., Hay, G. J., Ghaffarian, S. and Hugenholtz, C. H. (2020) "Geographic Object-Based Image Analysis: A Primer and Future Directions", *Remote Sensing*. Multidisciplinary Digital Publishing Institute, 12(12), p. 2012. doi:10.3390/rs12122012.
- Labrador García, M., Évora Brondo, J. A. and Arbleo Pérez, M. (2012) *Satélites de Teledetección para la Gestión del Territorio*. Canarias (España): Consejería de Agricultura, Ganadería, Pesca y Aguas. Gobierno de Canarias, p. 66.
- Lausch, A., Erasmi, S., King, D., Magdon, P. and Heurich, M. (2016) "Understanding Forest Health with Remote Sensing -Part I—A Review of Spectral Traits, Processes and Remote-Sensing Characteristics", *Remote Sensing*, 8(12), p. 1029. doi:10.3390/rs8121029.
- Leblon, B., Bourgeau-Chavez, L. and San-Miguel-Ayanz, J. (2012) "Use of Remote Sensing in Wildfire Management", in Curkovic, S. (ed.) *Sustainable Development - Authoritative and Leading Edge Content for Environmental Management*. InTech. doi:10.5772/45829.
- Lechner, A. M., Foody, G. M. and Boyd, D. S. (2020) "Applications in Remote Sensing to Forest Ecology and Management", *One Earth*, 2(5), pp. 405–412. doi:10.1016/j.oneear.2020.05.001.
- Liang, S., Li, X. and Wang, J. (eds) (2012) "Chapter 1 - A Systematic View of Remote Sensing", in *Advanced Remote Sensing*. Boston: Academic Press, pp. 1–31. doi:10.1016/B978-0-12-385954-9.00001-0.
- Liaw, A. and Wiener, M. (2002) "Classification and Regression by randomForest", 2, p. 6.
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P. and Liu, Y. (2017) "A review of supervised object-based land-cover image classification", *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, pp. 277–293. doi:10.1016/j.isprsjprs.2017.06.001.
- Marino, E., Ranz, P., Tomé, J. L., Noriega, M. Á., Esteban, J. and Madrigal, J. (2016) "Generation of high-resolution fuel model maps from discrete airborne laser scanner and Landsat-8 OLI: A low-cost and highly updated methodology for large areas", *Remote Sensing of Environment*, 187, pp. 267–280. doi:10.1016/j.rse.2016.10.020.
- Menze, B. H., Kelm, B. M., Masuch, R., Himmelreich, U., Bachert, P., Petrich, W. and Hamprecht, F. A. (2009) "A comparison of random forest and its Gini importance with standard chemometric methods for the feature selection and classification of spectral data", *BMC Bioinformatics*, 10(1), p. 213. doi:10.1186/1471-2105-10-213.

Miller, J. D. and Thode, A. E. (2007) "Quantifying burn severity in a heterogeneous landscape with a relative version of the delta Normalized Burn Ratio (dNBR)", *Remote Sensing of Environment*, 109(1), pp. 66–80. doi:10.1016/j.rse.2006.12.006.

Ministerio de Agricultura, Pesca y Alimentación (2019) *Decenio 2006-2015. Los Incendios Forestales en España*.

Ministerio para la Transición Ecológica y Reto Demográfico (2020) *Los Incendios Forestales en España. Avance informático del 2020*. Madrid: Ministerio para la Transición Ecológica y Reto Demográfico, p. 4.

Molina, J. R., González-Cabán, A. and Rodríguez y Silva, F. (2019) "Potential Effects of Climate Change on Fire Behavior, Economic Susceptibility and Suppression Costs in Mediterranean Ecosystems: Córdoba Province, Spain", *Forests*, 10(8), p. 679. doi:10.3390/f10080679.

Ngadze, F., Mpakairi, K. S., Kavhu, B., Ndaimani, H. and Maremba, M. S. (2020) "Exploring the utility of Sentinel-2 MSI and Landsat 8 OLI in burned area mapping for a heterogeneous savannah landscape", *PLOS ONE*. Edited by A. Chemura, 15(5), p. e0232962. doi:10.1371/journal.pone.0232962.

Pebesma, E., Nüst, D. and Bivand, R. (2012) "The R software environment in reproducible geoscientific research", *Eos, Transactions American Geophysical Union*, 93(16), pp. 163–163. doi:10.1029/2012EO160003.

RStudio Team (2020) *RStudio: Integrated Development for R*. Boston, MA: RSTUDIO,PBC. Available at: <https://rstudio.com/>.

Sánchez García, S. S., García González, M., Velasco Moreno, A. and Canga Lábano, E. (2019) "Generación cartografía de modelos combustibles a partir de datos LiDAR: herramienta flexible, actualizable y escalable", *TRESEME44*, June, p. 4. Available at: https://www.researchgate.net/publication/334784261_Generacion_de_cartografia_de_modelos_de_combustible_a_partir_de_datos_LiDAR_herramienta_flexible_actualizable_y_escalable_Revista_TRESEME44.

Sauro, J. and Lewis, J. (2005) "Estimating Completion Rates from Small Samples Using Binomial Confidence Intervals: Comparisons and Recommendations", *PROCEEDINGS of the HUMAN FACTORS AND ERGONOMICS SOCIETY 49th ANNUAL MEETING*—, pp. 2100–2104.

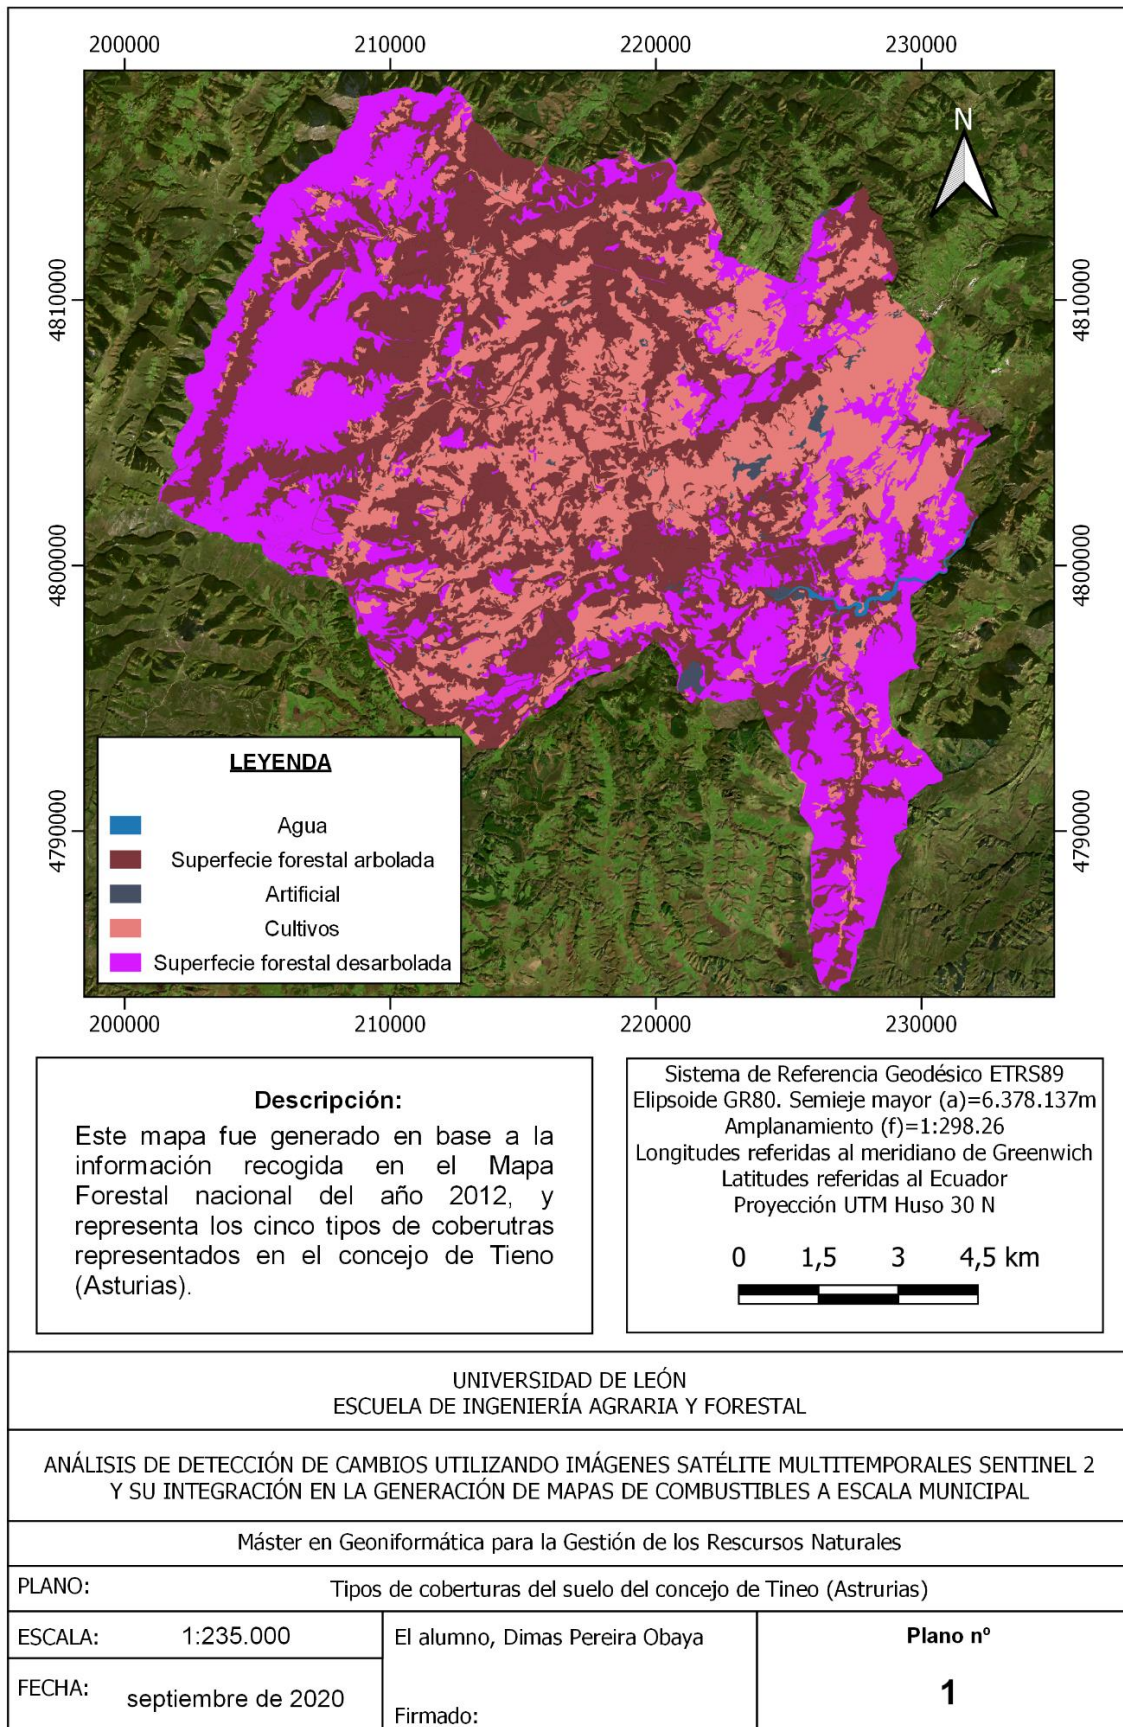
Stoffels, J., Hill, J., Sachtler, T., Mader, S., Buddenbaum, H., Stern, O., Langshausen, J., Dietz, J. and Ontrup, G. (2015) "Satellite-Based Derivation of High-Resolution Forest Information Layers for Operational Forest Management", *Forests*, 6(12), pp. 1982–2013. doi:10.3390/f6061982.

Szapkowski, D. and Jensen, J. (2019) "A Review of the Applications of Remote Sensing in Fire Ecology", *Remote Sensing*, 11(22), p. 2638. doi:10.3390/rs11222638.

- Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S. and Brisco, B. (2020) "Google Earth Engine for geo-big data applications: A meta-analysis and systematic review", *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, pp. 152–170. doi:10.1016/j.isprsjprs.2020.04.001.
- Tempfli, K., Huurneman, G. C., Bakker, W. H., Janssen, L. L. F., Feringa, W. F., Gieske, A. S. M., Grabmaier, K. A., Hecker, C. A. and Horn, J. A. van der (2009) *Principles of remote sensing: an introductory textbook*. Enschede: ITC.
- Tobler, W. (1987) "Measuring spatial resolution", *Proceedings, Land Resources Information Systems Conference*, pp. 12–16.
- Trimble, Inc (2016) *Trimble eCognition Essentials*. California, US: Trimble Inc. Available at: <https://geospatial.trimble.com/products-and-solutions/ecognition-essentials>.
- Wessel, M., Brandmeier, M. and Tiede, D. (2018) "Evaluation of Different Machine Learning Algorithms for Scalable Classification of Tree Types and Tree Species Based on Sentinel-2 Data", *Remote Sensing*, 10(9), p. 1419. doi:10.3390/rs10091419.
- White, J. C., Coops, N. C., Wulder, M. A., Vastaranta, M., Hilker, T. and Tompalski, P. (2016) "Remote Sensing Technologies for Enhancing Forest Inventories: A Review", *Canadian Journal of Remote Sensing*, 42(5), pp. 619–641. doi:10.1080/07038992.2016.1207484.
- Zeng, L., Wardlow, B. D., Xiang, D., Hu, S. and Li, D. (2020) "A review of vegetation phenological metrics extraction using time-series, multispectral satellite data", *Remote Sensing of Environment*, 237, p. 111511. doi:10.1016/j.rse.2019.111511.

ANEXOS

Anexo 1: Mapa de los tipos de coberturas del suelo del concejo de Tineo (Asturias)



Anexo 2: Script en diseño en RStudio para el procesamiento de las imágenes Sentinel 2

```

# Procesado de Imágenes Satélite Sentinel 2

# Carga de librerías
library(sf)
library(ggplot2)
library(dplyr)
library(rgdal)
library(raster)
library(tidyverse)
library(gtools)
library(sen2r)

# Carpeta donde se irán guardando los resultados

Subset_29TPJ<-
"D:/Master/CETEMAS/TFM/Imagenes_S2/2020_06_23_summer/L2A/S2B_MSIL2A_20200623T112119_N0214_R037_T2
9TPJ/Subset" #Tile 29TPJ

Subset_29TPH<-
"D:/Master/CETEMAS/TFM/Imagenes_S2/2020_06_23_summer/L2A/S2B_MSIL2A_20200623T112119_N0214_R037_T2
9TPH/Subset" #Tile 29TPJ

Subset_29TQJ<-
"D:/Master/CETEMAS/TFM/Imagenes_S2/2020_06_23_summer/L2A/S2B_MSIL2A_20200623T112119_N0214_R037_T2
9TQJ/Subset" #Tile 29TQJ

Subset_29TQH<-
"D:/Master/CETEMAS/TFM/Imagenes_S2/2020_06_23_summer/L2A/S2B_MSIL2A_20200623T112119_N0214_R037_T2
9TQH/Subset" #Tile 29TQH

Mosaico<- "D:/Master/CETEMAS/TFM/Imagenes_S2/2020_06_23_summer/L2A/Mosaico" #En esta carpeta se irán
guardando las bandas mosaicadas y los Índices espectrales

#---- 29TPJ---#

#Establecemos los directorios de trabajo, así los que se podrán como parámetros a lo largo del script
#Carpeta donde las están las bandas de resolución 10m/píxel

T29TPJ_R_10m<-
list.files(path="D:/Master/CETEMAS/TFM/Imagenes_S2/23_06_2020_summer/L2A/S2B_MSIL2A_20200623T112119_N0
214_R037_T29TPJ/GRANULE/L2A_T29TPJ_A017223_
20200623T112637/IMG_DATA/R10m",full.names = T, recursive = T)

#Carpeta donde las están las bandas de resolución 20m/píxel

T29TPJ_R_20m<-
list.files(path="D:/Master/CETEMAS/TFM/Imagenes_S2/23_06_2020_summer/L2A/S2B_MSIL2A_20200623T112119_N0
214_R037_T29TPJ/GRANULE/L2A_T29TPJ_A017223_
20200623T112637/IMG_DATA/R20m",full.names = T,recursive = T)

#---- 29TPH---#

#Establecemos los directorios de trabajo, así los que se podrán como parámetros a lo largo del script
#Carpeta donde las están las bandas de resolución 10m/píxel

T29TPH_R_10m<-
list.files(path="D:/Master/CETEMAS/TFM/Imagenes_S2/23_06_2020_summer/L2A/S2B_MSIL2A_20200623T112119_N0
214_R037_T29TPH/GRANULE/L2A_T29TPH_A017223_
20200623T112637/IMG_DATA/R10m",full.names = T, recursive = T)

```



```

#Carepta donde las están las bandas de resolucion 20m/píxel
T29TPH_R_20m<-
list.files(path="D:/Master/CETEMAS/TFM/Imagenes_S2/23_06_2020_summer/L2A/S2B_MSIL2A_20200623T112119_N0
214_R037_T29TPH/GRANULE/L2A_T29TPH_A017223_
                20200623T112637/IMG_DATA/R20m",full.names = T,recursive = T)

#---- 29TQJ---#
#Establecemos los directorios de trabajo, así los se podrán como parámetros a lo largo del script
#Carepta donde las están las basndas de resolución 10m/píxel
T29TQJ_R_10m<-
list.files(path="D:/Master/CETEMAS/TFM/Imagenes_S2/23_06_2020_summer/L2A/S2B_MSIL2A_20200623T112119_N0
214_R037_T29TQJ/GRANULE/L2A_T29TQJ_A017223_
                20200623T112637/IMG_DATA/R10m",full.names = T, recursive = T)

#Carepta donde las están las bandas de resolucion 20m/píxel
T29TQJ_R_20m<-
list.files(path="D:/Master/CETEMAS/TFM/Imagenes_S2/23_06_2020_summer/L2A/S2B_MSIL2A_20200623T112119_N0
214_R037_T29TQJ/GRANULE/L2A_T29TQJ_A017223_
                20200623T112637/IMG_DATA/R20m",full.names = T,recursive = T)

#----29TQH---#
#Establecemos los directorios de trabajo, así los se podrán como parámetros a lo largo del script
#Carepta donde las están las basndas de resolución 10m/píxel
T29TQH_R_10m<-
list.files(path="D:/Master/CETEMAS/TFM/Imagenes_S2/23_06_2020_summer/L2A/S2B_MSIL2A_20200623T112119_N0
214_R037_T29TQH/GRANULE/L2A_T29TQH_A017223_
                20200623T112637/IMG_DATA/R10m",full.names = T, recursive = T)

#Carepta donde las están las bandas de resolucion 20m/píxel
T29TQH_R_20m<-
list.files(path="D:/Master/CETEMAS/TFM/Imagenes_S2/23_06_2020_summer/L2A/S2B_MSIL2A_20200623T112119_N0
214_R037_T29TQH/GRANULE/L2A_T29TQH_A017223_
                20200623T112637/IMG_DATA/R20m",full.names = T,recursive = T)

# Se carga el Área de interes que se usará como máscara de recorte (agilizar el procesado)
Subset<-shapefile("D:/Master/Datos/AoI_P.shp")
plot(Subset)
#---- 29TPJ---#
setwd(Subset_29TPJ)
# Primero:Se cargan, se recortan y guardan las bandas de 10 m/píxel
B2<-raster(T29TPJ_R_10m[2])
B2_Subset<-crop(B2,Subset)#Recorte por máscara con la función crop del paquete ráster
plot(B2)
plot(Subset,add=T)
# Se comprueban las características del ráster resultante
crs(B2_Subset) #CRS
res(B2_Subset) #Resolución x - y
ncell(B2_Subset) #Número de celdas
dim(B2_Subset) #Dimensiones
writeRaster(B2_Subset,filename = "T29TPJ_Subset_B02.tif")
B3<-raster(T29TPJ_R_10m[3])
  
```

```

B3_Subset<-crop(B3,Subset)
writeRaster(B3_Subset,filename = "T29TPJ_Subset_B03.tif")
B4<-raster(T29TPJ_R_10m[4])
B4_Subset<-crop(B4,Subset)
writeRaster(B4_Subset,filename = "T29TPJ_Subset_B04.tif")
B8<-raster(T29TPJ_R_10m[5])
B8_Subset<-crop(B8,Subset)
writeRaster(B8_Subset,filename = "T29TPJ_Subset_B08.tif")
#Segundo: A continuación, se van a resamplear las bandas de 20 m/píxel que se necesitan(B5,B6,B7,B11,B12)
# ¿Cómo?: 1: Se cargan; 2:Se recortan; 3:Sampling; 4: Se guardan
B5_20m<-raster(T29TPJ_R_20m[5])
B5_20m_Subset<-crop(B5_20m,Subset)
B5_10m<-resample(B5_20m_Subset,B2_Subset,Method='ngb')
res(B5_10m)
writeRaster(B5_10m,filename = "T29TPJ_Subset_B05.tif")
B6_20m<-raster(T29TPJ_R_20m[6])
B6_20m_Subset<-crop(B6_20m,Subset)
B6_10m<-resample(B6_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B6_10m,filename = "T29TPJ_Subset_B06.tif")
B7_20m<-raster(T29TPJ_R_20m[7])
B7_20m_Subset<-crop(B7_20m,Subset)
B7_10m<-resample(B7_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B7_10m,filename = "T29TPJ_Subset_B07.tif")
B11_20m<-raster(T29TPJ_R_20m[8])
B11_20m_Subset<-crop(B11_20m,Subset)
B11_10m<-resample(B11_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B11_10m,filename = "T29TPJ_Subset_B11.tif")
B12_20m<-raster(T29TPJ_R_20m[9])
B12_20m_Subset<-crop(B12_20m,Subset)
B12_10m<-resample(B12_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B12_10m,filename = "T29TPJ_Subset_B12.tif")
#---- 29TPH---#
setwd(Subset_29TPH)
# Primero:Se cargan, se recortan y guardan las bandas de 10 m/píxel
B2<-raster(T29TPH_R_10m[2])
B2_Subset<-crop(B2,Subset)#Recorte por máscara con la función crop del paquete ráster
plot(B2)
plot(Subset,add=T)
# Se comprueban las características del ráster resultante
crs(B2_Subset) #CRS
res(B2_Subset) #Resolución x - y
ncell(B2_Subset) #Número de celdas
dim(B2_Subset) #Dimensiones

```

```

writeRaster(B2_Subset,filename = "T29TPH_Subset_B02.tif")
B3<-raster(T29TPH_R_10m[3])
B3_Subset<-crop(B3,Subset)
writeRaster(B3_Subset,filename = "T29TPH_Subset_B03.tif")
B4<-raster(T29TPH_R_10m[4])
B4_Subset<-crop(B4,Subset)
writeRaster(B4_Subset,filename = "T29TPH_Subset_B04.tif")
B8<-raster(T29TPH_R_10m[5])
B8_Subset<-crop(B8,Subset)
writeRaster(B8_Subset,filename = "T29TPH_Subset_B08.tif")

#Segundo: A continuación, se van a resamplear las bandas de 20 m/píxel que se necesitan(B5,B6,B7,B11,B12)
# ¿Cómo?: 1: Se cargan; 2:Se recortan; 3:Sampling; 4: Se guardan
B5_20m<-raster(T29TPH_R_20m[5])
B5_20m_Subset<-crop(B5_20m,Subset)
B5_10m<-resample(B5_20m_Subset,B2_Subset,Method='ngb')
res(B5_10m)
writeRaster(B5_10m,filename = "T29TPH_Subset_B05.tif")
B6_20m<-raster(T29TPH_R_20m[6])
B6_20m_Subset<-crop(B6_20m,Subset)
B6_10m<-resample(B6_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B6_10m,filename = "T29TPH_Subset_B06.tif")
B7_20m<-raster(T29TPH_R_20m[7])
B7_20m_Subset<-crop(B7_20m,Subset)
B7_10m<-resample(B7_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B7_10m,filename = "T29TPH_Subset_B07.tif")
B11_20m<-raster(T29TPH_R_20m[8])
B11_20m_Subset<-crop(B11_20m,Subset)
B11_10m<-resample(B11_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B11_10m,filename = "T29TPH_Subset_B11.tif")
B12_20m<-raster(T29TPH_R_20m[9])
B12_20m_Subset<-crop(B12_20m,Subset)
B12_10m<-resample(B12_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B12_10m,filename = "T29TPH_Subset_B12.tif")
#---- 29TQJ---#
setwd(Subset_29TQJ)
# Primero:Se cargan, se recortan y guardan las bandas de 10 m/píxel
B2<-raster(T29TQJ_R_10m[2])
B2_Subset<-crop(B2,Subset)#Recorte por máscara con la función crop del paquete ráster
plot(B2_Subset)
plot(Subset,add=T)
# Se comprueban las características del ráster resultante
crs(B2_Subset) #CRS

```

```

res(B2_Subset) #Resolución x - y
ncell(B2_Subset) #Número de celdas
dim(B2_Subset) #Dimensiones
writeRaster(B2_Subset,filename = "T29TQJ_Subset_B02.tif")
B3<-raster(T29TQJ_R_10m[3])
B3_Subset<-crop(B3,Subset)
writeRaster(B3_Subset,filename = "T29TQJ_Subset_B03.tif")
B4<-raster(T29TQJ_R_10m[4])
B4_Subset<-crop(B4,Subset)
writeRaster(B4_Subset,filename = "T29TQJ_Subset_B04.tif")
B8<-raster(T29TQJ_R_10m[5])
B8_Subset<-crop(B8,Subset)
writeRaster(B8_Subset,filename = "T29TQJ_Subset_B08.tif")
#Segundo: A continuación, se van a resamplear las bandas de 20 m/píxel que se necesitan(B5,B6,B7,B11,B12)
# ¿Cómo?: 1: Se cargan; 2:Se recortan; 3:Sampling; 4: Se guardan
B5_20m<-raster(T29TQJ_R_20m[5])
B5_20m_Subset<-crop(B5_20m,Subset)
B5_10m<-resample(B5_20m_Subset,B2_Subset,Method='ngb')
res(B5_10m)
writeRaster(B5_10m,filename = "T29TQJ_Subset_B05.tif")
B6_20m<-raster(T29TQJ_R_20m[6])
B6_20m_Subset<-crop(B6_20m,Subset)
B6_10m<-resample(B6_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B6_10m,filename = "T29TQJ_Subset_B06.tif")
B7_20m<-raster(T29TQJ_R_20m[7])
B7_20m_Subset<-crop(B7_20m,Subset)
B7_10m<-resample(B7_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B7_10m,filename = "T29TQJ_Subset_B07.tif")
B11_20m<-raster(T29TQJ_R_20m[8])
B11_20m_Subset<-crop(B11_20m,Subset)
B11_10m<-resample(B11_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B11_10m,filename = "T29TQJ_Subset_B11.tif")

B12_20m<-raster(T29TQJ_R_20m[9])
B12_20m_Subset<-crop(B12_20m,Subset)
B12_10m<-resample(B12_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B12_10m,filename = "T29TQJ_Subset_B12.tif")
#----- TQH
setwd(Subset_29TQH)
# Primero:Se cargan, se recortan y guardan las bandas de 10 m/píxel
B2<-raster(T29TQH_R_10m[2])
B2_Subset<-crop(B2,Subset)#Recorte por máscara con la función crop del paquete ráster
plot(B2_Subset)

```

```

plot(Subset,add=T)
# Se comprueban las características del ráster resultante
crs(B2_Subset) #CRS
res(B2_Subset) #Resolución x - y
ncell(B2_Subset) #Número de celdas
dim(B2_Subset) #Dimensiones
writeRaster(B2_Subset,filename = "T29TQH_Subset_B02.tif")
B3<-raster(T29TQH_R_10m[3])
B3_Subset<-crop(B3,Subset)
writeRaster(B3_Subset,filename = "T29TQH_Subset_B03.tif")
B4<-raster(T29TQH_R_10m[4])
B4_Subset<-crop(B4,Subset)
writeRaster(B4_Subset,filename = "T29TQH_Subset_B04.tif")
B8<-raster(T29TQH_R_10m[5])
B8_Subset<-crop(B8,Subset)
writeRaster(B8_Subset,filename = "T29TQH_Subset_B08.tif")
#Segundo: A continuación, se van a resamplear las bandas de 20 m/píxel que se necesitan(B5,B6,B7,B11,B12)
# ¿Cómo?: 1: Se cargan; 2:Se recortan; 3:Sampling; 4: Se guardan
setwd(Subset_29TQH)
B5_20m<-raster(T29TQH_R_20m[5])
B5_20m_Subset<-crop(B5_20m,Subset)
B5_10m<-resample(B5_20m_Subset,B2_Subset,Method='ngb')
res(B5_10m)
writeRaster(B5_10m,filename = "T29TQH_Subset_B05.tif")
B6_20m<-raster(T29TQH_R_20m[6])
B6_20m_Subset<-crop(B6_20m,Subset)
B6_10m<-resample(B6_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B6_10m,filename = "T29TQH_Subset_B06.tif")
B7_20m<-raster(T29TQH_R_20m[7])
B7_20m_Subset<-crop(B7_20m,Subset)
B7_10m<-resample(B7_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B7_10m,filename = "T29TQH_Subset_B07.tif")
B11_20m<-raster(T29TQH_R_20m[8])
B11_20m_Subset<-crop(B11_20m,Subset)
B11_10m<-resample(B11_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B11_10m,filename = "T29TQH_Subset_B11.tif")
B12_20m<-raster(T29TQH_R_20m[9])
B12_20m_Subset<-crop(B12_20m,Subset)
B12_10m<-resample(B12_20m_Subset,B2_Subset,Method='ngb')
writeRaster(B12_10m,filename = "T29TQH_Subset_B12.tif")
plot(B12_10m)
# Una vez todas las bandas han sido recortadas y tienen la misma resolución, se van a mosaicar
Subset_29TPJ_files<-list.files(path = Subset_29TPJ,full.names = T, recursive = T)

```

```

Stack_29TPJ<-stack(Subset_29TPJ_files)
names(Stack_29TPJ) <- c('blue','green','red','RE1','RE2','RE3','NIR','SWIR1','SWIR2')
plot(Stack_29TPJ)
Subset_29TPH_files<-list.files(path = Subset_29TPH,full.names = T, recursive = T)
Stack_29TPH<-stack(Subset_29TPH_files)
names(Stack_29TPH) <- c('blue','green','red','RE1','RE2','RE3','NIR','SWIR1','SWIR2')
plot(Stack_29TPH)
Subset_29TQJ_files<-list.files(path = Subset_29TQJ,full.names = T, recursive = T)
Stack_29TQJ<-stack(Subset_29TQJ_files)
names(Stack_29TQJ) <- c('blue','green','red','RE1','RE2','RE3','NIR','SWIR1','SWIR2')
plot(Stack_29TQJ)
Subset_29TQH_files<-list.files(path = Subset_29TQH,full.names = T, recursive = T)
Stack_29TQH<-stack(Subset_29TQH_files)
names(Stack_29TQH) <- c('blue','green','red','RE1','RE2','RE3','NIR','SWIR1','SWIR2')
plot(Stack_29TQH)
setwd(Mosaico)
UNION<-merge(Stack_29TPJ,Stack_29TPH,Stack_29TQJ,Stack_29TQH,tolerance=0.05)
names(UNION) <- c('blue','green','red','RE1','RE2','RE3','NIR','SWIR1','SWIR2')
plot(UNION)
plot(UNION$blue)
plot(Subset,add=T)
# Se guardan cda una de las bandas del ráster
writeRaster(UNION$blue,filename = "B02.tif")
writeRaster(UNION$green,filename = "B03.tif")
writeRaster(UNION$red,filename = "B04.tif")
writeRaster(UNION$RE1,filename = "B05.tif")
writeRaster(UNION$RE2,filename = "B06.tif")
writeRaster(UNION$RE3,filename = "B07.tif")
writeRaster(UNION$NIR,filename = "B08.tif")
writeRaster(UNION$SWIR1,filename = "B11.tif")
writeRaster(UNION$SWIR2,filename = "B12.tif")
##### Composiciones de color #####
#Composiciones a color
plotRGB(UNION, r="red", g="green", b="blue", axes=TRUE, stretch="lin", main="True Color") # 4 3 2
plotRGB(UNION, r="NIR", g="red", b="green", axes=TRUE, stretch="lin", main="Falso Color Infrarojo") # 8 4 3
plotRGB(UNION, r="SWIR2", g="NIR", b="red", axes=TRUE, stretch="lin", main="SWIR") # 12 8 4
plotRGB(UNION, r="NIR", g="RE3", b="blue", axes=TRUE, stretch="lin", main="VegetaciÃ³n") # 8 5 2(4)
plotRGB(UNION, r="SWIR2", g="SWIR1", b="blue", axes=TRUE, stretch="lin", main="Masas de Agua") # 12 11 2
dev.off()
####-----Índices espectrales-----
NDVI<-((UNION$NIR-UNION$red)/(UNION$NIR+UNION$red))
plot(NDVI)
writeRaster(NDVI,"VI_NDVI.tif")

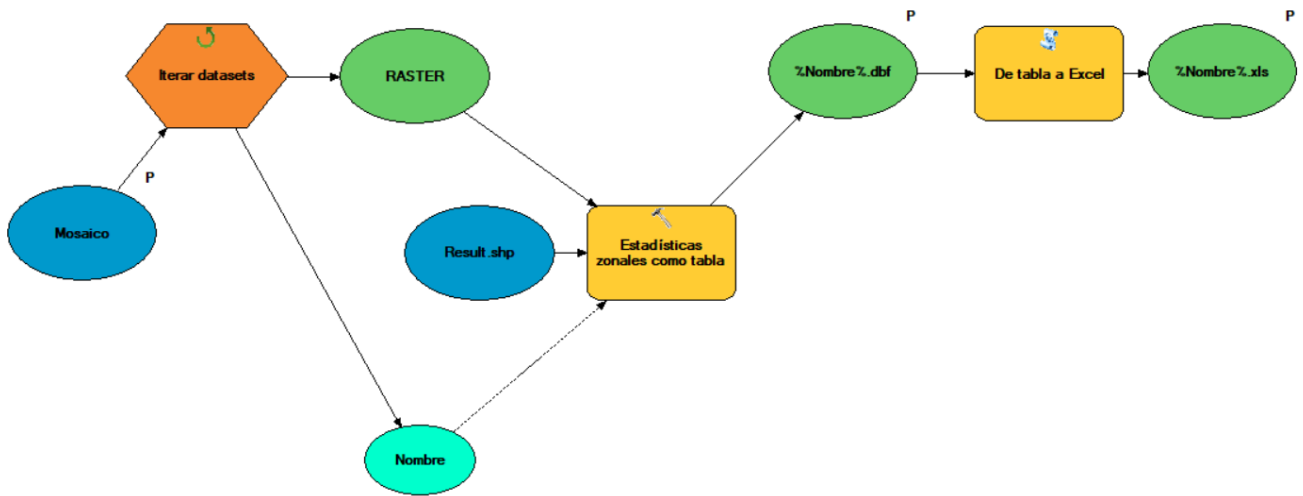
```

```

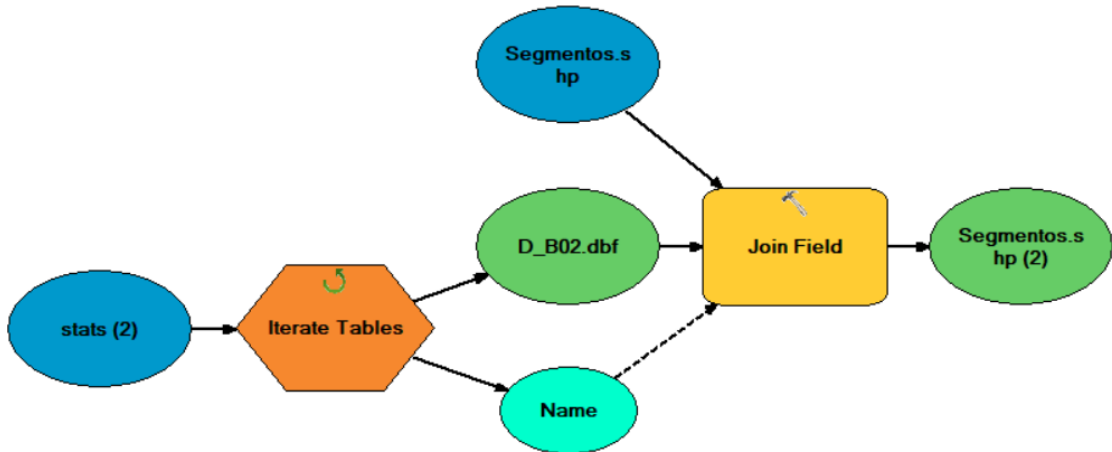
NDII<-((UNION$NIR-UNION$SWIR1)/(UNION$NIR+UNION$SWIR1))
plot(NDII)
writeRaster(NDII,"VI_NDII.tif")
SAVI<-((UNION$NIR-UNION$red)/(UNION$NIR+UNION$red+0.5))*0.5
plot(SAVI)
writeRaster(SAVI,"VI_SAVI.tif")
ARI<-(1/UNION$green)-(1/UNION$RE1)
writeRaster(ARI,"VI_ARI.tif")
plot(ARI)
plot(Subset,add=T)
ARI_II<-UNION$NIR*((1/UNION$green)-(1/UNION$RE1))
writeRaster(ARI_II,"VI_ARI_II.tif")
plot(ARI_II)
# Se crea el exporta el stack final
Mosaico_files<-list.files(path = Mosaico,full.names = T, recursive = T)
Stack<-stack(Mosaico_files)
names(Stack) <- c('blue','green','red','RE1','RE2','RE3','NIR','SWIR1','SWIR2','ARI','ARI_II','NDII','NDVI','SAVI')
plot(Stack)
writeRaster(Stack,filename = "Stack_20200623.tif")
setwd("D:/Master/CETEMAS/TFM/Imagenes_S2/12_09_2019_September/L2A/Junio")
bandas<-
list.files(path="D:/Master/CETEMAS/TFM/Imagenes_S2/12_09_2019_September/L2A/Junio",full.names=T,recursive = T)
Sateck_Junio<-stack(bandas)
plot(Sateck_Junio)
writeRaster(Sateck_Junio,filename="D:/Master/CETEMAS/TFM/Imagenes_S2/12_09_2019_September/L2A/Junio/Stack_Junio.tif")
# Se abre la capa vectorial con los objetos de la segmentación
SEG_shape<-st_read("D:/Master/Datos/segmentacion/Result.shp")
SEG_shape<-rownames_to_column(SEG_shape,var ="ID")
pred<-merge(SEG_shape,Segmentos$Pred,by="ID") # Se une con la predicción realiza sobre la BD
st_write(pred,"D:/Master/Datos/segmentacion/pred.shp") # Se exporta el resultado final

```

Anexo 3: Estadísticos como tabla



Anexo 4: Unión por ID



Anexo 5: Listado de variables empleadas en la clasificación de los grupos de vegetación.

Mes de la escena	Estadístico	Banda/índice espectral	Código
Septiembre (S)	Media (M)	B02	S_M_B02
	Desviación estándar (ST)	B02	S_ST_B02
	Media (M)	B03	S_M_B03
	Desviación estándar (ST)	B03	S_ST_B03
	Media (M)	B04	S_M_B04
	Desviación estándar (ST)	B04	S_ST_B04
	Media (M)	B05	S_M_B05
	Desviación estándar (ST)	B05	S_ST_B05
	Media (M)	B06	S_M_B06
	Desviación estándar (ST)	B06	S_ST_B06
	Media (M)	B07	S_M_B07
	Desviación estándar (ST)	B07	S_ST_B07
	Media (M)	B08	S_M_B08
	Desviación estándar (ST)	B08	S_ST_B08
	Media (M)	B11	S_M_B11
	Desviación estándar (ST)	B11	S_ST_B11
	Media (M)	B12	S_M_B12
	Desviación estándar (ST)	B12	S_ST_B12
	Media (M)	ARI	S_M_ARI
	Desviación estándar (ST)	ARI	S_ST_ARI
	Media (M)	ARI_II	S_M_ARI_II
	Desviación estándar (ST)	ARI_II	S_ST_ARI_II
	Media (M)	NDII	S_M_NDII
	Desviación estándar (ST)	NDII	S_ST_NDII
Media (M)	NDVI	S_M_NDVI	
Desviación estándar (ST)	NDVI	S_ST_NDVI	
Media (M)	SAVI	S_M_SAVI	
Desviación estándar (ST)	SAVI	S_ST_SAVI	

Mes de la escena	Estadístico	Banda/índice espectral	Código
Diciembre (D)	Media (M)	B02	D_M_B02
	Desviación estándar (ST)	B02	D_ST_B02
	Media (M)	B03	D_M_B03
	Desviación estándar (ST)	B03	D_ST_B03
	Media (M)	B04	D_M_B04
	Desviación estándar (ST)	B04	D_ST_B04
	Media (M)	B05	D_M_B05
	Desviación estándar (ST)	B05	D_ST_B05
	Media (M)	B06	D_M_B06
	Desviación estándar (ST)	B06	D_ST_B06
	Media (M)	B07	D_M_B07
	Desviación estándar (ST)	B07	D_ST_B07
	Media (M)	B08	D_M_B08
	Desviación estándar (ST)	B08	D_ST_B08
	Media (M)	B11	D_M_B11
	Desviación estándar (ST)	B11	D_ST_B11
	Media (M)	B12	D_M_B12
	Desviación estándar (ST)	B12	D_ST_B12
	Media (M)	ARI	D_M_ARI
	Desviación estándar (ST)	ARI	D_ST_ARI
	Media (M)	ARI_II	D_M_ARI_II
	Desviación estándar (ST)	ARI_II	D_ST_ARI_II
	Media (M)	NDII	D_M_NDII
	Desviación estándar (ST)	NDII	D_ST_NDII
Media (M)	NDVI	D_M_NDVI	
Desviación estándar (ST)	NDVI	D_ST_NDVI	
Media (M)	SAVI	D_M_SAVI	
Desviación estándar (ST)	SAVI	D_ST_SAVI	

Mes de la escena	Estadístico	Banda/índice espectral	Código
Mayo (M)	Media (M)	B02	M_M_B02
	Desviación estándar (ST)	B02	M_ST_B02
	Media (M)	B03	M_M_B03
	Desviación estándar (ST)	B03	M_ST_B03
	Media (M)	B04	M_M_B04
	Desviación estándar (ST)	B04	M_ST_B04
	Media (M)	B05	M_M_B05
	Desviación estándar (ST)	B05	M_ST_B05
	Media (M)	B06	M_M_B06
	Desviación estándar (ST)	B06	M_ST_B06
	Media (M)	B07	M_M_B07
	Desviación estándar (ST)	B07	M_ST_B07
	Media (M)	B08	M_M_B08
	Desviación estándar (ST)	B08	M_ST_B08
	Media (M)	B11	M_M_B11
	Desviación estándar (ST)	B11	M_ST_B11
	Media (M)	B12	M_M_B12
	Desviación estándar (ST)	B12	M_ST_B12
	Media (M)	ARI	M_M_ARI
	Desviación estándar (ST)	ARI	M_ST_ARI
	Media (M)	ARI_II	M_M_ARI_II
	Desviación estándar (ST)	ARI_II	M_ST_ARI_II
	Media (M)	NDII	M_M_NDII
	Desviación estándar (ST)	NDII	M_ST_NDII
	Media (M)	NDVI	M_M_NDVI
	Desviación estándar (ST)	NDVI	M_ST_NDVI
	Media (M)	SAVI	M_M_SAVI
	Desviación estándar (ST)	SAVI	M_ST_SAVI

Mes de la escena	Estadístico	Banda/índice espectral	Código
Junio(J)	Media (M)	B02	D_M_B02
	Desviación estándar (ST)	B02	D_ST_B02
	Media (M)	B03	D_M_B03
	Desviación estándar (ST)	B03	D_ST_B03
	Media (M)	B04	D_M_B04
	Desviación estándar (ST)	B04	D_ST_B04
	Media (M)	B05	D_M_B05
	Desviación estándar (ST)	B05	D_ST_B05
	Media (M)	B06	D_M_B06
	Desviación estándar (ST)	B06	D_ST_B06
	Media (M)	B07	D_M_B07
	Desviación estándar (ST)	B07	D_ST_B07
	Media (M)	B08	D_M_B08
	Desviación estándar (ST)	B08	D_ST_B08
	Media (M)	B11	D_M_B11
	Desviación estándar (ST)	B11	D_ST_B11
	Media (M)	B12	D_M_B12
	Desviación estándar (ST)	B12	D_ST_B12
	Media (M)	ARI	D_M_ARI
	Desviación estándar (ST)	ARI	D_ST_ARI
	Media (M)	ARI_II	D_M_ARI_II
	Desviación estándar (ST)	ARI_II	D_ST_ARI_II
	Media (M)	NDII	D_M_NDII
	Desviación estándar (ST)	NDII	D_ST_NDII
	Media (M)	NDVI	D_M_NDVI
	Desviación estándar (ST)	NDVI	D_ST_NDVI
	Media (M)	SAVI	D_M_SAVI
	Desviación estándar (ST)	SAVI	D_ST_SAVI

Anexo 6: Script para llevar a cabo la clasificación supervisada en RStudio

Se cargan las librerías necesarias

```
library(caret)
library(randomForest)
library(parallel)
library(doParallel)
library(sp)
library(sf)
library(raster)
library(FactoMineR)
```

A continuación se carga la BD de con los puyos para el entrenamiento y la validación

```
Plots<-read.csv2("D:/Master/CETEMAS/TFM/Imagenes_S2/BBDD_Ref/Todo.csv",header = T,sep = ',',dec = '.')
```

Se renombran los campos para poder identificarlos

```
names(Plots)<-
c("FID","Cobertura","Coment","FID_Sgements","OID_","FID_","D_M_B02","D_ST_B02","D_M_B03","D_ST_B03","D
_M_B04","D_STB04","D_M_B05","D_ST_B05","D_M_B06","D_STB06","D_M_B07","D_ST_B07","D_M_B08","D_ST
B08","D_M_B11","D_ST_B11","D_M_B12","D_STB12","D_M_ARI","D_ST_ARI","D_M_ARI_II","D_ST_ARI_II","D_
M_NDII","D_ST_NDII","D_M_NDVI","D_ST_NDVI","D_M_SAVI","D_STSAVI","J_M_B02","J_ST_B02","J_M_B03","
J_ST_B03","J_M_B04","J_STB04","J_M_B05","J_ST_B05","J_M_B06","J_STB06","J_M_B07","J_ST_B07","J_M_B08",
"J_STB08","J_M_B11","J_ST_B11","J_M_B12","J_STB12","J_M_ARI","J_ST_ARI","J_M_ARI_II","J_ST_ARI_II","J_M
_NDII","J_ST_NDII","J_M_NDVI","J_ST_NDVI","J_M_SAVI","J_STSAVI","M_M_B02","M_ST_B02","M_M_B03","M
_ST_B03","M_M_B04","M_STB04","M_M_B05","M_ST_B05","M_M_B06","M_STB06","M_M_B07","M_ST_B07","M
_M_B08","M_STB08","M_M_B11","M_ST_B11","M_M_B12","M_STB12","M_M_ARI","M_ST_ARI","M_M_ARI_II","M
_ST_ARI_II","M_M_NDII","M_ST_NDII","M_M_NDVI","M_ST_NDVI","M_M_SAVI","M_STSAVI","S_M_B02","S
_ST_B02","S_M_B03","S_ST_B03","S_M_B04","S_STB04","S_M_B05","S_ST_B05","S_M_B06","S_STB06","S_M_B0
7","S_ST_B07","S_M_B08","S_STB08","S_M_B11","S_ST_B11","S_M_B12","S_STB12","S_M_ARI","S_ST_ARI","S_
M_ARI_II","S_ST_ARI_II","S_M_NDII","S_ST_NDII","S_M_NDVI","S_ST_NDVI","S_M_SAVI","S_ST_SAVI")
```

```
Plots$Cobertura<-as.factor(Plots$Cobertura)
```

```
Plots$Coment<-as.factor(Plots$Coment)
```

Se divide de forma aleatoria la BD de referencia en dos subconjuntos (30% entrenamiento, 70% validación)

```
set.seed(20)
```

```
Training<-createDataPartition(Plots$Cobertura,p=0.3,list = FALSE)
```

#Se entrena el modelo

```
set.seed(20)
```

```
modelo_RF<-randomForest(x=Plots[Training,7:118],
```

```
  y=Plots[Training,2],
```

```
  ntree=500)
```

```
modelo_RF
```

```
summary(modelo_RF)
```

```
modelo_RF$importance
```

```
plot(modelo_RF)
```

#Se hace la validación del modelo ajustado

Primero un predicción sobre el conjunto de parcelas de validación

```
pred<-predict(modelo_RF,Plots[-Training,])
```

Segundo se compara la predicción y la clasificación asignada en primer momento

```
confusionMatrix(Plots[-Training,"Cobertura"],pred)
```

SELECCIÓN DE VARIABLES IMPORTANTES

```
Plots<-Plots[,c("FID","Cobertura","FID_Sgmentos","OID_","FID_","
"D_M_NDII","D_M_SAVI","J_M_B08","J_M_B11","J_M_ARI","J_M_ARI_II","M_M_B03","M_M_B11","M_M_ARI","
M_M_ARI_II","M_M_NDVI","S_M_B03","S_M_B04","S_M_B05","S_M_B08","S_STB08","S_M_ARI","S_ST_ARI","S
_M_ARI_II","S_ST_ARI_II","S_M_NDVI","S_M_SAVI")]
```

Se divide de forma aleatoria la BD de referencia en dos subconjuntos (30% entrenamiento, 70% validación)

```
set.seed(20)
```

```
Training<-createDataPartition(Plots$Cobertura,p=0.3,list = FALSE)
```

#Se entrena el modelo

```
set.seed(20)
```

```
modelo_RF<-randomForest(x=Plots[Training,6:27],
```

```
  y=Plots[Training,2],
```

```
  ntree=500,
```

```
  importance = T)
```

```
modelo_RF
```

```
summary(modelo_RF)
```

#Se hace la validación del modelo ajustado

Primero un predicción sobre el conjunto de parcelas de validación

```
pred<-predict(modelo_RF,Plots[-Training,])
```

```
modelo_RF$importance
```

Segundo se compara la predicción y la clasificación asignada en primer momento

```
confusionMatrix(Plots[-Training,"Cobertura"],pred)
```

#Calsificacion

Caragar los segmentos

```
Segmentos<-read.csv2("D:/Master/CETEMAS/TFM/Imagenes_S2/BBDD_Ref/Stats_Segmentos.csv",header = T,sep = ',',dec = '.')
```

Se renombran los campos para poder identificarlos

```
names(Segmentos)<-
```

```
c("X","FID","Pred","D_M_B02","D_ST_B02","D_M_B03","D_ST_B03","D_M_B04","D_STB04","D_M_B05","D_ST_B0
5","D_M_B06","D_STB06","D_M_B07","D_ST_B07","D_M_B08","D_STB08",
"D_M_B11","D_ST_B11","D_M_B12","D_STB12","D_M_ARI","D_ST_ARI","D_M_ARI_II","D_ST_ARI_II","D_M_ND
II","D_ST_NDII","D_M_NDVI","D_ST_NDVI","D_M_SAVI","D_STSAVI","J_M_B02",
"J_ST_B02","J_M_B03","J_ST_B03","J_M_B04","J_STB04","J_M_B05","J_ST_B05","J_M_B06","J_STB06","J_M_B07",
"J_ST_B07","J_M_B08","J_STB08","J_M_B11","J_ST_B11","J_M_B12",
"J_STB12","J_M_ARI","J_ST_ARI","J_M_ARI_II","J_ST_ARI_II","J_M_NDII","J_M_NDVI","J_ST_NDV
I","J_M_SAVI","J_STSAVI","M_M_B02","M_ST_B02","M_M_B03","M_ST_B03",
"M_M_B04","M_STB04","M_M_B05","M_ST_B05","M_M_B06","M_STB06","M_M_B07","M_ST_B07","M_M_B08",
M_STB08","M_M_B11","M_ST_B11","M_M_B12","M_STB12","M_M_ARI","M_ST_ARI",
"M_M_ARI_II","M_ST_ARI_II","M_M_NDII","M_ST_NDII","M_M_NDVI","M_ST_NDVI","M_M_SAVI","M_STSAVI",
"S_M_B02","S_ST_B02","S_M_B03","S_ST_B03","S_M_B04","S_STB04","S_M_B05",
"S_ST_B05","S_M_B06","S_STB06","S_M_B07","S_ST_B07","S_M_B08","S_STB08","S_M_B11","S_ST_B11","S_M_
B12","S_STB12","S_M_ARI","S_ST_ARI","S_M_ARI_II","S_ST_ARI_II","S_M_NDII","S_ST_NDII","S_M_NDVI","S_
ST_NDVI","S_M_SAVI","S_ST_SAVI")
```

Se clasifica cada uno de los segmentos de la imagen tras ajustar el modelo

```
Segmentos$Pred<-predict(modelo_RF,Segmentos)
```

```
write.csv2(Segmentos,"D:/Master/CETEMAS/TFM/Imagenes_S2/BBDD_Ref/clasificación_2.csv")
```

Anexo 7: Clasificación de zonas en la plataforma GEE

```
// Imagen PRE incendio
```

```
var Image_PRE=ee.ImageCollection('COPERNICUS/S2_SR')
```

```

    .filterDate('2019-12-29','2020-01-01')
    .filterBounds(Tineo)
    .mosaic()
    .clip(Tineo);
print('Imagen PRE (31/12/2019)',Image_PRE);
Map.setCenter(-6.41196048913538,43.334313546915894);
Map.addLayer(Image_PRE,{
  max:5000,
  min:0,
  gamma:1,
  bands:['B4','B3','B2']},
  'Composición RGB PRE incendio');
// Se calcula el NBR antes del incendio
var NBR_PRE=Image_PRE.normalizedDifference(['B8','B12'])
Map.addLayer(NBR_PRE,{'NBR PRE incendio');
// Imagen POST incendio
var Image_POST=ee.ImageCollection('COPERNICUS/S2_SR')
  .filterDate('2020-04-03','2020-04-05')
  .filterBounds(Tineo)
  .mosaic()
  .clip(Tineo);
print('Imagen Post (05/04/2020)',Image_POST);

Map.setCenter(-6.41196048913538,43.334313546915894);
Map.addLayer(Image_POST,{
  max:5000,
  min:0,
  gamma:1,
  bands:['B4','B3','B2']},
  'Composición RGB POST incendio');
// Se calcula el NBR antes del incendio
var NBR_POST=Image_POST.normalizedDifference(['B8','B12'])
Map.addLayer(NBR_POST,{'NBR POST incendio');
// A continuación se calcula el dNBR, es decir, la diferencia entre el valor de índice antes y después del incendios
var dNBR=NBR_PRE.subtract(NBR_POST);
print('dNBR',dNBR);
Map.addLayer(dNBR)
// De forma manual se crearon parcelas de referencia
// que se unen en una variable a continuación:
var plots=Not_Burned.merge(Burned);
print('Parcelas de referencia',plots);
// Extraemos la información que ofrece el dNBR en cada una de las parcelas
var reference= Image_POST.sampleRegions({

```

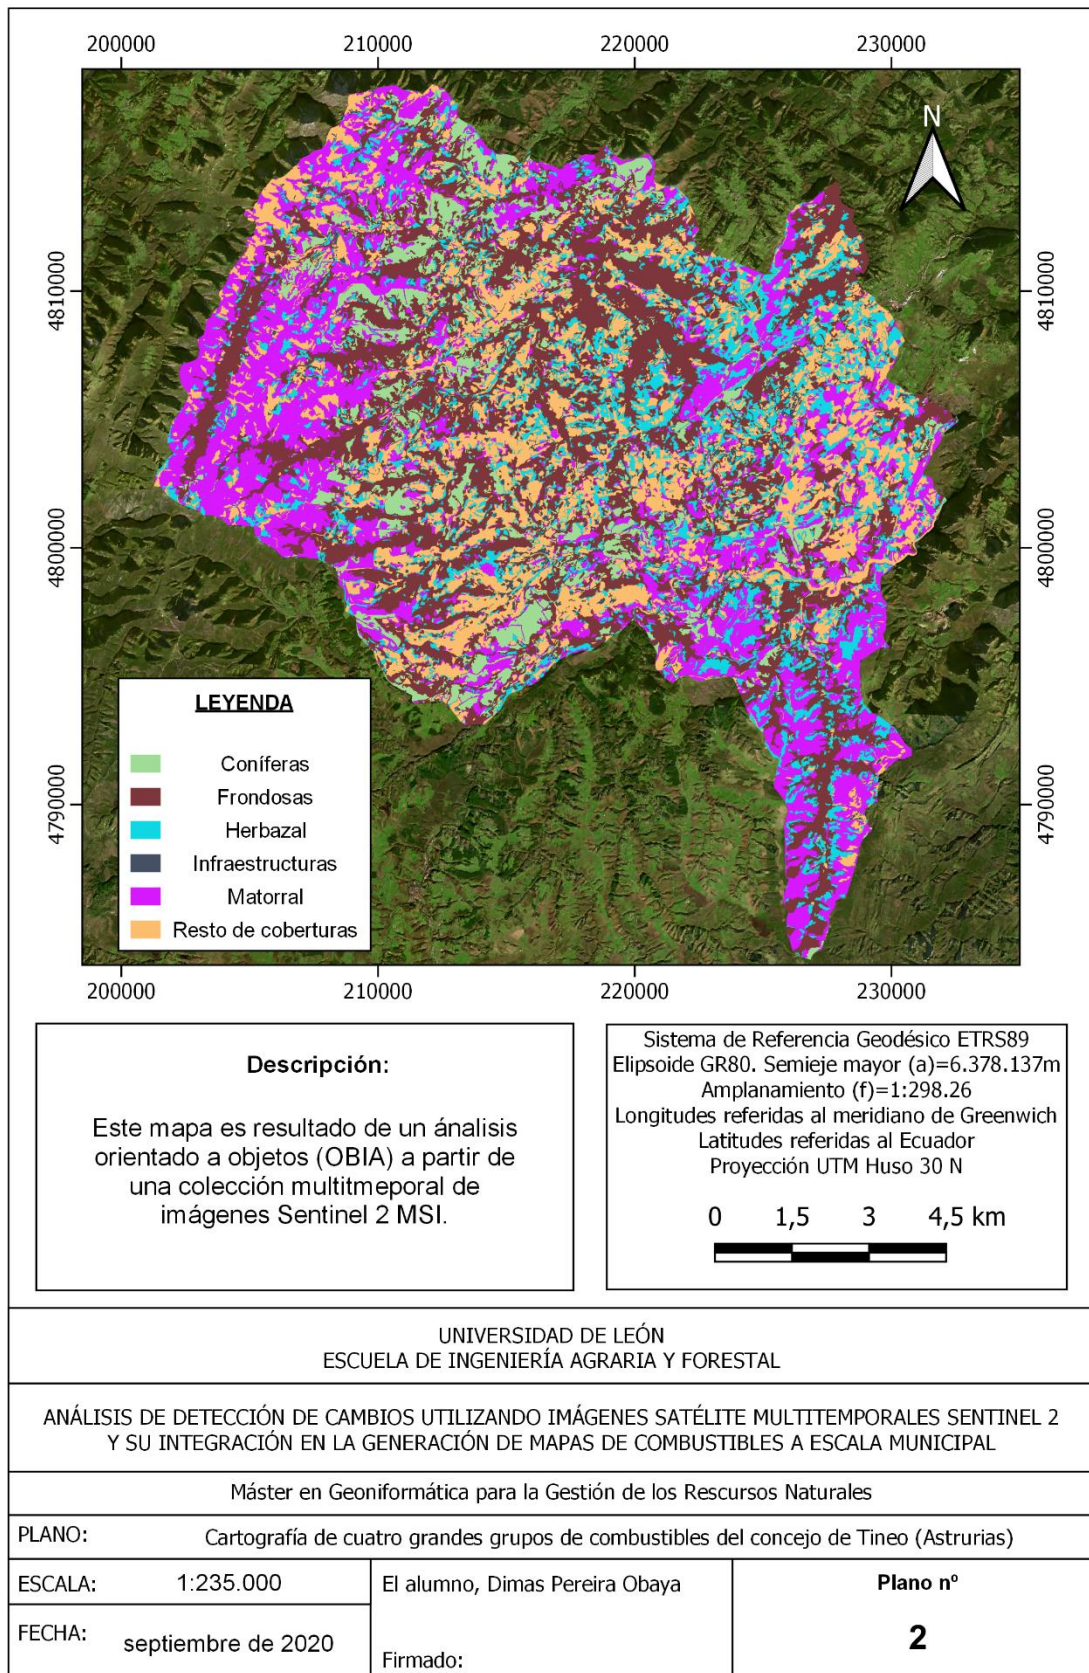
```

collection:plots,
properties:['LC'],
scale:10
});
print(reference);
// A continuación, se divide la BD en dos partes
reference = reference.randomColumn();
var split = 0.3; // 70% entrenamiento, 30% validación
var training = reference.filter(ee.Filter.lt('random', split));
print('Número de píxeles para el entrenamiento',training.size());
var validation = reference.filter(ee.Filter.gte('random', split));
print('Número de píxeles para la validación',validation.size());
// Con este código se consigue evitar que haya correlación entre las parcelas al separarlas 1000 m
var distFilter = ee.Filter.withinDistance({
  distance: 1000,
  leftField: 'geo',
  rightField: 'geo',
  maxError: 10
});
var join = ee.Join.inverted();
// Apply the join.
training = join.apply(training, validation, distFilter);
// Se prepara y entrena un modelo Random Forest
var classifier = ee.Classifier.smileRandomForest(10)
  .train({
    features: training,
    classProperty: 'LC',
    inputProperties: ['B2','B3','B4','B5','B6','B7','B8','B11','B12'],
    subsamplingSeed:50// se establece una semilla (en caso contrario cda vez que se ejecute el script sería distinto)
  });
// Clasificación de las bandas con valores de dNBR
var classified = Image_POST.classify(classifier);
print('clasificación',classified)
// Matriz de condusión del entrenamiento
var trainAccuracy = classifier.confusionMatrix();
print('Resubstitution error matrix: ', trainAccuracy);
print('Training overall accuracy: ', trainAccuracy.accuracy());
// Clasificación de los datos de validación
var validated = validation.classify(classifier);
// Matriz de condusión de la validación
var testAccuracy = validated.errorMatrix('LC', 'classification');
print('Validation error matrix: ', testAccuracy);
print('Validation overall accuracy: ', testAccuracy.accuracy());

```

```
// Análisis de la importancia de variables
var classifier_Importance = ee.Classifier.smileRandomForest(500).setOutputMode('PROBABILITY')
  .train({
    features: training,
    classProperty: 'LC',
    inputProperties: ['B2','B3','B4','B5','B6','B7','B8','B11','B12'],
    subsamplingSeed:50// se establece una semilla (en caso contrario cda vez que se ejecute el script sería distinto)
  });
var dict = classifier_Importance.explain();
var explainTitle = 'Explain :';
print(explainTitle, dict);
//Importancia de las variables del Random Forest
var variable_importance = ee.Feature(null, ee.Dictionary(dict).get('importance'));
// Gráfico de la importancia
var chartTitle = 'Importancia de cada banda espectral usada como varibale del modelo Random Forest' ;
var chart =
  ui.Chart.feature.byProperty(variable_importance)
    .setChartType('ColumnChart')
    .setOptions({
      title: chartTitle,
      legend: {position: 'none'},
      hAxis: {title: 'Bandas'},
      vAxis: {title: 'Importancia (%)'}
    });
print(chart);
// Visualización de los Resultados
Map.centerObject(Tineo, 10)
Map.addLayer(classified,{min:0, max:1,'palette': ['WHITE','RED']}, 'Zonas Quemadas');
// Se exporta en formato GeoTIFF
Export.image.toDrive({
  image: classified,
  description: 'Zonas Quemadas Tineo (2020)',
  scale: 10,
  region: Tineo,
  fileFormat: 'GeoTIFF',
  formatOptions: {
    cloudOptimized: true
  }
});
```


Anexo 8: Cartografía de combustibles del concejo de Tineo (Asturias)



Anexo 9: Cartografía de áreas quemadas en el concejo de Tineo (Asturias) durante la temporada invernal de incendios

