



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Geodésica,
Cartográfica y Topográfica

Cartografiado de modelos de combustible forestal en la
Sierra de Espadán


Trabajo Fin de Máster

Máster Universitario en Ingeniería Geomática y Geoinformación

AUTOR/A: Alcover Estrela, José Vicente

Tutor/a: Recio Recio, Jorge Abel

CURSO ACADÉMICO: 2021/2022



**ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA**
UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Autor: Jose Vicente Alcover Estrela

Tutor: Jorge Abel Recio Recio

TRABAJO FIN DE MÁSTER UNIVERSITARIO
EN INGENIERÍA GEOMÁTICA Y
GEOINFORMACIÓN

Cartografiado de Modelos de Combustible Forestal en la Sierra de Espadán

Curso 2021-2022

Jose Vicente Alcover Estrela

INDICE IMÁGENES

Figura 1.- Imagen de la sierra del Espadán desde Google Maps	8
Figura 2.- Imagen de las dos zonas de trabajo en la Sierra del Espadán	9
Figura 3.- Apartado de incendios del Centro de descarga del ICV	9
Figura 4.- Características del Grupo GR2	11
Figura 5.- Centro de descargas de los modelos digitales del CNIG	12
Figura 6.- Grupo de Ortofotos elegidas para la descarga	12
Figura 7.- Flujo de Trabajo	14
Figura 8.- Polígonos dentro de la zona de trabajo clasificados por modelos de combustión	15
Figura 9.- Puntos de muestra de los diferentes modelos de combustión de nuestra zona	16
Figura 10.- Fórmula para el cálculo del NDVI a partir de las bandas de una imagen RGBI	17
Figura 11.- Conjunto de todas las diferentes imágenes NDVI calculadas.	17
Figura 12.- Unión de todas las imágenes NDVI calculadas en una sola	18
Figura 13.- Recorte de la imagen NDVI del polígono de trabajo	19
Figura 14.- Grupo de herramientas de QGIS del toolbox de LAsTools	20
Figura 15.- Herramienta laszipPro del toolbox LAsTools	21
Figura 16.- Fichero txt de la lista de ficheros las	22
Figura 17.- Comando de la herramienta GroundFilter	22
Figura 18.- Comando de la herramienta GridSurfaceCreate	22
Figura 19.- Comando de la herramienta FilterData	23
Figura 20.- Comando de la herramienta CanopyModel	23
Figura 21.- Comando de la herramienta DTM2ASCII	23
Figura 22.- Programa del Google Earth Engine con el polígono de la geometría dibujado	25
Figura 23.- Código de carga de datos	25
Figura 22.- Herramienta ArcGis Aspect	24
Figura 23.- Mapa de orientación para la zona de trabajo	25
Figura 24.- Tabla del fichero segmentado con el indicador	26
Figura 25.- Herramienta de trabajo Fetex	27
Figura 26.- Opciones de los parámetros de textura de Fetex	28
Figura 27.- Opciones de los parámetros de Semivariograma de Fetex	28
Figura 28.- Opciones de los parámetros de Forma de Fetex	28
Figura 29.- Código de carga de datos de las polarizaciones; extracción de características GEE 1	29
Figura 30.- Código de iteración	30
Figura 31.- Código cálculo valor medio	30
Figura 32.- Código creación de la función	30

Figura 33.- Código aplicación función y extracción a csv	31
Figura 34.- Código de carga de datos extracción de características GEE 2	31
Figura 35.- Código de la función de eliminación de nubes extracción de características GEE 2	31
Figura 36.- Código de la iteración función de eliminación de nubes extracción de características GEE 2	32
Figura 37.- Código del cálculo del valor medio extracción de características GEE 2	32
Figura 38.- Código de la segunda función de eliminación de nubes extracción de características GEE 2	32
Figura 39.- Código de exportación del csv extracción de características GEE 2	33
Figura 40.- Código de la función del cálculo NDVI extracción de características GEE 3	33
Figura 41.- Código de la iteración función del cálculo NDVI extracción de características GEE 3	33
Figura 42.- Código del valor medio NDVI extracción de características GEE 3	33
Figura 43.- Código de la segunda función extracción de características GEE 3	34
Figura 44.- Código de exportación del csv extracción de características GEE 3	34
Figura 45.- Herramienta Fusion PolyClipData	34
Figura 46.- Herramienta Fusion CloudMetrics	35
Figura 47.- Ficheros Resultantes Gis-Fetex	35
Figura 48.- Figura de la carga del fichero unión csv en WEKA	38
Figura 49.- Imagen de WEKA con todos los atributos cargados	39
Figura 50.- Imagen de la ventana del proceso de clasificación de WEKA	40
Figura 51.- Segundo resultado del cálculo de clasificación en WEKA	41
Figura 52.- Proceso RandomForest con 200 iteraciones	41
Figura 53.- Proceso RandomForest con 500 iteraciones	41
Figura 54.- Filtros realizados para la obtención de los atributos más relevantes	42
Figura 55.- Atributos restantes después del uso de los filtros	43
Figura 56.- Resultado de la clasificación con los atributos filtrados y 100 iteraciones	44
Figura 57.- Resultado de la clasificación con los atributos filtrados y 200 iteraciones	44
Figura 58.- Resultado de la clasificación con los atributos filtrados y 500 iteraciones	44
Figura 59.- Matriz de confusión usando todos los atributos y polígonos	46
Figura 60.- Matriz de confusión usando todos los polígonos y una selección de atributos	48
Figura 61.- Matriz de confusión usando todos los atributos y un límite de 50 polígonos por método	49
Figura 62.- Matriz de confusión usando una selección de atributos y el límite de 50 polígonos	51
Figura 63.- Ventana de modificación del output de la predicción	51
Figura 64.- Resultado visual de los polígonos ya clasificados	52
Figura 65.- Resultados de las 4 mejores clasificaciones	52

INDICE PROYECTO

Contenido

INDICE IMÁGENES	1
INDICE PROYECTO	3
AGRADECIMIENTOS.....	5
COMPROMISO.....	5
RESUMEN IDEAS CLAVE.....	6
1.- INTRODUCCIÓN.....	7
1.1-OBJETIVOS.....	7
2- DATOS	8
2.1-ZONA DE TRABAJO	8
2.2-CLASES POR COMBUSTIÓN	9
2.3-DATOS INICIALES DESCARGADOS	12
2.4-SOFTWARES UTILIZADOS	13
3.-METODOLOGÍA	14
3.1-SEGMENTACIÓN DE LA ZONA	15
3.1.1-OBTENCIÓN PUNTOS DE LA ZONA.....	15
3.1.2-OBTENCIÓN IMAGEN NDVI DE LA ZONA MEDIANTE CALCULO DE BANDAS Y LAS ORTOS.....	17
3.1.3-OBTENCIÓN MEDIANTE FUSION Y LOS .LAS DE EL MDS NORMALIZADO	20
3.1.4- OBTENCIÓN TIF DE ORIENTACIONES A PARTIR DE DTM OBTENIDO	24
3.2-EXTRACCIÓN DE CARACTERÍSTICAS	26
3.2.1- ASIGNACIÓN IDENTIFICADOR ÚNICO A CADA POLÍGONO.....	26
3.2.2-OBTENCIÓN DE CARACTERÍSTICAS MEDIANTE FETEX	27
3.2.3-OBTENCIÓN DE CARACTERÍSTICAS MEDIANTE GOOGLE EARTH ENGINE	29
3.2.4- OBTENCIÓN DE CARACTERÍSTICAS MEDIANTE FUSION.....	34
3.2.5- OBTENCIÓN DE CARACTERÍSTICAS MEDIANTE QGIS y FETEX.....	35
3.3- CREACIÓN DE LA CLASIFICACIÓN MEDIANTE WEKA.....	37
3.3.1-UNIÓN CAPA PUNTOS CON CAPA DE POLÍGONOS PARA ASIGNACIÓN DE CLASES A LOS POLÍGONOS	37
3.3.2-UNIÓN FICHEROS CARACTERÍSTICAS	37
3.3.3-USO DEL PROGRAMA WEKA	38
4.-RESULTADOS	52

5.-CONCLUSIONES.....	53
6.-BIBLIOGRAFÍA.....	54
7.-ANEXOS.....	55
ANEXO 1.- IMPORTANCIA DE CADA UNO DE LOS TIPOS DE ATRIBUTOS.....	55
ANEXO 2.- PLANO.....	68

AGRADECIMIENTOS

Quiero agradecer en primera estancia a mi familia, a mi padre, a mi madre y a mi hermana. Ellos han estado conmigo durante todo este camino, dándome su apoyo y ánimos durante no solo los meses de trabajo de este proyecto, pero los años de trabajo y esfuerzo que ha sido esta etapa de mi vida.

También quiero agradecer a mis compañeros, con los que he pasado estos dos últimos años y he aprendido junto a ellos. Juntos hemos desarrollado nuestro trabajo en equipo, se han entablado buenas amistades, y hemos sido un apoyo mutuo entre nosotros durante estos dos últimos años de duro trabajo, siempre siendo una mano más en la espalda que nos empuja para caminar hacia adelante y dando motivación para no abandonar.

Por último, quiero dar las gracias al profesorado y equipo docente que durante tantos años han dedicado a enseñarme en esta carrera desde el propio principio, agradezco enormemente sus esfuerzos. Y a mi tutor, quien me ha guiado durante este proyecto lo mejor posible y por su guía durante todos estos meses de trabajo, le quiero dar las gracias.

COMPROMISO

El presente documento ha sido realizado completamente por el firmante; no ha sido entregado como otro trabajo académico previo y todo el material tomado de otras fuentes ha sido convenientemente entrecomillado y citado su origen en el texto, así como referenciado en la bibliografía

RESUMEN IDEAS CLAVE

El proyecto que se va a realizar como el Trabajo Final del Master tiene como objetivo principal la creación de un método de clasificación de zonas u polígonos de vegetación en función de los modelos de combustión que posee cada tipo de vegetación, en función de los atributos de zonas ya clasificadas. Para ello, el proyecto se realizará en 3 grandes apartados.

En el primer paso, se deberá realizar una preparación de los datos, obteniendo mediante softwares GIS y programas como Google Earth Engine, los datos necesarios para poder realizar la segmentación de la zona de trabajo en diferentes polígonos. Para ello se obtendrá el mapa de orientación de la zona, el Modelo Digital De Superficies normalizado y una imagen NDVI, solamente de nuestra zona de trabajo. También se tiene que sacar al principio de todo una capa de puntos de muestra de los diferentes modelos de combustión de la zona.

Una vez ya se ha realizado la segmentación con los datos anteriores, toca la extracción de atributos de los polígonos que se han creado y a los que daremos un identificador por polígono. Se obtendrán diferentes atributos de maneras diferentes, como usando el software Fetex, el Google Earth Engine para sacar diferentes ficheros Excel con información de atributos diferentes, e incluso los software GIS como ArcGIS (ArcMap) y QGis para la obtención de atributos como la orientación media por polígono, la pendiente media y la cota media.

El último paso sería la realización de la clasificación en sí, donde usando el fichero de los polígonos segmentados con identificador, se les da a los polígonos el modelo de combustión más cercano (si tienen) basándonos en la capa de puntos usando herramientas del software GIS, y luego se unen a la capa los diferentes ficheros de atributos que se han obtenido, dejándolo todo en un solo fichero. Este fichero se usará en el programa WEKA para obtener la clasificación final de toda la zona de trabajo, que se visualizará en cualquier software GIS.

1.- INTRODUCCIÓN

Desde el comienzo del año 2022, la cantidad de incendios forestales ocurridos en España ha llegado ya a una cifra desbordante de 37 incendios que han afectado a sectores con más de 500 hectáreas, la mayor cifra registrada en esta última década. Esto demuestra sin duda alguna el peligro y la gravedad que se tienen estos incendios forestales, y la necesidad de mejorar y optimizar los métodos de prevención ante ellos.

Una de las maneras con las que se busca disminuir la peligrosidad de los incendios forestales es en la predicción y modelación del comportamiento de un fuego forestal en base de las características de combustión de cada tipo de vegetación. Esto es debido a que no toda la vegetación tiene la misma reacción y características en su combustión, lo que lleva a diferentes comportamientos durante el incendio dependiendo del tipo de vegetación. Gracias a esto se ha podido crear una clasificación de la vegetación en base a su combustibilidad.

1.1-OBJETIVOS

El objetivo de este proyecto es clasificar los diferentes tipos de combustible forestal de una zona específica de trabajo mediante un método de teledetección de estratificación donde se usan Ortoimágenes y datos LiDAR entre otros datos, para obtener una clasificación de la zona de trabajo del parque natural de la Sierra de Espadán, en Castellón. Al acabar se evaluará la fiabilidad del método realizado.

Para alcanzar dicho objetivo, se tendrán que conseguir los datos necesarios, como el modelo digital de superficies normalizado y la imagen NDVI de la zona de trabajo entre otros, a partir de los datos LiDAR y las Ortoimágenes de dicha zona. Luego se usarán todos estos datos obtenidos en este paso para obtener la capa de polígonos en la que se divide la zona de trabajo por e-cognition. Esta capa servirá para el siguiente paso, donde se tendrán que extraer las características de la zona de trabajo, basándose en los polígonos, mediante diferentes métodos y softwares para obtener las diferentes características deseadas.

Estas características son las que se usarán en el software WEKA para poder realizar la nueva clasificación de los tipos de combustión de la vegetación de los polígonos basándonos en los atributos obtenidos anteriormente. Además, será donde se obtendrá el porcentaje de fiabilidad del método realizado, y se podrá ver si el proceso ha sido suficientemente bien realizado, o se debería mejorar.

2- DATOS

2.1-ZONA DE TRABAJO

Como ya ha sido mencionado con anterioridad, la zona de trabajo en la que se basará el estudio es una parte del parque natural de la sierra de Espadán, que se encuentra en la provincia de Castellón, de la Comunidad Valenciana, entre las comarcas de Plana Baja, Alto Mijares y Alto Palancia. Teniendo un total de 31180 hectáreas, este parque consiguió la posición de espacio natural protegido el 29 de septiembre de 1996.




Figura 1.- Imagen de la sierra del Espadán desde Google Maps

Debido a su alto índice de pluviosidad, y los suelos de rodano que son encontrados en dicha zona, el nivel de humedad que se encuentra en el parque es bastante alto, causa por la cual esta zona es la que contiene la mayor cantidad de alcornoques de, no solo Castellón, sino toda la Comunidad Valenciana. A esto también se le pueden sumar a la masa forestal el pino rodano que se encuentra acompañando en ocasiones a los alcornoques, el matorral (constituido por brezo y enebro), y las zonas de cultivo de algarrobos, olivos, cerezos entre otros. Estos últimos han sido cultivos que desde hace mucho tiempo han ayudado a la economía de la zona.

Como no estudiaremos la zona entera del parque natural, se usará un fichero shape de polígonos (2 de ellos para ser exacto), para marcar la zona especificada del estudio.




Figura 2.- Imagen de las dos zonas de trabajo en la Sierra del Espadán

2.2-CLASES POR COMBUSTIÓN

Para conocer los tipos de clases de combustión que se encuentran en la zona de trabajo, se usará una capa ráster con los modelos de combustible, que será transformada en un shape para poder trabajar en ella. De esta manera , se puede ver qué hay de todos los tipos de clases de vegetación conocidos en “CLAVE PARA LA IDENTIFICACIÓN DE LOS MODELOS DE COMBUSTIBLE DE LA COMUNITAT VALENCIANA”, exceptuando la clase NB8.

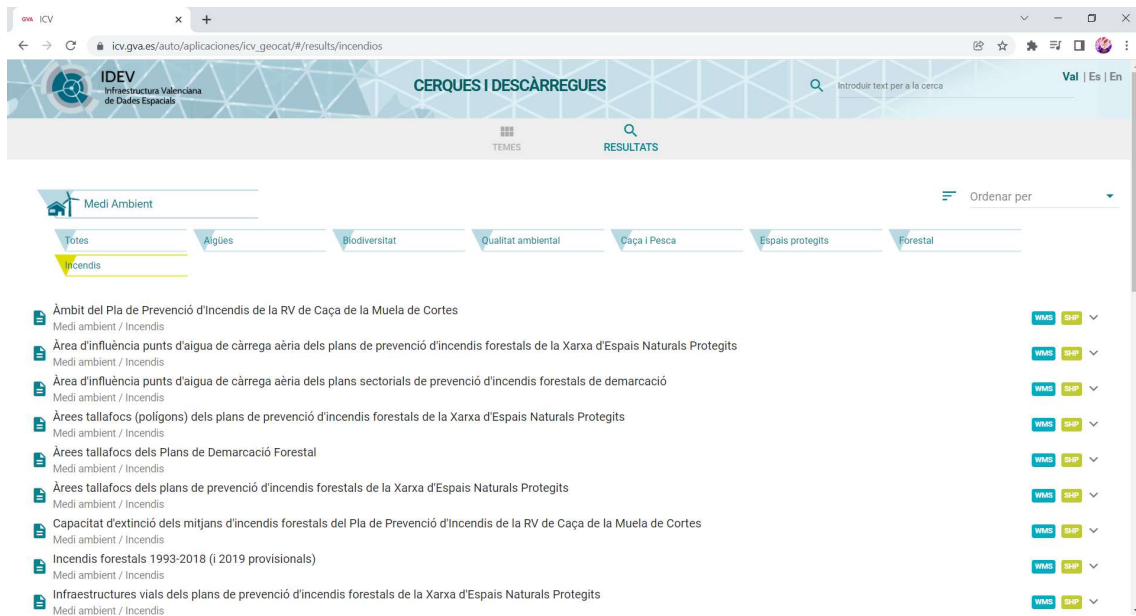


Figura 3.- Apartado de incendios del Centro de descarga del ICV

Estos modelos se dividen en sus propios grupos, como los modelos GR de pasto, SH de matorral, TU de matorral bajo arbolado, modelos incombustibles NB y los modelos de matorral y restos leñosos junto con arbolado adulto SB. [2]

El modelo **GR-2** contiene los pastizales más o menos continuos cuya altura no es superior al metro, típico de campos de cultivo recientemente abandonados entre otras zonas. El conductor del fuego del modelo es el combustible herbáceo, sea natural o pastoreado.

Por su parte, el modelo **GR-4** es aquel que contiene los pastizales de características muy similares al anterior, pero cuya altura supera el metro.

GR-7 es el modelo que representa las zonas húmedas o marjales(carrizales, juncos...). Con una carga de combustible alta y alturas generalmente superiores a 1m.

GR-8 en cambio, representa mayoritariamente las cañas Arundo donax como el combustible mayoritario, aunque se puede juntar a veces con zarzales o juncos.

NB-1 es el grupo de zonas de infraestructuras y suelos urbanos, suburbanos e industriales que son incombustibles, pero que pueden presentar pérdidas estructurales debido a incendios forestales.

NB-3 por su parte, hace referencia a las zonas agrícolas y arrozales como el grupo incombustible, a pesar de que hay ciertas zonas agrícolas que no mantienen dicha condición de incombustibilidad (como las abandonadas o con aquellas donde la hierba ha crecido bajo los árboles).

NB-9 es el suelo desnudo por donde el fuego es incapaz de propagarse, debido a la superficie desprovista de vegetación y demás características cuya falta crean la incombustibilidad del suelo desnudo.

El modelo **SB-3** se encuentra compuesto por matorrales y restos leñosos que cubren un tercio de la superficie de estudio, todo esto junto a una arbolada adulta.

En **SH-1**, nos encontramos con que la propagación del fuego es debida al matorral disperso y a los restos encontrados en esto, aunque contiene una baja carga de combustible y continuidad.

Mientras que en el **SH-3** el fuego sigue creciendo debido a un matorral relativamente disperso, se encuentra más continuo que en el modelo SH-1

El conductor principal del fuego para el modelo **SH-4** suelen ser los arbustos leñosos y las hojarascas de arbusto. Estas especies poseen elevada continuidad.

SH-5 se caracteriza por que su propagación es debida a los matorrales con una gran densidad vertical y horizontal. Dichos matorrales poseen una altura normalmente mayor a 1 metro.

El modelo **SH-9** por su parte, tiene una vegetación proveniente de la combinación de matorrales con una regeneración de arbolado densa y compacta con altura comprendida entre 1.8 y 8 metros.

La propagación del fuego en el modelo **TU-1** es debida a las herbáceas, el matorral y la hojarasca que se encuentra bajo arbolado. También están incluidos los bosques de gran densidad de coníferas.

TU-2 son matorrales inferiores a un metro de altura que se encuentran bajo dosel de un arbolado adulto, pináceo o de quercínea, mientras que **TU-3** es lo mismo para aquellos matorrales superiores a un metro de altura.

Para acabar, existe el modelo de combustible **TU-5**, que comparte características con el modelo TU-3 pero para las exposiciones de umbría, además de una menor inflamabilidad en sus composiciones vegetales y menor velocidad en su propagación.

Parámetros descriptivos	GR-2
FCC arbolado (Hm > = 4 m)	< 30 %
FCC matorral (Hm < 4m)	< 30 %
FCC pastizal (Hm < 4m)	> = 30 %
Altura media (m)	0 < = Hm < =1 m

Características paramétricas	GR-2
Carga de combustibles de 1h (t/ac)	0,1
Carga de combustibles de 10h (t/ac)	0
Carga de combustibles de 100h (t/ac)	0
Carga de combustibles de herbáceas vivas (t/ac)	1
Carga de combustibles de leñosas vivas (t/ac)	0
Tipo de modelo de combustible	Dinámico
SAV de combustibles muertos 1h (1/ft)	2.000
SAV herbáceas (1/ft)	1.800
SAV leñosas (1/ft)	9.999
Profundidad del combustible (ft)	1
Humedad de extinción del combustible muerto (%)	15
Calor de combustión (BTU/lb)	8.000

Figura 4.- Características del Grupo GR2

Como podemos ver en la imagen de la figura 4, cada grupo/modelo tiene sus propias características que los distinguen de las demás. Por un lado, se tienen los datos paramétricos que nos indican la fracción de cabida cubierta de este grupo junto con la altura media correspondiente.

Por otro lado, se tienen las características paramétricas de las que se depende la reacción de la vegetación frente a un fuego. Por un lado, tenemos las cargas combustibles con sus horas de retardo (lapso temporal del combustible donde se pierde o ganan dos tercios de la diferencia del contenido original de humedad y la humedad del ambiente. Como se puede ver, se tienen valores de 1 hora, 10 horas y 100 horas y sus medidas son en toneladas por acre. También hay otros atributos como el tipo de combustión, la profundidad del combustible...

En resumen, estos son los factores con los que se distinguen un modelo de otros, aunque aquellos que forman parte del mismo grupo son más parecidos entre ellos que con otros, pudiendo llegar a encontrarse confusión entre ellos a la hora de clasificarlos.

2.3-DATOS INICIALES DESCARGADOS

El primer tipo de dato a descargar para la realización del proyecto, son los **Ficheros LiDAR 2ª Cobertura** (.laz), que son los ficheros digitales de nubes de puntos 3D obtenidos con LIDAR, de ámbito nacional, tanto a color verdadero(RGB) como infrarrojo(IRC). Se han obtenido desde el centro de descargas del organismo autónomo centro nacional de información geográfica (CNIG), en el apartado de modelos digitales de elevación. Para seleccionar todas las que abarcan nuestra zona de trabajo, se han seleccionado desde la 712 hasta la 726, y de cada una de ellas de la 4422 a la 4432.

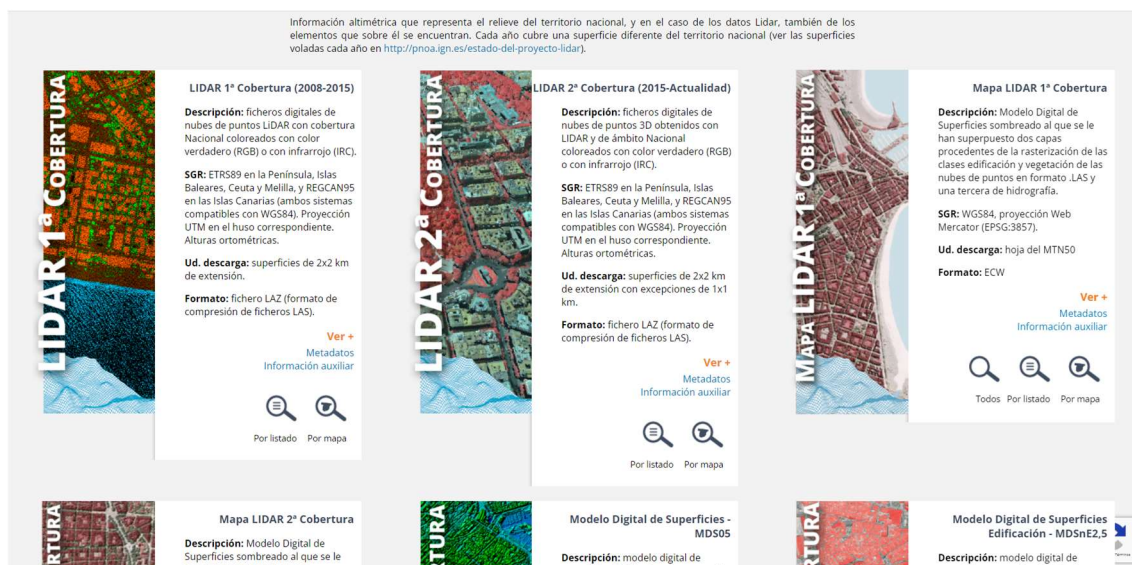


Figura 5.- Centro de descargas de los modelos digitales del CNIG

El segundo tipo de dato que se han descargado para la realización del proyecto, son las **Ortofotos correspondientes a la zona de trabajo** que abarca los polígonos del fichero shape desde el propio catálogo de metadatos del ICV. Se han elegido las Ortoimágenes con las bandas RGBI porque serán usadas para el cálculo del NDVI como uno de sus usos, y por ello se descargan en fichero TIFF. Se han elegido las correspondientes al año 2018 con 25 centímetros de resolución, y se han seleccionado todas (las 4) las correspondientes 639-8, 640-1, 640-2, 640-3, 640-4).



Figura 6.- Grupo de Ortofotos elegidas para la descarga

2.4-SOFTWARES UTILIZADOS

FUSION: EL software FUSION es un programa gratuito que proporciona la visualización 3D, examinación y valoración/análisis de datos LiDAR, capas SIG y modelos de superficie. Su desarrollo viene a manos del Servicio Forestal del Departamento de Agricultura de Estados Unidos (USDA). [4]

FETEX: Este software tiene como función la extracción de características de forma automática de imágenes u objetos-imagen, orientado a objetos cartográficos definidos mediante Shapefiles e imágenes satélites. [5]

GOOGLE EARTH ENGINE: Es una Plataforma online de Google que nos ayuda a la visualización y análisis de imágenes satélite mediante estudios de teledetección entre otros métodos. [3]

ECOGNITION: Potente software de teledetección que permite, mediante una extracción previa de características, transformar datos geográficos en información geográfica.

QGIS: Software libre de SIG (Sistema de Información Geográfica) y de código abierto, que nos facilita el uso de datos en formatos ráster y vectoriales mediante la biblioteca GDAL (GADL/OGR), así como bases de datos. [8]

ARCGIS: Nomenclatura del paquete de softwares en el campo de los SIG (*Sistemas de Información Geográfica*) producido y comercializado por ESRI. Agrupa la capacidad de utilizar varias aplicaciones para la captura, edición, análisis, tratamiento, diseño, publicación e impresión de información geográfica. [7]

WEKA: Weka (*Waikato Environment for Knowledge Analysis,*) es el software que se usa para el aprendizaje automático y la minería de datos mediante el uso de Java. Fue creado en la Universidad de Waikato, de ahí la primera palabra de su nombre completo. El software Weka es capaz de realizar diferentes trabajos relacionados con la minería de datos. Entre ellos tenemos los ejemplos de preprocesamiento de datos, clustering, clasificación, regresión, visualización, y selección. En este proyecto nos será necesario el de clasificación. [6]

3.-METODOLOGÍA

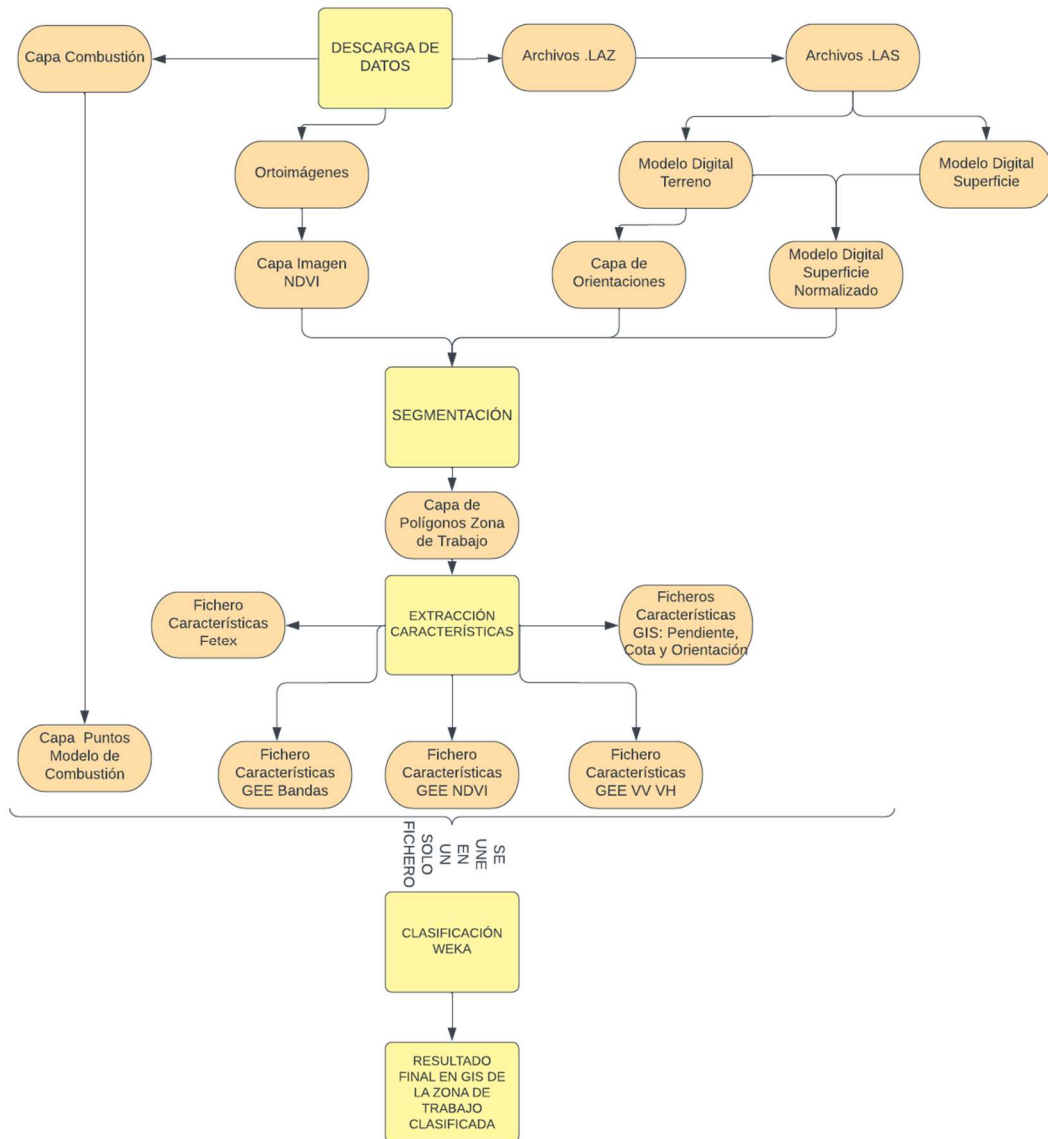


Figura 7.- Flujo de Trabajo

3.1-SEGMENTACIÓN DE LA ZONA

3.1.1-OBTENCIÓN PUNTOS DE LA ZONA

El primer paso del proyecto es la obtención de nuestra zona de trabajo clasificada en sus distintos modelos de combustión, consiguiendo esto a partir de la imagen raster de los modelos de combustión obtenidos. Para empezar, se deberá recortar esta cartografía de combustión con el shape polígono de la zona de trabajo, lo que no solo nos marcará la zona de trabajo para obtener posteriormente la visualización los diferentes modelos de combustión de la zona, sino que también disminuye bastante el tamaño del fichero, agilizando el trabajo. También tenemos que realizar la transformación de la imagen a una capa shape de polígonos, y luego eligiendo el campo de los modelos de combustión realizar una simbología para distinguir cada tipo.

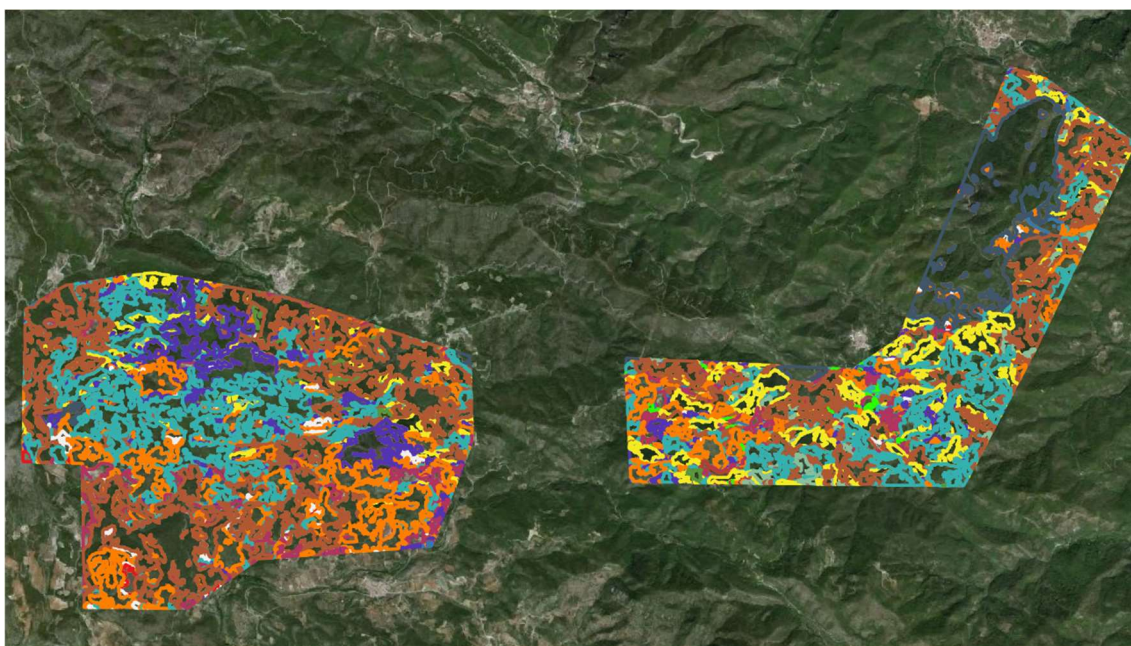


Figura 8.- Polígonos dentro de la zona de trabajo clasificados por modelos de combustión

Luego, se tienen que conseguir puntos de ejemplo para cada clase dentro de la zona de trabajo. El método de selección de la cantidad de puntos ha sido basado en la cantidad de polígonos por método de combustión, puesto que la cantidad de puntos a seleccionar por grupo es un 5% del total de números de polígonos por método, pero poniendo un mínimo de 30 puntos. Si por algún casual, el número de polígonos es inferior a 30, se selecciona como mínimo un punto por polígono y más si el polígono es lo suficientemente grande y tienen suficiente distancia entre ellos. Al final, la cantidad de puntos por grupo es:

GR2 = 277 polígonos, el 5% de ellos es igual a 14, cogemos un mínimo de 30 puntos

GR4 = 261 polígonos, el 5% de ellos es igual a 13, cogemos un mínimo de 30 puntos

GR7 = 32 polígonos, el 5% de ellos es igual a 2, cogemos un mínimo de 30 puntos

GR8 = 2 polígonos, el 5% de ellos es igual a 1, cogemos un mínimo de 2 puntos

NB1 = 13 polígonos, el 5% de ellos es igual a 1, cogemos un mínimo de 13 puntos

NB3 = 442 polígonos, el 5% de ellos es igual a 22, cogemos un mínimo de 30 puntos

NB9 = 16 polígonos, el 5% de ellos es igual a 1, cogemos un mínimo de 16 puntos

SB3 = 147 polígonos, el 5% de ellos es igual a 7, cogemos un mínimo de 30 puntos

SH1 = 39 polígonos, el 5% de ellos es igual a 2, cogemos un mínimo de 30 puntos (debido a la gran proximidad entre ciertos polígonos de este grupo, solo se han acabado seleccionando 26 puntos)

SH3 = 342 polígonos, el 5% de ellos es igual a 17, cogemos un mínimo de 30 puntos

SH4 = 2136 polígonos, el 5% de ellos es igual a 107, cogemos un mínimo de 107 puntos

TU5 = 1624 polígonos, el 5% de ellos es igual a 81, cogemos un mínimo de 81 puntos

SH5 = 2119 polígonos, el 5% de ellos es igual a 106, cogemos un mínimo de 106 puntos

SH9 = 135 polígonos, el 5% de ellos es igual a 7, cogemos un mínimo de 30 puntos

TU1 = 677 polígonos, el 5% de ellos es igual a 34, cogemos un mínimo de 34 puntos

TU2 = 3371 polígonos, el 5% de ellos es igual a 169, cogemos un mínimo de 169 puntos

TU3 = 3237 polígonos, el 5% de ellos es igual a 162, cogemos un mínimo de 162 puntos

En total, se van a crear un total de 964 puntos correspondientes a las diferentes clases de combustión en la nueva capa dependiendo del polígono donde se hayan seleccionado. Para diferenciar entre las clases de los puntos, se ha creado una segunda columna en la tabla de atributos donde se define el modelo de combustión de cada uno.

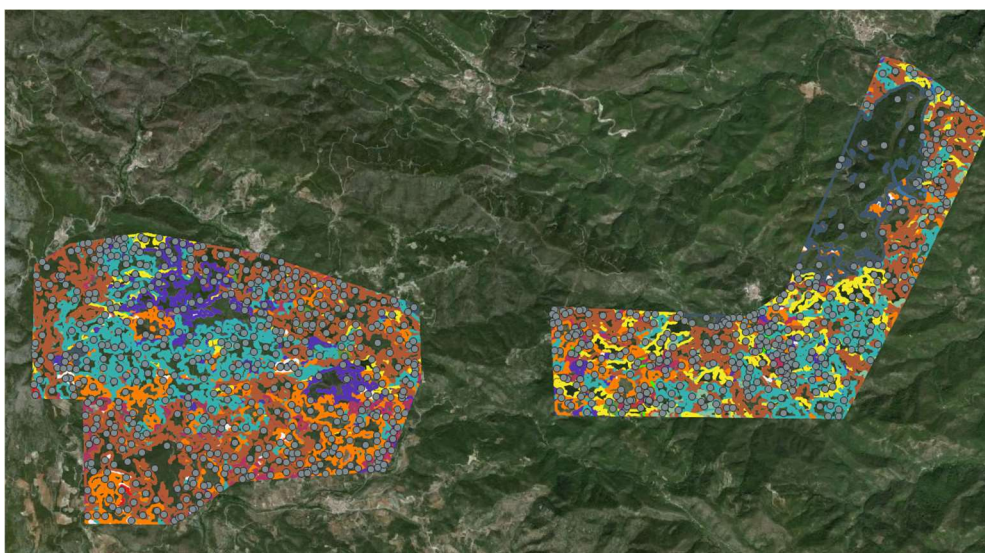


Figura 9.- Puntos de muestra de los diferentes modelos de combustión de nuestra zona

3.1.2-OBTENCIÓN IMAGEN NDVI DE LA ZONA MEDIANTE CALCULO DE BANDAS Y LAS ORTOS

Para poder calcular el valor NDVI de la zona de trabajo, mediante imágenes representativas de este, nos vamos a tener que basar en las imágenes tif de las Ortofotos descargadas. Estas imágenes, al estar en formato tif, poseen 4 bandas diferentes, la Roja, la Verde, la Azul y la Infrarroja. Mediante la Raster Calculator de QGIS, programa en el cual realizaremos el proceso, se han calculado la imagen NDVI de cada una de las ortofotos mediante la fórmula del NDVI.

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

Figura 10.- Fórmula para el cálculo del NDVI a partir de las bandas de una imagen RGBI

Esto se realizará para cada una de las ortofotos en nuestra posesión. El siguiente paso, consistiría en unir las, pero se han encontrado ciertos impedimentos que nos han obligado a realizar ciertos cálculos primero.




Figura 11.- Conjunto de todas las diferentes imágenes NDVI calculadas.

Las imágenes NDVI de cada zona pesaban demasiado como para poder unirse, tardando más de 48 horas procesando sin mostrar indicios de que fuera a acabar, se han tenido que realizar una serie de transformaciones para cada una de las imágenes para reducir su tamaño, y al mismo tiempo entender de manera más sencilla sus valores.

La primera transformación es la transformación de los valores de gris de la imagen NDVI de cada ortofoto a una escala que tenga de rango del valor 0 al 255. Para poder realizar eso, se ha vuelto a usar la calculadora raster, usando la fórmula $(x+1)*255/2$, donde X es la ortofoto que se está calculando en ese momento. La imagen resultante sigue pesando bastante, por lo que el siguiente paso es transformar el tipo de imagen con la que nos encontramos, por lo que se han guardado como archivos byte cada una de las imágenes NDVI resultantes.

Una vez se tienen las imágenes transformadas, ya se han podido unir todas las imágenes, aunque para asegurarnos de no sobrecargar el programa, se han ido uniendo primero en grupos correspondientes a las hojas pertenecientes de cada ortofoto (1,2,3,4 y 8). Luego se han unido los 5 grupos, dando como resultado la imagen unión final




Figura 12.- Unión de todas las imágenes NDVI calculadas en una sola

Como el resultado buscado no es de toda la zona, sino de nuestra zona de trabajo, pero no queremos quitar demasiados valores que puedan afectar a los valores obtenidos, se ha creado una capa de polígono simple que engloba los dos polígonos de nuestra zona de trabajo. Este fichero shape, servirá de máscara para la obtención de la zona de estudio con la que se trabajará hasta la obtención de la clasificación final. Una vez obtenida, solo se tiene que usar como la máscara en la herramienta de extracción con máscara de QGis para obtener el resultado final del NDVI de la zona deseada.




Figura 13.- Recorte de la imagen NDVI del polígono de trabajo

3.1.3-OBTENCIÓN MEDIANTE FUSION Y LOS .LAS DE EL MDS NORMALIZADO

Para poder trabajar con los archivos LiDAR en Fusion, primero se tuvieron que transformar de .laz a .las, cosa que se realizó mediante una herramienta de QGIS. Esta herramienta proviene de una toolbox externa que se ha instalado en QGIS que se llama LAStools. Más concretamente, la que se va a utilizar es la herramienta dentro de la sección de folder-conversion llamada laszipPro, que nos permite utilizar todos los ficheros .laz de una carpeta de golpe, en vez de ir transformándolos de uno en uno.

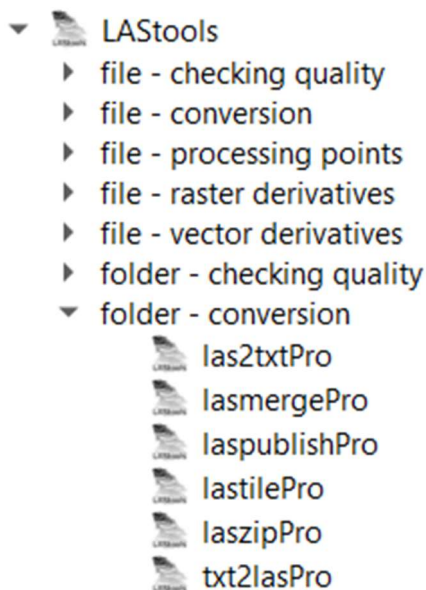


Figura 14.- Grupo de herramientas de QGIS del toolbox de LAStools

Para usar la herramienta, se tiene que primero especificar la carpeta donde se encuentran los ficheros datos a transformar, luego se seleccionó cual es la terminación deseada. Como los ficheros base se encuentran en formato .laz, este no nos sirve ya que Fusion solo trabaja con los ficheros LiDar en formato .las, por lo que esa será la solución de la opción Output Format. Solo queda especificar el fichero donde se quieren los ficheros .las resultantes y dejamos que la herramienta realice su función

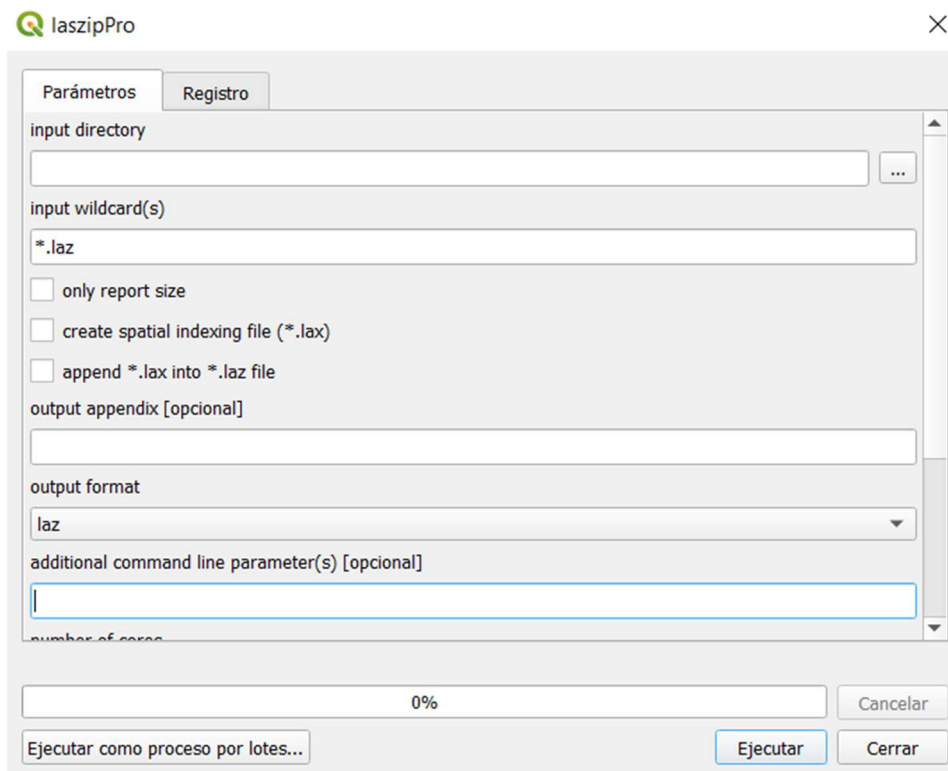



Figura 15.- Herramienta laszipPro del toolbox LAStools

Luego, dentro de la propia carpeta donde se guardaron todos los nuevos archivos en formato .las, tenemos que crear un fichero txt con el nombre que queramos pero que indique cuál es su uso. En este fichero, es donde se escribirá las dirección de cada uno de los ficheros .las resultantes junto con la dirección de la carpeta donde se encuentran. De esta manera, usando ese fichero txt, nos servirá como una manera para poder trabajar con todos los ficheros .las al mismo tiempo con las diferentes herramientas de Fusion.

 listplota.txt: Bloc de notas

Archivo Edición Formato Ver Ayuda

```
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_710-4422_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_710-4424_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_710-4426_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_710-4428_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_710-4430_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_710-4432_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_712-4422_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_712-4424_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_712-4426_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_712-4428_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_712-4430_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_712-4432_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_714-4422_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_714-4424_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_714-4426_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_714-4428_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_714-4430_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_714-4432_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_716-4422_ORT-CLA-RGB.las
D:\tfm\las\RGB\PNOA_2017_CLM-CAS_716-4424_ORT-CLA-RGB.las
```

Figura 16.- Fichero txt de la lista de ficheros las

Para poder calcular el modelo digital de superficies normalizado, se tiene que conseguir primero el modelo digital terreno y el modelo digital de superficie mediante Fusion. Para ello se han creado 5 archivos .bat diferentes, cada uno realizando un paso para obtener los dos modelos.

En el primer paso, se ha usado la herramienta de Fusion GroundFilter para realizar un filtrado terreno de los puntos de nuestra lista de ficheros, obteniendo de esta manera un solo fichero .las de toda nuestra zona con los puntos filtrado.

```
1 C:\fusionlatest\GroundFilter /gparam:-1 /wparam:1 D:\tfm\las\RGB\terrainpointsRGB15.las 1.5 D:\tfm\las\RGB\listplota.txt
```

Figura 17.- Comando de la herramienta GroundFilter

En el segundo, se ha usado la herramienta GridSurfaceCreate para crear el modelo digital terreno a partir del fichero .las obtenido con anterioridad.

```
C:\fusionlatest\GridSurfaceCreate D:\tfm\las\RGB\pc_dtmRGB15.dtm 2 m m 1 30 0 0 D:\tfm\las\RGB\terrainpointsRGB15.las
```

Figura 18.- Comando de la herramienta GridSurfaceCreate

El tercer paso consiste en la realización de otro tipo de filtrado a la lista original de puntos, mediante FilterData, para la obtención del fichero .las que nos servirá como base para la creación del Modelo Digital de Superficies con Fusion.

```
1 C:\fusionlatest\FILTERData /minpts:3 outlier 4.5 5 D:\tfm\las\RGB\pointsfilteredRGB15.las D:\tfm\las\RGB\listplota.txt
```

Figura 19.- Comando de la herramienta FilterData

Como se ha mencionado con anterioridad, el siguiente paso consiste en la creación del modelo digital de superficies a partir del fichero de puntos filtrados .las que se ha conseguido con el programa bat (el batch file) anterior. Para ello, nos valdremos de la herramienta de Fusion conocida como CanopyModel, que nos dará como resultado el fichero del DSM deseado.

```
C:\fusionlatest\CanopyModel D:\tfm\las\RGB\pc_dsmRGB15.dtm 2 m m 1 30 0 0 D:\tfm\las\RGB\pointsfilteredRGB15.las
```

Figura 20.- Comando de la herramienta CanopyModel

El último paso realizado en FUSION para este apartado es la transformación de los dos modelos digitales obtenidos a formato ASCII. Esto es necesario porque luego se tendrán que usar ambos para el cálculo del modelo digital de superficies normalizado. La herramienta necesaria para ello de FUSION es DTM2ASCII

```
2009.bat x 2015.bat x 2012.bat x 2009F.bat x fusion6.bat x fusion1.bat x fusion2.bat x
1 C:\fusionlatest\DTM2ASCII /raster D:\tfm\las\RGB\pc_dtmRGB15.dtm
2 C:\fusionlatest\DTM2ASCII /raster D:\tfm\las\RGB\pc_dsmRGB15.dtm
```

Figura 21.- Comando de la herramienta DTM2ASCII

Ahora, ya con ambos modelos digitales en formato ASCII, se podrán cargar en el software GIS deseado para realizar el cálculo para obtener el modelo digital de superficies normalizado. En este caso se ha usado el software libre de QGIS, donde se han cargado ambos modelos y calculado el modelo digital de superficies normalizado mediante la diferencia de los dos modelos originales usando la calculadora ráster que el propio QGIS nos ofrece.

3.1.4- OBTENCIÓN TIF DE ORIENTACIONES A PARTIR DE DTM OBTENIDO

El mapa de orientaciones es bastante simple de obtener usando el software de ArcGis, ArcMap, que es lo que se ha realizado. Para ello se cargará en ArcMap el modelo digital terreno obtenido mediante Fusion, en formato ASCII. Luego, en la caja de herramientas, se sigue el camino que se puede ver en la imagen

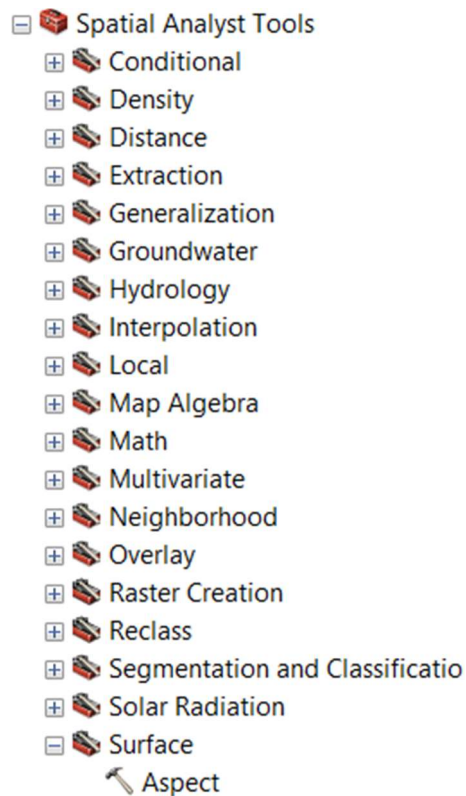


Figura 22.- Herramienta ArcGis Aspect

La herramienta Aspect es la que se va a usar para obtener el mapa de orientaciones y, en ella, solo tendremos que cargar el modelo digital del terreno e indicar donde queremos que nos guarde el mapa de orientaciones resultantes.




Figura 23.- Mapa de orientación para la zona de trabajo

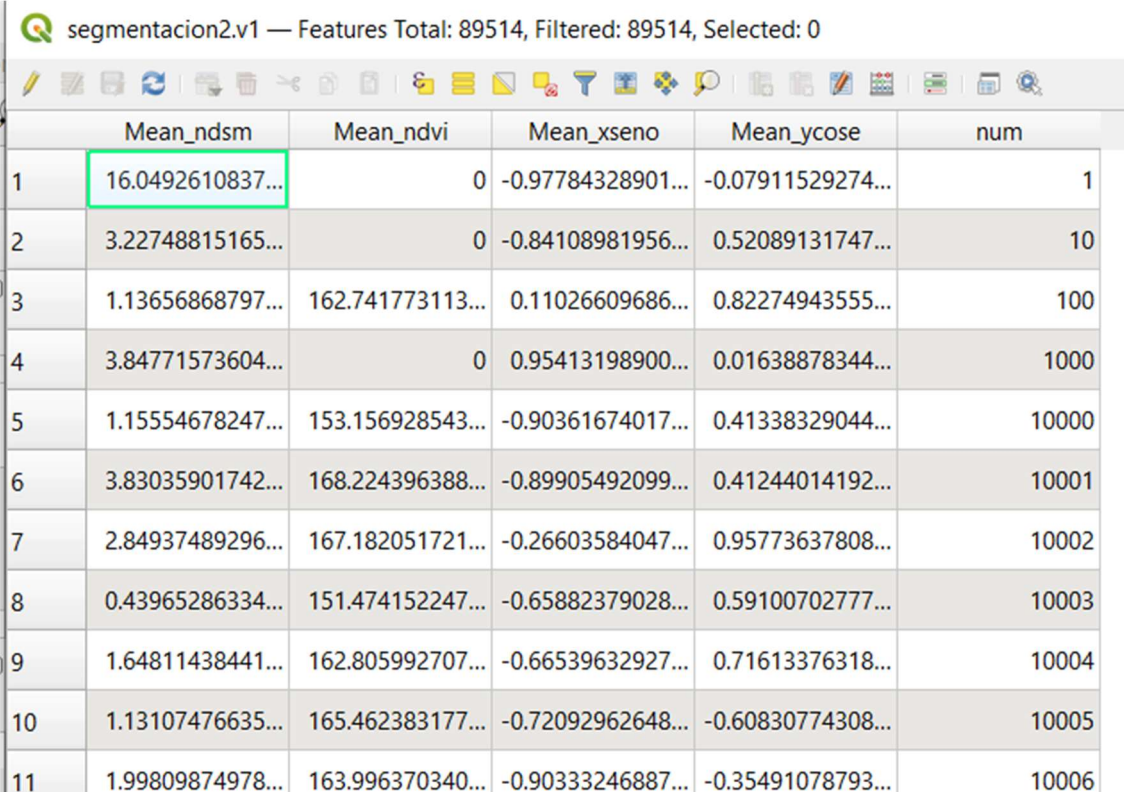
Ya solo queda realizar la segmentación de la zona de trabajo en los polígonos, objetivo de esta parte del trabajo. Para ello, se usará el software E-cognition, y como datos se usarán en formato tif, la imagen NDVI de la zona, la imagen de Orientación (que se ha dividido en 2 capas correspondientes al seno y coseno de la orientación) y el nDSM. En E-cognition, con los parámetros de un factor de escala de 80, se aplica el algoritmo *Multiresolution segmentation* y se obtendrá el fichero deseado que servirá de base para la extracción de características de los polígonos.

3.2-EXTRACCIÓN DE CARACTERÍSTICAS

Ahora que ya tenemos la zona de trabajo dividida por polígonos gracias al programa ecognition, se tienen que sacar las características de cada uno de los polígonos, que serán las que luego nos sirvan para clasificarlos con su modelo de combustión correspondiente. Se van a usar diferentes métodos y programas para la extracción de características, con el objetivo de buscar características diferentes y tener más información que pueda posteriormente facilitar la clasificación. Para facilitar la resolución del proyecto, se analizarán solamente los 900 polígonos que han sido clasificados manualmente, de esta manera se sacará un modelo de trabajo que se podría extrapolar al conjunto de los 80000 polígonos totales sin ningún problema para obtener una solución total.

3.2.1- ASIGNACIÓN IDENTIFICADOR ÚNICO A CADA POLÍGONO

Lo primero, antes que nada, es crear en el fichero shape de los polígonos una nueva columna que se rellenará con un nuevo identificador propio para cada polígono. Esto se ha realizado con el objetivo de facilitar la unión de los diferentes ficheros de características extraídos del fichero shapefile de polígonos, mediante el uso de una columna en común, en este caso la columna id, donde cada uno de los más de 900 polígonos clasificados que tenemos tiene su propio número con su orden.



segmentacion2.v1 — Features Total: 89514, Filtered: 89514, Selected: 0

	Mean_ndsm	Mean_ndvi	Mean_xseno	Mean_ycose	num
1	16.0492610837...	0	-0.97784328901...	-0.07911529274...	1
2	3.22748815165...	0	-0.84108981956...	0.52089131747...	10
3	1.13656868797...	162.741773113...	0.11026609686...	0.82274943555...	100
4	3.84771573604...	0	0.95413198900...	0.01638878344...	1000
5	1.15554678247...	153.156928543...	-0.90361674017...	0.41338329044...	10000
6	3.83035901742...	168.224396388...	-0.89905492099...	0.41244014192...	10001
7	2.84937489296...	167.182051721...	-0.26603584047...	0.95773637808...	10002
8	0.43965286334...	151.474152247...	-0.65882379028...	0.59100702777...	10003
9	1.64811438441...	162.805992707...	-0.66539632927...	0.71613376318...	10004
10	1.13107476635...	165.462383177...	-0.72092962648...	-0.60830774308...	10005
11	1.99809874978...	163.996370340...	-0.90333246887...	-0.35491078793...	10006

Figura 24.- Tabla del fichero segmentado con el indicador

3.2.2-OBTENCIÓN DE CARACTERÍSTICAS MEDIANTE FETEX

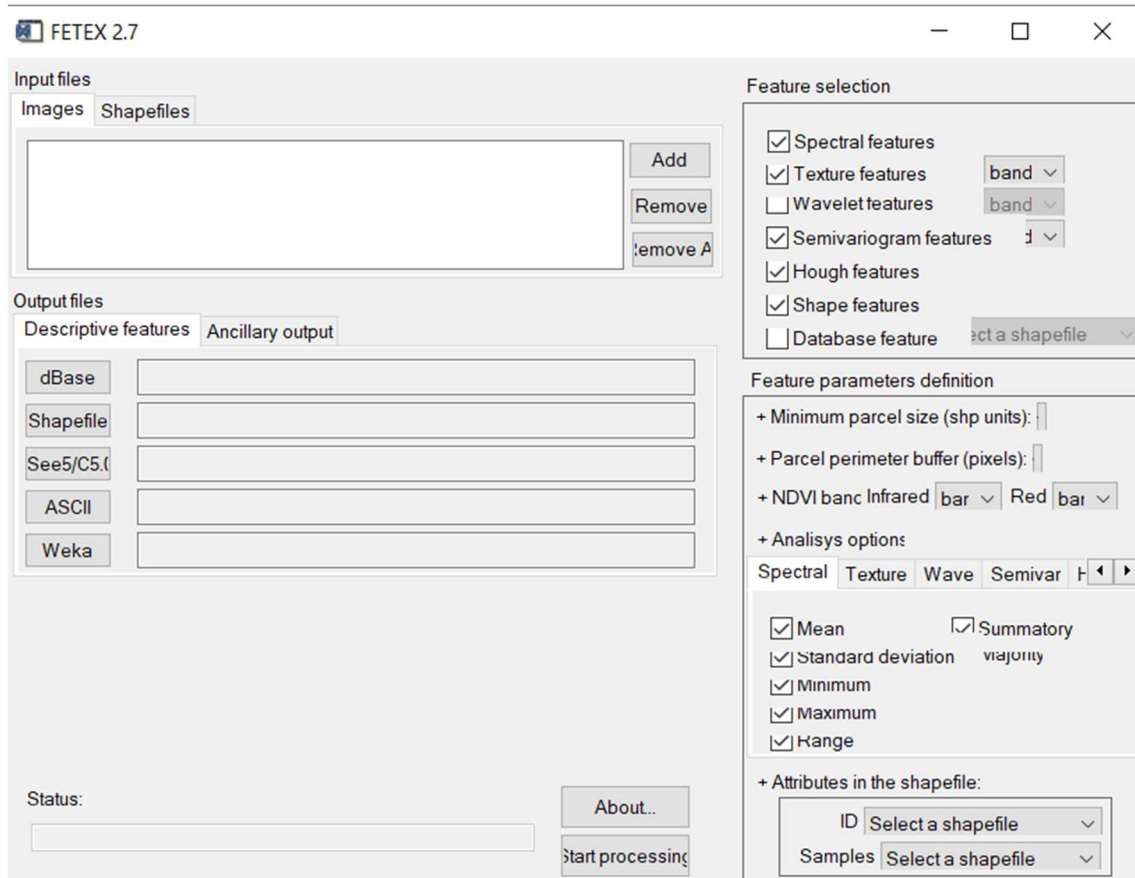


Figura 25.- Herramienta de trabajo Fetex

El primer método para la extracción de características será mediante el uso del software FETEX2, usando la versión 2.7 del programa. Los datos que se necesitan introducir para la obtención del primer fichero de características son dos:

- En la ventana de Images se tienen que cargar todas las ortofotos que se descargaron originalmente del ICV de nuestra zona, las que se usaron para calcular la imagen NDVI.
- En la ventana de Shapefiles, por su parte, se introducirá el fichero shape de polígonos ya con la columna de identificación creada y rellena.

Una vez se han añadido los datos, se tiene que indicar qué características se quiere exactamente obtener. Para ello se seleccionan las que se desean usar en la ventana de Feature Selection, siendo en nuestro caso las características espectrales, las características de textura, las características de semivariograma y las características de forma.

Luego se tiene que dar una mayor definición a los parámetros tanto que queremos como de los datos. Se dejan el tamaño mínimo de parcela y el buffer del perímetro de parcela en los

valores predeterminados, y se indica los valores de las bandas de la imagen para el cálculo del NDVI. En este caso la banda roja es la 1 y la infrarroja es la 4.

Ahora seleccionamos de cada característica los valores que deseamos, siendo por ejemplo la media, desviación estándar, el mínimo, el máximo, el rango y moda de las opciones presentadas. Por su parte, de los otros tres tipos de características, se desean todas las opciones:

- Para las características de Textura:

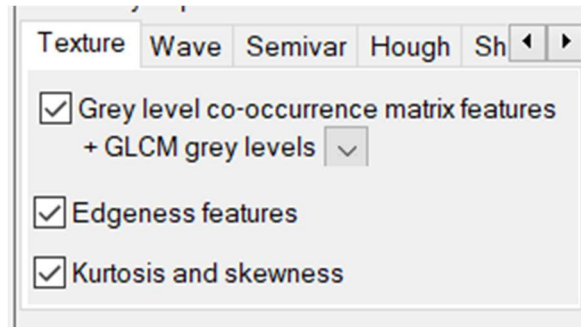


Figura 26.- Opciones de los parámetros de textura de Fetex

- Para las características de Semivariograma

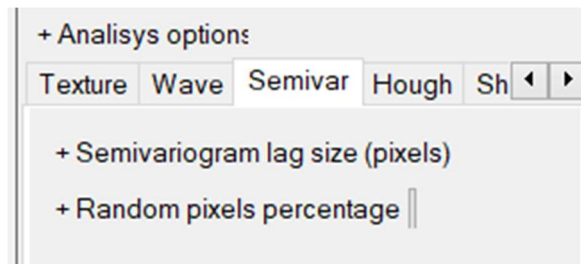


Figura 27.- Opciones de los parámetros de Semivariograma de Fetex

- Para las características de forma

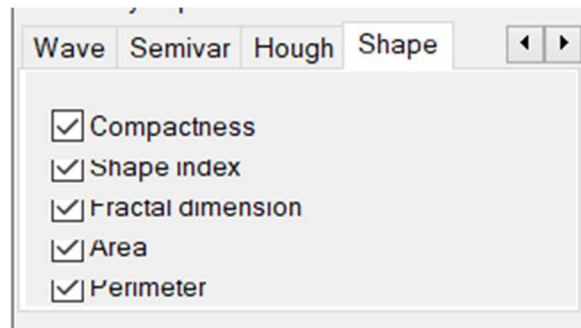


Figura 28.- Opciones de los parámetros de Forma de Fetex

Y ya solo quedaría marcar la columna identificadora que hemos creado en el shapefile de polígonos como el atributo correspondiente al ID en el shapefile para tener todos los parámetros de las características necesarios definidos. Solo queda rellenar en el apartado de Output files el tipo de fichero que queremos que nos devuelva con los resultados de la extracción de característica, y dónde nos lo crea. En esta situación se ha elegido un modelo base para tener el fichero en terminación .csv.

El proceso se repetirá para la obtención de otro tipo de datos, usando como el fichero de imágenes el nDSM en extensión tif sacado con anterioridad. De este apartado, solo se pedirán los atributos de las características espectrales.

3.2.3-OBTENCIÓN DE CARACTERÍSTICAS MEDIANTE GOOGLE EARTH ENGINE

Las características extraídas mediante el programa Google Earth Engine son 3 diferentes. El primero es, una vez más, la extracción de las polarizaciones VV y VH medias de todo el año 2019 referidas al fichero de polígonos creado, donde cada polígono de los 900 clasificados tendrá su valor propio.

En la primera parte del código, se tendrán que cargar los ficheros datos necesarios para el código. En este caso se trata del fichero de polígonos que se ha creado inicialmente, al que se le ha dado el nombre de shape. También se tendrá que dibujar en el propio mapa de Google Earth Engine una geometría simple de nuestra zona de trabajo que nos servirá para reducir la zona del cálculo.

```
Imports (4 entries)
▶ var geometry: Polygon, 4 vertices
▶ var shape1: Table users/JosviAlcover/true_comb_modelo
▶ var shape: Table users/JosviAlcover/puntos
▶ var shape2: Table users/JosviAlcover/shape2
// Map.addLayer(geometry,undefined,'geometria');
// Map.addLayer(shape,undefined,'shape');
// Map.centerObject(geometry,12);
```

Figura 29.- Código de carga de datos de las polarizaciones; extracción de características GEE 1

Luego, se realiza el cálculo de las polarizaciones, introduciendo primero la colección de imágenes de Sentinel 1 para la zona y fecha indicada (se va a realizar un cálculo quincenal para todo el año, siendo cada variable resultante la mitad del mes correspondiente), y luego se realiza un filtrado de la variable para obtener la polarización deseada de ella. Primero se calculará la VH y luego se calculará la VV siguiendo el mismo código, pero cambiando solo el filtrado para tener un único resultado cada vez).

Para acabar este apartado del código, se ha especificado que solo se busquen los valores descendentes, y que al final, nos devuelva el resultado medio de la quincena correspondiente, que quedará como una variable con su propio nombre para poder identificar. Esto, como ya ha sido mencionado, se tendrá que realizar para todas las quincenas del año, obteniendo así un total de 24 variables diferentes.

```

// ITERA 1
var sentinel1 = ee.ImageCollection('COPERNICUS/S1_GRD').filterBounds(geometry).filterDate('2019-01-01','2019-01-16');
var vh = sentinel1.filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
.filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
.filter(ee.Filter.eq('instrumentMode', 'IW'));
var vhDescending = vh.filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'));
var mediaVVdes1=vhDescending.select("VV").mean().rename('M_VVdes_2019JAN1');

// ITERA 2
var sentinel1 = ee.ImageCollection('COPERNICUS/S1_GRD').filterBounds(geometry).filterDate('2019-01-16','2019-02-01');
var vh = sentinel1.filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
.filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
.filter(ee.Filter.eq('instrumentMode', 'IW'));
var vhDescending = vh.filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'));
var mediaVVdes2=vhDescending.select("VV").mean().rename('N_VVdes_2019JAN2');

// ITERA 3
var sentinel1 = ee.ImageCollection('COPERNICUS/S1_GRD').filterBounds(geometry).filterDate('2019-02-01','2019-02-16');
var vh = sentinel1.filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
.filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VH'))
.filter(ee.Filter.eq('instrumentMode', 'IW'));
var vhDescending = vh.filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'));
var mediaVVdes3=vhDescending.select("VV").mean().rename('M_VVdes_2019FEB1');

```

Figura 30.- Código de iteración

Con las 24 variables, podemos ser capaces de calcular la variable mediaVVdes2019 y mediaVHdes2019, que contienen las 24 imágenes con los valores de polarización medio para cada quincena.

```
var mediaVVdes2019=ee.Image.cat(mediaVVdes1,mediaVVdes2,mediaVVdes3,mediaVVdes4,mediaVVdes5,mediaVVdes6,mediaVVdes7,med
```

Figura 31.- Código cálculo valor medio

El último paso importante, es la creación de una función que aplique todos los pasos creados anteriormente para calcular la media de las polarizaciones, y al mismo tiempo nos devuelva el resultado reducido a la geometría simple de cada uno de nuestros polígonos, devolviéndonos dicho resultado.

```

function estadVVdes(feature) {
  return feature.set(mediaVVdes2019.reduceRegion({
    reducer: ee.Reducer.mean(),
    scale:5,
    geometry: feature.geometry(),
    maxPixels: 100000000,
    bestEffort:true
  }));
}

```

Figura 32.- Código creación de la función

Lo único que queda por hacer es la aplicación de la función creada anteriormente con el fichero de polígonos, al que se ha nombrado en Google Earth Engine como shape. Al resultado de este cálculo se le dará el nombre de parcelastats3, y será una variable, puesto que luego se querrá exportar dicha variable al Drive con el nombre verdadero que le queramos dar (VVDdesSeg2019), que será exportada como un fichero CSV.


```

3
4 var parcelastats3=shape2.map(estadVVdes);
5
6 Export.table.toDrive(parcelastats3,'VVDesSeg2019');
7

```

Figura 33.- Código aplicación función y extracción a csv

El segundo grupo de características que se tiene que conseguir a partir de Google Earth Engine es el valor medio quincenal de las bandas 2,3,4,5,6,7,8,11 y 12 de las imágenes de la zona de trabajo para Sentinel-2 de Copernicus. El proceso para la obtención de estos ficheros es bastante similar al anterior donde primero se cargan los datos externos(el fichero shapefile de los polígonos clasificados ya con identificador).

```

Imports (3 entries)
▶ var geometry2: Polygon, 6 vertices
▶ var shape: Table users/JosviAlcover/ParcExt
▶ var shape2: Table users/JosviAlcover/segmentacion2
var SentinelCol = ee.ImageCollection("COPERNICUS/S2_SR");

```

Figura 34.- Código de carga de datos extracción de características GEE 2

Luego se ha llamado como variable a la colección de imágenes de Sentinel2 de Copernicus, para poder usarla en pasos posteriores con mayor facilidad, y se ha hecho lo mismo con la tabla correspondiente a la geometría subida por nosotros.

Entonces, nos queda usar una función que nos permita eliminar el efecto de las nubes de nuestras imágenes, para tener un mejor resultado final. Esta función será utilizada en pasos posteriores del código. Es importante especificar con qué banda se está trabajando en este momento, pues el código se va a tener que repetir para cada una de las bandas de estudio.

```

//función para eliminar nubes
function maskS2clouds(image) {
  var qa = image.select('QA60');
  // var bandas=image.select('B2','B3','B4','B5','B6','B7','B8','B11','B12');
  var bandas=image.select('B2');
  // Bits 10 and 11 are clouds and cirrus, respectively.
  var cloudBitMask = 1 << 10; //pone el valor del bit 10 en el 1
  var cirrusBitMask = 1 << 11; //pone el valor del bit 11 en el 1

  // Both flags should be set to zero, indicating clear conditions.
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0)); //crea una mascara con lo spixeles que son 0 en las dos mascaras anterior
  return bandas.updateMask(mask).divide(10000);
}

```

Figura 35.- Código de la función de eliminación de nubes extracción de características GEE 2

Como se tiene que sacar un valor para cada quincena del año, se tendrá un total de 24 valores y variables diferentes para cada polígono. Esto significa la repetición del proceso y el código unas 24 veces para obtener el valor medio de cada quincena, aplicando la reducción de la geometría y el filtro de fecha deseado a la imagen. Entonces se calcula la media y se nombra con una variable indicando fecha y banda usada.

```
// QUINCENA 1-----
//filtro por geometria
var Sentinel=SentinelCol.filterBounds(geometry).filterDate('2019-01-01','2019-01-16').filterMetadata('MGRS_TILE', "contair
var Sentinel_sin_nubes=Sentinel.map(maskS2clouds);

var Senmedian1=Sentinel_sin_nubes.median().rename('A_B2_ENE1_2019');
// Map.addLayer(NDVImax1,undefined,'NDVImax1');

// QUINCENA 2-----
//filtro por geometria
var Sentinel=SentinelCol.filterBounds(geometry).filterDate('2019-01-16','2019-02-01').filterMetadata('MGRS_TILE', "contair
var Sentinel_sin_nubes=Sentinel.map(maskS2clouds);

var Senmedian2=Sentinel_sin_nubes.median().rename('B_B2_ENE2_2019');
//

// QUINCENA 3-----
//filtro por geometria
var Sentinel=SentinelCol.filterBounds(geometry).filterDate('2019-02-01','2019-02-16').filterMetadata('MGRS_TILE', "contair
var Sentinel_sin_nubes=Sentinel.map(maskS2clouds);

var Senmedian3=Sentinel_sin_nubes.median().rename('C_B2_FEB1_2019');
//
```

Figura 36.- Código de la iteración función de eliminación de nubes extracción de características GEE 2

Tal y como se puede leer en el código, una vez se tengan todos los 24 ya hechos, se tienen que juntar el máximo de cada quincena en una imagen, dejándolo, así como una variable más.

```
//juntamos el maximo de cada quincena en una imagen
var Senmedian2019=ee.Image.cat(Senmedian1,Senmedian2,Senmedian3,Senmedian4,Senmedian5,Senmedian6,Senmedian7,Senmedian8,S
```

Figura 37.- Código del cálculo del valor medio extracción de características GEE 2

Con todo el proceso anterior realizado, solo queda hacerlo en una función que al mismo tiempo reduzca la zona de estudio por nuestra geometría dicha, con el objetivo de poder usarla más adelante.

```
function estad(feature) {
  return feature.set(Senmedian2019.reduceRegion({
    reducer: ee.Reducer.mean(),
    // reducer: reducers,
    geometry: feature.geometry(),
    maxPixels: 100000000,
    scale: 10,
    bestEffort: true
  }));
}
```

Figura 38.- Código de la segunda función de eliminación de nubes extracción de características GEE 2

Y se usará con la variable que representa el fichero de polígonos de segmentación, cuya variable representativa será la exportada al Drive como fichero .csv para descargar. Como ya se ha mencionado con anterioridad, este proceso se tiene que repetir con el mismo código, pero especificando cada una de las bandas deseadas cada vez hasta haberlo realizado con todas ellas.

```

:50
:51
:52   | var parcelastats=shape.map(estad);
:53   | // print(parcelastats3.propertyNames())
:54
:55
:56   Export.table.toDrive(parcelastats,"Sentinel2_B2_19");

```

Figura 39.- Código de exportación del csv extracción de características GEE 2

El último fichero por obtener mediante la extracción de características por Google Earth Engine es el NDVI en base al fichero de polígonos y las bandas 4 y 8. Una vez más, se sigue un método bastante similar al anterior, donde usando los mismos datos que en la media de bandas, primero se tiene que crear la función que calcula el NDVI en base a las dos bandas mencionadas.

```

- function CalcularNDVI(imagen){
  var bandas_seleccionadas=imagen.select('B4','B8');
  var NDVI=bandas_seleccionadas.normalizedDifference(['B8','B4']).rename('NDVI');
  return NDVI;
}

```

Figura 40.- Código de la función del cálculo NDVI extracción de características GEE 3

Luego, se aplica dicha función a la colección de imágenes de Sentinel-2, ordenadas por las quincenas de todo el año, de las cuales se obtendrá el valor máximo como la nueva variable a devolver. Esto nos dará una vez más 24 valores diferentes, correspondientes al valor máximo del NDVI de cada una de las quincenas.

```

// QUINCENA 1
var SentinelColFil=SentinelCol.filterBounds(geometry).filterDate('2019-01-01','2019-01-16').filterMetadata('MGRS_TILE', 'contains','30');
var NDVICol=SentinelColFil.map(CalcularNDVI);
var NDVImax1=NDVICol.max().rename('A_NDVI_2019ENE1');
Map.addLayer(NDVImax1,undefined,'NDVImax1');

// QUINCENA 2
var SentinelColFil=SentinelCol.filterBounds(geometry).filterDate('2019-01-16','2019-02-01').filterMetadata('MGRS_TILE', 'contains','30');
var NDVICol=SentinelColFil.map(CalcularNDVI);
var NDVImax2=NDVICol.max().rename('B_NDVI_2019ENE2');
Map.addLayer(NDVImax2,undefined,'NDVImax2');

```

Figura 41.- Código de la iteración función del cálculo NDVI extracción de características GEE 3

Una vez más se saca la media de todas ellas para cada polígono, y se devuelve como variable.

```

var NDVI2019=ee.Image.cat(NDVImax1,NDVImax2,NDVImax3,NDVImax4,NDVImax5,NDVImax6,NDVImax7,NDVImax8,NDVImax9,NDVImax10,NDVImax11,NDVImax12

```

Figura 42.- Código del valor medio NDVI extracción de características GEE 3

También se convierte todo este proceso en una función que vuelve a tener el efecto añadido de reducir la zona de estudio a la geometría inicial puesta por nosotros al principio del código.

```
function estad(feature) {  
  return feature.set(NDVI2019.reduceRegion({reducer: ee.Reducer.mean(), geometry: feature.geometry(), maxPixels: 100000000, scale: 10, bestEffort: true}));  
}
```

Figura 43.- Código de la segunda función extracción de características GEE 3

Se aplica la función al fichero shape de los polígonos que se tenía como variable inicial y se exporta el resultado al Drive personal con su nombre identificativo, junto con el resto de los ficheros de características extraídas por Google Earth Engine.

```
var parcelastats=shape.map(estad);  
Export.table.toDrive(parcelastats, "Sentinel2_NDVI_19");
```

Figura 44.- Código de exportación del csv extracción de características GEE 3

3.2.4- OBTENCIÓN DE CARACTERÍSTICAS MEDIANTE FUSION

Para poder obtener los atributos de nuestra zona mediante los ficheros LiDAR, se usará la herramienta de FUSION conocida como CloudMetrics. Para poder usarla, primero se tiene que conseguir transformar los ficheros .las a unos referenciados a cada polígono de los 900 clasificados, para que cada uno tenga su propia información.

Este proceso se realiza con otra herramienta de FUSION llamada Polyclipdata, pero esta solo acepta un máximo de 500 polígonos por uso, por lo que se tendrá que dividir el shape de polígonos en 2. Luego se usa los switch multifile y shape. El switch multifile es el que ordena obtener un fichero .las de resultado para cada polígono. El switch shape obliga al fichero creado a tener el nombre de la columna del shape especificada (como creamos un fichero para cada polígono, cada polígono tendrá de nombre el número identificador propio). Solo queda poner la ruta donde se quiere crear los ficheros .las de los polígonos y la lista con los ficheros .las originales.

```
C:\fusionlatest\polyclipdata /multifile /shape:7, * C:\las\cap2.shp E:\tfm\las\RGB\fusionext2\.las C:\las\listplota.txt
```

Figura 45.- Herramienta Fusion Polyclipdata

Una vez se tienen ya todos los ficheros .las para cada uno de los 900 polígonos, se crea una nueva lista .txt con la ruta de cada uno de ellos, hecho con más sencillez con comandos de la

ventana cmd. Con esta lista, ya se puede usar la herramienta CloudMetrics para obtener el fichero csv con los atributos, especificando la ruta donde se quiere crear.

```
C:\fusionlatest\CloudMetrics E:\tfm\las\RGB\fusionext2\filenames.txt E:\tfm\las\RGB\pmetricsT.csv
```

Figura 46.- Herramienta Fusion CloudMetrics

3.2.5- OBTENCIÓN DE CARACTERÍSTICAS MEDIANTE QGIS y FETEX

Los últimos atributos que vamos a extraer son 3; la cota media de cada polígono, su pendiente media y su orientación media. La forma con la que se van a obtener estos 3 ficheros será mediante el uso del software QGIS para la creación de las 3 capas, que luego serán cargadas en formato tif en Fetex, para obtener los valores medios de cada uno dependiendo de los polígonos de la zona.

Comenzaremos con la obtención de la capa de orientaciones media para cada polígono de nuestra zona de trabajo. Para ello se usará la imagen de orientación ya obtenida con anterioridad de nuestra zona, cuyo proceso ha sido usar la herramienta de QGIS de análisis raster llamada Aspecto usando como dato el modelo digital terreno (también se podría realizar con la misma herramienta Aspect de ArcGis). Pero como solo se quiere la zona específica en la que se está trabajando, se tendrá que recortar la imagen de orientaciones en una nueva capa de solo las orientaciones de esa zona.




Figura 47.- Ficheros Resultantes Gis-Fetex

Una vez se tiene ya la capa, se transforma dentro del propio QGIS a formato tif. Con la imagen, se usará la herramienta Fetex2 para obtener el valor medio por polígono de esta capa de orientación, cargando la imagen y el fichero shape de los polígonos clasificados. Solo se deja marcado la opción de características espectrales MEAN para que nos devuelva un fichero solo con los valores medios por polígono.

Para la obtención de la segunda imagen, que será la de pendientes, junto con su fichero de valores medios, se seguirá un proceso similar al anterior, con la diferencia que, en esta ocasión, se debe crear la imagen del mapa de pendientes en QGIS, puesto que, a diferencia de la capa de orientaciones, no se ha realizado con anterioridad. Para crear este mapa, se ha usado en el shape del modelo digital de terreno la herramienta de QGIS de Raster Analysis conocida como Pendiente. El resultado de esta herramienta será la imagen correspondiente al mapa de

pendientes. Una vez más, se recortará esta imagen para la obtención de una capa nueva que sea solo la imagen del mapa de pendientes para nuestra zona de trabajo que tiene el tamaño exacto al fichero de polígonos de segmentación.

Luego, igual que se ha realizado para los datos de orientación, se ha transformado la imagen final a extensión tif, con el objetivo de cargarlo como imagen en la herramienta Fetex. Se volverá a usar el fichero de polígonos clasificados y se seleccionará solo la característica espectral "Mean" para obtener únicamente el valor medio de la pendiente.

Este último paso será más parecido a la obtención del fichero de orientaciones que al fichero de pendientes, debido a que como en el primero, ya se tiene la capa base con la que trabajar, y no hay que crearla desde cero como en las pendientes. Esta es el modelo digital de terreno que se obtuvo en Fusion. Para usarlo, primero se tiene que transformar en formato tif de imagen, pero, primero se tiene que recortar la capa a nuestra zona de trabajo para que solo se estudien los datos equivalentes a esta y el programa tenga mayor facilidad a la hora de calcular. Luego, se carga la imagen y el fichero de polígonos clasificado en Fetex y una vez más se obtiene un fichero .dbf con los datos de valores medios de las cotas.

De esta manera se obtiene el tercer y último fichero de extracción de características por los dos programas, QGis y Fetex. Además, se finaliza ya el paso de extracción de características, teniendo ya todos los ficheros deseados. Ahora, se entrará en la parte final del proceso, donde usando los ficheros obtenidos y el software de aprendizaje automático y minería de datos WEKA, se podrá realizar la clasificación basada en las características obtenidas.

3.3- CREACIÓN DE LA CLASIFICACIÓN MEDIANTE WEKA

3.3.1-UNIÓN CAPA PUNTOS CON CAPA DE POLÍGONOS PARA ASIGNACIÓN DE CLASES A LOS POLÍGONOS

Para poder empezar a trabajar con Weka, se tiene que realizar un paso preliminar antes de unir todos los ficheros de atributos que han sido extraídos previamente. Este paso preliminar es la unión de la capa de puntos con su respectivo modelo de combustión para cada punto, con la capa de polígonos obtenidos de la segmentación. Esta unión se realiza con la intención de que los polígonos que contengan un punto se clasifiquen con el modelo de combustión correspondiente, dejando los demás vacíos. De esta manera se podrá usar el atributo de modelo de combustión como la base para la clasificación.

Para poder realizar esto, se debe cargar ambos ficheros en uno de los softwares GIS que se han estado usando durante todo el proyecto, QGIS o ArcGis. Una vez se tienen ambos cargados, la herramienta que calculara la unión de ambas capas en base a la posición de cada uno de los puntos se llama “Spatial Join” dejando a la capa de polígonos de segmentación con una nueva columna de modelo de combustión.

3.3.2-UNIÓN FICHEROS CARACTERÍSTICAS

El software WEKA pide una forma específica para cargar el archivo de atributos que servirá como fuente de datos para la clasificación. Para empezar, solo carga un archivo en total, por lo que tendremos que unir todos los ficheros Excel que se han obtenido en los apartados de extracción de características en uno solo con la capa de polígonos segmentada y con modelos de combustión.

Este proceso se realizará en QGIS, donde el primer paso será cargar todos los ficheros csv en un proyecto nuevo. Luego se tendrá que realizar la unión de todos ellos con la capa de polígonos de segmentación con los modelos de combustión incorporados. Para ello se usa en las propiedades de la capa de polígonos la función de join que nos permitirá unir la capa con todas las tablas de datos usando el identificador puesto por nosotros como columna en común entre ellos, y añadiendo un prefijo en el nombre de las nuevas columnas para identificar de dónde viene cada uno.

Ahora toca modificar la información para poder ponerla tal y como la acepta el software WEKA. Para poder trabajar con ella, se tendrá que exportar la tabla resultado de la unión realizada en el shape de polígonos como fichero Excel xlsx, para poder tener los datos de una manera visual distinguible que nos permita realizar con mayor facilidad los cambios deseados. El primer paso es la eliminación de todas las columnas que el programa Weka no puede leer, como las que contienen corchetes y comas con la geometría de cada polígono, pues el propio programa WEKA rechaza el fichero si están incluidas dentro, también las columnas nominales como system:index, o aquellas que no aportan ninguna información o es información repetida.

El segundo cambio está enfocado en las casillas en blanco. El programa WEKA no reconoce las casillas del fichero Excel en blanco como que no se tienen datos de ese polígono. Para que el programa sea capaz de distinguir esta información, hay que rellenar todas las casillas sin datos con el símbolo de interrogación “?” que es el que el programa WEKA reconoce como falta de datos de ese apartado. Para el intercambio, se selecciona toda la tabla de datos en el Excel, se realiza una selección especial de solo las casillas vacías, y se rellenan todas al instante con el símbolo deseado. El último paso será transformar el Excel en formato .xlsx a formato .csv, pues es el formato que acepta el software WEKA. La separación del fichero csv será por comas.

3.3.3-USO DEL PROGRAMA WEKA

Con los datos ya preparados en un fichero csv separado por comas y sin casillas vacías, podemos pasar a la realización de la clasificación. Para ello ya podemos abrir el programa WEKA, donde se empezará un nuevo proyecto con la opción Explorer, que se usará para trabajar. Una vez abierto el proyecto, se carga el fichero de unión .csv dentro del programa, designándolo como los atributos/características con las que vamos a tratar para realizar la clasificación. Si por alguna razón el programa no acepta el fichero, es que hay alguna casilla con datos que el programa no pueda leer o en blanco, por lo que se tendrá que solucionar.

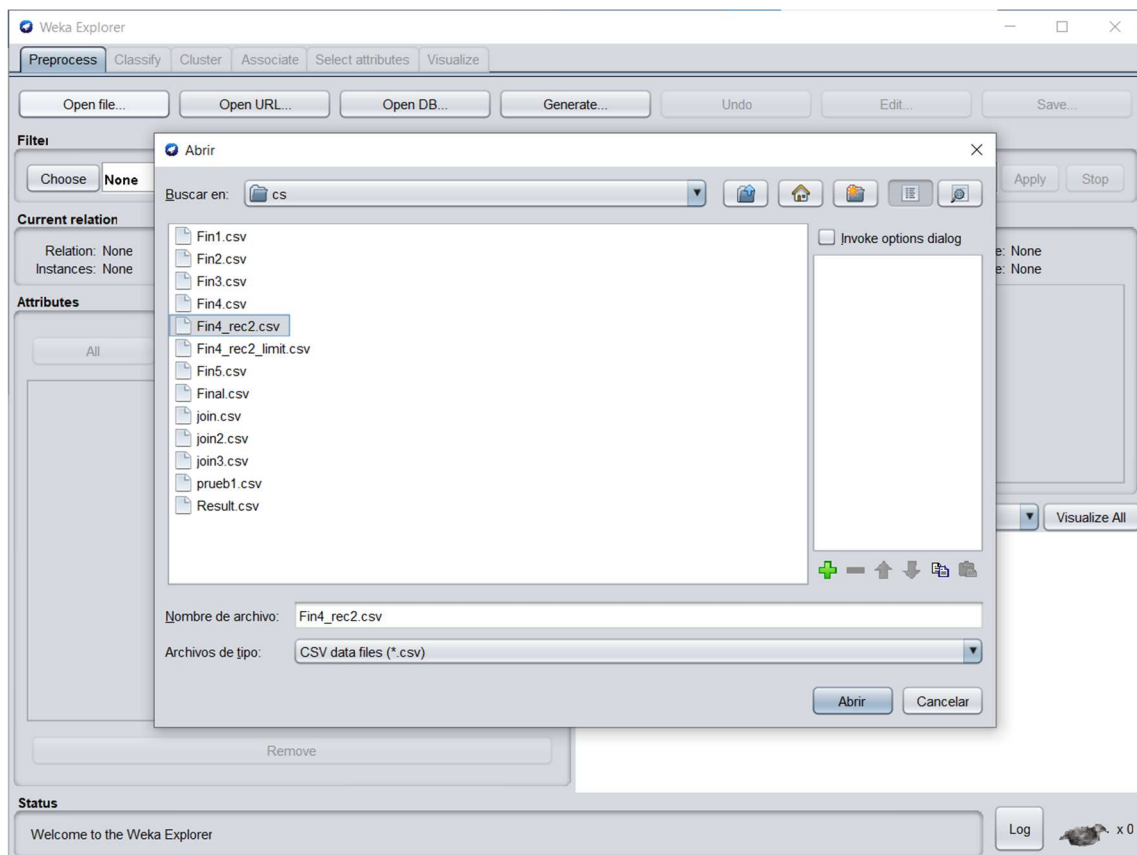


Figura 48.- Figura de la carga del fichero unión csv en WEKA

Una vez se tienen ya todos los atributos, se procede a hacer una selección de los atributos con los que se va a trabajar para realizar la clasificación. En esta clasificación inicial, se utilizarán todos los atributos numéricos y usará el atributo nominal de los modelos como la clase a usar en la clasificación.

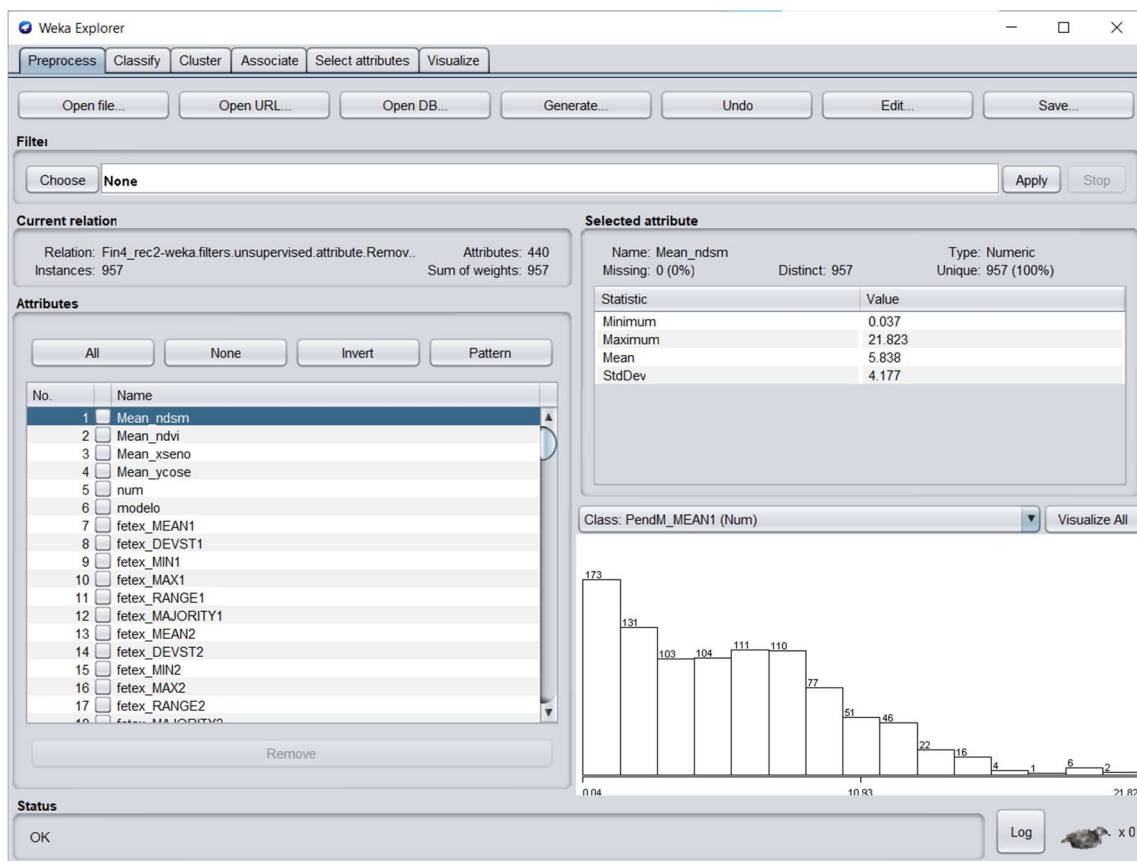


Figura 49.- Imagen de WEKA con todos los atributos cargados

Ahora, se realiza una primera clasificación con todos los atributos. Para ello se entra a la ventana de Classify. Una vez en ella se debe elegir el método de clasificador con el que se va a trabajar, que en esta ocasión se ha decidido que sea el método Random Forest, usando un total de 100 iteraciones (el valor que viene predeterminado). Por su parte, se elige la opción de test como la cross-validation, usando un total de 10 iteraciones. Para acabar, solo queda especificar que la variable que se usará para crear las clases va a ser la única variable nominal que se ha dejado, la llamada modelo que corresponde con los modelos de combustión conocidos.

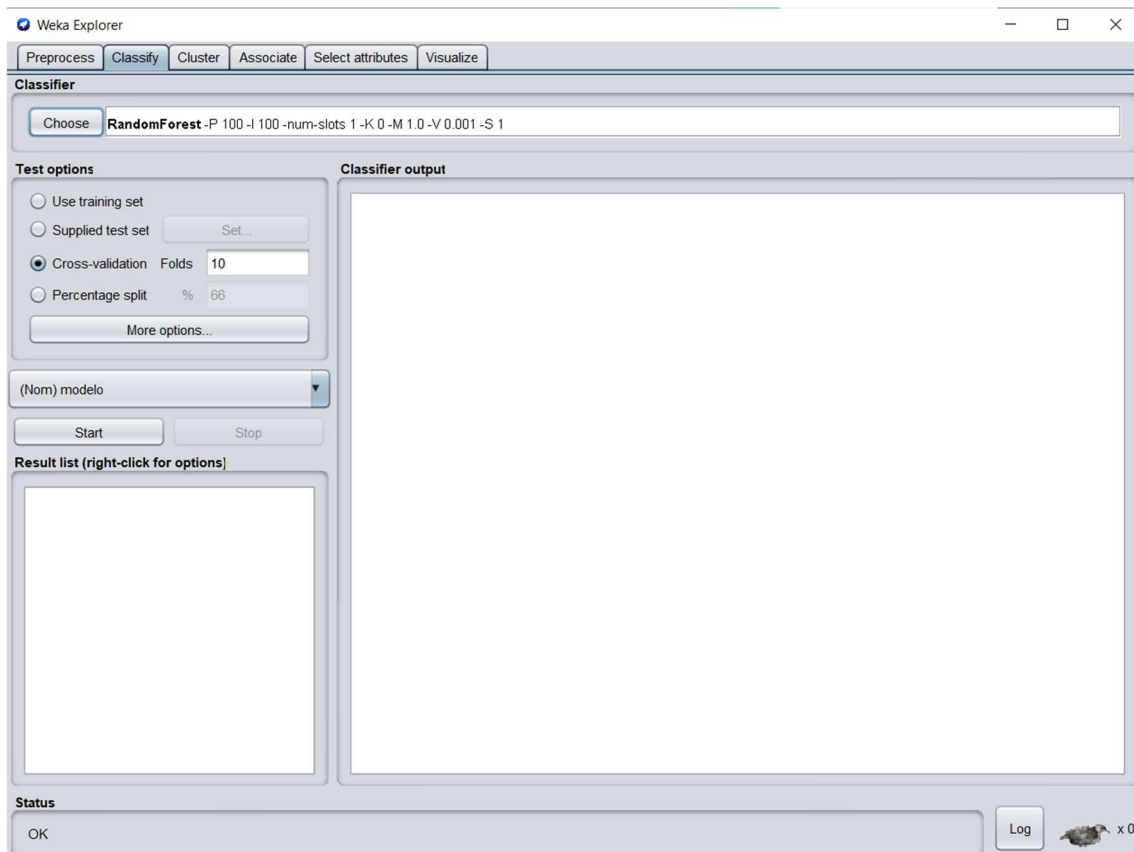


Figura 50.- Imagen de la ventana del proceso de clasificación de WEKA

Este modelo de clasificación inicial, una vez dado start y obtenido el resultado, nos daba un porcentaje de fiabilidad del 47%, algo que no es ni óptimo ni aceptable para considerar usable. Esto indicó que hacía falta realizar ciertos cambios con el objetivo de mejorar el nivel de fiabilidad obtenido en la realización de pruebas posteriores.

El primer cambio, se realizó en el propio fichero de datos Excel/csv y en los modelos de combustión. Repasando los modelos conocidos que se tenían en los polígonos, se llegó a identificar la poca cantidad que se tenían en algunos modelos, lo que podría llevar a un error en el cálculo del programa. Como por suerte, los propios modelos estaban unidos en grupos de mismas características, tal y como se comentó al principio, se decidió unir los polígonos con muy pocos tipos de modelos con otros del mismo grupo, en la columna de clasificación de modelos de combustión. Se acabaron por unir el modelo GR8 al modelo GR7 para crear el nuevo modelo que recoge a ambos, GR78. Además, los modelos NB1 y NB9 también se unieron al modelo NB3 para crear el grupo NB.

Volviendo a realizar la clasificación con el nuevo fichero .csv con estos cambios, se notó una ligera mejoría en el porcentaje de fiabilidad de la clasificación, llegando a subir a un total del 49%.

```
Time taken to build model: 1.41 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      474           49.5298 %
Incorrectly Classified Instances    483           50.4702 %
Kappa statistic                    0.4264
Mean absolute error                0.0919
```

Figura 51.- Segundo resultado del cálculo de clasificación en WEKA

El siguiente paso pensado para intentar mejorar el nivel de fiabilidad del método, fue aumentar el número de iteraciones usadas usando el nuevo fichero .csv . Se hicieron dos pruebas, una con 200 iteraciones, y otra con 500 iteraciones.




Figura 52.- Proceso RandomForest con 200 iteraciones



Figura 53.- Proceso RandomForest con 500 iteraciones

Se pudo notar que, al aumentar el número de iteraciones, mejoró levemente la fiabilidad del método. Para el método usando 200 iteraciones, se consiguió una fiabilidad de 50.2612 %, mientras que el que se usó con 500 iteraciones, tenía una fiabilidad de 50.5747 %. Aunque son valores mejores que el inicial, sin duda, todavía no se ha llegado a un porcentaje aceptable de fiabilidad para el método, por lo que se pasó al siguiente paso, el uso de filtros para la selección de atributos.

Para el filtrado de atributos, se realizan diferentes tipos de evaluadores de atributos con sus métodos de búsqueda, con el objetivo de conseguir sacar las variables más relevantes de todas las usadas. Se usaron diferentes evaluadores, como WrapperSubsetEval, CfsSubsetEval y los classifiers, junto a sus posibles métodos de búsqueda (BestFirst, GreedyStepwise y Rank) para la obtención de atributos.



Figura 54.- Filtros realizados para la obtención de los atributos más relevantes

Cada uno calculó sus propios grupos de atributos relevantes, exceptuando el ranker que ponía en orden de mayor relevante a menor relevante todos y cada uno de los atributos. Pero entre todos ellos, había unos que se encontraban en los grupos que se mostraban de ejemplo; por lo que se realizó una prueba con ellos. Los atributos usados de los 174 en total eran:

- 1: TARGET_FID
- 2: Mean_ndsm
- 3: Mean_ndvi
- 5: Mean_ycose
- 6: num (el identificador de los polígonos que pusimos nosotros)
- 7: modelo (el modelo de combustión)
- 8: fetex_Mean1
- 26: fetex_Mean4
- 31: fetex_Majority4
- 42: fetex_IDM
- 52: fetex_RVF
- 70: cotatdB_Count
- 72: cotatdB_Mean
- 78: penddtm_Mean
- 86: VHDesSeg2019_Mean_ndsm

87: VHDesSeg2019_Mean_ndvi

89: VHDesSeg2019_Mean_ycose

114: VVDesSeg2019_Mean_ndsm

135: Sentinel2_B2_19_Mean_ndsm

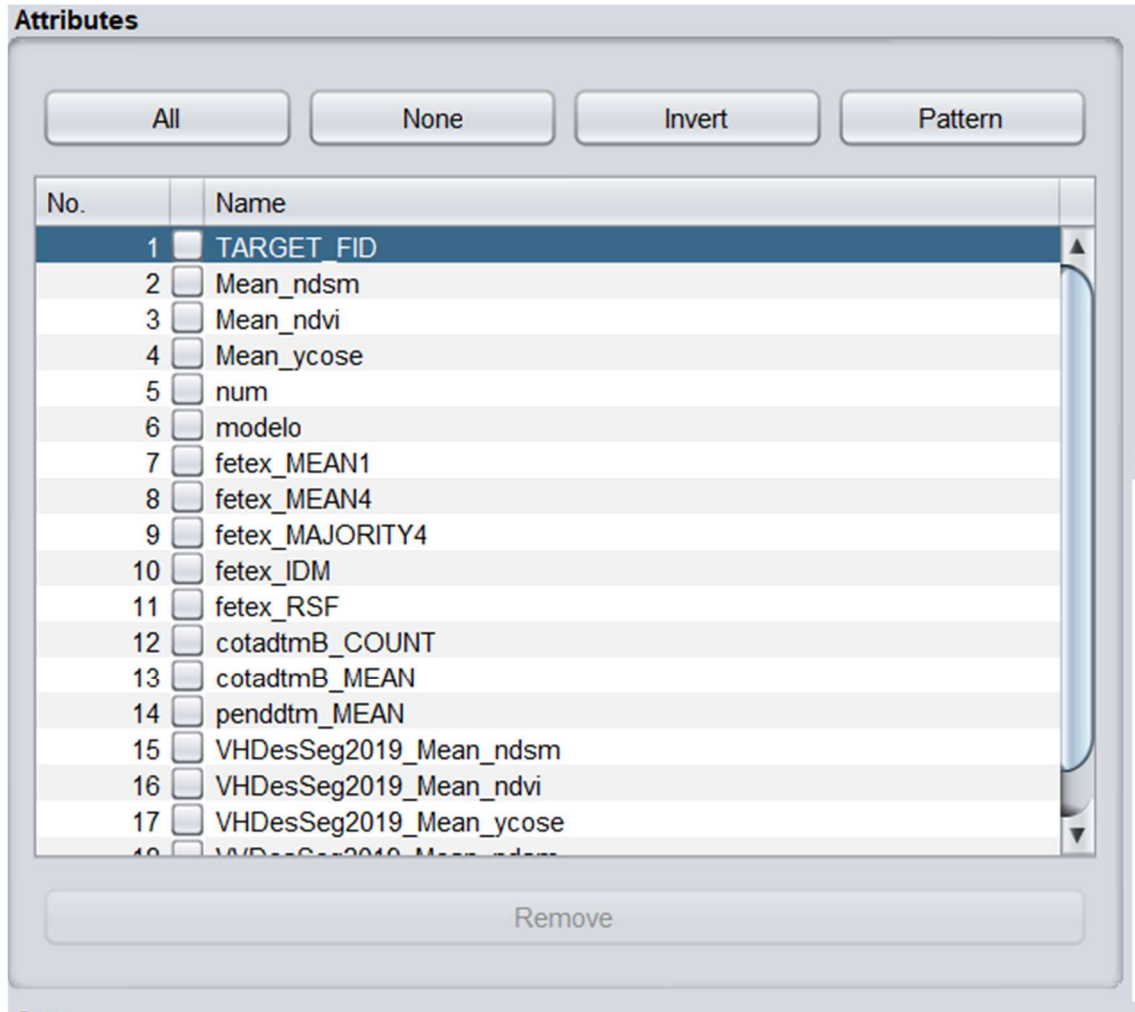


Figura 55.- Atributos restantes después del uso de los filtros

Con estos atributos, se volvió a realizar el random forest tal y como se hizo anteriormente, con iteraciones de 100, 200 y 500 para comprobar cual daba mejor resultado. En esta ocasión, cuando se ha usado el método random forest con 100 iteraciones, se ha obtenido un resultado de fiabilidad del 52.0376 %.

```

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      498          52.0376 %
Incorrectly Classified Instances    459          47.9624 %
Kappa statistic                    0.4565
Mean absolute error                0.0858
Root mean squared error            0.2047
Relative absolute error            71.9317 %
Root relative squared error        83.8644 %
Total Number of Instances          957
Ignored Class Unknown Instances    88557

```

Figura 56.- Resultado de la clasificación con los atributos filtrados y 100 iteraciones

Cuando se ha usado el método de random forest con 200 iteraciones se ha obtenido un resultado del porcentaje de fiabilidad del 53.396 %.

```

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      511          53.396 %
Incorrectly Classified Instances    446          46.604 %
Kappa statistic                    0.4717
Mean absolute error                0.0857
Root mean squared error            0.204
Relative absolute error            71.8925 %
Root relative squared error        83.5725 %
Total Number of Instances          957
Ignored Class Unknown Instances    88557

```

Figura 57.- Resultado de la clasificación con los atributos filtrados y 200 iteraciones

Y para el método de Random Forest con 500 iteraciones se ha obtenido un porcentaje de fiabilidad del 52.8736 %.

```

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      506          52.8736 %
Incorrectly Classified Instances    451          47.1264 %
Kappa statistic                    0.4655
Mean absolute error                0.0857
Root mean squared error            0.2036
Relative absolute error            71.8646 %
Root relative squared error        83.422 %
Total Number of Instances          957
Ignored Class Unknown Instances    88557

```

Figura 58.- Resultado de la clasificación con los atributos filtrados y 500 iteraciones

Como el valor resultante es demasiado bajo, se ha mirado las matrices de confusión de los resultados, y en ella se ha podido ver que hay valores de modelos que se confunden entre ellos, sobre todo en sus propios grupos (GR, SH, TU, NB...), por lo que se ha decidido realizar una agrupación por clases mayores:

- Grupos GR2 Y GR4 = GR = Herbáceas
- Grupos GR7 y GR8 = GRC = Cañas
- Grupos SH1 y SH3 = MAT1 = Matorrales con combustibilidad baja
- Grupos SH4 y SH5 = MAT2 = Matorrales con combustibilidad alta
- Grupo SH9, TU1, TU2, TU3 y TU5 = ARB = Arbolado
- Grupo SB3 es el grupo mixto
- Grupos NB1, NB3, NB8 y NB9 = NBB = Grupo de suelo no quemable

Los grupos han sido creados basándonos sobre todo en la similitud de los parámetros de cada clase, ya que algunos se confunden con otros grupos debido a la similitud de parámetros, por lo que se han agrupado. El primer grupo GR corresponde a los modelos de pasto herbáceos, como pastizales típicos de campos recién abandonados. El segundo grupo de pastos hace referencia al grupo de cañas, carriza, junco... con un una carga de combustible más alta que la anterior.

Las clases de matorrales también se han dividido en dos grupos diferentes, el primer grupo formado por SH1 y SH3, caracterizados por ser matorrales dispersos, y el SH4 junto con el SH5, donde se encuentra una mayor continuidad entre los matorrales. Por su parte, aunque el SH9 debería pertenecer al grupo de matorrales, se ha juntado con el grupo TU de matorral bajo arbolado (donde todos los miembros forman parte del grupo), debido a que proviene del regenerado del árbol.

El grupo SB3 es un valor mixto del grupo de matorrales y el de matorrales bajo arbolado, encontrándonos ambos casos con su propios parámetros, por lo que este grupo mixto seguirá siendo su propia clase sin unirse a nadie. Por su parte, todo el grupo de clases no quemable (NB) se unirá en uno solo, que representará toda zona no quemable.

Realizando estos cambios en el fichero .csv, se ha vuelto a cargar y se ha realizado una clasificación con todos los datos. El resultado obtenido ha mejorado mucho en comparación a lo que se tenía con anterioridad:

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	703	73.4587 %
Incorrectly Classified Instances	254	26.5413 %
Kappa statistic	0.5875	

Mean absolute error	0.1154
Root mean squared error	0.2305
Relative absolute error	59.7185 %
Root relative squared error	74.236 %
Total Number of Instances	957

Con su respectiva matriz de confusión

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
31	17	6	0	3	0	16	NBB
1	451	32	0	2	0	2	ARB
7	42	148	0	9	0	6	MAT2
0	25	8	2	0	0	0	SB3
4	0	17	0	39	0	0	MAT1
5	5	6	0	0	6	8	GRC
17	9	5	0	0	2	26	GR

Figura 59.- Matriz de confusión usando todos los atributos y polígonos

Pero también se ha querido comprobar si se pudiera mejorar aún más el resultado. El primer intento de mejora ha sido mediante el uso de una selección de atributos usando el evaluador CFS Subset Evaluator y el método de Best First, obteniendo los siguientes atributos:

Selected attributes:

1,5,23,25,30,36,41,44,45,51,53,117,120,123,129,136,139,145,163,174,176,179,188,189,194,202,286,287,288,307,309,328,329,330,331,332,333,335,342,344,353,358,374,376,378,380,382,402,408,421,422,423,424,429,434 : 55

- Mean_ndsm
- num
- fetex_RANGE3
- fetex_MEAN4
- fetex_MAJORITY4
- fetex_MEAN_EDG
- fetex_IDM
- fetex_CORRELAC
- fetex_SKEWNESS
- fetex_RSF
- fetex_SDT
- FetexNDSM_MEAN1
- FetexNDSM_MAX1
- FetexNDSM_MAJORITY1
- LiDar_Return 5 count

- LiDar_Elev maximum
- LiDar_Elev stddev
- LiDar_Elev AAD
- LiDar_Elev P60
- LiDar_Int maximum
- LiDar_Int mode
- LiDar_Int CV
- LiDar_Int L CV
- LiDar_Int L skewness
- LiDar_Int P20
- LiDar_Int P80
- Sentinel2_B5_19_K_B5_JUN1_2019
- Sentinel2_B5_19_L_B5_JUN2_2019
- Sentinel2_B5_19_M_B5_JUL1_2019
- Sentinel2_B6_19_I_B6_MAY1_2019
- Sentinel2_B6_19_K_B6_JUN1_2019
- Sentinel2_B7_19_G_B7_ABR1_2019
- Sentinel2_B7_19_H_B7_ABR2_2019
- Sentinel2_B7_19_I_B7_MAY1_2019
- Sentinel2_B7_19_J_B7_MAY2_2019
- Sentinel2_B7_19_K_B7_JUN1_2019
- Sentinel2_B7_19_L_B7_JUN2_2019
- Sentinel2_B7_19_N_B7_JUL2_2019
- Sentinel2_B7_19_U_B7_NOV1_2019
- Sentinel2_B7_19_X_B7_DEC2_2019
- Sentinel2_B8_19_I_B8_MAY1_2019
- Sentinel2_B8_19_N_B8_JUL2_2019
- Sentinel2_B11_19_G_B11_ABR1_2019
- Sentinel2_B11_19_I_B11_MAY1_2019
- Sentinel2_B11_19_K_B11_JUN1_2019
- Sentinel2_B11_19_M_B11_JUL1_2019
- Sentinel2_B11_19_O_B11_AGO1_2019
- Sentinel2_B12_19_L_B12_JUN2_2019
- Sentinel2_B12_19_R_B12_SEP2_2019
- Sentinel2_NDVI_19_H_NDVI_2019ABR2
- Sentinel2_NDVI_19_I_NDVI_2019MAY1
- Sentinel2_NDVI_19_J_NDVI_2019MAY2
- Sentinel2_NDVI_19_K_NDVI_2019JUN1
- Sentinel2_NDVI_19_P_NDVI_2019AGO2
- Sentinel2_NDVI_19_U_NDVI_2019NOV1

Realizando esta clasificación junto al atributo nominal del modelo, se ha conseguido mejorar la fiabilidad un poquito.

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances 707 73.8767 %
Incorrectly Classified Instances 250 26.1233 %
Kappa statistic 0.5959
Mean absolute error 0.1086
Root mean squared error 0.226
Relative absolute error 56.1859 %
Root relative squared error 72.7598 %
Total Number of Instances 957

Con su propia matriz de confusión

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
28	16	10	0	0	1	18	NBB
0	444	40	0	2	0	2	ARB
6	38	152	0	8	2	6	MAT2
0	26	7	2	0	0	0	SB3
3	0	15	0	42	0	0	MAT1
8	5	4	0	0	7	6	GRC
12	10	5	0	0	0	32	GR

Figura 60.- Matriz de confusión usando todos los polígonos y una selección de atributos

El segundo método de mejora ha sido tratando de limitar el número de polígonos de las clases con mayor número a los 50 primeros. Se ha realizado una copia del fichero y eliminado de los dos mayores grupos todos los polígonos excepto los 50 primeros. Luego se ha realizado una clasificación con todos los atributos y se ha podido ver como la fiabilidad ha bajado en comparación a cuando se usaban todos los polígonos.

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances 241 67.507 %
 Incorrectly Classified Instances 116 32.493 %
 Kappa statistic 0.6159
 Mean absolute error 0.1477
 Root mean squared error 0.2558
 Relative absolute error 61.052 %
 Root relative squared error 73.5543 %
 Total Number of Instances 357

Y su matriz de confusión

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
48	0	0	2	0	0	0	NBB
0	32	2	1	1	18	5	ARB
2	8	15	0	0	5	0	MAT2
0	0	0	50	3	7	0	SB3
2	1	1	3	35	4	4	MAT1
8	24	1	3	2	33	2	GRC
2	0	0	2	3	0	28	GR

Figura 61.- Matriz de confusión usando todos los atributos y un límite de 50 polígonos por método

Se ha intentado hacer una selección de atributos también al csv con las limitaciones para ver como mejoraba el resultado. Se ha vuelto a usar el evaluador CFS Subset Evaluator y el método de Best First:

Selected attributes:

1,5,12,15,27,30,36,50,75,156,168,227,286,306,307,320,331,332,365,398,421,425,429,430,434 : 25

Mean_ndsm

- num
- fetex_MAJORITY1
- fetex_MIN2
- fetex_MIN4
- fetex_MAJORITY4
- fetex_MEAN_EDG
- fetex_RVF
- VHDesSeg2019_M_VHdes_2019MAY1

- LiDar_Elev P05
- LiDar_Elev P95
- Sentinel2_B2_19_U_B2_NOV1_2019
- Sentinel2_B5_19_K_B5_JUN1_2019
- Sentinel2_B6_19_H_B6_ABR2_2019
- Sentinel2_B6_19_I_B6_MAY1_2019
- Sentinel2_B6_19_W_B6_DEC1_2019
- Sentinel2_B7_19_J_B7_MAY2_2019
- Sentinel2_B7_19_K_B7_JUN1_2019
- Sentinel2_B8_19_U_B8_NOV1_2019
- Sentinel2_B12_19_H_B12_ABR2_2019
- Sentinel2_NDVI_19_H_NDVI_2019ABR2
- Sentinel2_NDVI_19_L_NDVI_2019JUN2
- Sentinel2_NDVI_19_P_NDVI_2019AGO2
- Sentinel2_NDVI_19_Q_NDVI_2019SEP1
- Sentinel2_NDVI_19_U_NDVI_2019NOV1

Y se ha realizado la clasificación con estos atributos, demostrando que hay una cierta mejora, pero que no es tan bueno como los resultados obtenidos con el fichero sin limitación.

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	258	72.2689 %
Incorrectly Classified Instances	99	27.7311 %
Kappa statistic	0.6717	
Mean absolute error	0.1254	
Root mean squared error	0.2345	
Relative absolute error	51.8129 %	
Root relative squared error	67.4227 %	
Total Number of Instances	357	

Y su matriz de confusión

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
49	0	0	1	0	0	0	NBB
0	36	1	0	1	20	1	ARB
0	5	18	0	1	6	0	MAT2
0	0	0	53	1	6	0	SB3
4	0	0	1	38	4	3	MAT1
2	24	1	3	4	36	3	GRC
0	0	0	2	4	1	28	GR

Figura 62.- Matriz de confusión usando una selección de atributos y un límite de 50 polígonos por método

Por lo que, como resultado final, se ha obtenido el método con mayor fiabilidad. Con un 73.8767 %, el modelo seleccionado será el del fichero .csv no limitado, pero con la selección de atributos realizada.

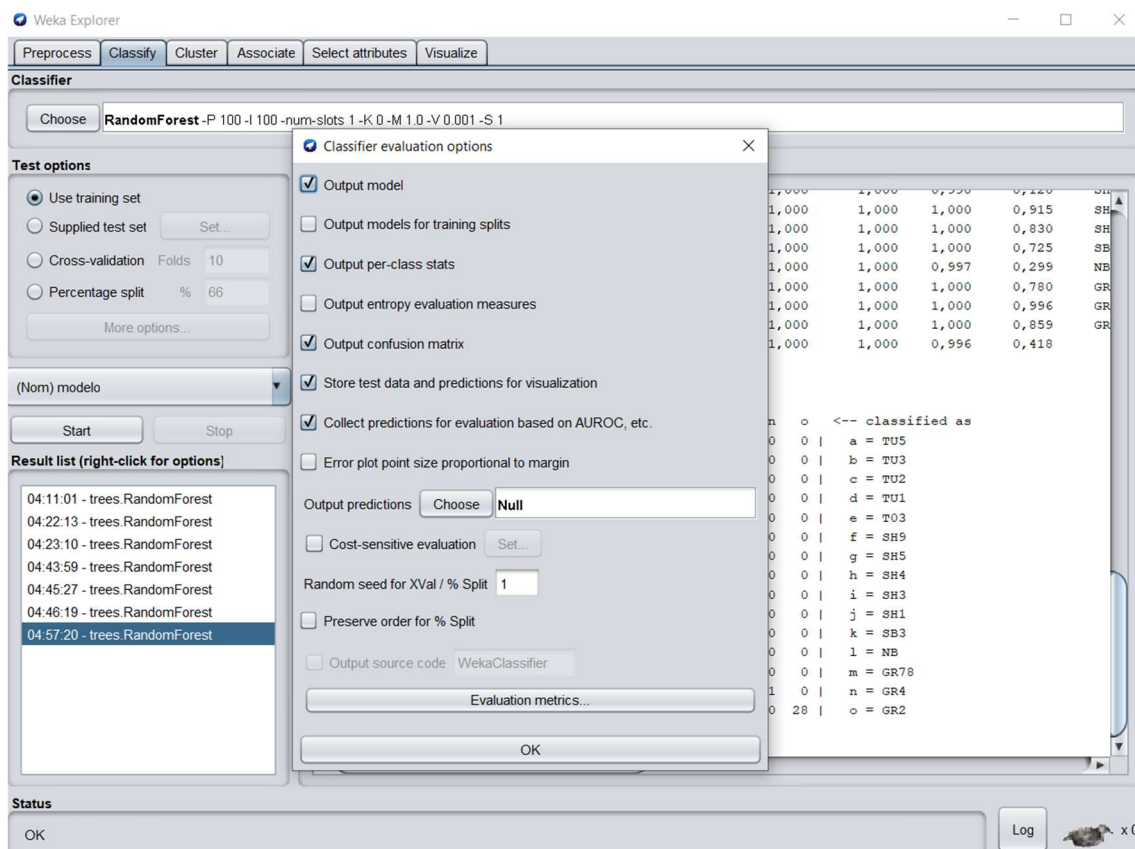


Figura 63.- Ventana de modificación del output de la predicción

Ya solo queda realizar la clasificación training set con este modelo obtenido, y exportar los resultados de todos los polígonos clasificados con su nueva clasificación a un fichero csv desde la opción de output predictions en “More Options”, especificando la ruta de salida del fichero. Luego ese fichero se subirá a un proyecto QGIS junto con el fichero shape de los 900 polígonos, se realizará una unión entre ambos (para realizarla, primero se ha unido el fichero resultado con el fichero de atributos original usando la clasificación antigua como punto en común y luego se ha unido al fichero shape). Se realiza una simbología con la nueva clasificación y se ha obtenido el resultado de manera visual.

4.-RESULTADOS




Figura 64.- Resultado visual de los polígonos ya clasificados

Al final, como ya se ha mencionado, se ha elegido el modelo obtenido de la agrupación de modelos en grupos grandes, sin limite en la cantidad de polígonos por grupo, y realizando una selección de los atributos más importantes. Esto nos da un porcentaje de fiabilidad del 73.88%. Aunque si lo comparamos con el porcentaje de fiabilidad del método con el mismo fichero, pero sin la realización de la selección de datos, se puede comprobar que no hay una diferencia significativa en la fiabilidad de ambos, dando un resultado del 73.46%.

Por su parte, aunque se intentaba conseguir un mejor resultado al limitar el número de polígonos por grupo, debido a la gran disparidad en la cantidad de polígonos entre los grupos más grandes con los grupos más pequeños, se ha podido comprobar que esto solo baja la fiabilidad del resultado final, mucho más si se usan todas las variables (un 67.51%) que si se realiza una selección igual al ejemplo anterior (72.27%).

	Limitando	Sin Limitar
Con Selección	72.27%	73.88%
Sin Selección	67.51%	73.46%

Figura 65.- Resultados de las 4 mejores clasificaciones

5.-CONCLUSIONES

El plano del modelo de combustión tiene como objetivo ser otro punto, con bastante importancia, que permita al entendimiento del comportamiento de un fuego y ayude a saber reaccionar ante él, sea priorizando una zona por su tipo de vegetación ante otra, conociendo como avanzará el incendio...

Con un valor de fiabilidad del 73.88%, este modelo y manera de trabajo se confirma como una manera viable para poder usarse en lugar de los métodos tradicionales, expandiéndolo a más polígonos de la Sierra del Espadán o incluso otras zonas de estudio. Las ventajas que tiene sobre el método de trabajo tradicional, por su parte, son bastante importantes. Nos encontramos primero ante una ventaja económica, debido a que todos los datos y la mayoría de los softwares a utilizar son de uso público, y no hacen falta instrumentos de gran valor para obtener los datos. También hay una ventaja de tiempo y sencillez con este método, ya que nos evita tener que desplazarnos durante días a la zona de estudio para la toma de datos (que también puede llevar a sus propios errores).

Son ventajas considerables a la hora de comparar métodos de trabajo cuya fiabilidad y resultado no se llevan una diferencia tan grande como para decir que uno es claramente mejor que el otro. Además, el propio método de trabajo de este proyecto se le podrían aplicar ciertas mejoras para intentar conseguir un mejor resultado.

Uno de los problemas que se han encontrado en este trabajo desde el comienzo ha sido la disparidad entre la cantidad de polígonos pertenecientes a cada clase de combustibilidad en la zona de trabajo, debido sobre todo a la zona. Limitar los grupos más grandes no ha sido una solución, puesto que bajaba la fiabilidad del resultado, por lo que se podría realizar es un aumento al número de muestras de las clases menos representadas.

También se podría buscar aún más tipos de características a los usados para intentar conseguir una clasificación más precisa. Buscar atributos relevantes que no se consideren repetidos o innecesarios con los ya usados en este proyecto. Incluso la obtención de datos con mayor precisión sería una ayuda a este proyecto, como unos datos LiDAR con mayor densidad a los usados (0.5 puntos por metro cuadrado).

También se debería analizar cualquier posible error realizado en la clasificación actual con mayor intensidad, haciendo revisiones que no se han podido realizar en este proyecto. Un ejemplo de esto es la comprobación de la calidad de los datos iniciales, como la cartografía inicial descargada o la clasificación de combustibilidad original. Una forma para realizar esto podría ser una visita de campo a la zona para la comprobación de datos (a diferencia del método tradicional donde se deben realizar varias visitas y se hace la toma de datos, aquí es una comprobación). Realizando este tipo de mejora, se podría conseguir incluso una mejor clasificación, confirmando aún más las ventajas de este método de trabajo al tradicional.

6.-BIBLIOGRAFÍA

Luis Ángel Ruiz, Jorge Abel Recio, Pablo Crespo-Peremarch & Marta Sapena (2016): An object-based approach for mapping forest structural types based on low-density LiDAR and multispectral imagery, Geocarto International, DOI: 10.1080/10106049.2016.1265595[1]

<http://dx.doi.org/10.1080/10106049.2016.1265595>

CLAVE PARA LA IDENTIFICACIÓN DE LOS MODELOS DE COMBUSTIBLE DE LA COMUNITAT VALENCIANA[2]

https://agroambient.gva.es/documents/162905929/169203680/Clave+fotogr%C3%A1fica+mo+delos+combustible_20200430/fd5ae58d-3b3f-4e50-866a-d83544a6f1b2

Google Earth Engine: Análisis a nivel planetario en la nube de Google[3]

<https://www.google.com/earth/education/tools/google-earth-engine/>

Diego Alonso: FUSION: Un software para análisis y visualización de datos LiDAR[4]

<https://mappinggis.com/2016/09/fusion-software-analisis-visualizacion-datos-lidar/>

Luis Ángel Ruiz, Jorge Abel Recio: FETEX: Programa de extracción de características de objetos cartográficos, Ingeniería Cartográfica, Geodesia y Fotogrametría, ETSI. Geodésica, Cartográfica y Topográfica [5]

<https://riunet.upv.es/bitstream/handle/10251/83343/Ruiz%3BRrecio%20-%20FETEX%3A%20Programa%20de%20extracci%C3%B3n%20de%20caracter%C3%ADsticas%20de%20objetos%20cartogr%C3%A1ficos.pdf?sequence=1>

Weka 3: Machine Learning Software in Java[6]

<https://www.cs.waikato.ac.nz/ml/weka/>

¿Qué es ArcGIS? [7]

<https://resources.arcgis.com/es/help/getting-started/articles/026n00000014000000.htm>

QGIS - El SIG Líder de Código Abierto para Escritorio [8]

<https://www.qgis.org/es/site/about/index.html>

7.-ANEXOS

ANEXO 1.- IMPORTANCIA DE CADA UNO DE LOS TIPOS DE ATRIBUTOS

Como hemos visto con anterioridad, cada grupo de variables ha sido obtenida de una manera distinta, sea por Fetex, por Google Earth Engine o por Fusion. Cada grupo de atributos, además, tiene un nivel de importancia propio en la clasificación. Teniendo en cuenta esta diferencia de relevancia entre grupos de atributos, se ha decidido buscar a continuación cuanto aporta cada grupo de atributos.

Para realizar esto, se ha realizado una clasificación con los modelos de combustión, usando únicamente un tipo de atributos en cada ocasión (Fetex, LiDAR, Bandas...). El nivel de fiabilidad de cada uno nos indicará la relevancia que ha tenido el atributo en la clasificación global respecto al resto de atributos. Como nos basamos en el método con mejor resultado (usando el fichero de atributos sin limitación del número de polígonos por modelo y una selección de atributos), podemos descartar los atributos correspondientes a la retrodispersión en las polarizaciones VV y VH, las bandas 2, 3 y 4 obtenidas de Google Earth Engine, y los atributos de la Cota Media, Pendiente Media y Orientación Media. Esto es debido a que ninguno de estos atributos fue usado en la clasificación basada en la selección de atributos.

Fetex

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	655	68.4431 %
Incorrectly Classified Instances	302	31.5569 %
Kappa statistic	0.4939	
Mean absolute error	0.134	
Root mean squared error	0.2496	
Relative absolute error	69.3026 %	
Root relative squared error	80.3799 %	
Total Number of Instances	957	

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,247	0,034	0,375	0,247	0,298	0,259	0,828	0,299	NBB
0,928	0,292	0,768	0,928	0,840	0,654	0,909	0,901	ARB
0,646	0,123	0,598	0,646	0,621	0,509	0,868	0,682	MAT2
0,057	0,000	1,000	0,057	0,108	0,235	0,885	0,438	SB3
0,433	0,013	0,684	0,433	0,531	0,521	0,931	0,570	MAT1
0,233	0,009	0,467	0,233	0,311	0,315	0,860	0,329	GRC
0,203	0,026	0,343	0,203	0,255	0,228	0,922	0,329	GR
Weighted Avg.	0,684	0,182	0,668	0,684	0,652	0,531	0,893	0,715

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
18	23	17	0	1	1	13	NBB
6	453	28	0	0	1	0	ARB
4	56	137	0	11	2	2	MAT2
0	25	8	2	0	0	0	SB3
3	2	27	0	26	0	2	MAT1
4	9	4	0	0	7	6	GRC
13	22	8	0	0	4	12	GR

fetexNDSM

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	632	66.0397 %
Incorrectly Classified Instances	325	33.9603 %
Kappa statistic	0.4563	
Mean absolute error	0.1346	
Root mean squared error	0.2558	
Relative absolute error	69.6423 %	

Root relative squared error 82.3766 %

Total Number of Instances 957

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,151	0,029	0,297	0,151	0,200	0,167	0,775	0,243	NBB
0,916	0,264	0,783	0,916	0,844	0,664	0,907	0,888	ARB
0,670	0,179	0,516	0,670	0,583	0,451	0,855	0,617	MAT2
0,000	0,000	?	0,000	?	?	0,821	0,187	SB3
0,350	0,018	0,568	0,350	0,433	0,418	0,927	0,521	MAT1
0,133	0,003	0,571	0,133	0,216	0,266	0,788	0,287	GRC
0,119	0,026	0,233	0,119	0,157	0,128	0,814	0,260	GR
Weighted Avg.	0,660	0,179	?	0,660	?	?	0,874	0,672

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
11	19	32	0	4	0	7	NBB
4	447	33	0	1	0	3	ARB
5	47	142	0	8	0	10	MAT2
0	31	4	0	0	0	0	SB3
5	3	29	0	21	1	1	MAT1
3	9	10	0	2	4	2	GRC
9	15	25	0	1	2	7	GR

LiDAR

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	642	67.0846 %
Incorrectly Classified Instances	315	32.9154 %
Kappa statistic	0.4785	
Mean absolute error	0.128	
Root mean squared error	0.2495	
Relative absolute error	66.1975 %	
Root relative squared error	80.3375 %	
Total Number of Instances	957	

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,247	0,034	0,375	0,247	0,298	0,259	0,830	0,292	NBB
0,912	0,269	0,779	0,912	0,840	0,655	0,913	0,911	ARB
0,646	0,132	0,583	0,646	0,613	0,497	0,872	0,688	MAT2
0,029	0,004	0,200	0,029	0,050	0,063	0,918	0,284	SB3
0,350	0,025	0,488	0,350	0,408	0,381	0,924	0,479	MAT1
0,033	0,004	0,200	0,033	0,057	0,070	0,807	0,190	GRC
0,322	0,035	0,380	0,322	0,349	0,311	0,874	0,379	GR
Weighted Avg.	0,671	0,173	0,623	0,671	0,638	0,512	0,893	0,709

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
18	25	13	0	1	1	15	NBB
7	445	28	2	3	0	3	ARB
4	45	137	2	16	1	7	MAT2
0	27	7	1	0	0	0	SB3
6	4	28	0	21	1	0	MAT1
3	11	8	0	1	1	6	GRC
10	14	14	0	1	1	19	GR

Banda 5

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	664	69.3835 %
Incorrectly Classified Instances	293	30.6165 %
Kappa statistic	0.5231	
Mean absolute error	0.1264	
Root mean squared error	0.2458	
Relative absolute error	65.4045 %	
Root relative squared error	79.1606 %	
Total Number of Instances	957	

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,329	0,046	0,369	0,329	0,348	0,298	0,867	0,365	NBB
0,910	0,213	0,816	0,910	0,860	0,703	0,917	0,909	ARB
0,675	0,134	0,588	0,675	0,629	0,516	0,867	0,677	MAT2

0,000 0,000 ? 0,000 ? ? 0,889 0,332 SB3
0,550 0,026 0,589 0,550 0,569 0,542 0,933 0,547 MAT1
0,067 0,002 0,500 0,067 0,118 0,174 0,906 0,302 GRC
0,305 0,030 0,400 0,305 0,346 0,312 0,906 0,372 GR
Weighted Avg. 0,694 0,146 ? 0,694 ? ? 0,901 0,720

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
24	9	17	0	6	0	17	NBB
3	444	38	0	2	0	1	ARB
7	46	143	0	12	0	4	MAT2
0	29	6	0	0	0	0	SB3
6	1	19	0	33	0	1	MAT1
9	6	8	0	1	2	4	GRC
16	9	12	0	2	2	18	GR

Banda 6

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances 663 69.279 %
Incorrectly Classified Instances 294 30.721 %
Kappa statistic 0.5213
Mean absolute error 0.1254
Root mean squared error 0.2434
Relative absolute error 64.8741 %
Root relative squared error 78.3689 %
Total Number of Instances 957

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,356	0,045	0,394	0,356	0,374	0,326	0,857	0,330	NBB
0,908	0,224	0,808	0,908	0,855	0,691	0,920	0,912	ARB
0,670	0,126	0,602	0,670	0,634	0,524	0,881	0,694	MAT2
0,000	0,000	?	0,000	?	?	0,871	0,286	SB3
0,350	0,018	0,568	0,350	0,433	0,418	0,944	0,591	MAT1
0,400	0,008	0,632	0,400	0,490	0,490	0,940	0,477	GRC
0,322	0,036	0,373	0,322	0,345	0,307	0,927	0,370	GR
Weighted Avg.	0,693	0,149	?	0,693	?	?	0,907	0,729

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
26	16	11	0	3	0	17	NBB
2	443	41	0	0	1	1	ARB
6	43	142	0	13	2	6	MAT2
0	30	5	0	0	0	0	SB3
5	1	32	0	21	0	1	MAT1
4	4	3	0	0	12	7	GRC
23	11	2	0	0	4	19	GR

Banda 7

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	670	70.0104 %
Incorrectly Classified Instances	287	29.9896 %
Kappa statistic	0.5321	
Mean absolute error	0.1251	
Root mean squared error	0.2425	

Relative absolute error 64.7339 %
 Root relative squared error 78.075 %
 Total Number of Instances 957

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,342	0,044	0,391	0,342	0,365	0,317	0,856	0,332	NBB
0,914	0,224	0,809	0,914	0,859	0,698	0,916	0,899	ARB
0,684	0,117	0,625	0,684	0,653	0,550	0,884	0,703	MAT2
0,000	0,000	?	0,000	?	?	0,838	0,266	SB3
0,383	0,014	0,639	0,383	0,479	0,470	0,948	0,644	MAT1
0,267	0,006	0,571	0,267	0,364	0,378	0,944	0,479	GRC
0,390	0,041	0,383	0,390	0,387	0,346	0,931	0,394	GR
Weighted Avg.	0,700	0,147	?	0,700	?	?	0,905	0,729

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
25	16	11	0	2	0	19	NBB
2	446	35	0	2	1	2	ARB
8	42	145	0	9	1	7	MAT2
0	29	6	0	0	0	0	SB3
4	2	31	0	23	0	0	MAT1
5	6	2	0	0	8	9	GRC
20	10	2	0	0	4	23	GR

Banda 8

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances 674 70.4284 %
 Incorrectly Classified Instances 283 29.5716 %

Kappa statistic 0.537
 Mean absolute error 0.126
 Root mean squared error 0.2434
 Relative absolute error 65.1701 %
 Root relative squared error 78.3883 %
 Total Number of Instances 957

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,384	0,043	0,424	0,384	0,403	0,357	0,847	0,336	NBB
0,912	0,232	0,803	0,912	0,854	0,688	0,915	0,904	ARB
0,693	0,121	0,620	0,693	0,655	0,551	0,883	0,692	MAT2
0,000	0,000	?	0,000	?	?	0,845	0,294	SB3
0,400	0,014	0,649	0,400	0,495	0,485	0,939	0,629	MAT1
0,300	0,008	0,563	0,300	0,391	0,397	0,948	0,450	GRC
0,356	0,029	0,447	0,356	0,396	0,364	0,923	0,430	GR
Weighted Avg.	0,704	0,151	?	0,704	?	?	0,903	0,731

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
28	16	12	0	2	2	13	NBB
2	445	37	0	1	1	2	ARB
9	43	147	0	9	0	4	MAT2
0	29	6	0	0	0	0	SB3
4	2	30	0	24	0	0	MAT1
6	6	2	0	0	9	7	GRC
17	13	3	0	1	4	21	GR

Banda 11

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	656	68.5475 %
Incorrectly Classified Instances	301	31.4525 %
Kappa statistic	0.5089	
Mean absolute error	0.1218	
Root mean squared error	0.2422	
Relative absolute error	63.0276 %	
Root relative squared error	77.9815 %	
Total Number of Instances	957	

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
	0,288	0,040	0,375	0,288	0,326	0,281	0,843	0,326	NBB
	0,904	0,224	0,808	0,904	0,853	0,687	0,928	0,925	ARB
	0,656	0,145	0,563	0,656	0,606	0,485	0,878	0,691	MAT2
	0,000	0,000	?	0,000	?	?	0,915	0,447	SB3
	0,550	0,032	0,532	0,550	0,541	0,510	0,950	0,640	MAT1
	0,033	0,002	0,333	0,033	0,061	0,097	0,901	0,239	GRC
	0,356	0,024	0,488	0,356	0,412	0,385	0,878	0,372	GR
Weighted Avg.	0,685	0,153	?	0,685	?	?	0,907	0,737	

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
21	11	20	0	10	0	11	NBB
2	441	41	0	1	1	2	ARB
5	47	139	0	16	0	5	MAT2
0	27	8	0	0	0	0	SB3
6	0	21	0	33	0	0	MAT1
7	9	7	0	2	1	4	GRC
15	11	11	0	0	1	21	GR

Banda 12

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	671	70.1149 %
Incorrectly Classified Instances	286	29.8851 %
Kappa statistic	0.5342	
Mean absolute error	0.1219	
Root mean squared error	0.242	
Relative absolute error	63.0445 %	
Root relative squared error	77.9215 %	
Total Number of Instances	957	

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,288	0,024	0,500	0,288	0,365	0,342	0,852	0,381	NBB
0,906	0,211	0,817	0,906	0,859	0,701	0,926	0,926	ARB
0,698	0,146	0,576	0,698	0,631	0,517	0,873	0,684	MAT2
0,000	0,001	0,000	0,000	0,000	-0,006	0,902	0,354	SB3
0,650	0,028	0,609	0,650	0,629	0,604	0,958	0,697	MAT1
0,067	0,005	0,286	0,067	0,108	0,125	0,882	0,267	GRC
0,322	0,029	0,422	0,322	0,365	0,333	0,876	0,371	GR
Weighted Avg.	0,701	0,146	0,656	0,701	0,671	0,560	0,905	0,741

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
21	8	24	0	6	0	14	NBB
2	442	40	1	1	1	1	ARB
2	42	148	0	13	0	7	MAT2
0	27	8	0	0	0	0	SB3
4	0	17	0	39	0	0	MAT1
4	10	7	0	3	2	4	GRC
9	12	13	0	2	4	19	GR

Cálculo NDVI

=== Stratified cross-validation ===

=== Summary ===

Correctly Classified Instances	670	70.0104 %
Incorrectly Classified Instances	287	29.9896 %
Kappa statistic	0.5334	
Mean absolute error	0.1219	

Root mean squared error 0.242
 Relative absolute error 63.0565 %
 Root relative squared error 77.9369 %
 Total Number of Instances 957

=== Detailed Accuracy By Class ===



TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
0,260	0,026	0,452	0,260	0,330	0,304	0,848	0,356	NBB
0,900	0,224	0,807	0,900	0,851	0,682	0,915	0,913	ARB
0,703	0,126	0,613	0,703	0,655	0,550	0,884	0,729	MAT2
0,000	0,002	0,000	0,000	0,000	-0,009	0,869	0,252	SB3
0,617	0,025	0,627	0,617	0,622	0,597	0,968	0,743	MAT1
0,167	0,009	0,385	0,167	0,233	0,238	0,903	0,402	GRC
0,356	0,037	0,389	0,356	0,372	0,333	0,883	0,319	GR
Weighted Avg.	0,700	0,148	0,657	0,700	0,673	0,558	0,903	0,743

=== Confusion Matrix ===

NBB	ARB	MAT2	SB3	MAT1	GRC	GR	
19	14	13	1	7	0	19	NBB
2	439	40	1	2	1	3	ARB
4	47	149	0	9	1	2	MAT2
0	27	7	0	1	0	0	SB3
2	0	21	0	37	0	0	MAT1
5	5	4	0	2	5	9	GRC
10	12	9	0	1	6	21	GR


El valor de fiabilidad más alto entre todos los atributos es el correspondiente a la Banda 8 con un porcentaje del 70.4284 %.


ANEXO 2.- PLANO



Clase Combustión

- ARB
- GR
- GRC
- MAT1
- MAT2
- NBB
- SB3



 UNIVERSITAT POLITÈCNICA DE VALÈNCIA	Escuela Técnica Superior de Ingeniería Geodésica, Cartográfica y Topográfica	
	ASIGNATURA: Trabajo Final de Master	PLANO:
	PLANO: Plano Clasificación Sierra Espadán	01
	Autor: Jose Vicente Alcover Estrela	
	Tutor: Jorge Abel Recio Recio	
Fecha: 7 de septiembre 2022		