

Universidad de La Laguna
Programa de Doctorado de Física e Ingeniería



Tesis doctoral

**Cartografiado de combustibles forestales
mediante técnicas de teledetección**

Alfonso S. Alonso Benito

Directores:

Manuel Arbelo Pérez

Universidad de La Laguna

Lara A. Arroyo Méndez

Instituto de Economía, Geografía y Demografía (IEGD), Centro
Superior de Investigaciones Científicas (CSIC)

Pedro A. Hernández Leal

Universidad de La Laguna

San Cristóbal de La Laguna, octubre 2016

D. Manuel Arbelo Pérez, Doctor en Física por la Universidad de La Laguna, D^a. Lara A. Arroyo Méndez, Doctora en Silvopascicultura por la Universidad Politécnica de Madrid, y D. Pedro A. Hernández Leal, Doctor en Física por la Universidad de La Laguna,

HACEN CONSTAR,

que D. Alfonso S. Alonso Benito, Ingeniero de Montes por la Universidad de Valladolid, ha realizado bajo nuestra supervisión la presente memoria titulada **Cartografiado de combustibles forestales mediante técnicas de teledetección**, para optar al grado de Doctor por la Universidad de La Laguna.


Y para que así conste, autorizamos la presentación de la misma y firmamos la presente.

San Cristóbal de La Laguna, octubre de 2016

Fdo: Manuel Arbelo Pérez

Fdo: Lara A. Arroyo Méndez

Fdo: Pedro A. Hernández Leal



Dedicado a mi mujer y a mis hijos Ayesha y Luca

AGRADECIMIENTOS

En primer lugar me gustaría dar las gracias a mis directores de tesis, Manuel Arbelo, Lara Arroyo y Pedro Hernández por su paciencia y ayuda en todo momento, como pueden ver, al final se ha escrito la tesis.

A los compañeros que tuve en el grupo GOTA durante los proyectos SATELMAC y PALMERA, Alejandro Lorenzo Gil y Laia Núñez Casillas, gracias por vuestra ayuda y por la colaboración prestada.

Esta tesis se la dedico a mis padres, Alfonso y Marisa, por su apoyo. A mi mujer, Luchy, por su paciencia en los peores momentos. Y a mis hijos, Ayesha y Luca, por su comprensión y por el diseño de la portada y contraportada.

Gracias a todos por aguantarme estos años.

ÍNDICE

Capítulo I. Introducción	17
I.1 Introducción.....	19
I.2 Terminología: Tipos y modelos de combustibles	24
I.3 Clasificación de los combustibles forestales	26
I.4 Cartografiado de tipos de combustibles	27
I.4.1 Imágenes de satélite	28
I.4.2 Datos LiDAR	30
I.4.3 Fusión de datos.....	31
I.5 Objetivos de la tesis	32
I.6 Estructura de la tesis	33
Capítulo II. Cartografiado de tipos de combustibles usando imágenes ASTER	35
II.1 Resumen	37
II.2 Zona de estudio.....	37
II. 3 Materiales y métodos.....	40
II.3.1 Imágenes ASTER	40
II.3.2 Mapa de referencia	44
II.3.3 Métodos de clasificación.....	49

II.3.4 Evaluación del error	55
II.4 Resultados y discusión.....	59
Capítulo III. Cartografiado de tipos de combustibles usando imágenes WorldView-2	71
III.1 Resumen	73
III.2 Zona de estudio.....	74
III.3 Materiales y métodos.....	75
III.3.1 Imágenes WorldView-2.....	75
III.3.2 Datos de campo	79
III.3.3 Clasificación OBIA	83
III.3.4 Evaluación del error	86
III.4 Resultados y discusión.....	87
Capítulo IV. Cartografiado de tipos de combustibles mediante fusión de imágenes WorldView-2 y datos LiDAR	93
IV.1 Resumen.....	95
IV.2 Introducción	96
IV.3 Zona de estudio	97
IV.4 Materiales y métodos	98
IV.4.1 Datos LiDAR.....	98

IV.4.2 Fusión de los datos LiDAR y multiespectrales.....	103
IV.4.3 Clasificación OBIA	104
IV.4.4 Evaluación del error.....	105
IV.5 Resultados y discusión	106
Capítulo V. Conclusiones	115
V.1 Conclusiones	117
Referencias.....	121
Anexo A.....	141
Anexo B	155
Anexo C	175

LISTA DE FIGURAS

Figura 1.1. Actividades relacionadas con la gestión de los incendios forestales (Fuente: GAO, 2003).....	21
Figura 1.2. Tipos de incendios forestales.	25
Figura 2.1. Ubicación del área de estudio: (a) Islas Canarias; (b) Isla de Tenerife (Fuente: Ortoexpress de GRAFCAN); (c) Área de estudio (imagen ASTER en falso color).	38
Figura 2.2. División de la zona de estudio según rangos altitudinales. Altitud en metros sobre el nivel del mar.	39
Figura 2.3. El sensor ASTER. (a) Instrumentos del sensor ASTER (Fuente: https://asterweb.jpl.nasa.gov/); b) Satélite TERRA (Fuente: Satellite Imaging Corporation).....	41
Figura 2.4. Mapa de tipos de combustible para el área de estudio de acuerdo a la clasificación BEHAVE del III Inventario forestal Nacional.	46
Figura 2.5. Mapa de referencia empleado para este estudio. Tipos de combustible según el sistema de clasificación de combustibles FBFT (Scott & Burgan, 2005).	47
Figura 2.6. Mapas de combustibles forestales obtenidos con el clasificador de Máxima Probabilidad (arriba) y Red Neuronal (abajo). ...	61
Figura 2.7. Mapas de combustibles forestales obtenidos con el clasificador de SVM (arriba) y OBIA (abajo).....	62
Figura 2.8. Comparación entre el mapa de referencia y las clasificaciones obtenidas. El color azul indica coincidencia (acierto en la clasificación). El resto de colores indican, para aquellas áreas en las que hay desacuerdo, el tipo de combustible obtenido para el clasificador de Máxima Probabilidad (arriba) y Red Neuronal (abajo).	63

Figura 2.9. Comparación entre el mapa de referencia y las clasificaciones obtenidas. El color azul indica coincidencia (acierto en la clasificación). El resto de colores indican, para aquellas áreas en las que hay desacuerdo, el tipo de combustible obtenido para el clasificador de SVM (arriba) y OBIA (abajo).64

Figura 2.10. Análisis de los errores encontrados en los mapas de combustibles generados a partir de imágenes ASTER para todos los sistemas de clasificación empleados.65

Figura 2.11. Análisis de los errores encontrados para cada tipo de combustible cartografiado a partir de imágenes ASTER para los clasificadores de Máxima Probabilidad (arriba) y Red Neuronal (abajo). 68

Figura 2.12. Análisis de los errores encontrados para cada tipo de combustible cartografiado a partir de imágenes ASTER para los clasificadores de SVM (arriba) y OBIA (abajo).69

Figura 3.1. Zona de estudio. Ubicación dentro de la isla de Tenerife (esquina superior izquierda) e imagen WV-2 de la zona de estudio en color verdadero. Los círculos rojos indican la ubicación de las parcelas del trabajo de campo.74

Figura 3.2. Respuesta espectral de las bandas del satélite WV-2 (Fuente, Updike & Comp 2011).76

Figura 3.3. Ejemplo de una parcela de campo y esquema con la disposición de cuatro transectos siguiendo las direcciones N, S, E y W. Dentro de cada transecto se tomaron medidas de cada metro. En el centro de las parcelas, se tomó la coordenada GPS (marcado en rojo). .80

Figura 3.4. Clasificación de los tipos de combustibles según Prometheus. Imagen elaborada a partir de Arroyo *et al.*, 2006.81

Figura 3.5. Ejemplos de las formaciones encontradas en la zona de estudio correspondientes a los tipos de combustibles Prometheus.	83
Figura 3.6. Ejemplos de la influencia de la escala (<i>scale parameter</i>) en el proceso de segmentación. Imagen WV-2 original (representada en color verdadero) y segmentaciones obtenidas para valores de escala de 10, 25, 90, 150 y 250 (representadas en ese orden, empezando por el panel superior izquierdo).	86
Figura 3.7. Mapa de tipos de combustibles obtenido en la zona de estudio aplicando OBIA.	88
Figura 3.8. Distribución de los tipos de combustible en la zona de estudio. Las columnas representan las superficies relativas (en %) y los valores el tamaño medio por objeto para cada clase (en píxeles).....	88
Figura 3.9. Errores por cantidad y ubicación para cada tipo de combustible.....	90
Figura 4.1. Diagrama de flujo usado para la comparación de técnicas de fusión y cartografiado de tipos de combustibles a partir de datos LiDAR y WV-2.	98
Figura 4.2. Zona de estudio: a) Localización del área de trabajo en la isla de Tenerife; b) Imagen WV-2 (composición verdadero color). Las líneas amarillas muestran las escenas LiDAR y los puntos rojos son las parcelas del trabajo de campo; c) Composición 3D con datos LiDAR de la zona La Caldera; d) Imagen WV-2 de La Caldera en verdadero color. (Fuente: Alonso-Benito <i>et al.</i> , 2016).	99
Figura 4.3. Mapas MDT y CHM (Altura de la Vegetación) obtenidos a partir de los datos LiDAR de la zona objeto de estudio.	101
Figura 4.4. Mapas de densidad: #1 hasta 0,5 m, #8 entre 3,5 y 4 m, y #17 mayor a 15m. Todos comparados con la imagen RGB de la zona.	102

Figura 4.5. Ejemplos de la segmentación en cada imagen con diferentes parámetros de escala: (a) WV-2, (b) IS, (c) PCA y (d) MNF (Fuente: Alonso-Benito *et al.*, 2016).105

Figura 4.6. Mapas de tipos de combustibles obtenidos para: a) Imagen WV-2 sola; b) IS; c) PCA; d) MNF.107

Figura 4.7. Mapas de tipos de combustibles obtenidos para: a) imagen WV-2 sola; b) IS; c) PCA; d) MNF.108

Figura 4.8. Distribución de la superficie de cada tipo de combustible obtenido.....109

LISTA DE TABLAS

Tabla 2.1. Características de los subsistemas del sensor ASTER.	41
Tabla 2.2. Características de la imagen ASTER L1B. Datos tomados del archivo de metadatos asociado a la misma.....	44
Tabla 2.3. Correspondencia entre los tipos de combustible BEHAVE y FBFT para la zona de estudio, incluyendo su descripción (descripción tipos BEHAVE extraída de Rothermel, 1983, p.9).	48
Tabla 2.4. Parámetros de segmentación utilizados para cada zona del área de estudio.....	54
Tabla 2.5. Tipos de combustibles presentes en cada zona del área de estudio. Se muestra la superficie total (ha), la superficie relativa con respecto al área total (%) y la superficie cubierta por áreas de entrenamiento (ha).	56
Tabla 2.6. Matriz de confusión empleada para la evaluación de la exactitud (adaptada de Pontius y Millones, 2011).....	58
Tabla 3.1. Resolución espacial y espectral del sensor WV-2.....	76
Tabla 3.2. Pesos relativos de cada banda MS utilizados en la segmentación.....	84
Tabla 3.3. Matriz de confusión obtenida tras la clasificación.	89
Tabla 3.4. Errores cometidos por tipo de combustible (las medidas del error por cantidad y ubicación son relativas y vienen dadas en %).	89
Tabla 4.1. Medidas por tipo de combustible del acierto obtenido (errores relativos y totales por cantidad y ubicación) para los tres mapas generados por fusión y el obtenido con la imagen WV-2 sola (valores en %).	110

Capítulo I. Introducción

I.1 Introducción

Los incendios son el principal agente perturbador de los ecosistemas forestales después de la actividad humana y agrícola (Bond y van Wilgen, 1996; Goldammer, 2006). Sin embargo, hay incendios forestales que forman parte natural del ecosistema y mantienen la biodiversidad del mismo.

En los últimos años se ha incrementado el número de incendios no naturales, y con ello, se ha producido un aumento de los daños, convirtiéndose en una grave amenaza para la salud pública, el bienestar económico y los valores ecológicos del ecosistema afectado (Pyne, 2001).

Anualmente, los incendios forestales afectan alrededor de tres a cuatro millones de km² en todo el mundo, lo que equivale a un 3% de la superficie vegetal de la Tierra (Giglio *et al.*, 2013). Estos incendios producen unas emisiones de gases de efecto invernadero (fundamentalmente CO₂) estimadas entre un 25-35% sobre el total de emisiones netas (FAO, 2012).

En Europa, el 70% de los incendios se producen en los países de la cuenca mediterránea (JRC, 2014). Durante las décadas de los 80 y 90, los incendios aumentaron debido a un abandono masivo de tierras (Mouillot & Field, 2005), aunque un mayor número de incendios, sin embargo, no se tradujo en un aumento del área quemada. Se ha observado una gran variabilidad interanual con una tendencia a la baja (San-Miguel-Ayanz *et al.*, 2013), posiblemente provocada por la crisis financiera que ha sufrido Europa estos últimos años, especialmente en los países mediterráneos.

En España se han producido 416.000 incendios durante el período 1991-2014. De ellos, un 63% fueron conatos y sólo un 37% incendios con superficie mayor a 1 hectárea (ha). Los incendios sufridos durante estos

años han quemado una superficie equivalente a la Comunidad Autónoma de Cataluña (32.000 km²). De estos, un 42% se corresponden con grandes incendios forestales (GIF), incendios que superan las 500 ha de superficie (ADCIF, 2002; ADCIF, 2012; ADCIF, 2013; ADCIF, 2014). Estos incendios han supuesto unas pérdidas económicas estimadas en no menos de 1.100 millones de euros anuales (Ortuño Pérez y Fernández-Cavada Labat, 2007).

En las Islas Canarias se han dado 1.693 incendios durante el período 2000-2015, de los cuales un 85% fueron conatos. Del 15% de los incendios ocurridos (superficie mayor a 1 ha), un 3,9% se declararon como GIF. En la última década, el 93% de la superficie quemada ha ocurrido en el 0,6% de los incendios ocurridos en las islas. De estos, un 57% (35.500 ha) se produjeron en dos GIF en el año 2007 (datos extraídos de ISTAC, Instituto Canario de Estadística).

Una adecuada y eficaz gestión de los incendios forestales conlleva actuaciones en tres momentos distintos (GAO, 2003) (Figura 1.1). Las actividades previas a un incendio se centran en minimizar el riesgo, y consisten en el seguimiento de cambios en la vegetación, el control de los combustibles forestales y la observación y predicción de las variables meteorológicas temperatura, humedad y viento fundamentalmente. Otras actividades durante esta fase incluyen la gestión de los recursos humanos y la evaluación de los materiales disponibles. Las actividades que se llevan a cabo durante un incendio incluyen la detección del mismo, la planificación del ataque contra el fuego y el envío de recursos. Con respecto a las actividades post-incendio se incluye la evaluación del impacto del fuego (cuanto, cómo y dónde se ha quemado), los mecanismos de estabilización que protejan frente a los efectos secundarios del fuego (inundaciones, contaminación de la cuenca o erosión de la superficie), la rehabilitación de las zonas afectadas y la realización de trabajos de restauración.

En varias de las actividades relacionadas con la gestión de los incendios forestales, la teledetección desempeña un papel importante. La teledetección consiste en la medición de la radiación electromagnética reflejada o emitida por los objetos de la superficie terrestre mediante sensores que no están en contacto directo con ellos. Estos sensores pueden estar a bordo de satélites, vehículos aéreos o drones, y miden la energía en diferentes partes del espectro electromagnético, desde el ultravioleta a las microondas.

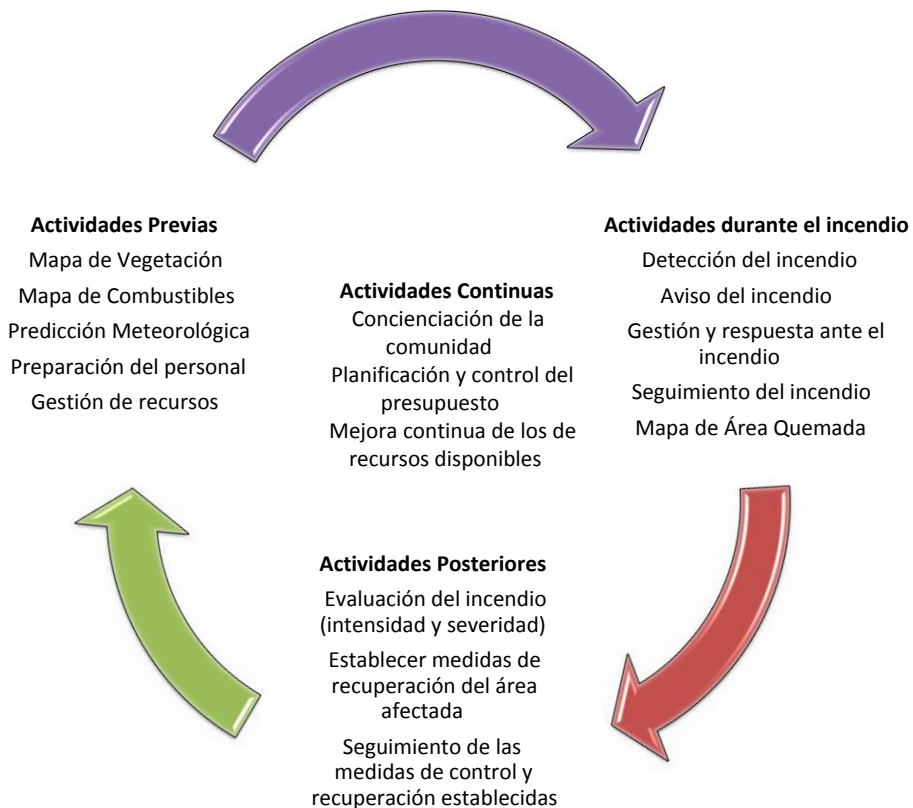


Figura 1.1. Actividades relacionadas con la gestión de los incendios forestales (Fuente: GAO, 2003).

Durante la fase previa al incendio, sensores sensibles a la radiación en el rojo ($\sim 0,6 \mu\text{m}$) e infrarrojo próximo ($\sim 0,8 \mu\text{m}$) permiten obtener información del estado de la vegetación mediante los denominados índices espectrales. Una completa revisión sobre el tema se encuentra

en Xie *et al.* (2008). La predicción del riesgo de incendio también se aborda mediante técnicas de teledetección. Los sensores remotos permiten obtener el contenido de humedad de la vegetación y las condiciones meteorológicas que se utilizan para generar índices de riesgo. En ecosistemas mediterráneos, Piñol *et al.* (1998) relacionaron datos de una estación meteorológica con índices de riesgo de incendio desde satélite. Para la Península Ibérica, Pausas (2004) analizó la relación entre la climatología y la ocurrencia de incendios. En las Islas Canarias, fuertemente afectadas por los incendios forestales durante la última década, se han desarrollado herramientas de evaluación del riesgo de incendios. Para ello, se ha usado un modelo de regresión logística multivariante, que combina los datos de Teledetección y diferentes variables asociadas al riesgo (tipo de vegetación, horas de insolación, proximidad a las carreteras, estadísticas de incendios...), y las integra en un Sistema de Información Geográfico (Hernández-Leal *et al.*, 2006; 2008). En el trabajo de Yebra *et al.* (2013) se hace un completo repaso a la literatura publicada sobre la obtención del contenido en humedad de la vegetación viva mediante teledetección. Por último, la teledetección se emplea para el cartografiado de los combustibles forestales, tema fundamental en este trabajo de tesis y que será tratado con más detalle en el tercer apartado de este capítulo.

Durante la fase de ocurrencia del incendio, los sensores remotos pueden detectar un fuego por la pluma de humo producida (Leblon *et al.*, 2012) o por las altas temperaturas originadas. Varios autores han desarrollado algoritmos de detección de incendios usando principalmente sensores con bandas situadas en el infrarrojo medio ($\sim 4 \mu\text{m}$) y el térmico (10 – 12 μm). Ayanzi *et al.* (2005) utilizaron imágenes del sensor SEVIRI (Spinning Enhanced Visible and Infrared Imager) a bordo del Meteosat, Li *et al.* (2001) el sensor AVHRR (Advanced Very High Resolution Radiometer). Utilizando las mismas bandas, pero con el sensor MODIS (Moderate-Resolution Imaging Spectroradiometer) de los satélites TERRA y AQUA de NASA, Kaufman *et al.* (1998) desarrolló un algoritmo de detección que

posteriormente fue mejorado por Giglio *et al.* (2003) ampliando el número de canales utilizados.

Tras el fuego, se han empleado técnicas de teledetección para cartografiar la extensión y determinar la severidad del incendio. En muchos trabajos se realizan estimaciones del área quemada a nivel global usando imágenes del NOAA-AVHRR (Pereira, 1999; Moreno-Ruiz *et al.*, 2012), SPOT Vegetation (Satellite Pour l'Observation de la Terre Vegetation) o ATSR-2 (Along Track Scanning Radiometer) (Tansey *et al.*, 2008; Simon *et al.*, 2004). A nivel regional, podemos citar el uso de imágenes MODIS (Justice *et al.*, 2002; Alonso-Benito *et al.*, 2008), o el uso de los productos MODIS de áreas quemadas para estudios de comparación con datos reales (Moreno-Ruiz *et al.*, 2014) o la comparación entre los productos MODIS con datos de NOAA-AVHRR y SPOT Vegetation (Núñez-Casillas *et al.*, 2013), Landsat-TM (Thematic Mapper) (Michalek *et al.*, 2000; Chuvieco y Congalton, 1989; Mallinis y Koutsias, 2012) o ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) (Alonso-Benito *et al.*, 2008). En relación con la severidad se han determinado diferentes índices o clasificaciones. En EEUU por ejemplo, se utiliza BARC (Burned Area Reflectance Classification), el cual presenta cuatro clases de severidad. Roy *et al.* (2006) utilizan el índice NBR (Normalized Burn Ratio) con imágenes Landsat ETM+ (Enhanced Thematic Mapper Plus). Miller *et al.* (2009) propone el RdNBR (Relative Differenced Normalized Burn Ratio) para clasificar cuatro tipos de severidad. Santis y Chuvieco (2009) modificaron el índice CBI (Composite Burn Index) para crear el GeoCBI, que tiene en cuenta la fracción de cabida cubierta de la vegetación y los cambios que se producen en el índice de área foliar (LAI, Leaf Area Index). Malone *et al.* (2011) utilizaron datos históricos de incendios con imágenes Landsat y el índice dNBR (differenced Normalized Burn Ratio).

I.2 Terminología: Tipos y modelos de combustibles

Antes de introducir el concepto de combustible forestal y las diferentes clasificaciones que se utilizan para su cartografiado, conviene comentar brevemente qué tipos de incendios forestales se pueden producir de acuerdo a la forma en que se propagan.

Los incendios forestales se clasifican en fuego de suelo o subsuelo, fuego de superficie o fuego de copas (Figura 1.2).

En los incendios de suelo, el fuego se propaga por la materia orgánica en descomposición y las raíces. Casi siempre se queman despacio y en combustión incandescente (poca o ausencia de llama) al no disponer de suficiente oxígeno (Scott & Reinhardt, 2001). En el incendio de superficie, el fuego se propaga por la hojarasca, hierbas, arbustos y madera caída que se encuentra en el suelo, pero no por restos vegetales en descomposición (Scott & Reinhardt, 2001). Y en los incendios de copas el fuego consume la cubierta arbórea. Estos, pueden presentar tres sub-tipos: pasivos o de antorcha, donde las copas se encienden de forma intermitente debido a la presencia del frente de fuego en el sotobosque; activos, en los que simultáneamente se produce la combustión del material de superficie y las copas de los árboles; e incendios de copas independientes, donde el frente del incendio avanza rápidamente, sin influir la presencia o no de un fuego de superficie.

Toda la vegetación dispuesta a arder son los **combustibles forestales**. Para caracterizar correctamente estos combustibles, se necesita conocer la cantidad y proporción de biomasa viva y muerta, como se distribuyen los tamaños (ramas, hojas, troncos,...), la distribución horizontal de la vegetación (composición de la misma) y su estructura vertical (Burgan *et al.*, 1998; Andrews and Queen, 2001). Como resulta imposible obtener esta información para toda la superficie forestal, se simplifica la realidad definiendo distintos **tipos de combustibles**. Una posible definición la

podemos tomar de Merrill y Alexander (1987), que definen los tipos de combustibles como “aquellas asociaciones vegetales, con especies, formas, tamaños y continuidad, que presentan un mismo comportamiento ante un incendio forestal”.

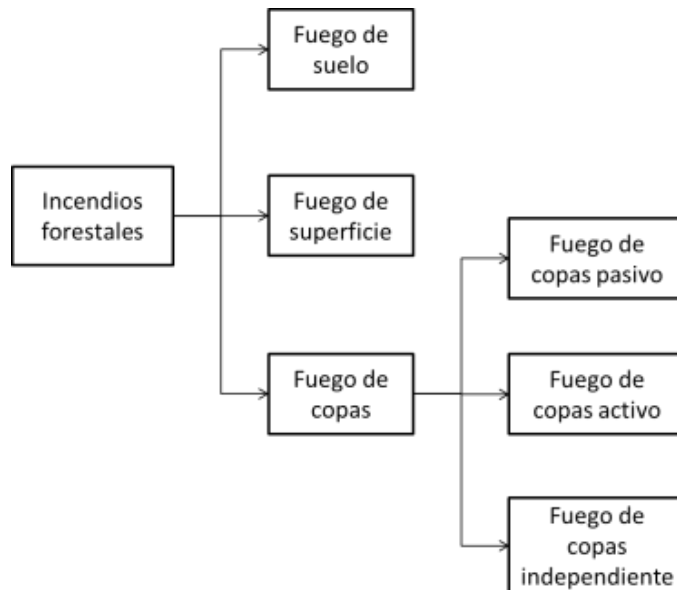


Figura 1.2. Tipos de incendios forestales.

Para estudiar los incendios históricos o para planificar las labores de extinción en un incendio activo se utilizan modelos de simulación matemáticos del comportamiento y propagación del fuego. Están basados en el triángulo del fuego forestal formado por los combustibles, el tiempo atmosférico y la topografía, teniendo cada uno de los lados de ese triángulo sus propios modelos o simplificaciones de la realidad. Uno de los datos de entrada necesarios para ejecutar esos programas de simulación son los denominados modelos de combustibles (Keane and Reeves, 2012). Este término se refiere a las ecuaciones matemáticas que describen las características potenciales de un combustible forestal. Entre los modelos de simulación de comportamiento del fuego más conocidos cabe citar: FARSITE (Finney 2004), BehavePlus (Andrews, 2009), FlamMap (Finney, 2006) o Prometheus (Tymstra *et al.*, 2010).

I.3 Clasificación de los combustibles forestales

Existen numerosas clasificaciones de combustibles forestales. EEUU, Canadá y Australia son los países que más investigación y desarrollo han realizado en este campo (Arroyo et al., 2008).

La clasificación más usada en EEUU se basa en el modelo NFDRS (National Fire Danger Rating System) (Rothermel, 1972), que simula la propagación del incendio en fuegos de superficie y tiene en cuenta las condiciones meteorológicas. NFDRS fue desarrollado en 1968 con el fin de completar un sistema de evaluación del riesgo de incendios. Consideraba en origen 9 tipos de combustibles, que más tarde se ampliaron a 13 (Deeming *et al.*, 1972) y posteriormente a 26 (Deeming *et al.*, 1977).

Otra clasificación muy usada en EEUU para estudios a nivel local es la NFFL (Northern Forest Fire Laboratory). Es la base del modelo BEHAVE (Deeming *et al.*, 1977; Albini, 1976) y distingue 13 tipos de combustibles. El modelo FARSITE (Finney, 1998; 2004) también utiliza la clasificación NFFL, además de un modelo de fuego de copas. En Europa también se ha usado la clasificación NFFL adaptada a las condiciones de la vegetación mediterránea.

A partir de 2005 se propone una mejora del sistema NFDRS denominada FBFT (Fire Behavior Fuel Types) (Scott & Burgan, 2005). Esta clasificación propone siete grandes grupos de combustibles con diferente número de tipos indicados entre paréntesis: no quemables (5), hierbas (10), hierbas-matorrales (4), matorrales (9), restos bajo cubierta (5), restos de corta (10) y hojarasca (6). En total 49 tipos de combustibles.

En Canadá se utiliza el Canadian Forest Fire Danger Rating System (CFFDRS) que está basado en el modelo meteorológico Canadian Fire Weather Index System (FWI) (van Wagner and Pickett, 1985), y en el modelo de propagación del fuego Canadian Fire Behaviour Prediction

System (FBP) (Forestry Canada, 1992). Considera 16 tipos de combustibles.

En Europa, fruto de un proyecto de la Unión Europea, surge en 1999 la clasificación Prometheus (Prometheus, 2000), que distingue siete tipos de combustibles por la altura de la vegetación y la distancia entre el sotobosque y el estrato arbóreo. Esta clasificación será expuesta en profundidad en el capítulo 3 de esta memoria.

I.4 Cartografiado de tipos de combustibles

Cartografiar los combustibles forestales a escala global resulta fundamental para simular procesos dinámicos de gran importancia como la evolución de contenido de carbón, el cambio climático o los ciclos ambientales. A nivel regional o local, los gestores forestales necesitan disponer de mapas actualizados y veraces del estado de los combustibles. Esta información les permite evaluar y planificar los tratamientos que deben hacerse, calcular el peligro, analizar el riesgo de incendio o evaluar las subvenciones económicas con fines ambientales. Estos últimos son los que tienen mayor interés para la conservación de los ecosistemas y por tanto, en los que nos centraremos en la presente memoria.

Cartografiar los combustibles forestales es un proceso muy complejo, incluso a escala local. El principal inconveniente es la alta variabilidad temporal y espacial que presentan los tipos de combustibles. Esta variabilidad intrínseca, que influye de forma directa sobre la propagación del fuego y sus efectos, favorece la confusión entre los tipos de combustibles, y complica la descripción y clasificación de los mismos (Keane, 2013). Esto conduce muchas veces a mapas con poca fiabilidad y grandes errores (Keane and Reeves, 2012). La carga de combustible, cantidad total de combustible disponible, también presenta grandes variaciones. Por ejemplo, un combustible de suelo puede estar formado

por diferentes componentes (hojarasca, ramas, troncos, etcétera) y cada uno presentar su propio calor específico, su propia humedad y distintos tamaños, incluso dentro del mismo tipo de combustible.

Los tipos de combustibles se pueden cartografiar usando distintos métodos (Arroyo *et al.*, 2008):

1. Trabajo de campo: conlleva un costo económico muy elevado y mucho tiempo.
2. Interpretación de fotografías aéreas y validación con trabajo de campo: presenta un costo moderado en tiempo y dinero con resultados satisfactorios para escalas locales.
3. Teledetección, del cual se habla con más detalle a continuación.

I.4.1 Imágenes de satélite

En la segunda mitad de los años 60, algunos autores ya predijeron la importancia que tendría la teledetección en el cartografiado de los combustibles forestales (Adams, 1965). Desde entonces, ha habido una gran evolución de las técnicas usadas: los primeros trabajos estaban limitados por la resolución espacial y espectral de las imágenes, y no ha sido hasta la aparición de satélites con mejores resoluciones cuando se han empezado a producir mapas de combustibles a escala local fiables.

El primer trabajo publicado sobre el cartografiado de combustibles forestales a partir de imágenes de satélite se debe a Kourtz (1977). Utilizó imágenes del sensor MSS (Multi-Spectral Scanner) a bordo del Landsat (80 m de resolución espacial y 4 bandas espectrales en visible e infrarrojo próximo) en diferentes períodos y clasificó 9 tipos de combustibles forestales en el noroeste de Ottawa (Canada). Continuaron otros estudios con imágenes de media resolución espacial como Landsat-TM (Salas and Chuvieco, 1995; Maselli *et al.*, 2000). Desde entonces han sido numerosos los estudios que plantean el cartografiado de combustibles con sensores remotos y diferentes algoritmos de

clasificación. La exactitud global en general se sitúa entre un 60 y un 90%. Lasaponara & Lanorte (2007) aplicaron el algoritmo de Máxima Probabilidad con imágenes ASTER del sur de Italia usando la clasificación de Prometheus, obteniendo una exactitud del 91%. En la misma región, Coluzzi *et al.* (2007) obtuvieron una exactitud del 78% aplicando un algoritmo basado en redes neuronales. En otros casos el error aumentaba considerablemente, como presentan en su trabajo Falkowski *et al.* (2005). Obtuvieron un mapa de combustibles de una zona montañosa de Moscow (Idaho, EEUU) siguiendo la clasificación BEHAVE con una exactitud del 63%. En España, el estudio pionero se refiere a Riaño *et al.* (2002). Estos autores consiguieron alcanzar una exactitud del 83% usando imágenes Landsat-TM en el Parque Nacional de Cabañeros. Peterson *et al.* (2013) cartografiaron los tipos de combustibles del Parque Nacional de Yosemite en EEUU obteniendo exactitudes entre el 46 y 71%. Para ello, emplearon un árbol de decisión Random Forest, utilizando datos históricos de incendios, imágenes Landsat TM, imágenes AVIRIS (Airborne Visible/InfraRed Imaging Spectrometer), y variables topográficas y climáticas.

En la última década, con la puesta en órbita de satélites con sensores de muy alta resolución espacial, varios estudios abordan la utilización de algoritmos orientados al objeto (denominados OBIA, de las siglas en inglés de Object Based Image Analysis). Los resultados de dichos estudios describen mejoras en los resultados de dichos algoritmos frente a los tradicionales, basados en píxeles. Así, Arroyo *et al.* (2006) compararon OBIA con el clasificador tradicional de Máxima Probabilidad en una zona de la provincia de Madrid, obteniendo exactitudes del 82 y 75% respectivamente. Tanase y Gitas (2008) realizaron una comparación entre OBIA e ISODATA en la isla de Creta (Grecia), obteniendo una mejora del 10% del primero sobre el segundo. Mallinis *et al.* (2014) aplicando SVM (Support Vector Machine) compararon los mapas obtenidos con Quickbird, EO1-Hyperion (Earth Observing-1) y Landsat TM en una zona del norte de Grecia, obteniendo exactitudes del 74%

para el primero y 70% para los otros dos. Bajocco *et al.* (2015) analizaron con clúster una serie de imágenes MODIS NDVI de doce años, para cartografiar clases de combustibles basadas en la fenología de la vegetación en la isla italiana de Cerdeña.

La principal desventaja del uso de imágenes de sensores multiespectrales es su imposibilidad de penetrar bajo la cubierta forestal, lo que dificulta la identificación de combustibles con estructuras verticales de más de una capa de vegetación (Keane *et al.*, 2001).

I.4.2 Datos LiDAR

El LiDAR es un sensor activo que aporta información de la estructura vertical de la vegetación. Gracias a su capacidad para atravesar la cubierta vegetal, estos datos son útiles para estimar propiedades de la vegetación relevantes de cara a la predicción de la propagación del fuego. Los combustibles no siempre están relacionados con el tipo de vegetación existente, porque un mismo tipo de vegetación puede tener diferentes tipos de combustibles (Keane *et al.*, 2001).

El LiDAR emite pulsos láser y registra el tiempo de retraso entre la emisión del pulso y la detección de la señal reflejada, lo que permite estimar de forma precisa la distancia entre el sensor y el objeto que reflejó la señal. En la actualidad, la mayoría de los sensores LiDAR recogen además la intensidad de la señal reflejada.

Existen dos formas de cartografiar los combustibles con datos LiDAR: directamente o indirectamente. La primera calcula cuantitativamente propiedades de los combustibles de la nube de puntos. La segunda clasifica cualitativamente los datos de acuerdo a los tipos de combustibles (Ferraz *et al.*, 2009).

Los métodos directos han sido muy usados para obtener diferentes propiedades de los combustibles (Riaño *et al.*, 2003), para estimar diversos parámetros de los mismos (Andersen *et al.*, 2005; Holmgren &

Persson, 2004; Riaño *et al.*, 2004; Popescu & Zhao, 2008; Erdody y Moskal, 2010; Hermosilla *et al.*, 2013), para evaluar el riesgo de incendio (Morsdorf *et al.*, 2004) o para calcular el índice de área foliar (LAI) (Richardson *et al.*, 2009). Otros autores han obtenido medidas de los restos de cortas relacionando datos de campo con datos LiDAR (Pesonen *et al.*, 2008). En Hyypä *et al.* (2008) se recopilan diferentes métodos para extraer información forestal a partir de datos LiDAR.

Los métodos indirectos, por el contrario, han sido muy estudiados. Jakubowski *et al.* (2013), cartografiaron los combustibles en una zona montañosa de California (EEUU) usando LiDAR, y obtuvieron exactitudes que oscilan entre el 24% aplicando un análisis clúster k-means y un 37% aplicando el algoritmo SVM. Quatrini *et al.* (2014) estudiaron la posibilidad de usar datos LiDAR de baja densidad en dos zonas de Italia (Sicilia y la Toscana), para cartografiar los combustibles y los resultados variaron entre el 53% para Sicilia y el 87% para Toscana.

La mayoría de los trabajos de cartografiado con datos LiDAR se centran en su fusión con imágenes multiespectrales, como veremos en el siguiente apartado.

1.4.3 Fusión de datos

La fusión de datos de sensores de diferente naturaleza se usa para mejorar los resultados del cartografiado de combustibles. La tendencia de los trabajos publicados recientemente consiste en la fusión de imágenes de alta o muy alta resolución espacial con datos provenientes de sensores activos como RADAR o LiDAR. El interés de estos estudios radica en la posibilidad de estudiar la cobertura forestal con las imágenes multiespectrales y la estructura de la vegetación bajo esta cobertura con los sensores activos.

Mutlu *et al.* (2008) fusionaron los datos LiDAR con imágenes QuickBird y compararon diferentes técnicas de fusión para obtener mapas de

combustibles. Analizaron tres métodos de fusión: unión de todas las capas, PCA (análisis de componentes principales) y MNF (fracción del mínimo ruido). Con el primero se mejoraba la exactitud en un 11% con respecto a la clasificación usando sólo la imagen Quickbird, con PCA la exactitud no era mejor y con MNF obtuvieron una mejora del 14%. En 2011, García *et al.*, fusionaron datos LiDAR y una imagen ATM (Airborne Thematic Mapper). Primero aplicaron un algoritmo SVM sobre la imagen ATM y a continuación un árbol de decisión con los datos LiDAR, obteniendo una exactitud del 88%. Jakubowski *et al.* (2013) fusionaron LiDAR y una imagen aérea de infrarrojo, aplicando diferentes algoritmos de clasificación (clúster k-means, árboles de regresión y SVM con regresión). Usando la unión de LiDAR y la imagen obtuvieron exactitudes entre el 23% y 40%, prácticamente la misma que se obtenía sólo con datos LiDAR. Con LiDAR y MNF obtuvieron resultados entre el 23% y el 45% y con PCA no encontraron mejora en la exactitud (15% al 44%).

Los resultados obtenidos en estos estudios muestran mejoras en la exactitud alcanzada con respecto al uso de una imagen multiespectral sola del orden del 10%.

I.5 Objetivos de la tesis

El objetivo general de la presente tesis es evaluar la posibilidad de utilizar sensores remotos para cartografiar combustibles forestales a escala local en una región orográficamente compleja como las Islas Canarias. Para ello, se seleccionó un área de estudio representativa, tanto por su relieve como por la vegetación, ubicada en el término municipal de La Orotava, al Norte de la isla de Tenerife. Se establecieron los siguientes objetivos específicos:

1. Evaluar el potencial de las técnicas OBIA para generar un mapa de combustibles forestales a partir de imágenes del sensor ASTER

(Advanced Spaceborne Thermal Emission and Reflection Radiometer).

2. Evaluar el potencial de las técnicas OBIA para obtener un mapa de combustibles forestales a partir de imágenes del sensor WorldView-2.
3. Evaluar el potencial de combinar técnicas de fusión de datos y OBIA para obtener un mapa de combustibles forestales a partir de datos LiDAR y WorldView-2.

I.6 Estructura de la tesis

La presente memoria se estructura en cinco capítulos. En el **Capítulo 1** se describe el estado del arte del tema objeto de este trabajo y se plantean los objetivos generales y específicos. En el **Capítulo 2** se analizan los mapas de combustibles obtenidos con imágenes ASTER y se explican los algoritmos utilizados para generar dichos mapas (orientados al píxel y OBIA). En el **Capítulo 3** se describe y evalúa el uso de OBIA para cartografiar combustibles forestales utilizando imágenes WorldView-2 de muy alta resolución espacial. A continuación, el **Capítulo 4** describe y analiza diferentes técnicas de fusión datos LiDAR y WorldView-2 para combinar con técnicas de clasificación OBIA y producir mapas de combustibles. Por último, en el **Capítulo 5** se presentan las principales conclusiones.

Capítulo II. Cartografiado de tipos de combustibles usando imágenes ASTER

Los resultados de este capítulo han sido publicados en el artículo:

Alonso-Benito, A., Arroyo, L. A., Arbelo, M., Hernández-Leal, P., González-Calvo, A. (2013). Pixel and object-based classification approaches for mapping forest fuel types in Tenerife Island from ASTER data. *International Journal of Wildland Fire* 22, 306–317 <http://dx.doi.org/10.1071/WF11068>. Factor de impacto 2013: 2,79.

II.1 Resumen

En este capítulo se evalúan y comparan cuatro algoritmos para cartografiar los combustibles forestales a partir de imágenes del sensor Terra-ASTER, en una zona representativa de la isla de Tenerife. El mapa utilizado como referencia para validar los resultados se obtuvo mediante la adaptación del mapa de combustibles realizado en 2002 durante el III Inventario Forestal Nacional. Tres de los algoritmos aplicados eran orientados al pixel (Máxima Probabilidad, Red Neuronal y Máquina de Vectores de Soporte) y uno orientado a objetos (OBIA). La exactitud de las clasificaciones se evaluó teniendo en cuenta los errores por cantidad y por ubicación. De los algoritmos orientados al pixel, el mapa obtenido mediante Máquina de Vectores de Soporte mostró una exactitud global del 83%, con un error por ubicación del 14% y un 3% de error por cantidad. El algoritmo orientado a objetos produjo la mayor exactitud global, un 95%, con un 4% de error por ubicación y un 1% por cantidad. Este resultado mejoró en un 12% al mejor de los algoritmos orientados al pixel. La incorporación de información contextual ayudó a discriminar entre combustibles con una respuesta espectral similar.

Comenzaremos este capítulo describiendo la zona de estudio y sus características principales. A continuación, se explica el pre-procesamiento realizado sobre la imagen ASTER antes de aplicarle cualquier algoritmo. En el siguiente apartado se indica cómo se obtuvo el mapa de combustibles que se tomó como referencia, así como los métodos de clasificación utilizados. Finalizaremos con el análisis y discusión de los resultados.

II.2 Zona de estudio

La zona geográfica objeto del estudio es el término municipal de La Orotava, situado en el norte y centro de la isla de Tenerife (28° 23'N; 16° 31'W) (Figura 2.1). Con casi 215 km², es el más grande de la Isla, y el que

tiene un mayor rango altitudinal de toda España, desde 0 hasta 3.718 msnm (metros sobre el nivel del mar) (Pico del Teide). La orografía es muy compleja, con grandes pendientes y profundos barrancos, influyendo de forma determinante en la forma en que se producen los asentamientos humanos y en la interacción de éstos con el medio que les rodea.



Figura 2.1. Ubicación del área de estudio: (a) Islas Canarias; (b) Isla de Tenerife (Fuente: Ortoexpress de GRAFCAN); (c) Área de estudio (imagen ASTER en falso color).

De acuerdo al rango altitudinal, el área se divide en tres grandes zonas (Figura 2.2):

- 1) Zona Agrícola, que se corresponde con la parte baja del Valle de La Orotava (por debajo de los 600 msnm). En esta zona habita casi toda la población del municipio y se concentran los suelos de uso agrícola e industrial.

- 2) Zona Forestal, en la parte media y alta del Valle de La Orotava (entre 600 y 2.000 msnm). Corresponde a una franja de vegetación protegida casi en su totalidad al formar parte del Parque Natural de La Corona Forestal. Predominan los pinares y el monteverde.
- 3) Zona Teide, en La Caldera de Las Cañadas del Teide (por encima de 2.000 msnm) que pertenece al Parque Nacional de Las Cañadas del Teide.




Figura 2.2. División de la zona de estudio según rangos altitudinales. Altitud en metros sobre el nivel del mar.

En la zona media y alta del Valle de La Orotava (a la que llamaremos zona forestal), la especie dominante es el pino canario (*Pinus canariensis* C.

Sm. Ex DC.), que se puede encontrar en formaciones puras o mezclado con pino de Monterrey (*Pinus radiata* D. Don). También podemos encontrar la formación endémica del monteverde, el fayal-brezal (*Erica arborea* L. junto a *Myrica faya* Ait.) y bosques de laurisilva, donde predomina el Laurel (*Laurus azorica* Seub.) Franco) junto a *Persea indica* (L.) Spreng. o *Ilex canariensis* Poir., entre otros.

II. 3 Materiales y métodos

II.3.1 Imágenes ASTER

El sensor ASTER (Advanced Space-borne Thermal Emission and Reflection Radiometer) se encuentra a bordo del satélite Terra de la NASA (National Aeronautics and Space Administration). Está en órbita desde diciembre de 1999, a una altura de 705 km. A pesar de estar instalado en un satélite norteamericano, ASTER es una misión conjunta entre Japón y EEUU, siendo el único instrumento de alta resolución espacial de este satélite. A diferencia del resto de sensores a bordo, ASTER no toma imágenes continuamente de la superficie terrestre, sino tan sólo unos ocho minutos de datos por cada órbita.

ASTER consta de tres subsistemas independientes para la adquisición de imágenes (Figura 2.3) y recoge catorce bandas espectrales en las regiones visible e infrarrojo próximo VNIR (Visible and Near Infrared), en el infrarrojo de onda corta SWIR (ShortWave Infrared) y en el térmico TIR (Thermal Infrared), con diferentes resoluciones espaciales y radiométricas (Tabla 2.1).

Tabla 2.1. Características de los subsistemas del sensor ASTER.

Subsistema	VNIR	SWIR	TIR	
Rango Espectral (μm)	Banda 1 0,52 – 0,60	Banda 4 1,600 – 1,700	Banda 10 8,125 – 8,475	
	Banda 2 0,63 – 0,69	Banda 5 2,145 – 2,185	Banda 11 8,475 – 8,825	
	Banda 3 0,76 – 0,86	Banda 6 2,185 – 2,225	Banda 12 8,925 – 9,275	
		Banda 7 2,235 – 2,285	Banda 13 10,25 – 10,95	
		Banda 8 2,295 – 2,365	Banda 14 10,95 – 11,65	
		Banda 9 2,360 – 2,430		
	Resolución Espacial (m)	15	30	90
	Ancho Barrido (km)	60	60	60
	Resolución radiométrica (bits)	8	8	12

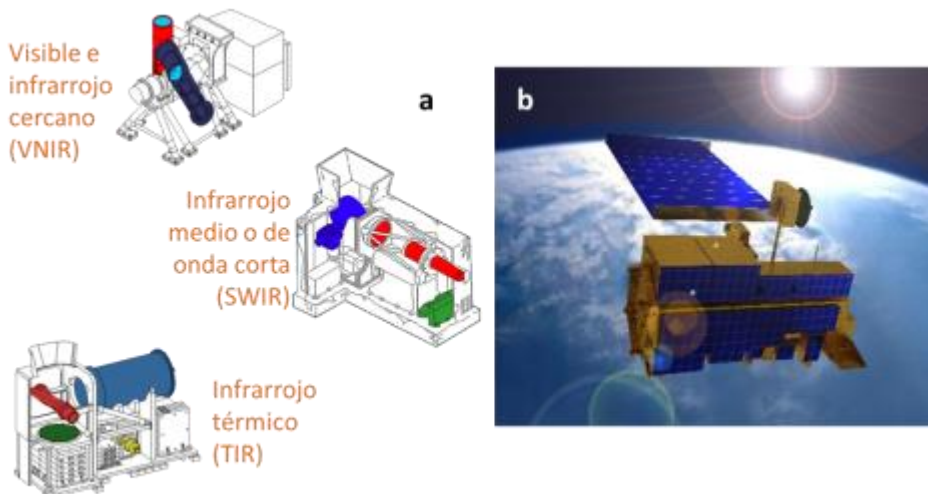


Figura 2.3. El sensor ASTER. (a) Instrumentos del sensor ASTER (Fuente: <https://asterweb.jpl.nasa.gov/>); b) Satélite TERRA (Fuente: Satellite Imaging Corporation).

Para este estudio, se usó una imagen ASTER-L1B del 3 de marzo de 2003. Esta imagen dispone de un nivel de pre-procesado que incluye corrección geométrica y radiométrica.

La imagen original fue convertida a reflectancias en lo alto de la atmósfera (R_{TOA}) de acuerdo al procedimiento descrito en detalle por Abrams *et al.* (2002), Abrams (2000) y Smith (2007). Primero se calcularon las radiancias, $L_{rad,j}$, para cada banda j de la imagen mediante (2.1):

$$L_{rad,j} = (ND_j - 1) \times UCC_j \quad (2.1)$$

donde ND_j es el nivel digital de cada banda j ; UCC_j es el coeficiente unitario de conversión [$W m^{-2} sr^{-1} \mu m^{-1}$]. De esta forma, las reflectancias en lo alto de la atmósfera, se obtendrían a través de la siguiente expresión:

$$R_{TOA,j} = \frac{(\pi L_{rad,j} d^2)}{(ESUN_j \cos z)} \quad (2.2)$$

siendo $ESUN_j$ la irradiancia solar extraterrestre de cada banda j , z el ángulo cenital solar (calculado como $90^\circ - \text{ángulo de elevación solar}$) y d [AU, unidades astronómicas], la distancia astronómica entre el Sol y la Tierra en el momento de la toma de la imagen, calculada mediante la ecuación (2.3).

$$d = \left(1 - 0,01672 \cos\left(RADIANES\left(0,9856(J - 4)\right)\right)\right) \quad (2.3)$$

con J indicando el día juliano correspondiente a la captura de la imagen.

Para trabajar con la misma resolución espacial en todas las bandas, las imágenes SWIR, con una resolución de 30 m, se remuestrearon a los 15 m de las VNIR utilizando una interpolación por el vecino más próximo.

De esta forma, la nueva imagen contenía un total de nueve bandas (VNIR + SWIR) con una resolución espacial de 15 m. Indicar que en este trabajo no se han utilizado las bandas TIR. A continuación, la imagen se georreferenció y ortorrectificó a UTM (Universal Transverse Mercator) WGS84 (Zona 28N). Por último, la imagen fue corregida topográficamente utilizando el método *C-correction* (Teillet *et al.*, 1982) y un modelo digital del terreno (MDT) de 15 x 15 m obtenido por GRAFCAN (Cartográfica de Canarias). Las características de la imagen utilizada se resumen en la Tabla 2.2.

Estudios precedentes han descrito mejoras en la clasificación de combustibles forestales cuando añadían bandas sintéticas, tales como índices de vegetación o componentes principales, a las bandas originales de la imagen de satélite (Lasaponara & Lanorte (2007), Falkowski *et al.* (2005), Bagan *et al.* (2008) o Riaño *et al.* (2002)). Teniendo en cuenta estos resultados, se decidió estimar y añadir las siguientes capas de información a las bandas originales:

- (1) Primera componente principal (PCA1), que explicaba el 96,7% del total de la varianza.
- (2) *NDVI* (Normalized Difference Vegetation Index) (Rouse *et al.* 1973).

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (2.4)$$

- (3) *SAVI* (Soil Adjusted Vegetation Index) (Huete 1989).

$$SAVI = (1 + L) \frac{NIR - RED}{NIR + RED + L} \quad (2.5)$$

- (4) *MSAVI* (Modified Soil Adjusted Vegetation Index) (Qi *et al.* 1994).

$$MSAVI = NIR + 0,5 - \sqrt{(NIR + 0,5)^2 - 2(NIR - RED)} \quad (2.6)$$

- (5) *EVI2* (Enhanced Vegetation Index Two-band) (Jiang *et al.* 2008).

$$EVI2 = 2,5 \frac{NIR - RED}{NIR + 2,4 RED + 1} \quad (2.7)$$

Tabla 2.2. Características de la imagen ASTER L1B. Datos tomados del archivo de metadatos asociado a la misma.

Corrección	Geométrica y radiométrica
Formato	HDFEOS_V2.12
Día de captura	03/03/2003
Hora	11:53:56
Proyección geográfica	UTM huso 28 N
Sistema de referencia	WGS-84
Centro de la imagen	28,309425° N – 16,425913° O

II.3.2 Mapa de referencia

Desde finales de los años 70 se viene realizando en España el Inventario Forestal Nacional (IFN). Hasta la fecha, se han elaborado tres inventarios forestales: el IFN1, realizado entre los años 1966 y 1975; el IFN2, entre 1986 y 1996, y el último, IFN3, para el periodo 1997 – 2007. El objetivo de estos inventarios consiste en recopilar tanta información como sea posible de la situación, propiedad, nivel de protección, estatus legal, posibilidades de desarrollo y capacidad de producción de los recursos forestales de España. En el más reciente, el IFN3, a cada parcela de campo se le asignó un tipo de combustible de acuerdo al sistema BEHAVE (Figura 2.4).

Sin embargo, BEHAVE no tiene en cuenta las peculiaridades de la vegetación de Canarias. En este estudio se utilizó una adaptación del sistema de clasificación de los FBFTs (Fire Behaviour Fuel Types). Se trata de un esquema de clasificación más reciente, desarrollado por Scott y Burgan, (2005). Los FBFTs mejoran la comprensión del comportamiento de la vegetación ante un incendio y su posterior simulación con respecto a BEHAVE (Tabla 2.3).

La clasificación de los FBFTs considera siete grandes grupos de combustibles:

- NB: no incendiable, con cinco subgrupos;
- GR: hierba, con diez subgrupos;
- GS: hierba-arbusto, con cuatro subgrupos;
- SH: arbustos, con nueve subgrupos;
- TB: bosque con sotobosque, con cinco subgrupos;
- TL: madera fina (TL), con diez subgrupos;
- SB: restos de corta, con seis subgrupos.

Para construir el mapa de referencia de este trabajo, se tuvieron en cuenta los datos recogidos durante el trabajo de campo del IFN3 junto al Mapa de Vegetación de las islas Canarias (Arco et al. 2003), el Mapa Forestal de Tenerife (MdMA, 2002), el Mapa de Usos del Suelo de Tenerife (VVAA, 2002) y ortofotos aéreas de 2002 (escala 1:5.000).

Todos los mapas anteriores se cruzaron creando polígonos mediante un sistema de información geográfica. A cada polígono se le asignó uno de los catorce subgrupos de combustibles FBFT que se encuentran en la zona de estudio y que representan a los grupos SB, SH, TL y NB (Figura 2.5).




Figura 2.4. Mapa de tipos de combustible para el área de estudio de acuerdo a la clasificación BEHAVE del III Inventario forestal Nacional.

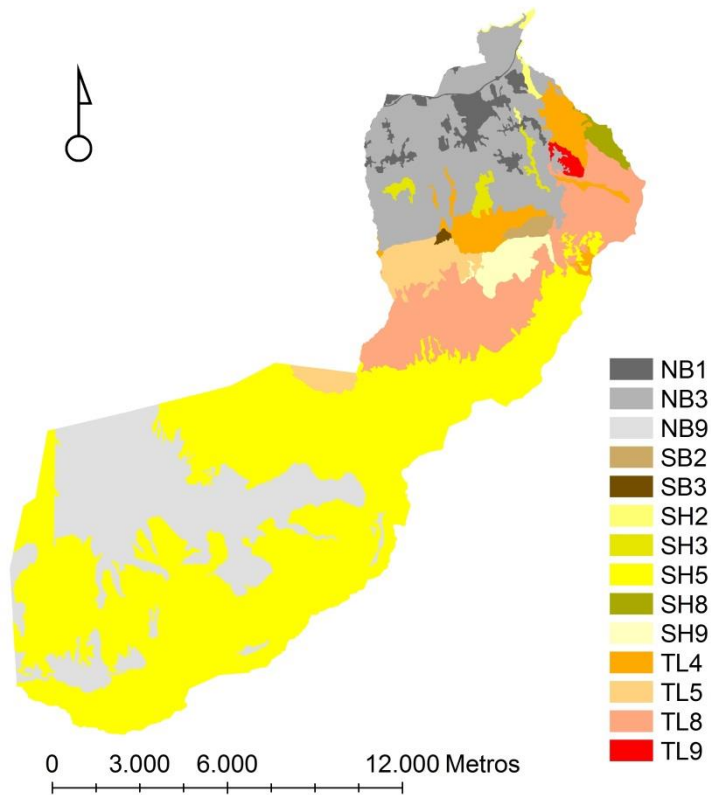


Figura 2.5. Mapa de referencia empleado para este estudio. Tipos de combustible según el sistema de clasificación de combustibles FBFT (Scott & Burgan, 2005).

A grandes rasgos, se puede observar que en la zona de alta montaña, correspondiente al Parque Nacional de Las Cañadas del Teide, existen dos tipos de combustible: el NB9 o zona de vegetación de alta montaña, y el SH5, matorral de alta montaña. Con respecto a la zona forestal, se han identificado nueve tipos de combustibles que abarcan desde el pinar canario (TL8) a la laurisilva (TL4) o el fayal-brezal (SB3).

Tabla 2.3. Correspondencia entre los tipos de combustible BEHAVE y FBFT para la zona de estudio, incluyendo su descripción (descripción tipos BEHAVE extraída de Rothermel, 1983, p.9).

Tipo de combustible BEHAVE	Descripción BEHAVE	Tipo de combustible FBFT	Descripción FBFT
5	Matorral denso pero bajo	SH2	Matorral costero formado por diferentes especies
6	Matorral disperso y de mayor altura que el anterior	SH5	Arbustos de alta montaña
13	Restos de cortas	SH3	<i>Masas discontinuas de Erica arborea y cortas irregulares de Erica arborea con Castanea sativa</i>
7	Matorral inflamable que propaga el fuego bajo el arbolado	SH8	<i>Masas de Pinus canariensis con sotobosque de Erica arborea y masas uniformes de Pinus radiata</i>
7	Matorral inflamable que propaga el fuego bajo el arbolado	SH9	<i>Masas uniformes de Erica arborea y Myrica faya con Pinus radiata y/o Pinus canariensis</i>
9	Hojarasca en bosque denso de conífera poco compactada	TL8	<i>Masas uniformes de Pinus canariensis</i>
8	Hojarasca compacta en bosque denso de coníferas o frondosas	TL4	<i>Cortas de Erica arborea con Castanea sativa, laursilva, masas de Eucalyptus sp. y bosques maduros de Pinus canariensis</i>
8	Hojarasca compacta en bosque denso de coníferas o frondosas	TL5	<i>Masas mixtas de Pinus radiata y Pinus canariensis</i>
9	Hojarasca en bosque denso de conífera poco compactada	TL9	<i>Masas mixtas de Castanea sativa, Pinus canariensis y Erica arborea</i>
11	Restos ligeros recientes de cortas poco compacta	SB2	<i>Faja de cortas en masas de Pinus canariensis y Pinus radiata</i>
13	Grandes acumulaciones de restos gruesos	SB3	Formaciones mixtas de <i>Erica arborea</i> y <i>Myrica faya</i>
0	Sin descripción	NB1	Asentamientos humanos y carreteras
0	Sin descripción	NB3	Áreas rurales y cultivos
0	Sin descripción	NB9	Zona sin vegetación de alta montaña

Y por último, en la zona agrícola se han encontrado tres subgrupos: carreteras y centros urbanos (NB1), áreas rurales y cultivos (NB3) y matorral costero (SH2). Los subgrupos SB2 y SB3 cubren el 0,49% de la superficie. Los cinco subgrupos incluidos en SH ocupan el 50,65% de la superficie: SH2, compuesto por matorral halófito; SH3 formado por masas discontinuas de brezo, faya y castaño (*Castanea sativa* Mill.); SH5, compuesto por matorral altamente inflamable; y SH8, formado por masas continuas de pino canario mezclado con brezos o con pino radiata. El grupo TL, por su parte, ocupa el 16,09% de la zona de estudio

e incluye cuatro subgrupos: TL4, masas mixtas de laurisilva; TL5 y TL8, pinares con restos de corta; y TL9, compuesto por masas uniformes de castaño, pino canario y brezo. Finalmente, en el mapa de referencia encontramos tres subgrupos NB que ocupan el 32,78% de la superficie total de La Orotava: NB1, formada por las zonas urbanas; NB3 compuesta por cultivos agrícolas y NB9, que se corresponde con las zonas de alta montaña del Teide.

II.3.3 Métodos de clasificación

En las últimas décadas se han desarrollado un gran número de métodos de clasificación para el cartografiado de la superficie terrestre usando imágenes de satélite (Lu y Weng, 2007). Estos métodos se pueden diferenciar en tres grandes grupos: métodos orientados al pixel, al sub-pixel y a objetos. Los clasificadores orientados al pixel constituyen la técnica clásica de clasificación en teledetección, y suponen que cada pixel es puro y se etiqueta con una clase determinada, en nuestro caso, un tipo de combustible. Las técnicas orientadas al sub-pixel, consideran a los píxeles mezclados, estimando el porcentaje de superficie que le corresponde a cada clase. Y por último, los métodos de clasificación basados en objetos, donde los píxeles individuales se agrupan en objetos, que son considerados como la unidad básica a clasificar. En este estudio se han aplicado clasificadores basados en píxeles y en objetos, comparando sus resultados.

II.3.3.1 Clasificaciones orientadas al pixel

Se han aplicado tres algoritmos de clasificación basados en píxeles ampliamente utilizados; Máxima Probabilidad (ML, del inglés *Maximum Likelihood*), Red Neuronal (NN, *Neural Network*) y Máquina de Vectores de Soporte (SVM, *Support Vector Machine*). Para todos ellos, se han usado las bandas VNIR y SWIR de ASTER junto a la primera componente principal (PCA1), los cuatro índices de vegetación antes citados y el MDT.

Máxima Probabilidad

El algoritmo ML (Lillesand et al., 2004) es considerado uno de los más importantes, debido a su simplicidad y robustez. Ha sido ampliamente utilizado para cartografiar vegetación y usos del suelo (Hagner y Reese, 2007; Yang *et al.*, 2016; Leverington & Schindler, 2016; Burai *et al.*, 2015; Li *et al.*, 2014). Es un algoritmo paramétrico supervisado que supone que los valores digitales de los píxeles de cada una de las clases consideradas (tipos de combustible) siguen una distribución estadística gaussiana. De esta forma, para calcular la probabilidad $p(x | \omega_i)$ de que un pixel x de la imagen pertenezca a una clase ω_i ($i=1,..n$) solamente necesitaremos calcular la media m_i y la matriz de varianza-covariancia Σ_i de esa clase i a partir de los datos de las áreas de entrenamiento que previamente habremos tenido que seleccionar en base al conocimiento del área de estudio y los tipos de combustible presentes en ella. Las áreas de entrenamiento y el proceso seguido para obtenerlas se describe en el apartado II.5.1.4, siendo las mismas para todos los métodos de clasificación aplicados.

Si suponemos un modelo gaussiano multivariado, es decir, cada pixel x determinado por los valores de reflectancia o niveles digitales de sus N bandas espectrales, se puede calcular la probabilidad de pertenencia a cada una de las 14 clases (tipos de combustible) de acuerdo a la expresión:

$$p(x | \omega_i) = (2\pi)^{-N/2} |\Sigma_i|^{-1/2} \exp\left[-1/2(x - m_i)^t \Sigma_i^{-1} (x - m_i)\right] \quad (2.8)$$

Asignando finalmente cada pixel x , al tipo de combustible que maximice la función de probabilidad.

Red Neuronal

Los algoritmos basados en redes neuronales artificiales simulan la forma de trabajar del sistema nervioso de los animales. Para ello crean una red de neuronas que colaboran entre sí para producir un estímulo de salida.

El algoritmo NN está compuesto por un conjunto de elementos dispuestos en capas de nodos (neuronas): nodos de entrada (uno por cada banda espectral usada), nodos ocultos (como mínimo deben tener el mismo número que los de entrada) y los nodos de salida (uno por cada tipo de combustible). Estas capas de nodos están enlazadas por funciones de activación definidas por pesos w_{ij} , que son calculados iterativamente durante el proceso de aprendizaje del algoritmo.

Si consideramos x como los nodos de entrada ($x_1 \dots \dots x_n$), z como los nodos ocultos ($z_1 \dots \dots z_n$) e y como los nodos de salida ($y_1 \dots \dots y_n$), tomando i, j, k como subíndices de las capas de entrada, oculta y salida respetivamente, las funciones para calcular el algoritmo de red neuronal se expresa como:

$$y_k = g_A \left(\sum_{j=1}^n z_j \beta_{jk} + \varphi_k \right) \quad (2.9)$$

$$z_j = f_A \left(\sum_{i=1}^n x_i w_{ij} + \tau_j \right) \quad (2.10)$$

donde τ_j es el error del nodo z_j ; φ_k es el error del nodo y_k ; w_{ij} es el peso de la conexión entre las neuronas x_i y z_j ; β_{jk} es el peso de la conexión entre las neuronas z_j e y_k ; y g_A y f_A son las funciones de activación continuas, acotadas y no decrecientes.

El algoritmo aplicado para el cartografiado de combustibles es un clasificador supervisado que usa la técnica denominada *backpropagation* (Rumelhart *et al.*, 1986; Chuvieco, 2002). Primero, se aplican unos

valores iniciales a los nodos de entrada de acuerdo a las zonas de entrenamiento seleccionadas y se calcula el error entre el resultado obtenido en los nodos de salida y la clasificación deseada. Este error se propaga hacia atrás en la red neuronal repitiendo el proceso hasta que se minimice.

Máquina de vectores de soporte

El algoritmo SVM (Vapnik, 1999) es un clasificador lineal supervisado basado en la teoría de aprendizaje estadístico. Este algoritmo es capaz de separar los tipos de combustibles (clases) mediante una superficie de decisión denominada hiperplano óptimo, que maximiza el margen entre las clases. Los puntos más próximos a esta superficie son los vectores de soporte, elementos fundamentales del conjunto de áreas de entrenamiento.

Para aplicar esta técnica de clasificación se utiliza una función núcleo o *kernel*. Existen *kernels* de tipo local o global (Mercier & Lennon, 2003). Las funciones locales sólo consideran los datos más próximos y en general se basan en funciones de distancia. Por el contrario, en las funciones globales son los datos más alejados los que tienen más influencia. Tras analizar diferentes *kernels* (Pal, 2009; Szuster *et al.*, 2011; Kavzoglu & Colkesen, 2009) en pequeñas zonas de prueba, en este trabajo se usó la función núcleo RBF (*Radial Basis Function*) representada por:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0 \quad (2.11)$$

donde x_i e y_i son los píxeles de entrenamiento y los píxeles a ser clasificados respectivamente, y γ un parámetro con gran influencia en la clasificación resultante. Según Huang *et al.* (2002), γ puede tomar valores entre 1 y 20. Para el presente trabajo se estimó un valor de 2,0

ya que valores superiores no representaron mejoras significativas e incrementaban considerablemente el tiempo de procesamiento.

II.3.3.2 Clasificación orientada a objetos

En la clasificación orientada a objetos (OBIA), los píxeles individuales se agrupan en objetos obtenidos mediante la segmentación de la imagen (Pal & Bhandari, 1992; Blaschke, 2010), sobre los cuales se realiza la clasificación. La segmentación se lleva a cabo en base a la información espectral, espacial, textural y contextual de la imagen original (Blaschke, 2010). Este tipo de clasificación es especialmente adecuada para analizar imágenes de muy alta resolución espacial (VHR), que se caracterizan por una elevada heterogeneidad espectral, lo que limita la eficacia y precisión de las técnicas tradicionales orientadas al pixel.

Los parámetros de segmentación (escala, pesos de las bandas, suavidad y compacidad) fueron determinados mediante aproximaciones de prueba y error, y validados por inspección visual del resultado basado en el conocimiento de la zona. Junto a la imagen ASTER se añadieron dos capas vectoriales. La primera incluye los límites de los espacios naturales protegidos presentes en el área de estudio, y se incluyó para que estos espacios no quedasen cortados en el proceso de segmentación. La segunda capa incluye las zonas en las que se subdivide el área de estudio (agrícola, forestal y Teide), y se utilizó para poder ajustar los parámetros de segmentación de forma específica en cada una de dichas zonas (Tabla 2.4).

La fase de clasificación se realizó en procesos iterativos (hasta 50 pasos por clasificación), con el objetivo de aumentar gradualmente la información contextual al proceso de clasificación. Así, el primer paso empleaba sólo información relativa a las propiedades intrínsecas de los objetos (por ejemplo, el valor medio para una banda espectral), y paulatinamente se iban incorporando elementos de contexto, como la

distancia a otras clases o el borde del objeto en contacto con una clase determinada.

Tabla 2.4. Parámetros de segmentación utilizados para cada zona del área de estudio.

Parámetros Segmentación	Teide	Forestal	Agrícola
Bandas utilizadas (peso)	NDVI (1) PC1 (1)	B4 (2) NDVI (1) PC1 (1)	B4 (2) NDVI (1) PC1 (1)
Forma (peso)	0,0005	0,005	0,005
Compacidad (peso)	0,7	0,7	0,7
Parámetro de escala	4	3	3

Durante la fase de clasificación cada zona se consideró de forma independiente. Se clasificó primero la zona agrícola, a continuación la zona forestal y por último, la zona de alta montaña (Teide). En todas ellas, se aplicó la misma técnica OBIA, con pasos sucesivos en los que se incorporaba información contextual al análisis de forma paulatina. Se identificaron primero aquellos elementos que presentaban un comportamiento espectral más distintivo, dejando para los últimos pasos de la clasificación la identificación de aquellos tipos de combustible que resultaban difíciles de clasificar atendiendo únicamente a su comportamiento espectral. En la zona forestal, por ejemplo, los tipos de combustibles SH8 y TL5 se clasificaron en los primeros pasos, en función de los valores medios de las bandas 9 y 1 y el MDT. Tipos de combustible más complejos, como el TL4, se clasificaron en siguientes fases del proceso de clasificación, atendiendo a propiedades de relación con otros objetos (“límites con la clase SH8” o “límites con la clase TL5”). Para la zona agrícola, la clase NB1 (carreteras y núcleos urbanos) se clasificó utilizando el valor medio de la banda 2, el número total de píxeles por objeto y la redondez del objeto (los objetos lineales tenían mayor probabilidad de ser clasificados como carreteras que los objetos redondos); y en un último paso se identificaron el tipo de combustible NB3 (zonas rurales y cultivos), usando para ello la propiedad de relación

“límites con la clase NB2” en combinación con características espectrales.

II.3.3.3 Áreas de entrenamiento

El conjunto de áreas de entrenamiento usadas para los clasificadores supervisados se construyó teniendo en cuenta la variabilidad de cada tipo de combustible (FBFT) y evitando las zonas de transición entre ellos. Todas las áreas de entrenamiento fueron rectangulares, de superficies variables y distribuidas aleatoriamente dentro de la zona de estudio. Para su selección realizamos una interpretación visual de ortofotos aéreas apoyada con información temática.

Las áreas de entrenamiento cubrían el 7,53% de la superficie total de la zona de estudio. El tipo de combustible SB3 de la zona forestal, con sólo un 0,09% de la superficie total, dispuso de la superficie relativa más alta del conjunto de entrenamiento con un 25,85%. La superficie relativa promedio cubierta por las áreas de entrenamiento fue del 6,98% en la zona del Teide; 12,97% para la zona forestal y el 7,15% en la zona agrícola (Tabla 2.5).

II.3.4 Evaluación del error

Tradicionalmente, la evaluación de la exactitud de un mapa temático obtenido mediante imágenes de satélite se ha estimado a partir de la matriz de confusión. Para n clases, ésta es una matriz cuadrada $n \times n$ que recoge las confusiones entre clases y la fiabilidad para cada una de ellas. A partir de la matriz de confusión es común analizar la bondad de la clasificación mediante el denominado índice *Kappa* (Congalton, 1991; Pontius, 2000; Liu *et al.*, 2007; Congalton & Green, 2009), que mide la diferencia entre la exactitud global obtenida y la que cabría esperar debida al azar. *Kappa* se define como $(C - E) / (1 - E)$, donde C es la exactitud observada, E es la exactitud esperada por azar y $1 - E$ representa el acuerdo máximo posible no debido al azar. El valor de

Kappa se interpreta como aquella exactitud del mapa que puede atribuirse exclusivamente al método de clasificación empleado, es decir, una vez tenidos en cuenta los posibles aciertos debidos al azar. Un valor de *Kappa* de 0 significaría que el acuerdo observado entre el mapa y la realidad es equivalente al acuerdo aleatorio esperado desde un punto de vista estadístico.

Tabla 2.5. Tipos de combustibles presentes en cada zona del área de estudio. Se muestra la superficie total (ha), la superficie relativa con respecto al área total (%) y la superficie cubierta por áreas de entrenamiento (ha).

Zona estudio	Tipo combustible	Superficie (ha)	Superficie %	Área entren. (ha)
Teide	NB9	3.802,59	18,06	256,32
	SH5	10.035,18	47,66	725,06
Forestal	SB2	83,99	0,40	13,43
	SB3	18,45	0,09	4,77
	SH3	149,51	0,71	16,02
	SH8	113,83	0,54	15,57
	SH9	300,17	1,43	33,08
	TL4	667,44	3,17	68,85
	TL5	576,81	2,74	70,45
	TL8	2.079,34	9,88	203,00
	TL9	63,86	0,30	4,61
Agrícola	NB1	452,77	2,15	25,97
	NB3	2.646,16	12,57	140,90
	SH2	65,14	0,31	6,77
TOTAL		21.055,23	100.00	1.584,79

Estudios recientes (Pontius & Millones, 2011; Olofsson *et al.*, 2014), recomiendan abandonar el uso de *Kappa*. Estos autores proponen evaluar la bondad de un método de clasificación en base a la exactitud global del mismo y en el estudio pormenorizado del error cometido. Las razones que argumentan estos autores son las siguientes: En primer lugar, *Kappa* es un cociente y, como tal, puede ocurrir que el denominador sea 0, dando un resultado indefinido que no se podría interpretar. En segundo lugar, *Kappa* está muy correlacionado con la exactitud global, por lo que dar este resultado resulta redundante. Y por

último, *Kappa* compara la exactitud tomando una referencia que se espera sea aleatoria, pero en la realidad esta aleatoriedad no es del todo cierta. Por estos motivos, en la presente tesis, se evaluó la exactitud global de los mapas de combustibles obtenidos en base al tipo de error cometido, de acuerdo al trabajo publicado por Pontius & Millones (2011).

A partir de la matriz de confusión se calcularon los siguientes errores:

- *Error por cantidad*: definido como la diferencia entre los mapas de referencia y clasificado debida al emparejamiento imperfecto en las proporciones de las clases.
- *Error por ubicación*: es la diferencia entre los mapas de referencia y clasificado debido al incorrecto emparejamiento de la ubicación espacial de las clases.
- *Error total*: definido como la diferencia total entre el mapa de referencia y el clasificado o la suma de los errores anteriores (es el complementario de la exactitud global).

Estas medidas de error permiten discriminar si un algoritmo de clasificación concreto no es capaz de detectar correctamente las abundancias relativas de los tipos de combustibles en la zona cartografiada (error por cantidad), o bien si sitúa los tipos de combustible identificados en lugares equivocados (error por ubicación). El cálculo de estos errores resulta muy interesante para este estudio, ya que conocer con precisión las cantidades, así como la ubicación espacial de los tipos de combustibles, es fundamental en los programas de simulación o modelado del comportamiento de un incendio.

Para el cálculo de las medidas de error asociadas a los mapas generados, se elaboraron en primer lugar sus respectivas matrices de confusión (Tabla 2.6). La matriz de confusión es una matriz cuadrada de tamaño $J \times J$, donde J es el número de clases identificadas (tipos de combustible en nuestro caso). Las columnas corresponden a los valores de referencia,

mientras que las filas corresponden a las asignaciones del clasificador. Así, cada p_{ij} corresponde a la proporción de píxeles asignados a la clase i según la clasificación y a la clase j según la información de referencia, donde $i, j = 1, \dots, J$. Como información de referencia se usó en este caso el mapa de combustibles de la zona. Esto implica que la matriz de confusión estimada correspondía al total de la población analizada (es decir, todos los píxeles de la imagen). Todas las medidas de error se calcularon a partir de dicha matriz de confusión.

Tabla 2.6. Matriz de confusión empleada para la evaluación de la exactitud (adaptada de Pontius y Millones, 2011).

		Mapa de referencia			Total obtenido
		$j = 1$	$j = 2$... $j = J$	
Mapa obtenido	$i = 1$	p_{11}	p_{12}	... p_{1J}	$\sum_{j=1}^J p_{1j}$
	$i = 2$	p_{21}	p_{22}	... p_{2J}	$\sum_{j=1}^J p_{2j}$
	
	$i = J$	p_{J1}	p_{J2}	... p_{JJ}	$\sum_{j=1}^J p_{Jj}$

El error por cantidad para la clase g (q_g) se calculó mediante la resta de la proporción de la clase g en la información de referencia y en el mapa obtenido:

$$q_g = \left| \left(\sum_{i=1}^J p_{ig} \right) - \left(\sum_{j=1}^J p_{gi} \right) \right| \tag{2.13}$$

El error total por cantidad (Q) se estimó sumando los errores por cantidad de las J clases, y dividiendo por 2, para compensar la sobreestimación de una clase frente a la subestimación de otra.

$$Q = \frac{\sum_{g=1}^J q_g}{2} \quad (2.14)$$

El error por ubicación de la clase g (a_g) se obtuvo tomando el mínimo valor entre el error por omisión y el error por comisión.

$$a_g = 2 \min \left[\left(\sum_{i=1}^J p_{ig} \right) - p_{gg}, \left(\sum_{j=1}^J p_{gj} \right) - p_{gg} \right] \quad (2.15)$$

El error total por ubicación (A) se calculó como la suma del error de ubicación para cada clase y dividiendo por 2.

$$A = \frac{\sum_{g=1}^J a_g}{2} \quad (2.16)$$

Del mismo modo, el acierto total (C) se computó según la siguiente ecuación.

$$C = \sum_{j=1}^J p_{jj} \quad (2.17)$$

Y el error total cometido se calculó según la ecuación:

$$D = 1 - C = Q + A \quad (2.18)$$

II.4 Resultados y discusión

Se obtuvieron cuatro mapas, uno por cada algoritmo de clasificación (Figuras 2.6 y 2.7). Los 14 tipos de combustibles presentes en la zona de estudio fueron identificados por los cuatro métodos, pero en diferente proporción y distribución espacial. Las principales diferencias entre ellos se observan con un simple análisis visual. Los mapas obtenidos usando

algoritmos basados en píxeles mostraron un marcado efecto de “sal y pimienta”, característico de la distribución aleatoria de los píxeles en estos clasificadores. Esto no ocurrió en el mapa obtenido con la clasificación OBIA.

Al cruzar los resultados obtenidos en cada uno de los cuatro mapas de combustibles con el mapa de referencia, podemos analizar los errores cometidos por cada clasificador (Figuras 2.8 y 2.9). En esta figura se representan en color azul aquellos píxeles en los tipos de combustible de la clasificación coincide con los del mapa de referencia. Los desacuerdos o errores se representan en diferentes colores, de acuerdo a los tipos de combustibles presentes en esa ubicación. Por ejemplo, las zonas de color amarillo (tipo de combustible SH9) se corresponden con aquellas áreas donde, de acuerdo a la clasificación, se encuentra el tipo SH5, pero que han sido erróneamente asignadas a otro tipo de combustible.

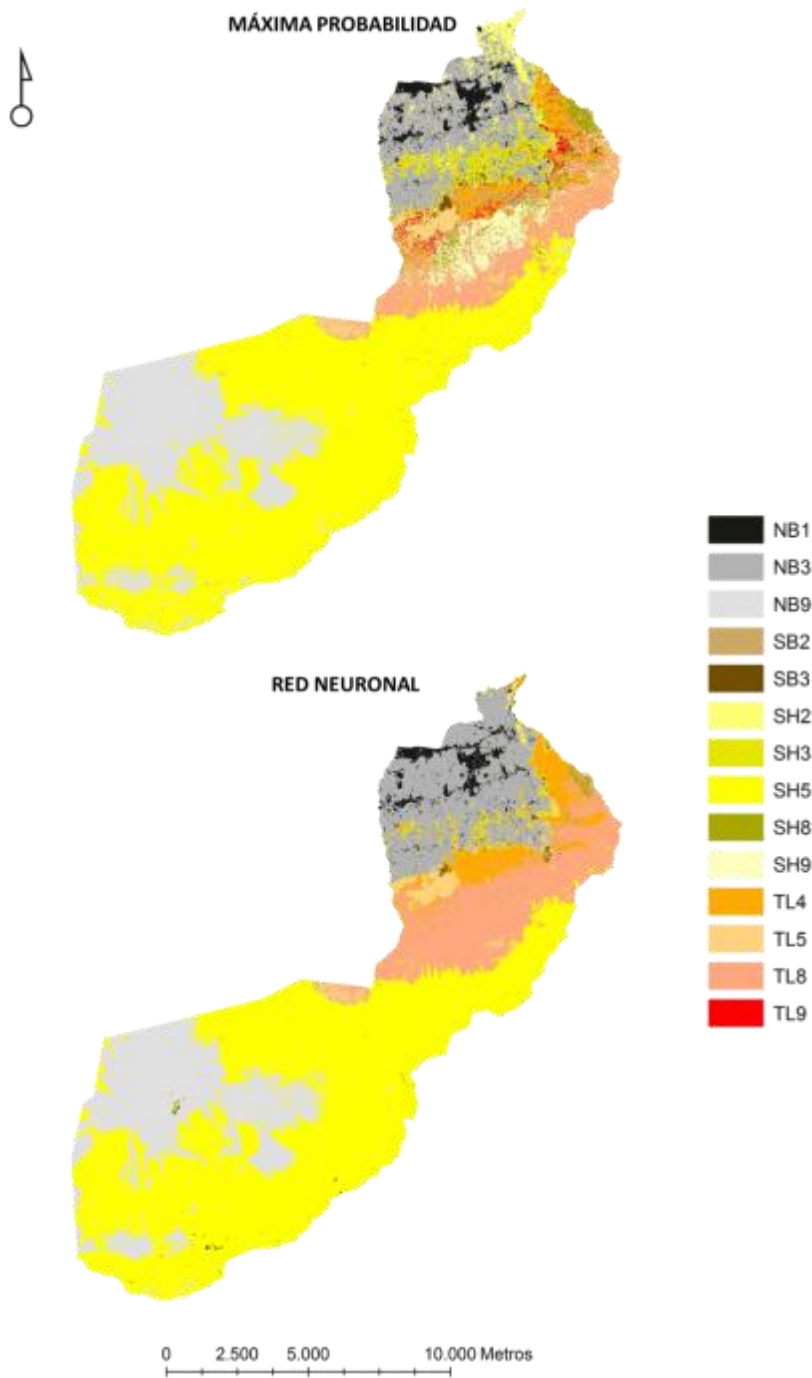


Figura 2.6. Mapas de combustibles forestales obtenidos con el clasificador de Máxima Probabilidad (arriba) y Red Neuronal (abajo).

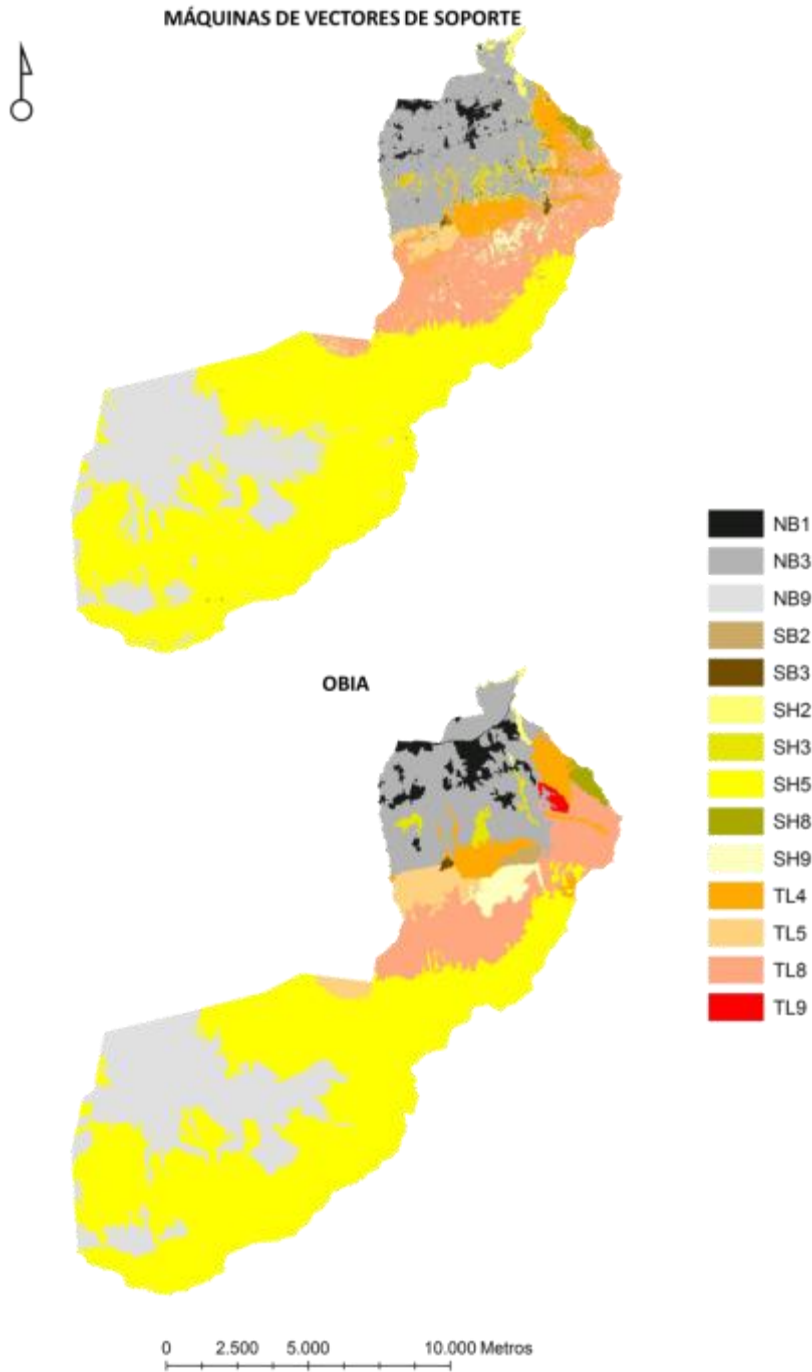


Figura 2.7. Mapas de combustibles forestales obtenidos con el clasificador de SVM (arriba) y OBIA (abajo).

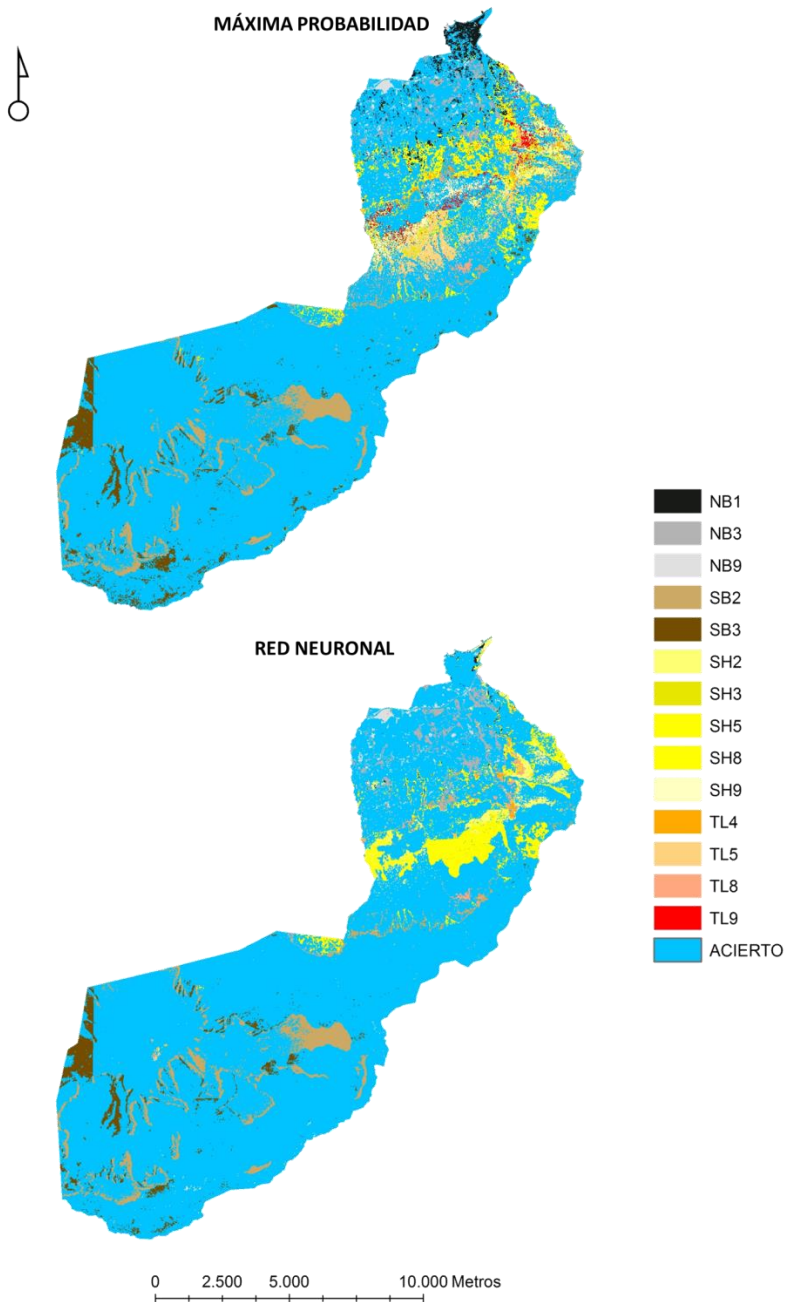


Figura 2.8. Comparación entre el mapa de referencia y las clasificaciones obtenidas. El color azul indica coincidencia (acierto en la clasificación). El resto de colores indican, para aquellas áreas en las que hay desacuerdo, el tipo de combustible obtenido para el clasificador de Máxima Probabilidad (arriba) y Red Neuronal (abajo).

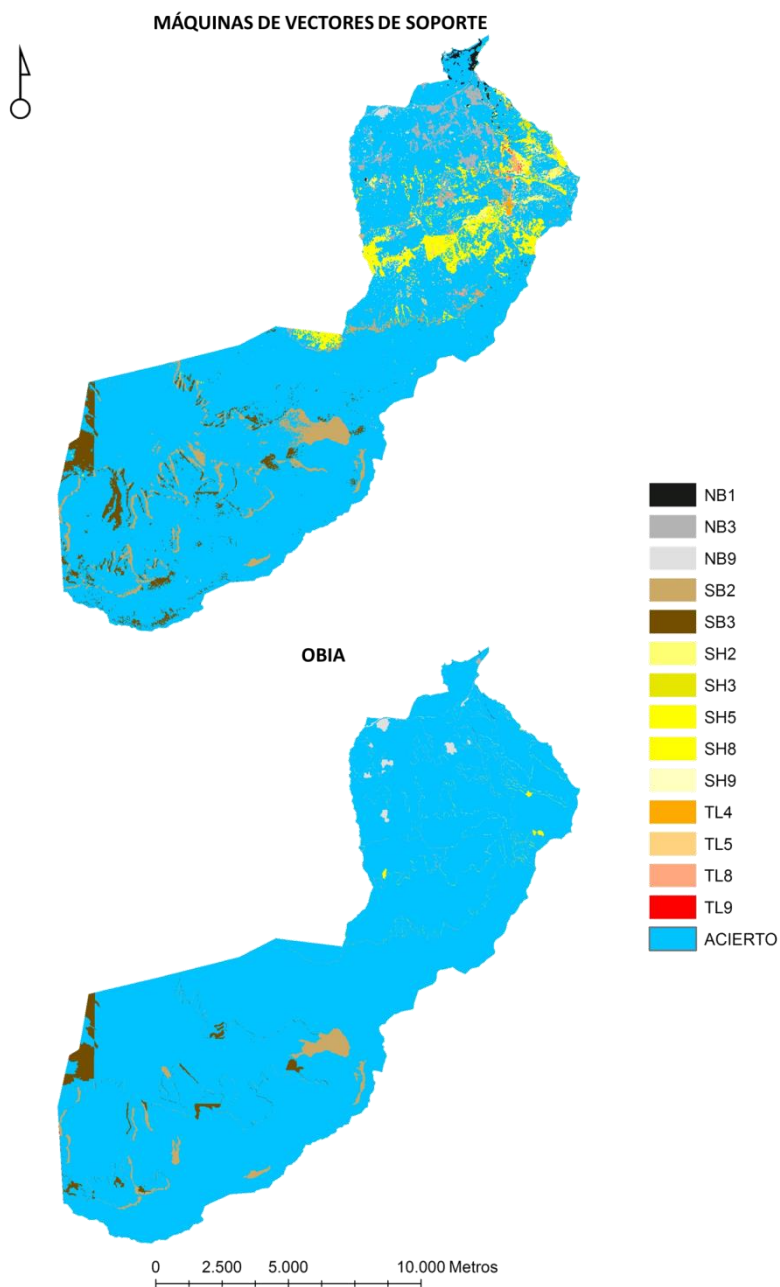


Figura 2.9. Comparación entre el mapa de referencia y las clasificaciones obtenidas. El color azul indica coincidencia (acierto en la clasificación). El resto de colores indican, para aquellas áreas en las que hay desacuerdo, el tipo de combustible obtenido para el clasificador de SVM (arriba) y OBIA (abajo).

La figura 2.10 presenta las medidas globales de error estimadas para los cuatro mapas. El error global se presenta como dos componentes: errores por cantidad y errores por ubicación. Con respecto al error global por ubicación, la clasificación OBIA produjo el menor error de todos los algoritmos, con tan sólo un 4%. El algoritmo de clasificación basado en píxeles que mostró menor error global por ubicación fue la red neuronal, con un 12%, frente al 14% y 15% de los resultantes de aplicar SVM y ML respectivamente. Con respecto al error por cantidad, el mejor método se obtuvo para la clasificación SVM, con un 3%, muy inferior al 5% y 8% de NN y ML respectivamente. En este caso, OBIA también registro el mejor resultado con un 1% de error por cantidad, lo que condujo al error total más bajo de todos los métodos (5%).

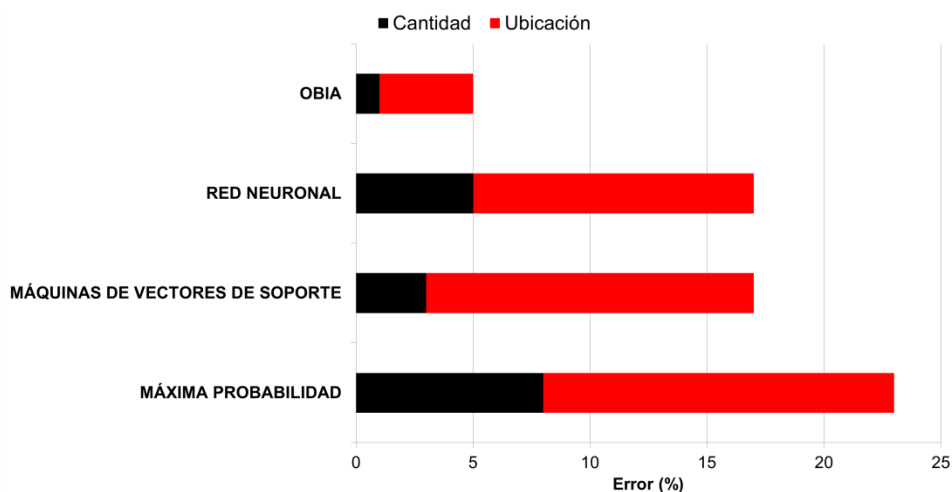


Figura 2.10. Análisis de los errores encontrados en los mapas de combustibles generados a partir de imágenes ASTER para todos los sistemas de clasificación empleados.

En general, los cuatro algoritmos han producido mayores errores por ubicación que por cantidad. Valores mayores de error por ubicación, indican errores principalmente debidos a la localización errónea de los tipos de combustibles; es decir, la principal fuente de error fue la incorrecta ubicación espacial de los tipos de combustibles en el mapa.

Los bajos valores de los errores por cantidad, indican que la proporción de los tipos de combustibles clasificados resultó ser similar a la proporción de los tipos de combustibles presentes en el mapa de referencia. En términos de error por cantidad, los mapas obtenidos mediante SVM y OBIA produjeron resultados similares, mostrando diferencias de sólo el 2% del área de estudio. En ese sentido, SVM fue capaz de estimar con exactitud las proporciones de los tipos de combustibles en la zona de estudio. La principal diferencia entre el producto obtenido mediante SVM (al pixel) y OBIA (al objeto) fue debida a un mayor error en la distribución espacial de tipos de combustibles erróneamente en el área de estudio por el clasificador SVM.

Las figuras 2.11 y 2.12 muestran los errores por cantidad y ubicación para cada tipo de combustible y zona altitudinal. Presentar los resultados por zonas es importante por varias razones, siendo la principal que se trata de zonas gestionadas de forma diferente desde un punto de vista administrativo. Además, desde la perspectiva de la vegetación, la estructura interna es muy diferente y los errores no se distribuyeron de forma homogénea entre las distintas zonas. Y finalmente, porque la mayoría de los incendios forestales que ocurren en la isla de Tenerife tienen su punto de inicio en el límite existente en la interfaz agrícola-forestal.

En la zona de alta montaña, que se corresponde con el Parque Nacional del Teide, predominaron los errores por ubicación. El algoritmo ML presentó el peor resultado (6,7% para el tipo NB9 y casi 9,0% para SH5). No obstante, conviene mencionar que el tipo SH5 es el que ocupa casi la mitad de la superficie total de la zona, por lo que es de esperar que se detecten mayores errores para este tipo de combustible. Con respecto al error por cantidad, el algoritmo NN produjo los peores resultados, un 2% para cada uno de los tipos de combustibles NB9 y SH5. Todos los algoritmos aplicados confundieron el tipo de combustible NB9 (zonas de montaña con vegetación dispersa) con el SH5 (arbustos de alta

montaña). En algunas zonas, la densidad de los arbustos es muy baja, con un porte achaparrado, lo que puede dar lugar a la confusión entre ambos tipos desde un punto de vista espectral. El tipo de combustible SH5 también fue confundido con el TL8 (bosque de pino canario) en áreas de transición entre ambos combustibles, en altitudes próximas a los 2000 m. En estas zonas, el pino canario no supera los 5,0 m de altura y se encuentra muy disperso, resultando en formaciones mezcladas en la frontera de ambas zonas.

En la zona agrícola, el principal componente del error dependía del algoritmo usado. El tipo de combustible NB3 (zonas rurales y cultivos) mostró los mayores errores, con un máximo del 3,1% de error por cantidad para ML, y un 3,3% de error por ubicación para NN. Todos los algoritmos produjeron incertidumbres entre las clases NB1 y NB3, ya que ambos tienen un comportamiento espectral muy parecido cuando el cultivo ha sido recolectado o el suelo permanece sin cultivar. También hubo confusión entre los tipos NB3 y SH3 (fayal-brezal), y en un menor grado entre los tipos NB3 y TL5 (pinar canario mezclado con pino radiata), sobre todo en la interfaz agrícola-forestal.




Figura 2.11. Análisis de los errores encontrados para cada tipo de combustible cartografiado a partir de imágenes ASTER para los clasificadores de Máxima Probabilidad (arriba) y Red Neuronal (abajo).




Figura 2.12. Análisis de los errores encontrados para cada tipo de combustible cartografiado a partir de imágenes ASTER para los clasificadores de SVM (arriba) y OBIA (abajo).

Finalmente, en la zona forestal, el tipo de combustible TL8 (pinar canario) mostró los errores más grandes tanto por cantidad como ubicación, con un máximo del 3,4% para SVM y 3,0% para ML. Los valores altos de error por ubicación para el tipo de combustible TL5 (pinar canario mezclado con pino radiata) y TL4 (laurisilva) son muy marcados en los algoritmos basados en píxeles, con un 2,5% tanto para ML como para el SVM. Igualmente, para los algoritmos ML y NN, el tipo de combustible SH9 (pinar canario mezclado con brezos y pino radiata) presentó un error por cantidad del 1,8% y 2,0% respectivamente. En general, los algoritmos orientados al pixel confundieron el tipo SB2 (faja de cortas en pinares) con el TL8 (pinar canario). De hecho, estas clases mostraban una firma espectral parecida. El algoritmo ML también mezcló el tipo SB2 con TL4 (brezos mezclados con castaños). El tipo TL9 (castaños mezclados con pinar canario y brezos) fue clasificado erróneamente como TL8 (pinar canario) y TL5, debido probablemente a su respuesta espectral similar en las bandas visibles. Este hecho, junto a la reducida superficie que ocupa este tipo de combustible, puede explicar que la mayor parte del error encontrado para los algoritmos ML y SVM sea debido a cantidad, mientras que para los algoritmos NN y OBIA lo haya sido por ubicación. El tipo de combustible SB3 (fayal-brezal) aparecía mezclado con el NB3 en todos los algoritmos orientados al píxel. De hecho, el SB3 se localiza usualmente próximo a la zona agrícola, donde existe un cambio gradual desde el tipo SB3 al tipo NB3.

Los algoritmos basados en píxeles están condicionados por la diferencia espectral y en cantidad entre clases a discriminar, y esto explica sus mayores errores por cantidad.

**Capítulo III. Cartografiado de tipos de
combustibles usando imágenes
WorldView-2**

III.1 Resumen

En este capítulo se analiza la viabilidad del uso de imágenes de muy alta resolución espacial del satélite Worldview-2 (WV-2), para la obtención y actualización de mapas de combustibles forestales. Se utiliza como área de estudio una zona forestal del Norte de la isla de Tenerife, en la que su compleja orografía, con numerosos barrancos, junto a la presencia de especies forestales endémicas del archipiélago, dificulta su caracterización. La imagen usada es del 23 de Junio de 2011, coincidente con la ventana temporal en la que se realizó el trabajo de campo entre los meses de mayo y agosto del mismo año. Con el objetivo de mejorar la precisión alcanzada, se ha optado por realizar una clasificación orientada a objetos, usando el algoritmo OBIA basado en el método del vecino más próximo. Tomando como referencia la clasificación Prometheus, que diferencia siete tipos de combustibles en función de la distribución de la vegetación en altura, los resultados obtenidos muestran una exactitud global del 76% y unos errores del 11 y 12% para cantidad y ubicación respectivamente.

Comenzaremos el capítulo con una descripción de las características principales de la zona de estudio. A continuación se describen las características la imagen WV-2 usada, así como todo el pre-procesamiento y correcciones aplicadas a la misma. En el siguiente apartado mostramos los datos obtenidos en la campaña de medidas en campo, para la identificación de los tipos de combustibles. Por último, se detallan especificaciones utilizadas para la clasificación OBIA, realizando en el último apartado el análisis de los resultados de dicha clasificación y la evaluación del error.

III.2 Zona de estudio

El área de estudio (figura 3.1), delimitada por las coordenadas $28^{\circ} 20' N - 16^{\circ} 29' W$ y $28^{\circ} 22' N - 16^{\circ} 33' W$, se encuentra en la vertiente norte de la isla de Tenerife y ocupa una extensión total de 15 km^2 , con un rango altitudinal comprendido entre 800 y 1.650 msnm. La zona se caracteriza por un relieve muy pronunciado, con abundantes barrancos. La vegetación se distribuye en dos pisos altitudinales: hasta 1.100 msnm predominan las formaciones de fayal-brezal (*Myrica fayae-Ericion arboreae* Oberd.) y laurisilva (*Prunus hixae-Lauretalia novocanariensis* Oberd. Ex Rivas-Martínez, Arnaiz, Barreno & Crespo), por encima de 1.100 msnm dominan las formaciones autóctonas de pino canario (*Pinus canariensis* C.SM. ex DC.) mezcladas en ocasiones con rodales de la especie introducida pino radiata (*Pinus radiata* D. Don.).




Figura 3.1. Zona de estudio. Ubicación dentro de la isla de Tenerife (esquina superior izquierda) e imagen WV-2 de la zona de estudio en color verdadero. Los círculos rojos indican la ubicación de las parcelas del trabajo de campo.

III.3 Materiales y métodos

III.3.1 Imágenes WorldView-2

El satélite de muy alta resolución espacial WorldView-2, lanzado el 8 de octubre de 2009, es una iniciativa privada de la empresa DigitalGlobe, concebido principalmente para el seguimiento de los recursos naturales y la agricultura. Se encuentra situado en una órbita heliosíncrona, casi circular, con un período de 100,2 minutos y una altitud de 770 km. Está dotado de un sensor con capacidad de recoger información en 8 bandas multiespectrales (MS) de 1,8 m de resolución espacial y una banda pancromática (PAN) de 0,46 m (Tabla 3.1). No obstante, el gobierno americano obligó a degradar estas resoluciones hasta los 2 m y 0,5 m respectivamente, para su uso comercial hasta junio de 2014, momento en que DigitalGlobe recibió permiso del Departamento de Comercio de Estados Unidos para capturar y vender las imágenes con las mejores resoluciones disponibles. En todas sus bandas, MS y PAN, la resolución radiométrica es de 11 bits. WV-2 es capaz de tomar imágenes con un ángulo de visión de hasta 45° con respecto a la vertical, cubriendo cualquier punto de la superficie terrestre en una franja de 1.355 km bajo la línea de paso del satélite. Además, durante una sola pasada es capaz de cubrir una superficie contigua de 96 x 110 km, a pesar de que su ancho de barrido es de sólo 16,4 km. En cuanto a su resolución temporal, la altura de su órbita y su moderna tecnología de captura y control giroscópico, le permiten reducir el periodo de revisita a 1,1 días. Todas estas características y, especialmente su excelente resolución espacial y espectral, hacen que ofrezca grandes ventajas para caracterizar las cubiertas forestales frente a sensores similares (GeoEye, Ikonos, etc).

WV-2 suministra tres tipos de imágenes:

- PAN: Imagen pancromática de 0,5 m/píxel de resolución espacial.

- MS: Imagen multiespectral (se pueden solicitar 4 u 8 bandas), de 2 m/píxel de resolución espacial.
- PS: Una fusión de las imágenes PAN y MS, que consigue una imagen de 3 ó 4 bandas con una resolución espacial de 0,5 m.

Tabla 3.1. Resolución espacial y espectral del sensor WV-2.

Banda espectral	Longitud de onda central (nm)	Intervalo espectral (nm)	Resolución espacial (m)
Pan	632	450 – 800	0,5
Azul-Costa	427	400 – 450	2,0
Azul	478	450 – 510	2,0
Verde	546	510 – 580	2,0
Amarillo	608	585 – 625	2,0
Rojo	659	630 – 690	2,0
Borde-Rojo	724	705 – 745	2,0
NIR 1	831	770 – 895	2,0
NIR 2	908	860 – 1040	2,0

La función de respuesta espectral para cada una de las bandas del WV-2 puede observarse en la Figura 3.2. Las curvas se han normalizado al máximo valor para cada banda.

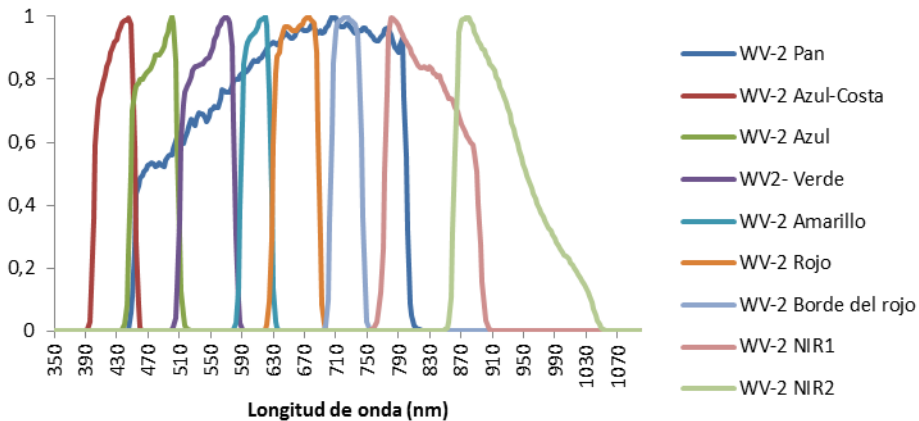


Figura 3.2. Respuesta espectral de las bandas del satélite WV-2 (Fuente, Updike & Comp 2011).

Para esta tesis se contactó con una empresa distribuidora de productos Digitalglobe, con objeto de programar la adquisición de una imagen del WV-2 de acuerdo a una ventana temporal coincidente con el período en el que se realizó el trabajo de campo. Finalmente la imagen fue capturada el 23 de junio de 2011. Se adquirió el producto denominado ortho-ready standard level-2 (ORS2A), que se distribuye con correcciones geométricas y radiométricas, proyectado sobre un plano base de elevación constante, lo que permite su ortorrectificación.

Las imágenes WV-2 comercializadas por DigitalGlobe, contienen un pre-procesamiento de la imagen original, consistente en la aplicación de alguno de los siguientes algoritmos de remuestreo: vecino más próximo, convolución cúbica 4x4, MTF, pan-sharpening y realce. En particular, para este caso, se aplicó el algoritmo del vecino más próximo, que asigna a cada pixel el ND correspondiente al de la posición más cercana. Este procedimiento no altera los ND de la imagen original, solo los traslada. Sin embargo, puede introducir fracturas en el trazado de los rasgos lineales de la imagen, creando un *efecto escalera*.

El pre-procesamiento de la imagen WV-2 implica una serie de correcciones radiométricas y geométricas, cuyo objetivo es obtener una imagen que reproduzca de la forma más fiel posible la energía reflejada y las características espaciales de la zona bajo estudio.

El primer paso del pre-procesamiento, consistió en la conversión de Niveles Digitales (ND) a radiancias en lo alto de la atmósfera ($W/m^2sr\mu m$). La ecuación aplicada para la conversión fue (3.1.):

$$L_{\lambda \text{ Pixel, Band}} = \frac{absCalFactor_{Band} \cdot q_{\text{Pixel, Band}}}{\Delta\lambda_{Band}} \quad (3.1)$$

donde $L_{\lambda \text{ Pixel, Band}}$ es la radiancia, $absCalFactor_{Band}$ se define como el factor de calibración radiométrica absoluto [W/m^2srND] y $\Delta\lambda_{Band}$ como el ancho de banda efectivo [μm]. Ambos valores se obtuvieron a partir

del archivo de metadatos que acompaña a la imagen. Por su parte, $q_{PixelBand}$ es el ND de cada píxel en la imagen. El desarrollo teórico y la derivación de esta ecuación se puede encontrar en Updike & Comp, (2010).

El siguiente paso consistió en la corrección del efecto de la atmósfera. Para ello se usó el módulo FLAASH (del inglés, *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*) (Berk *et al.*, 2002) del software ENVI. La información de entrada debía estar expresada en $[W/cm^2sr\ nm]$, por lo que se aplicó un factor multiplicativo de 10 a $L_{\lambda Pixel,Band}$. FLAASH utiliza un modelo de transferencia radiativa (Gao & Goetz, 1990) donde se deben introducir una serie de parámetros característicos del momento en que el satélite tomó la imagen. En nuestro caso, los parámetros para la corrección atmosférica fueron: atmósfera MLS (del inglés *Mid-Latitude Summer*) que es la que mejor se adapta a las condiciones del día 23 de junio de 2011 (temperatura de 21°C en la base y un contenido total en vapor de agua de 2,92 gr/cm², al que se le aplicó un factor multiplicativo de 0,59 para ajustar el valor del vapor de agua estimado a partir del radiosondeo obtenido por la AEMET para ese día, 1,74 gr/cm²); un modelo de aerosoles rural por ser en su mayoría una zona de bosque; un ángulo cenital de 155,6°; ángulo azimutal de -13,4° y una visibilidad de 30 km. La imagen finalmente corregida del efecto atmosférico representa la reflectancia de las cubiertas terrestres. Estos valores varían entre 0 y 1.

Por último, la imagen resultante fue ortorrectificada utilizando un Modelo Digital del Terreno (MDT) con la misma resolución espacial de 2x2 m que la imagen original, este MDT se describe en el siguiente capítulo. Para este trabajo no se utilizó la banda pancromática.

III.3.2 Datos de campo

Con el objeto de identificar y georreferenciar los diferentes tipos de combustibles representativos en la zona de estudio, se llevó a cabo una campaña de medidas in situ entre los meses de mayo y agosto de 2011. Se definieron un total de 84 parcelas circulares (10 m de radio y 314 m² de superficie), ubicadas en los vértices de una malla cuadrada con parcelas cada 500 m (Figura 3.1). Sólo en algunos casos, éstas se desplazaron ligeramente para poder cubrir todos los tipos de combustibles presentes en la zona.

Las coordenadas del centro de las parcelas fueron tomadas mediante un GPS GeoExplorer, con un mínimo de 60 posiciones, usando una antena de altura 2,5 m para mejorar la señal recibida bajo cubierta forestal. Dentro de cada parcela se efectuaron cuatro transectos de 10 m, siguiendo las direcciones N, S, E y W (Figura 3.3). La toma de medidas consistió en anotar, cada metro, la presencia/ausencia de cubierta vegetal, las especies encontradas, la altura de la vegetación (para lo que se utilizó un hipsómetro digital Vertex Laser II de la marca Haglöf Sweden AB) y la presencia/ausencia de huecos entre el sotobosque y el dosel arbóreo. Además, como información auxiliar para la posterior identificación de los tipos de combustibles, se tomaron fotos de cada transecto.

Con la información recabada en campo, se identificó el tipo de combustible que le correspondía a cada parcela.

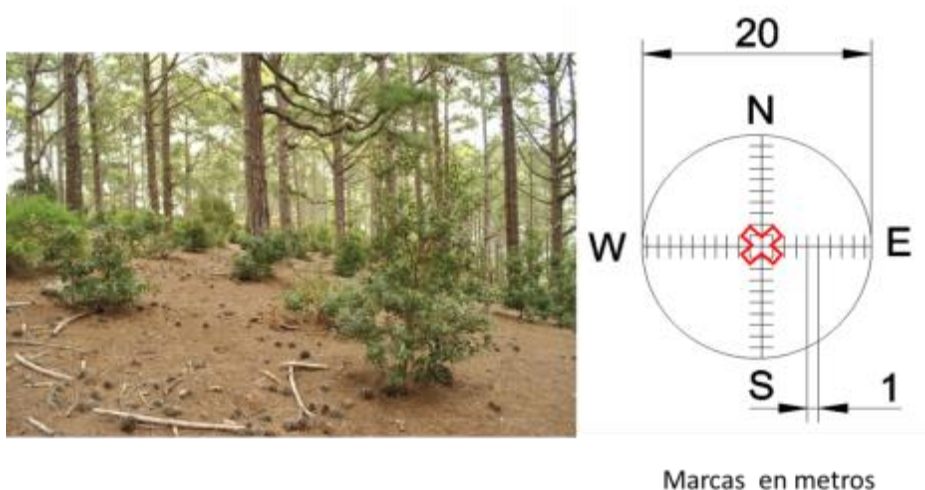


Figura 3.3. Ejemplo de una parcela de campo y esquema con la disposición de cuatro transectos siguiendo las direcciones N, S, E y W. Dentro de cada transecto se tomaron medidas de cada metro. En el centro de las parcelas, se tomó la coordenada GPS (marcado en rojo).

Se tomó como referencia la clasificación de Prometheus (Prometheus, 2000) (Figura 3.4), que identifica los siguientes tipos de combustibles en función de la estructura horizontal y vertical de la vegetación:

- **PFT1** (cubierta herbácea >50%): categoría compuesta fundamentalmente por vegetación herbácea y cultivos.
- **PFT2** (cubierta arbustiva >60% y cubierta arbórea <50%): categoría formada por vegetación herbácea y matorrales con altura inferior a 60 cm, así como zonas de corta donde todavía existan restos de la misma.
- **PFT3** (cubierta arbustiva >60% y cubierta arbórea <50%): zonas con arbustos de tamaño medio, los cuales no superan los 2 m de altura.
- **PFT4** (cubierta arbustiva >60% y cubierta arbórea <50%): zonas con arbustos de tamaño grande, los cuales superan los 2 m de altura pero inferiores a 4 m. En este modelo entran las zonas con

existencia de árboles jóvenes provenientes de regeneración natural o artificial (replantaciones).

- **PFT5** (cubierta arbustiva <30% y cubierta arbórea >50%): áreas forestales, donde predomina la cubierta arbórea sin o con muy poco sotobosque.
- **PFT6** (cubierta arbustiva >30% y cubierta arbórea >50%): áreas forestales donde existe sotobosque (o restos de cortas), y la distancia vertical entre estos y la primera rama verde de los árboles es mayor a 0,5 m.
- **PFT7** (cubierta arbustiva >30% y cubierta arbórea >50%): áreas forestales donde existe sotobosque (o restos de cortas), y la distancia vertical entre estos y la primera rama verde de los árboles es inferior a 0,5 m. Esto facilita que un incendio tenga continuidad vertical, con la aparición de fuegos de copa a partir de fuegos de superficie.

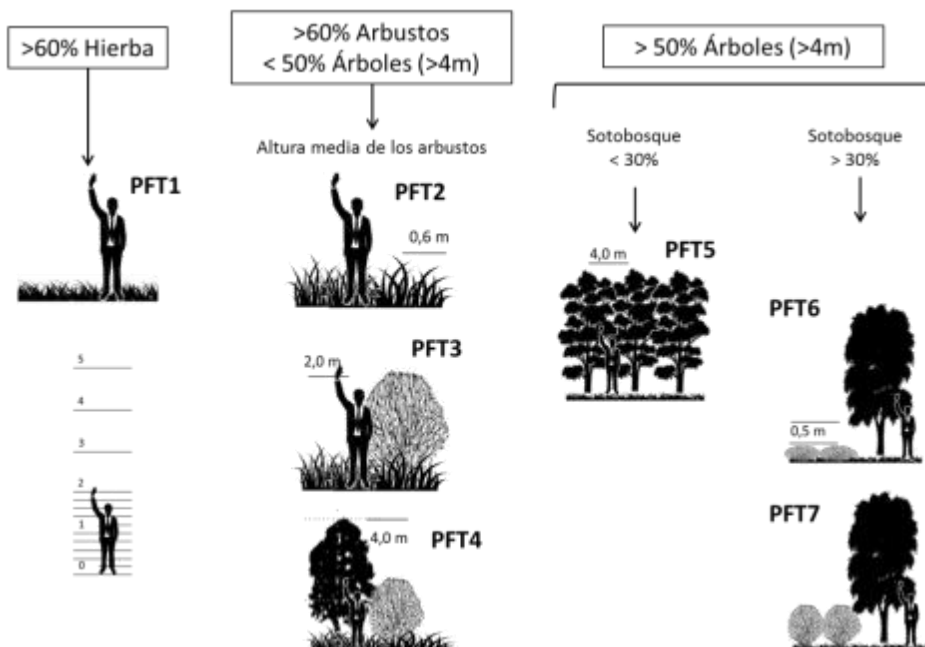


Figura 3.4. Clasificación de los tipos de combustibles según Prometheus. Imagen elaborada a partir de Arroyo *et al.*, 2006.

El combustible tipo PFT1 se asignó a las zonas donde las gramíneas empiezan a invadir el suelo desnudo, los cultivos y los fondos de barrancos con vegetación rupícola compuesta por especies del género *Aeonium spp.*, *Aichryson spp.* o *Sonchus spp.* El tipo PFT2 se encontró asociado a las áreas más antropizadas donde abundan herbazales de gramíneas dominados por cerrillo (*Cenchrus ciliaris* L.), panasco (*Hyparrhenietum hirtae*), inciensos (*Artemisio thusculae*) o tomillares (*Rumicetum lunariae*). El tipo PFT3 correspondía a zonas con presencia dominante de zarzas (*Rubus inermis* Pourr.) y helechos (*Pteridium aquilinum* (L.) Kuhn in Kersten) formando comunidades de transición hacia formaciones arbustivas más complejas. El tipo PFT4 se encontraba asociado a matorrales formados principalmente por jaguarzos (*Cistus monspeliensis* L.), codesos (*Adenocarpus foliolosus* (Ait.) DC.) y helechos (*Pteridium aquilinum* (L.) Kuhn in Kersten) entre otras especies. El combustible tipo PFT5 se correspondía con las masas de pinar canario (*Pinus canariensis* C.Sm. ex DC.) sin sotobosque. Finalmente, los tipos PFT6 y PFT7 se encontraron asociados a formaciones de pinar canario con sotobosque de fayal-brezal, laurisilva o regeneración natural del propio pinar. La diferencia entre ambos tipos de combustibles dependía de la existencia o no de continuidad vertical entre el sotobosque y el estrato arbóreo. En la figura 3.5 se muestran ejemplos de los tipos de combustibles Prometheus identificados en la zona de estudio.




Figura 3.5. Ejemplos de las formaciones encontradas en la zona de estudio correspondientes a los tipos de combustibles Prometheus.

III.3.3 Clasificación OBIA

Tal y como se comentó en el capítulo previo, en la clasificación orientada a objetos (OBIA), es necesario realizar en primer lugar el proceso de segmentación de la imagen, formando objetos mediante la unión de píxeles, para, a continuación, llevar a cabo la clasificación propiamente dicha, basándose en las características de los objetos generados en la primera fase.

Para este capítulo se usó el algoritmo de segmentación conocido como *Multi-resolution Segmentation* (Baatz y Schape, 2000), el cual está basado en una evolución fractal de los objetos (FNEA, Fractal Net Evolution Approach). Básicamente, consiste en la agrupación de píxeles a partir de un conjunto de semillas distribuidas por la imagen, en función

de un criterio previo. Es uno de los más utilizados en OBIA y está implementado en el software eCognition Developer 8.64 (Lucieer, 2004, Benz *et al.*, 2004), usado en el desarrollo de este estudio. Este proceso necesita que se definan una serie de parámetros: forma (shape), compacidad (compactness) y la escala (scale parameter). Los parámetros de forma y compacidad tienen un rango de valores entre 0 y 1; mientras que la escala puede tomar cualquier valor positivo. Cuanta más alta sea la escala, mayor será la heterogeneidad admitida dentro de los objetos. El parámetro de forma actúa de forma complementaria con el factor de heterogeneidad espectral; la forma de los objetos se analiza con los factores compacidad y suavidad, que son igualmente complementarios. El factor suavidad hace referencia a la sencillez de los bordes de los objetos, mientras que el factor compacidad hace referencia a la proporción entre el perímetro del objeto y su área. El valor de escala adecuado para este estudio fue determinado mediante aproximaciones de prueba y error, y validados por inspección visual del resultado basado en el conocimiento de la zona.

El parámetro de forma se estableció en 0,2 con la idea de dar un peso menor a la forma de los objetos y más importancia a la heterogeneidad espectral de los objetos. A la compacidad se le asignó un valor de 0,7, en lo que se refiere al valor de la escala, tras repetidas pruebas, se utilizó un valor de 90. El resultado de la segmentación con diferentes parámetros de escala se puede apreciar en la figura 3.6. Finalmente, se dieron distintos pesos relativos a las bandas MS, de acuerdo con la Tabla 3.2.

Tabla 3.2. Pesos relativos de cada banda MS utilizados en la segmentación.

Banda	Peso
Borde-Rojo, NIR1, NIR2	1
Azul-Costa, Azul, Verde, Amarillo, Rojo	2

La clasificación se realizó usando el algoritmo de mínima distancia (Nearest Neighbour - NN). Este algoritmo usa los valores extraídos de las parcelas de entrenamiento (que se respetan durante el proceso de segmentación) para asignar a cada objeto aquella clase que minimiza la distancia entre ese objeto y el centroide de la clase. Dicha distancia se calcula en función de una selección de características de los objetos (por ejemplo, valores medios de las bandas originales, índices sintéticos, forma de los objetos, información textural o contextual...).

El algoritmo NN trabaja en dos fases:

- a) La fase de entrenamiento, en la que se enseña o entrena al algoritmo, introduciendo la información obtenida en las parcelas definidas en la campaña de campo.
- b) La fase de asignación, en la que cada objeto de la escena se asigna a una de las clases definidas en la fase anterior. Esta asignación se lleva a cabo en base a las características de los objetos de la imagen (espectrales, de tamaño, contexto, etc.).

El algoritmo implementado en el software eCognition presenta dos opciones llamadas Standard Nearest Neighbor (NN) y Nearest Neighbor simple (NNS). En la primera opción, se emplea una selección predefinida de características de los objetos, y utiliza por defecto los valores medios de todas las bandas espectrales, aunque puede cambiarse. En cualquier caso, la fase de asignación utiliza las mismas características para todas las clases identificadas en la imagen. La segunda opción permite seleccionar distintas características de objeto para identificar distintas clases de interés. En el presente trabajo, se ha usado la opción NN con las siguientes características de los objetos: valores medios de todas las bandas, desviación estándar de todas las bandas, brillo y máxima diferencia. Por último, los objetos clasificados adyacentes asignados al mismo tipo de combustible se fusionaron con el fin de reducir el número final de los mismos.




Figura 3.6. Ejemplos de la influencia de la escala (*scale parameter*) en el proceso de segmentación. Imagen WV-2 original (representada en color verdadero) y segmentaciones obtenidas para valores de escala de 10, 25, 90, 150 y 250 (representadas en ese orden, empezando por el panel superior izquierdo).

III.3.4 Evaluación del error

La fiabilidad del mapa obtenido se evaluó mediante el análisis de los errores cometidos de forma similar a como se hizo en el capítulo anterior con la imagen ASTER. Además de la exactitud global, se analizaron los errores debidos a cantidad (*quantity disagreement*) y los errores por ubicación (*allocation disagreement*), de acuerdo a los trabajos de Pontius & Millones (2011) y Pontius & Santacruz (2014). También se analizó la fiabilidad de los mapas por categorías. Para ello, se estimaron los errores relativos (Warrens, 2015), teniendo en cuenta la superficie que ocupaba cada categoría en el mapa. Una descripción detallada de estos cálculos puede verse en el apartado II.6 del Capítulo 2 de la presente tesis.

Para la estimación del error se emplearon las 44 parcelas de campo reservadas para la validación. Cada parcela de campo se asoció a una

ventana de 10 x 10 píxeles. Aunque el tamaño real de las parcelas de campo era algo menor (314 m², en lugar de 400 m²), se consideró adecuado utilizar este tamaño de ventana, pues los límites de los tipos de combustibles son difusos; por tanto incluir un pequeño *buffer* alrededor de cada parcela de campo no afectaría el resultado de la validación. Los tipos de combustible identificados en campo para estos píxeles se compararon con los resultados obtenidos, y con esta información, se generó una matriz de confusión y se obtuvieron los errores por cantidad y ubicación.

III.4 Resultados y discusión

En la figura 3.7 se muestra el mapa de tipos de combustibles obtenido para la zona objeto de estudio. En él se observa que el tipo PFT7 es el que ocupa una mayor superficie (5,8 km²), lo que representa un 38% de la superficie total analizada. Este combustible se corresponde con el monteverde y fayal-brezal, colindante a las zonas de cultivo en el noreste de la imagen y con pinar canario con sotobosque, en la parte central. El tercio sur, que se corresponde con la zona de mayor altitud, está ocupado principalmente por el tipo PFT5, pinar canario sin sotobosque, ocupando 3,7 km² que suponen un 25% del total. Por el contrario nos encontramos con que el tipo PFT2, que se corresponde con herbazales y carrizales, ocupa la menor superficie con sólo 0,8 km², un 5,2% del total (Figura 3.8).




Figura 3.7. Mapa de tipos de combustibles obtenido en la zona de estudio aplicando OBIA.




Figura 3.8. Distribución de los tipos de combustible en la zona de estudio. Las columnas representan las superficies relativas (en %) y los valores el tamaño medio por objeto para cada clase (en píxeles).

Analizando la matriz de confusión (Tabla 3.3), obtenemos que la exactitud global del mapa obtenido es del 76,23%, con un error por cantidad del 11,73% y un 12,04% para el error por ubicación (Tabla 3.4). En función de cuál sea la utilidad final del mapa de combustibles, se priorizará la minimización de uno u otro tipo de error.

Tabla 3.3. Matriz de confusión obtenida tras la clasificación.

	PFT1	PFT2	PFT3	PFT4	PFT5	PFT6	PFT7
PFT1	251	23	0	0	0	0	4
PFT2	47	186	0	0	0	0	0
PFT3	0	82	200	114	0	4	13
PFT4	0	0	0	151	4	16	0
PFT5	0	0	0	0	614	14	205
PFT6	0	0	0	0	247	262	0
PFT7	2	9	0	35	32	4	1078

Tabla 3.4. Errores cometidos por tipo de combustible (las medidas del error por cantidad y ubicación son relativas y vienen dadas en %).

WV-2		
	Cantidad	Ubicación
PFT1	0,61	1,50
PFT2	1,86	2,61
PFT3	5,92	0,00
PFT4	3,59	1,11
PFT5	1,78	12,18
PFT6	5,81	2,11
PFT7	3,89	4,56

De acuerdo a los resultados, el tipo de combustible PFT5 es el que ha dado un error mayor, un 14%, seguido del PFT7 con un 8,5%. En general los tipos de combustibles arbóreos han sido peor clasificados que los tipos de combustibles inferiores a 4,0 m de altura (Figura 3.9).

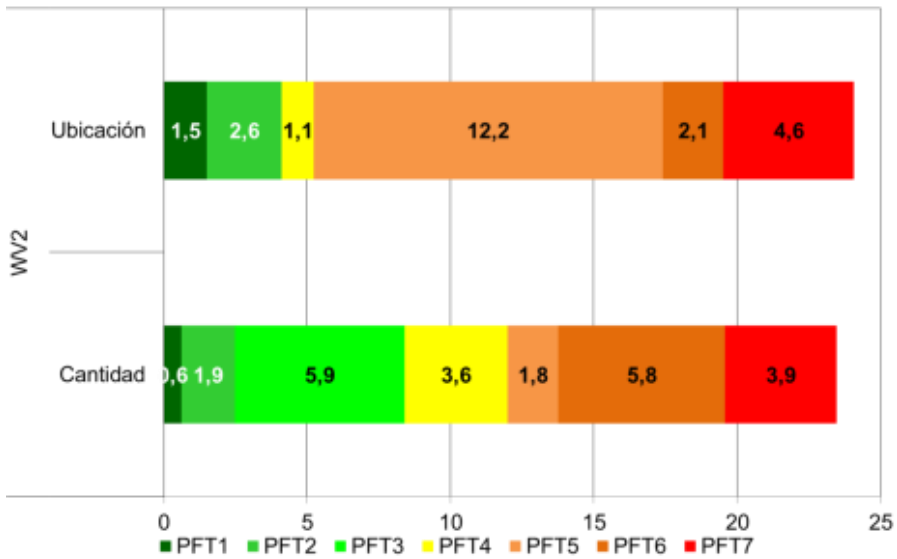


Figura 3.9. Errores por cantidad y ubicación para cada tipo de combustible.

Analizando por tipo de combustible (Figura 3.9), el PFT1 presentó un 2% de error por ubicación, debido a que fue confundido con el tipo PFT2, y 1% en error por cantidad. Por su parte, el tipo PFT 2 ha dado un 3% de error por ubicación, por su confusión con PFT3, y un 2% de error por cantidad dado por el tipo PFT1. El tipo PFT3 sólo ha presentado un 6% de error por cantidad, debido fundamentalmente a las aportaciones realizadas por los tipos PFT2 y PFT4. El tipo PFT4 ha mostrado 1% de error por ubicación al ser erróneamente clasificado como PFT3, y un 4% de error por cantidad, por la confusión con PFT5 y PFT6. El tipo PFT5 es el que peor resultado ha dado por ubicación, 12%, el cual ha sido debido a su confusión con el tipo PFT6, y un 2% de error por cantidad por la confusión con el tipo PFT7. El tipo PFT6 ha presentado un 2% de error por ubicación, al ser confundido con los tipos PFT4 y PFT5, y un error de cantidad del 6% por tener información añadida del PFT5. Por último, el tipo PFT7 ha tenido un 5% de error por ubicación al ser mezclado con el tipo PFT5, y un 4% de error por cantidad, por los tipos PFT4 y PFT5.

En líneas generales, estos datos demuestran que los tipos de combustibles pertenecientes a las formaciones arbóreas PFT5, PFT6 y PFT7, han dado peores resultados que los otros cuatro, debido a que de acuerdo a la clasificación Prometheus, la diferencia entre ellos en altura es muy difusa, y esta información de la estructura vertical es imposible de obtener con imágenes multiespectrales. Además, estos tres tipos presentan una respuesta espectral muy similar, por lo que su diferenciación es muy complicada.

Hemos visto que la falta de información acerca de la distribución vertical de la información supone una importante limitación de cara a la identificación de tipos de combustible a partir de imágenes WV-2 y OBIA. En el siguiente Capítulo se analiza la posibilidad de incorporar datos LiDAR al análisis OBIA. El objetivo es evaluar en qué medida la combinación de información LiDAR y óptica en un OBIA permitirían mejorar la identificación combustibles forestales.

Capítulo IV. Cartografiado de tipos de combustibles mediante fusión de imágenes WorldView-2 y datos LiDAR

Los resultados de este capítulo han sido publicados en el artículo:

Alfonso Alonso-Benito, Lara A. Arroyo, Manuel Arbelo, Pedro Hernández-Leal (2016). Fusion of WorldView-2 and LiDAR data to map fuel types in the Canary Islands. *Remote Sensing*, 2016, 8, 669, [doi:10.3390/rs8080669](https://doi.org/10.3390/rs8080669). Factor de impacto: 3,036.

IV.1 Resumen

En este trabajo se evalúa la viabilidad de combinar OBIA y fusión de imágenes WorldView-2 y datos LiDAR de baja densidad para obtener mapas de combustibles forestales en una zona orográficamente compleja y con abundante cambios en la vegetación situada en la isla de Tenerife. Se generaron y compararon cuatro mapas de tipos de combustibles según la clasificación Prometheus. Los mapas se generaron por aplicación de OBIA a tres imágenes fusión (WV-2 y LiDAR). Se compararon los siguientes métodos de fusión: Image Stack (IS), análisis de componentes principales (PCA) y fracción del mínimo ruido (MNF). La validación de los mapas se llevó a cabo por comparación frente a los tipos de combustible determinados en campo. Además de la exactitud global, se estimaron las componentes de error asociadas a ubicación y cantidad, tanto a nivel global como por tipo de combustible. Esto permitió un mejor conocimiento de la naturaleza del error asociado a cada mapa. La exactitud global de los mapas obtenidos variaba entre el 84,27 y el 85,43%. Los mapas obtenidos a partir de fusión de datos WV2 y LiDAR alcanzaron una exactitud global significativamente mayor que los generados a partir de la imagen WV-2 sola. La incorporación de la información LiDAR a los OBIA permitió mejoras en la exactitud global mayores al 10% en todos los casos. No se encontraron diferencias significativas en la exactitud global de las clasificaciones sobre imágenes fusionadas. Los resultados de este estudio demuestran que el uso combinado de OBIA y fusión de datos multiespectrales de alta resolución espacial y LiDAR de baja densidad es adecuado para generar cartografía de combustibles en las Islas Canarias.

Comenzaremos el capítulo con una descripción de los datos LiDAR utilizados. A continuación se describe la metodología usada para la fusión de la imagen WV-2 y LiDAR. En el siguiente apartado se detallan las especificaciones utilizadas para la clasificación OBIA, realizando en el

último apartado el análisis de los resultados de dicha clasificación y la evaluación del error.

IV.2 Introducción

Con objeto de aprovechar y combinar las ventajas que ofrecen los sensores pasivos (tanto multiespectrales como hiperespectrales) y activos (LiDAR fundamentalmente) por separado, se han llevado a cabo diversos trabajos fusionando ambos tipos de información. La fusión integra datos de diferente naturaleza pero complementarios para aumentar la confianza, reducir la ambigüedad y mejorar la fiabilidad del cartografiado o la clasificación (Rogers & Wood, 1990). En estudios anteriores se han fusionado imágenes multiespectrales (GeoEye 1 QuickBird) e hiperespectrales (HyMAP, Hyperion, AISA-Airborne Imaging Spectrometer for Applications) con datos LiDAR para cartografiar la vegetación forestal (Arroyo et al., 2010; Dalponte et al., 2008, 2012; Ghosh et al., 2014; Stavrakoudis et al., 2014). Estos autores encontraron mejoras de hasta el 13% en la exactitud global al trabajar sobre imágenes fusionadas frente al uso de las imágenes por sí solas. También se han utilizado imágenes fusionadas para generar mapas de usos del suelo, obteniendo mejoras en el nivel de exactitud de hasta el 18% (Huang & Zhang 2010, 2012; Huang et al., 2011; Pedergrana et al., 2011). Swatantran et al. (2011) fusionaron imágenes hiperespectrales AVIRIS y LiDAR para cartografiar biomasa, y encontraron una disminución del error de un 12% al trabajar sobre imágenes fusionadas. Con respecto a la fusión de datos LiDAR y multiespectrales para cartografiar los tipos de combustibles, en algunos trabajos se consiguió mejorar la exactitud de las clasificaciones con respecto al uso de un solo tipo de datos al menos en un 10% (Mutlu et al., 2008; García et al., 2011; Jakubowski et al., 2013). En todos los ejemplos anteriores se usaron algoritmos de clasificación basados en píxeles. Sin embargo, varios estudios han llegado a la conclusión de que la identificación de combustibles forestales es más fácil sobre objetos que frente a píxeles

individuales (Arroyo et al., 2006; Tanase and Gitas, 2008; Alonso-Benito et al., 2013; Alonso-Benito et al., 2016).

El objetivo principal de este trabajo es evaluar el potencial de combinar técnicas de fusión de imágenes y OBIA sobre datos LiDAR de baja densidad y multispectrales VHR del sensor WorldView-2 (WV-2) para cartografiar tipos de combustibles en una zona de estudio en la isla de Tenerife (Canarias, España). WorldView-2 es un sensor no usado hasta el momento para cartografiar tipos de combustibles, a pesar de poseer cuatro nuevas bandas espectrales (Azul-costa, Borde-Rojo, amarillo y NIR 2) que incrementan su sensibilidad para monitorizar la vegetación, comparado a otros sensores multispectrales equivalentes.

Para ello, se desarrollaron OBIA independientes con los que se generaron tres mapas de combustibles forestales de la zona de estudio, utilizando tres métodos de fusión de imagen: Image Stack (IS), análisis de componentes principales (PCA) y fracción del mínimo ruido (MNF). Un cuarto mapa se generó a partir de la imagen WV-2 no fusionada (obtenido en el capítulo 3 de esta memoria). Los mapas obtenidos son entonces analizados para (1) evaluar y comparar la calidad de los distintos métodos de fusión empleados y (2) comparar los resultados obtenidos al utilizar imágenes LiDAR y WV-2 fusionadas frente al uso de imágenes WV-2 solas. Los resultados de este estudio permiten, además, determinar la viabilidad de utilizar imágenes LiDAR de baja densidad y WV-2 para actualizar la cartografía de combustibles del archipiélago canario. Para este estudio, se ha utilizado la clasificación de combustibles Prometheus.

IV.3 Zona de estudio

El estudio llevado a cabo para esta parte del trabajo se desarrolló en la misma zona de estudio, previamente descrita en los apartados III.2 y III.3 del capítulo 3 de esta memoria.

IV.4 Materiales y métodos

Para evitar duplicar contenidos, se remite al lector al capítulo 3 para una descripción detallada de la metodología empleada durante el trabajo de campo y en el pre-procesado de la imagen WV-2.

En la figura 4.1 se presenta el diagrama de flujo utilizado para el presente trabajo.

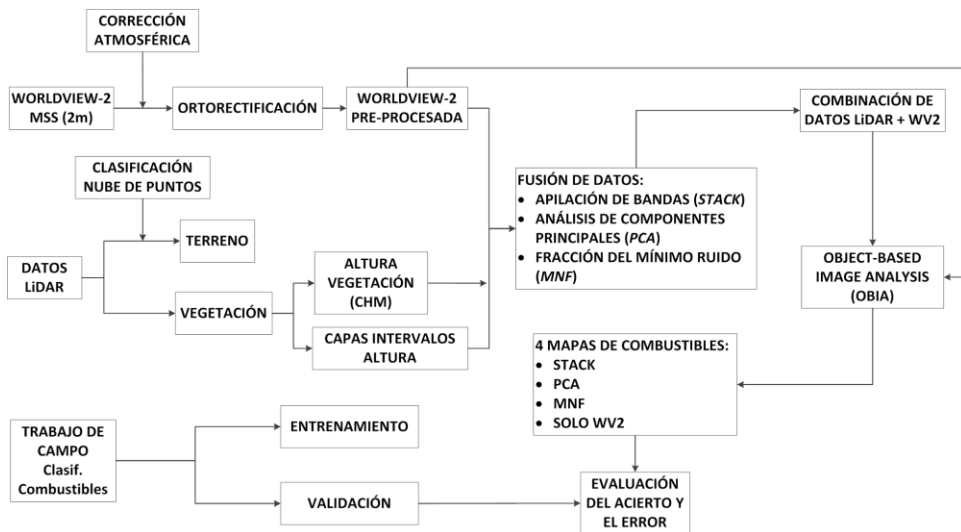


Figura 4.1. Diagrama de flujo usado para la comparación de técnicas de fusión y cartografiado de tipos de combustibles a partir de datos LiDAR y WV-2.

IV.4.1 Datos LiDAR

En esta tesis se han utilizado datos LiDAR discretos, de huella pequeña y múltiple retorno que fueron recogidos mediante un sensor ALS60 Leica entre julio y agosto de 2010. El sensor iba montado en una avioneta Cessna 421 Golden Eagle, con altura máxima de vuelo de 2.000 m sobre el suelo. El sistema recogió cuatro retornos por cada pulso láser emitido, registrando el tiempo de retorno y la intensidad (resolución radiométrica de 8 bits). El campo de visión variaba entre 35-45°, con un solape transversal del 20%, y un ancho de barrido de 1.660 m. La densidad

media de puntos por metro cuadrado era de 2,43, con una precisión espacial horizontal y vertical de 60 y 20 cm respectivamente. La información LiDAR fue cedida por GRAFCAN (Cartográfica de Canarias S.A.). Los puntos no se proporcionan clasificados.

Se utilizaron 83 escenas LiDAR de 500 x 500 m (Figura 4.2). La nube de puntos se filtró utilizando el código establecido por la American Society of Photogrammetry and Remote Sensing (ASPRS) generando dos grupos de puntos: (1) puntos de suelo, y (2) puntos de no-suelo, que conforman la vegetación (Lorenzo-Gil *et al.*, 2013).

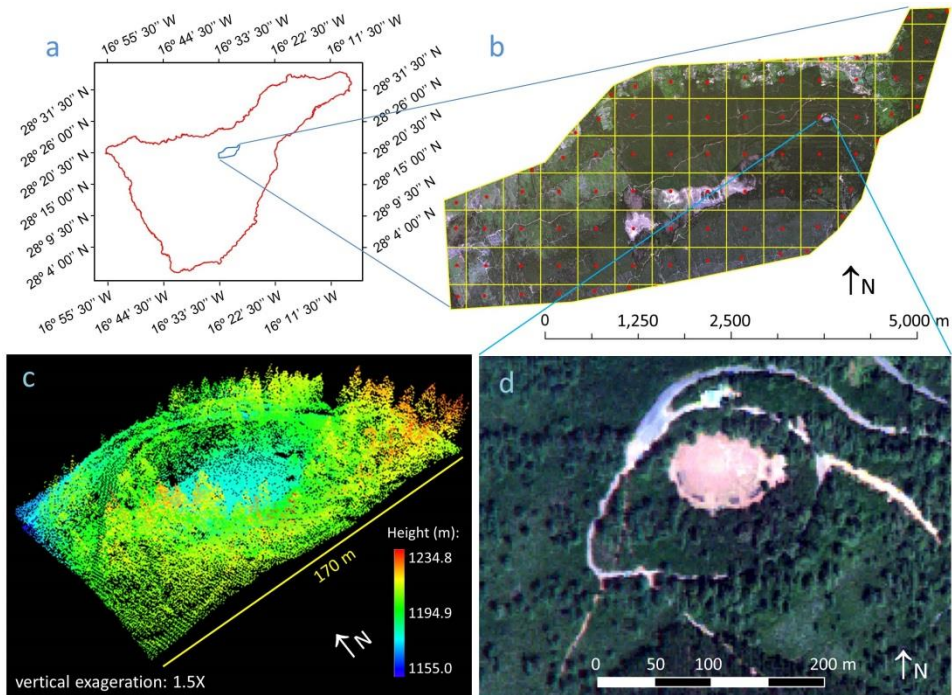


Figura 4.2. Zona de estudio: a) Localización del área de trabajo en la isla de Tenerife; b) Imagen WV-2 (composición verdadero color). Las líneas amarillas muestran las escenas LiDAR y los puntos rojos son las parcelas del trabajo de campo; c) Composición 3D con datos LiDAR de la zona La Caldera; d) Imagen WV-2 de La Caldera en verdadero color. (Fuente: Alonso-Benito *et al.*, 2016).

A partir de los puntos de suelo se derivó un Modelo Digital del Terreno (MDT) (Figura 4.3) con un tamaño de pixel de 2 m. Con los puntos de no-suelo, correspondientes al primer retorno, se elaboró un Modelo Digital de Superficie (MDS) con la misma resolución espacial. A continuación se estimó un Mapa de Altura de la Vegetación (Canopy Height Model, CHM) (Figura 4.3) como la resta entre MDS y MDT. Además se obtuvieron 13 capas de densidad relativa de puntos no-suelo por intervalos de alturas. Las densidades relativas por intervalos se estimaron como el cociente entre el número de puntos no-suelo para cada intervalo de altura y el número total de puntos no-suelo en ese pixel (2 x 2 m). Se consideraron ocho intervalos de altura de 0,5 m (entre 0 y 4 m), cuatro intervalos de 1,0 m (de 4 a 8 m) y un último intervalo para puntos por encima de 8 m (Figura 4.4).

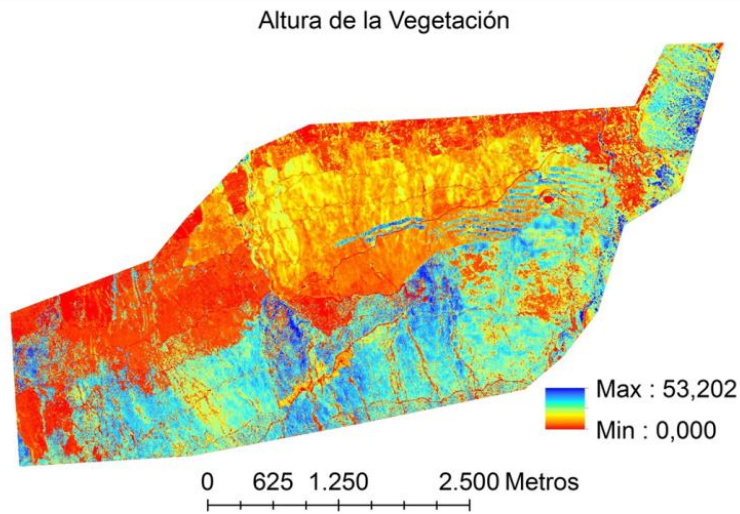
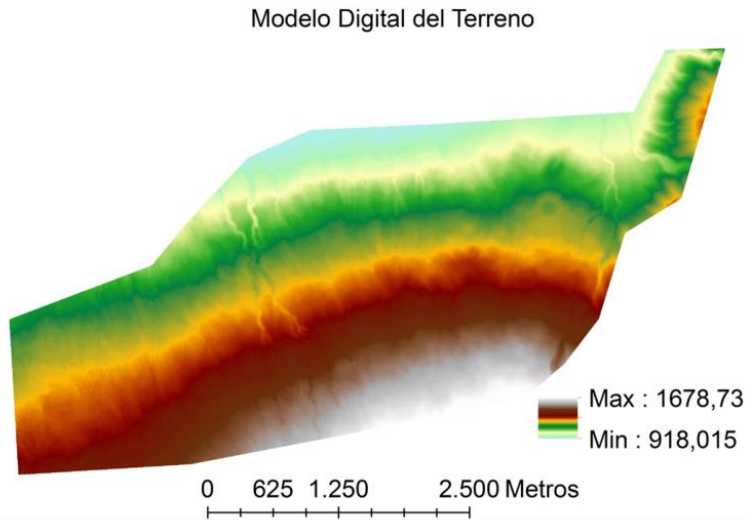


Figura 4.3. Mapas MDT y CHM (Altura de la Vegetación) obtenidos a partir de los datos LIDAR de la zona objeto de estudio.

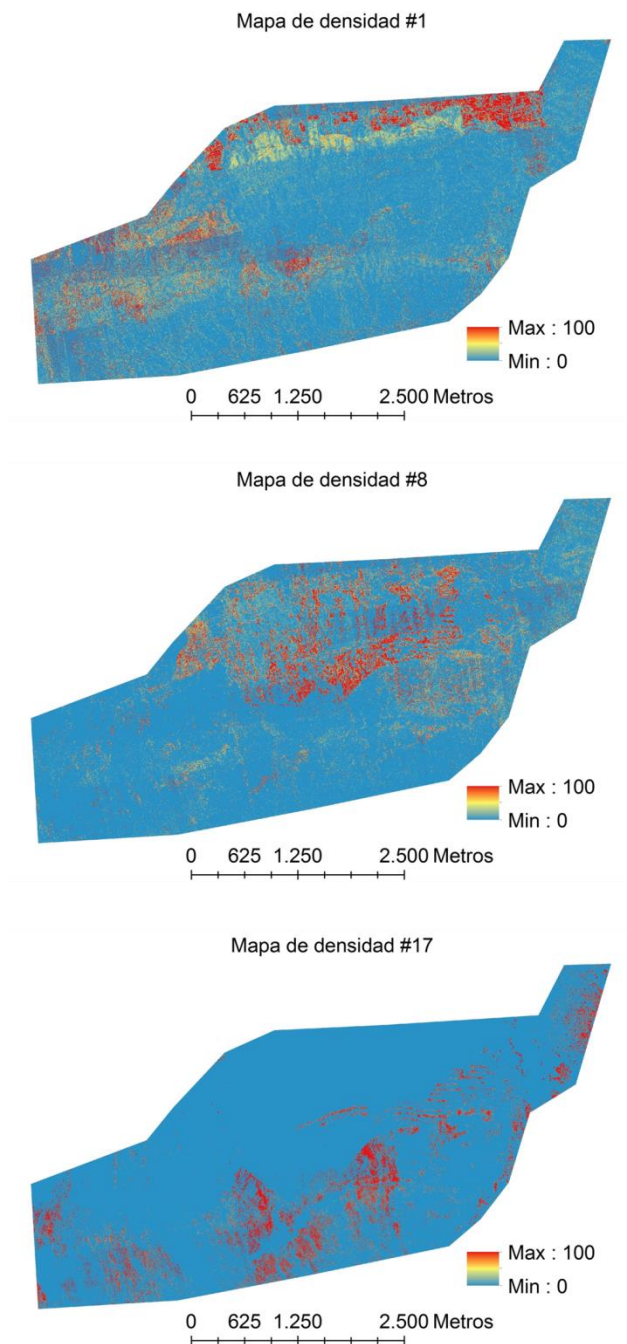


Figura 4.4. Mapas de densidad: #1 hasta 0,5 m, #8 entre 3,5 y 4 m, y #17 mayor a 15m. Todos comparados con la imagen RGB de la zona.

IV.4.2 Fusión de los datos LiDAR y multiespectrales

Se utilizaron tres métodos de fusión de datos, todos ellos implementados a nivel de pixel: (1) unión de capas (IS); (2) análisis de componentes principales (PCA); y (3) fracción del mínimo ruido (MNF).

Para la fusión IS se generó una imagen nueva con 22 bandas de 2 m de resolución espacial. Las bandas derivadas de la información LiDAR se unieron directamente a las bandas corregidas del sensor WV-2. Así, la nueva imagen estaba compuesta por ocho bandas multiespectrales, procedentes de la imagen WV-2 y 14 bandas derivadas a partir de los datos LiDAR (13 de densidad relativa por intervalos de alturas y una del CHM).

El método PCA permite reducir el número de bandas de la imagen fusionada (IS) a costa de una pequeña pérdida de información (Jensen, 2005). Estadísticamente, PCA busca si es posible representar adecuadamente la información original con un menor número de bandas, construidas como combinaciones lineales de las originales (Smith, 2002), de forma que las nuevas bandas expliquen el máximo de la variabilidad total sin correlación entre ellas. La imagen fusionada PCA constaba de las cinco primeras bandas, explicando un 99,47% de la variabilidad total de la imagen fusión IS.

La fusión MNF también buscaba reducir el número de bandas de la imagen IS a partir de la transformación de sus bandas originales. En este caso, las bandas fusionadas se estimaron como aquellas combinaciones lineales que maximizaban el ratio señal-ruido, minimizando así el ruido existente (Green *et al.*, 1988). Para la imagen fusión MNF se seleccionaron las ocho primeras bandas, las cuales explicaban el 99,30% de la varianza de la imagen IS.

IV.4.3 Clasificación OBIA

Se generaron tres mapas de combustibles forestales obtenidos de manera independiente para las tres imágenes creadas en los procesos de fusión de datos (IS, PCA y MNF). Además, con el fin de poder comparar los resultados encontrados frente a la clasificación obtenida a partir de información no fusionada de la imagen WV-2, se utilizó el mapa de combustibles generado en el capítulo anterior.

Todas las clasificaciones se llevaron a cabo mediante OBIA. La heterogeneidad interna de los objetos procedentes de la segmentación de las imágenes se estimó dando un peso de 0,8 al componente de color y 0,2 al componente de forma (con 0,3 a suavidad y 0,7 a compacidad). El parámetro de escala se estimó mediante pruebas de ensayo y error hasta conseguir una segmentación acorde a las características de los diferentes tipos de combustibles. Se obtuvieron valores de 45 para IS y MNF y 100 para PCA (Figura 4.5). Además, se incluyó una capa temática que delimitaba las parcelas de entrenamiento (43), para que la segmentación respetase dichas parcelas. Estas parcelas estaban repartidas homogéneamente por la zona de estudio y cubrían todos los tipos de combustibles. En el apartado III.3.3 se explica todo el proceso con más detalle.

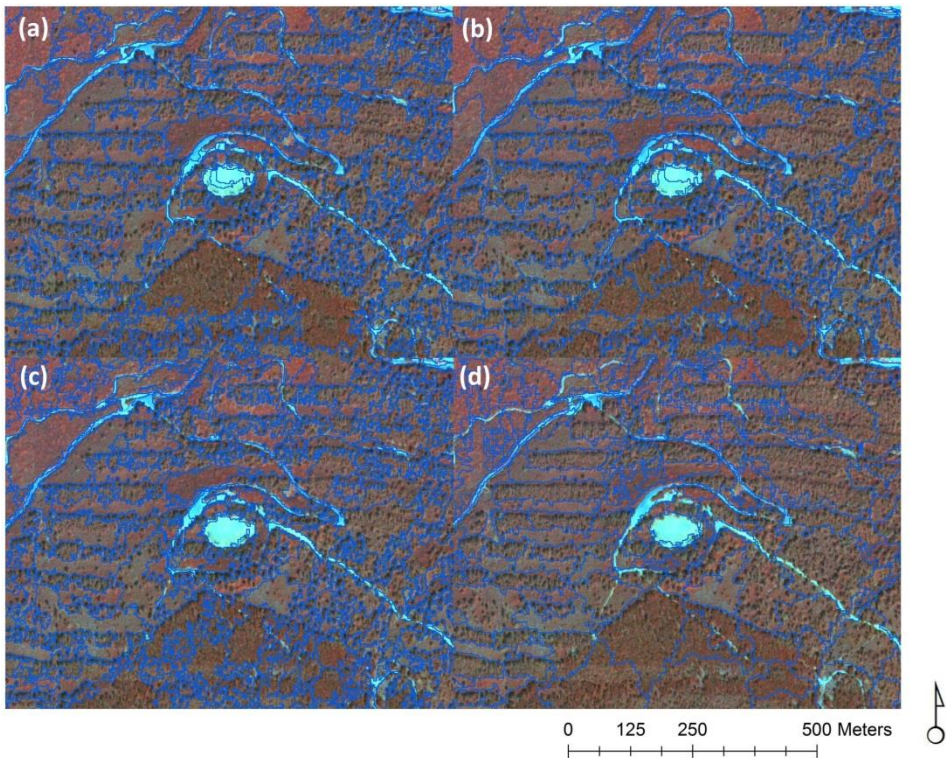


Figura 4.5. Ejemplos de la segmentación en cada imagen con diferentes parámetros de escala: (a) WV-2, (b) IS, (c) PCA y (d) MNF (Fuente: Alonso-Benito *et al.*, 2016).

IV.4.4 Evaluación del error

La fiabilidad de los mapas obtenidos se evaluó mediante el análisis de la exactitud global y los errores debidos a cantidad y ubicación, tanto absolutos como relativos, tal como se explica en los apartados II.3.4 y III.3.4 de la presente tesis.

A las cuatro clasificaciones obtenidas se les ha aplicado el test de McNemar's (Foody, 2004; 2009), para evaluar si existen diferencias significativas entre ellas, mediante la fórmula 4.1:

$$X^2 = \frac{(|f_{CI} - f_{IC}| - 1)^2}{f_{CI} + f_{IC}} \quad 4.1$$

donde f_{C1} el número de sitios correctamente asignados en el mapa 1 e incorrectamente asignados en el mapa 2, f_{IC} es el número de sitios incorrectamente asignados en el mapa 1 y correctamente asignados en el mapa 2. Los valores obtenidos fueron comparados mediante una distribución chi-cuadrado con una probabilidad del 95% (nivel de significancia del 0,05).

IV.5 Resultados y discusión

Se obtuvieron tres mapas de combustibles mediante fusión (IS, PCA y MNF), que se comparan con el obtenido en el capítulo III de la presente tesis usando sólo la imagen WV-2 (Figuras 4.6 y 4.7). En la figura 4.8 se muestra la superficie relativa ocupada por cada combustible para los cuatro mapas.

Los resultados son similares en todas las clasificaciones. El tipo de combustible PFT7 es el que ocupa una mayor superficie, ocupando una superficie relativa de más del 30% en todos los casos. Este combustible se corresponde con el monteverde y fayal-brezal colindante a las zonas de cultivos presentes en el noreste de la zona de estudio y con pinar canario con sotobosque en la parte central. Las zonas de mayor altitud, situadas en el sur de la zona de estudio, están ocupadas mayoritariamente por pinar canario sin sotobosque, que se asignó en gran medida al PFT5. Este combustible ocupa, según las distintas clasificaciones, entre el 22 y el 30% del área de estudio. El resto de combustibles son menos abundantes y aparecen de forma más o menos desagregada por la zona de estudio.

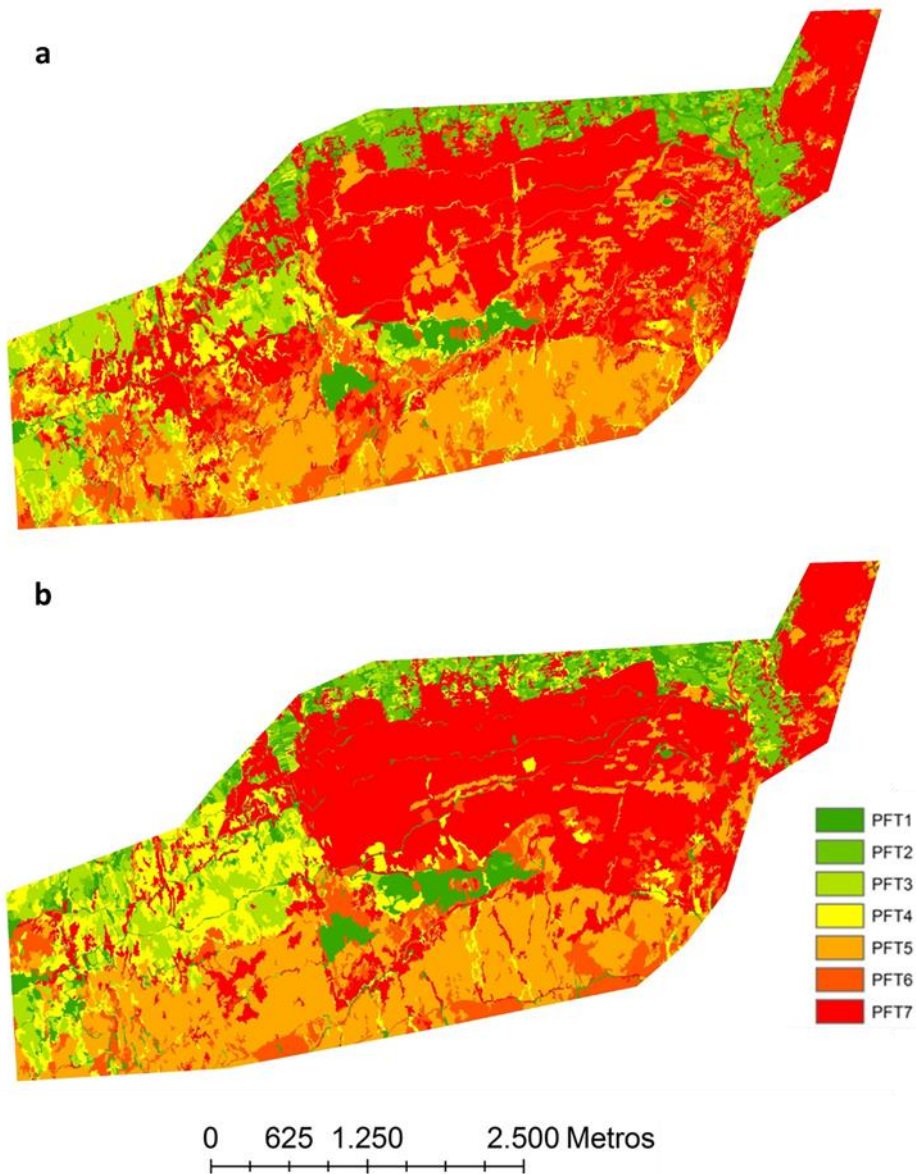


Figura 4.6. Mapas de tipos de combustibles obtenidos para: a) Imagen WV-2 sola; b) IS; c) PCA; d) MNF.

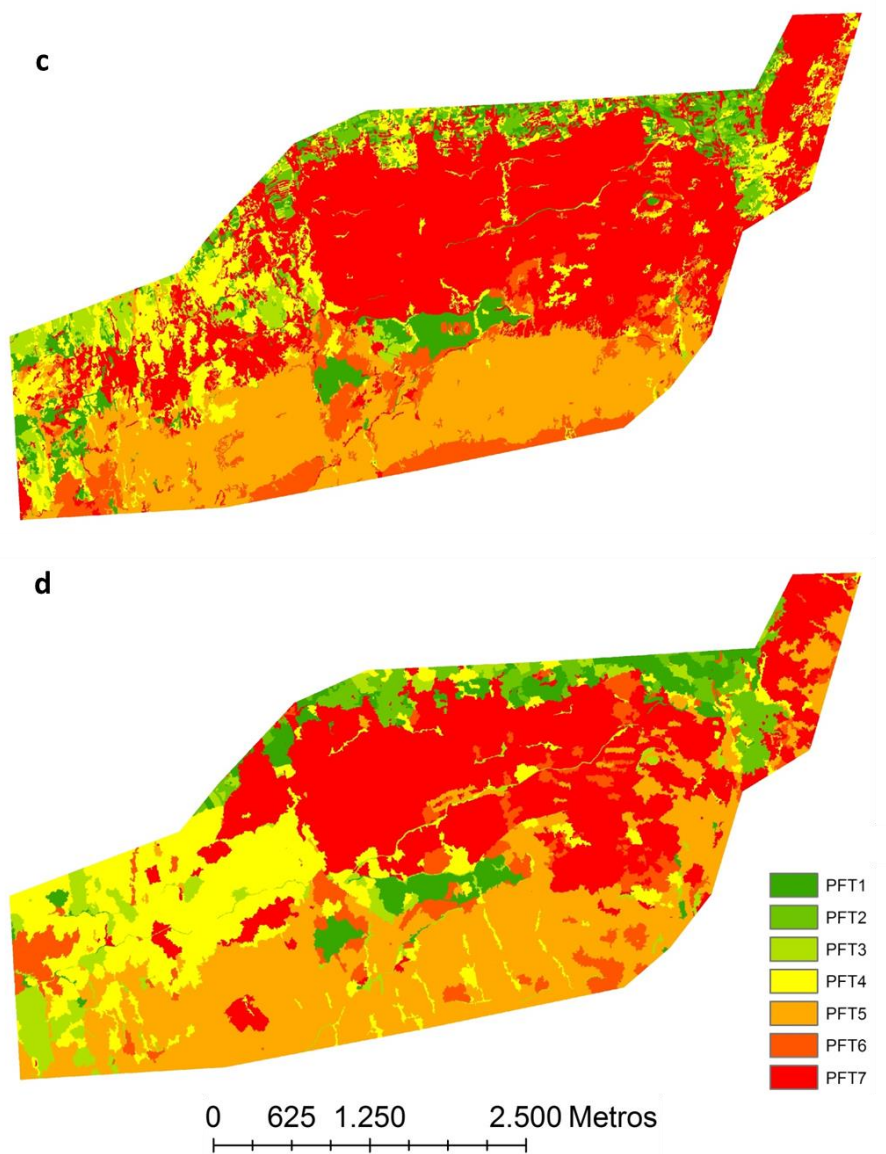


Figura 4.7. Mapas de tipos de combustibles obtenidos para: a) imagen WV-2 sola; b) IS; c) PCA; d) MNF.

Las mayores diferencias se detectan en el mapa obtenido a partir de la fusión MNF, que muestra un aspecto más homogéneo, con polígonos más grandes. Así, el tamaño medio de los polígonos del mapa obtenido a partir de la fusión MNF es aproximadamente el doble que en el resto de mapas. Además, las superficies ocupadas en el mapa MNF por los PFT4 y PFT5 son mayores que en los demás mapas, mientras que la superficie asignada al PFT7 es notablemente menor (Figura 4.8).




Figura 4.8. Distribución de la superficie de cada tipo de combustible obtenido.

La exactitud global obtenida para los mapas generados oscila entre el 76,23 y el 85,43% (Tabla 4.1). Estos resultados corroboran la capacidad de los OBIA para discriminar elementos complejos, como son los tipos de combustibles, sobre imágenes de elevada heterogeneidad espectral (VHR). La incorporación de las características contextuales en el análisis facilitó la identificación de los tipos de combustible Prometheus. Además, la segmentación inicial permitió convertir la escala de trabajo original, que venía impuesta por la resolución espacial de la imagen, a la escala de trabajo adecuada para el objetivo del trabajo (ie., la identificación de tipos de combustible). Estudios previos similares, aunque desarrollados sobre otro tipo de imágenes y áreas de estudio,

presentaron conclusiones similares (Arroyo *et al.*, 2006; Tanase and Gitas, 2008; Alonso-Benito *et al.*, 2013).

Tabla 4.1. Medidas por tipo de combustible del acierto obtenido (errores relativos y totales por cantidad y ubicación) para los tres mapas generados por fusión y el obtenido con la imagen WV-2 sola (valores en %).

	WV-2		IS		PCA		MNF	
	Cantidad	Ubicación	Cantidad	Ubicación	Cantidad	Ubicación	Cantidad	Ubicación
PFT1	0,61	1,50	0,08	1,95	2,03	2,45	0,11	0,00
PFT2	1,86	2,61	0,92	5,28	3,25	1,11	0,47	0,00
PFT3	5,92	0,00	2,03	3,39	0,64	2,06	3,11	0,00
PFT4	3,59	1,11	0,14	2,45	1,64	6,51	1,70	1,06
PFT5	1,78	12,18	3,28	1,56	2,28	0,00	1,75	6,62
PFT6	5,81	2,11	2,67	0,44	2,98	0,00	0,78	5,56
PFT7	3,89	4,56	1,50	5,78	0,36	4,84	1,81	6,17
Tot.	11,73	12,04	5,31	10,42	6,59	8,48	4,87	9,71

La menor exactitud global se obtuvo para el mapa creado a partir de la imagen WV-2 sin fusionar, con una exactitud global del 76,23%. Cuando se incorporó información sobre la distribución vertical de la vegetación mediante fusión con los datos LiDAR, los valores de exactitud global mejoraron para todos los mapas en al menos un 10%.

Los test de McNemars (Foody, 2004) confirmaron que las diferencias encontradas en la exactitud global alcanzada para este mapa y los tres obtenidos a partir de imágenes fusión eran significativas en todos los casos (*p-value* de 0,05).

Cabe destacar que esta mejora en la precisión de los mapas se alcanzó utilizando datos LiDAR de densidad media baja (2,43 ptos/m²) y en una zona de estudio de orografía muy compleja. Estudios anteriores coinciden en demostrar que el uso combinado de información óptica y LiDAR permite una mejor identificación de tipos de combustibles. En general, obtienen valores de exactitud global semejantes o incluso

superiores a los alcanzados en este estudio, pero en su mayoría utilizan información de mayor calidad (mayor resolución espacial y espectral de las imágenes ópticas; y mayor densidad de puntos en los datos LiDAR). García *et al.* (2011), por ejemplo, obtuvieron mapas de combustibles con una exactitud del 89% al fusionar imágenes Airborne Thematic Mapper (10 bandas espectrales con 2 m de resolución espacial) y LiDAR. Mutlu *et al.* (2008) también encontraron mejores resultados al clasificar tipos de combustible sobre imágenes QuickBird y LiDAR fusionadas en comparación con la imagen satélite sola. Estos autores alcanzaron una exactitud global del 90% en la clasificación de la imagen fusionada MNF, casi un 5% superior a los resultados de este trabajo. Como indica Jakubowski *et al.* (2013), los buenos resultados de Mutlu *et al.* (2008) pueden ser debidos a las características de la zona de estudio (se trata de una zona sin complejidad orográfica) y el menor número de tipos de combustibles presentes en ella. En una zona de relieve complejo, Jakubowski *et al.* (2013) obtuvieron una exactitud global del 76% al combinar a una imagen con cuatro bandas multispectrales procedentes del NAIP (National Agricultural Imagery Program) con datos LiDAR de baja densidad de puntos.

Los mapas obtenidos a partir de las imágenes fusionadas tenían una exactitud global de entre 84,27 y 85,43%. Las diferencias de exactitud global observadas entre los distintos métodos de fusión analizados no resultaron significativamente distintas, según los test McNemars, en ningún caso. No se ha encontrado evidencia que indique que un método de fusión sea mejor que el resto en cuanto a la exactitud global alcanzada. Podemos asumir que dichas diferencias se deben simplemente al azar. Por tanto, la selección del método de fusión más adecuado para un estudio dependerá fundamentalmente de los objetivos específicos de cada proyecto en concreto, así como de la disponibilidad de medios (tiempo de procesado y software necesario para cada técnica de fusión).

Para poder analizar la naturaleza de los errores encontrados, se estimaron las componentes de ubicación y cantidad de los mismos (Tabla 4.1). En los mapas generados a partir de imágenes fusionadas MNF y IS, el error por cantidad era prácticamente la mitad del error debido a ubicación de los combustibles. Esta distribución desigual de las componentes del error no se observaba para los mapas obtenidos para la imagen fusión PCA y la imagen WV-2 sola. Según estos resultados, los mapas generados a partir de imágenes MNF e IS (i.e., con menor error total por cantidad) serían especialmente adecuados en estudios que tengan como objetivo, por ejemplo, analizar la evolución de los combustibles en el tiempo. Cuando se necesite conocer con precisión la ubicación espacial de los distintos tipos de combustibles, sería recomendable utilizar el método fusión PCA. Este sería el caso, por ejemplo, de estudios orientados a la toma de decisiones sobre la detección precoz y el control del fuego activo (de cara a la ubicación de torres de vigilancia, por ejemplo). De forma coherente a lo discutido en apartados anteriores, la fusión con LiDAR sería siempre recomendable, ya que los mapas generados a partir de la imagen WV-2 sola produce mayores errores tanto de cantidad como de ubicación.

Además de las medidas del error total, se estimaron los errores por cantidad y ubicación para cada tipo de combustible en los cuatro mapas (Tabla 4.1). En lugar de las medidas absolutas, hemos usado las medidas relativas, con el fin de poder comparar los diferentes tipos de combustibles (Warrens, 2015). El PFT1 es el que mostraba menores errores, con valores por debajo del 2,5% en todos los casos. Este tipo de combustible está compuesto fundamentalmente por vegetación herbácea y cultivos, que fue correctamente identificado tanto en la imagen WV-2 sola como en las tres fusiones con LiDAR. En el extremo contrario, el combustible que mostró mayores errores fue el PFT7, que se corresponde con formaciones densas de pino canario y sotobosque de fayal-brezal. Los errores en la identificación del PFT7 se produjeron para todos los mapas generados, tanto en la imagen WV-2 sola como en las

tres fusiones. En el caso de la clasificación sobre la imagen WV-2, los datos del sensor óptico no permitían obtener información sobre la vegetación presente bajo la cubierta arbórea. Para las clasificaciones realizadas sobre imágenes fusionadas, esto pudo deberse probablemente a la baja densidad de puntos de los datos LiDAR, que resultó ser insuficiente en algunos casos. En las zonas de cubierta forestal densa, el número de retornos procedentes del suelo y los estratos más bajos disminuía notablemente, lo que dificultó distinguir entre los tipos de combustible arbóreos.

El análisis del error por categorías permitió un estudio pormenorizado acerca de la bondad selectiva de cada método para cada tipo de combustible. Comparando los resultados de la clasificación de la imagen WV-2 con las fusiones WV-2 y LiDAR, las mayores diferencias de error se encontraron en los tipos de combustible PFT5, PFT6 y PFT7. Para el resto de combustibles no se encontraron diferencias tan marcadas, llegando a ser en algunos casos incluso inexistentes. Así, los PFT1 y PFT2 mostraron errores similares o menores en el mapa sobre la WV-2 que en los mapas de las fusiones IS y PCA. Según este resultado, la información óptica de la imagen WV-2 fue suficiente para identificar los tipos de combustible no arbóreos. Esto fue posible gracias a la información de contexto que se introdujo en el sistema a través de OBIA. Para identificar los combustibles arbóreos, en cambio, la ausencia de información sobre la distribución vertical de la vegetación resultó especialmente limitante. Otro hecho destacable es que la exactitud alcanzada por la clasificación sobre la imagen fusionada MNF estaba sesgada hacia los tipos de combustibles herbáceos o arbustivos. En la fusión MNF, la información LiDAR facilitó la identificación de los modelos sin estrato arbóreo, pero apenas mostró mejora sobre la clasificación WV-2 para el resto de combustibles. Así, de las tres fusiones comparadas, la clasificación sobre la fusión MNF produjo los menores errores para todos los combustibles sin cubierta arbórea (PFT del 1 al 4), y los mayores errores para los combustibles con cubierta arbórea (PFT del 5 al 7). Puesto que los tres

métodos emplean la misma información de entrada, esta diferencia sólo puede ser debida al proceso de fusión. En cualquier caso, el conocimiento preciso de la distribución del error en los mapas generados es fundamental de cara a la selección del método de cartografiado más adecuado, en función de los objetivos del mismo, así como para conocer los errores esperados para cada método.

Capítulo V. Conclusiones

V.1 Conclusiones

En este último capítulo presentamos las conclusiones más importantes derivadas del trabajo presentado en esta tesis.

1. Se ha actualizado el mapa de combustibles del municipio de La Orotava (en el Norte de la isla de Tenerife, España) haciendo uso de una imagen del sensor ASTER y cuatro métodos de clasificación diferentes: tres clasificadores basados en el píxel (Máxima Probabilidad, Redes Neuronales y Máquina de Soporte Vectorial) y uno basado en Objetos (OBIA), obteniendo en todos ellos una exactitud global superior al 75%.
2. La bondad de los resultados obtenidos con los diferentes algoritmos se evaluó en términos del error por cantidad y error por ubicación, un análisis de la exactitud novedoso no usado hasta la fecha para este tipo de cartografiado. La principal ventaja del cálculo de estos errores es que permitieron conocer con precisión qué componente del error se asocia a cantidades incorrectas, frente al error en la ubicación espacial de los tipos de combustibles, aspectos fundamentales de cara a utilizar programas de simulación o modelado del comportamiento de un incendio.
3. La clasificación OBIA produjo los mapas más precisos, con una exactitud global un 12% por encima de los mejores resultados obtenidos para los algoritmos basados en píxeles. Esto fue en parte debido a la posibilidad que ofrece OBIA de incorporar información contextual en el análisis, un elemento clave para facilitar una mejor diferenciación de los combustibles con una respuesta espectral similar.

4. La principal fuente de error en todas las clasificaciones sobre la imagen ASTER, fue la ubicación incorrecta del tipo de combustible. El error asociado a la incorrecta proporción de los tipos de combustibles no superó en ningún caso el 8%. La mayoría de las áreas clasificadas erróneamente se localizaron dentro de zonas boscosas (masas mixtas de laurisilva, pinares con restos de corta y masas uniformes de castaño, pino canario y brezo), donde las firmas espectrales no resultaron ser en algunos casos suficientemente diferenciables para permitir la discriminación entre ellos.
5. Se ha evaluado la viabilidad de combinar imágenes multiespectrales de muy alta resolución espacial (del sensor WV-2), con datos LiDAR discretos de baja densidad en un entorno OBIA, para obtener mapas de combustibles forestales en las Islas Canarias. Para ello, se generaron 4 OBIA independientes, utilizando tres imágenes fusionadas (métodos IS, PCA y MNF) y la imagen WV-2 sin fusionar. La exactitud global de los mapas obtenidos fue superior al 75% para todos los casos. Estos resultados corroboran la capacidad de OBIA para discriminar elementos complejos, como los tipos de combustibles, en imágenes de elevada heterogeneidad espectral.
6. Todos los mapas de combustibles obtenidos a partir de las fusiones de la imagen WV-2 y los datos LiDAR, alcanzaron una exactitud global significativamente mayor que el mapa generado a partir de la imagen WV-2 sola. La incorporación de la información LiDAR a los OBIA permitió mejoras en la exactitud global mayores al 10% en todos los casos. Estos resultados son especialmente relevantes, teniendo en cuenta la escasa densidad de puntos de los datos LiDAR.

7. Los tres métodos de fusión utilizados en este estudio (IS, PCA y MNF) proporcionaron resultados similares, no habiéndose detectado diferencias significativas en los valores de exactitud global. Cualquiera de ellos podría ser usado con un error esperable en torno al 15%. De cara a la selección de uno u otro, se propone la evaluación de los componentes del error por cantidad, o de ubicación, y su adecuación a los objetivos específicos de cada estudio.

8. Uno de los principales factores limitantes para obtener cartografía de combustibles en las Islas Canarias, es la gran complejidad orográfica de la zona y la presencia de áreas con cubiertas forestales densas y de más de 30 m de altura. Estas características hacen disminuir la eficacia de los datos LiDAR para representar la estructura vertical de la vegetación, especialmente al trabajar con datos de baja densidad de puntos. Además, la presencia de barrancos y relieves muy pronunciados genera efectos de sombra difíciles de corregir en las imágenes ópticas, afectando a la corrección geométrica de la imagen. Todo esto afecta negativamente en la identificación de los modelos de combustibles. No obstante, los resultados de este estudio demuestran que es posible minimizar estas limitaciones mediante el uso combinado de OBIA y la fusión de datos WV-2 y LiDAR. Esta metodología podría ser extrapolada para generar, de una forma sencilla y con un bajo costo asociado, todos los mapas de combustibles de las zonas con cobertura forestal de las islas Canarias.

Referencias

-
- Abrams, M. (2000). *The Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER): data products for the high spatial resolution imager on NASA's Terra platform*. International Journal of Remote Sensing, 21, pp. 847-859.
- Abrams, M.; Hook, S.; Ramachandran, B. (2002). *ASTER User Handbook, v2: Advanced Spaceborne Thermal Emission and Reflection Radiometer*. Jet Propulsion Laboratory, Pasadena.
- Adams, J.L. (1965). *Fuel Classification and Mapping for Forest Fire Control*. University of California, Berkeley.
- ADCIF (2002). *Los incendios forestales en España. Decenio 1991-2000*. Área de Defensa Contra Incendios Forestales, Ministerio de Medio Ambiente, Enero 2002, pp. 80. Accesible online <http://goo.gl/PTsgG>, último acceso octubre 2015.
- ADCIF (2012). *Los incendios forestales en España. Decenio 2001-2010*. Área de Defensa Contra Incendios Forestales, Ministerio de Agricultura, Alimentación y Medio Ambiente, Diciembre 2012, pp. 138. Accesible online <http://goo.gl/lvtEv>, último acceso octubre 2015.
- ADCIF (2013). *Los incendios forestales en España. Año 2011*. Área de Defensa Contra Incendios Forestales, Ministerio de Agricultura, Alimentación y Medio Ambiente, Junio 2013, pp. 82. Accesible online <http://goo.gl/y2UETk>, último acceso octubre 2015.
- ADCIF (2014). *Los incendios forestales en España. Año 2012*. Área de Defensa Contra Incendios Forestales, Ministerio de Agricultura, Alimentación y Medio Ambiente, Junio 2014, pp. 138. Accesible online <http://goo.gl/SBwnGn>, último acceso octubre 2015.
- Albini, F.A. (1976). *Estimating wildfire behavior and effects*. Rep. No. GTR INT-30. USDA, Forest Service, Intermountain Forest and Range Experiment Station, Ogden, UT. Accesible online <http://goo.gl/9gD4De>, último acceso octubre 2015.
- Alonso-Benito, A.; Hernandez-Leal, P.A.; Gonzalez-Calvo, A.; Arbelo, M.; Barreto, A. (2008). *Analysis of Different Methods for Burnt Area Estimation using Remote Sensing and Ground Truth Data*. In

- Geoscience and Remote Sensing Symposium, 2008. IGARSS 2008. IEEE International , vol.3, no., pp.III - 828-III - 831, 7-11 July 2008.
- Alonso-Benito, A.; Arroyo L.A.; Arbelo, M.; Hernández-Leal, P.; González-Calvo, A. (2013). *Pixel and object-based classification approaches for mapping forest fuel types in Tenerife Island from ASTER data*. International Journal of Wildland Fire, Volume 22 (Issue 3), pp 306-317. <http://dx.doi.org/10.1071/WF11068>.
- Alonso-Benito, A.; Arroyo, L.A.; Arbelo, M.; Hernández-Leal, P. (2016). *Fusion of WorldView-2 and LiDAR data to Map Fuel Types in Canary Islands*. Remote Sensing, 2016, 8, 669, 18 pp. [doi: 10.3390/rs8080669](https://doi.org/10.3390/rs8080669).
- Andersen, H.E.; McGaughey, R.J.; Reutebuch, S.E. (2005). *Estimating forest canopy fuel parameter using LiDAR data*. Remote Sensing of Environment 94: 441-449.
- Andrews, P.L.; Queen, L.P. (2001). *Fire modeling and information system technology*. International Journal of Wildland Fire 10(4), 343–352.
- Andrews, Patricia L. (2009). *BehavePlus fire modeling system, version 5.0: variables*. General Technical Report RMRS-GTR-213WWW Revised. Fort Collins, CO: USDA Forest Service, Rocky Mountain Research Station, pp. 111. Accesible online <http://goo.gl/hZUv4r>, último acceso octubre 2015.
- Arco, M.D.; Wildpret, W.; Pérez de Paz, P.L.; Rodríguez, O.; Acebes, J.R.; García, A.; Martín, V.E.; Reyes, J.A.; Salas, M.; Díaz, M.A.; Bermejo, J.A.; González, R.; Cabrera, M.V.; García, S. (2003). *Cartografía 1:25000 de la Vegetación Canaria*. GRAFCAN S.A. (Santa Cruz de Tenerife, Spain).
- Arroyo, L.A.; Healey, S.P.; Cohen, W.B.; Cocero, D.; Manzanera, J.A. (2006). *Using object-oriented classification and high-resolution imagery to map fuel types in a Mediterranean region*. Journal of Geophysical Research 111, G04S04.
- Arroyo, L.A., Pascual, C., Manzanera, J.A. (2008). *Fire models and methods to map fuel types: The role of remote sensing*. Forest Ecology and Management 256(6), pp. 1239-1252.

-
- Arroyo, L.A.; Johansen, K.; Armston, J.; Phinn, S. (2010). *Integration of LiDAR and QuickBird imagery for mapping riparian biophysical parameters and land cover types in Australian tropical savannas*. *Forest Ecol. Manage.*, 259: 598-606. DOI: 10.1016/j.foreco.2009.11.018.
- Ayanzi, J.S.M.; Ravail, N.; Kelha, V.; Ollero, A. (2005). *Active Fire Detection for Fire Emergency Management: Potential and Limitations for the Operational Use of Remote Sensing*. *Natural Hazards*, 35, pp. 361–376.
- Baatz, M.; Schäpe, A. (2000). *Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation*. In: XII Angewandte Geographische Informationsverarbeitung, Wichmann-Verlag, Heidelberg, 2000.
- Bagan, H.; Wang, Q.; Watanabe, M.; Kameyama, S.; Bao, Y. (2008). *Land-cover classification using ASTER multi-band combinations based on wavelet fusion and SOM Neural Network*. *Photogrammetric Engineering & Remote Sensing* 74(3), pp. 333-342.
- Bajocco, S.; Dragoz, E.; Gitas, I.; Smiraglia, D.; Salvati, L.; Ricotta, C. (2015). *Mapping Forest Fuels through Vegetation Phenology: The Role of Coarse-Resolution Satellite Time-Series*. *PLoS ONE* 10(3): e0119811. Accesible online <http://goo.gl/yiq6Lz>, último acceso octubre 2015.
- Benz, U.C.; Hoffmann, P.; Willhauck, G.; Longenfelder, I.; Heynen, M. (2004). *Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information*. *ISPRS Journal of Photogrammetry & Remote Sensing*, Volume 58, Issue 3-4, 239-258. <http://dx.doi.org/10.1016/j.isprsjprs.2003.10.002>.
- Berk, A.; Adler-Golden, S.M.; Ratkowski, A.J.; Felde, G.W.; Anderson, G.P.; Hoke, M.L.; Cooley, T.; Chetwynd, J.H.; Gardner, J.A.; Matthew, M.W.; Bernstein, L.S.; Acharya, P.K.; Miller, D.; Lewis, P. (2002). *Exploiting MODTRAN radiaton transport for atmospheric correction: The FLAASH algorithm*. Information Fusion, 2002. Proceedings of the Fifth International Conference on, Annapolis, MD, USA, 2002, pp. 798-803 vol.2. [doi: 10.1109/ICIF.2002.1020888](http://dx.doi.org/10.1109/ICIF.2002.1020888).
-

- Blaschke, T. (2010). *Object based image analysis for remote sensing*. ISPRS Journal of Photogrammetry and Remote Sensing 65(1), pp. 2-16.
- Bond, W.J.; Van Wilgen, B.W. (1996). *Surviving fires-vegetative and reproductive responses*. Chapter 3 *Fire and plants* (Volumen 14 de Population and Community Biology Series), pp 34-51. Editor: Springer Science & Business Media.
- Burai, P.; Deák, B.; Valkó, O.; Tomor, T. (2015). *Classification of herbaceous vegetation using Airborne Hyperspectral Imagery*. Remote Sensing, 2015, 7(2) 2046-2066. [doi: 10.3390/rs70202046](https://doi.org/10.3390/rs70202046)
- Burgan, R.E.; Klaver, R.W.; Klaver, J.M. (1998). *Fuel model and fire potential from satellite and surface observations*. International Journal of Wildland Fire 8(3), 159–170.
- Chuvieco, E.,; Congalton, R.G. (1989). *Application of remote sensing and geographic systems to forest fire hazard mapping*. Remote Sensing of Environment, 29, 147-159.
- Chuvieco, E. (2002). *Teledetección Ambiental*. Editorial Ariel, España, 2002, 584 páginas.
- Coluzzi, R.; Didonna, I.; Lanorte, A.; Lasaponara, R. (2007). *Mapping forest fuel types by using satellite ASTER data and neural nets*. Proceedings of the Society for Photo-Instrumentation Engineers 6742, 67420T.
- Congalton, R.G. (1991). *A review of assessing the accuracy of classifications of remotely sensed data*. Remote Sensing of Environment, 37, pp. 35-46.
- Congalton, R.G.; Green, K. (2009). *Assessing the accuracy or remotely sensed data: principles and practices*. 2nd Edition, Boca Raton, FL, CRC Press.
- Dalponte, M.; Bruzzone, L.; Gianelle, D. (2008). *Fusion of hyperspectral and LIDAR remote sensing data for classification of complex forest areas*. IEEE Transactions on Geoscience and Remote Sensing, 46(5), pp. 1416–1427.
- Dalponte, M.; Bruzzone, L.; Gianelle, D. (2012). *Tree species classification in the Southern Alps based on the fusion of very high geometrical*

- resolution multispectral/hyperspectral images and LiDAR data. Remote Sens. Environ.*, 123: 258-270. DOI: 10.1016/j.rse.2012.03.013.
- De Santis, A.; Chuvieco, E. (2009). *GeoCBI: A modified version of the Composite Burn Index for the initial assessment of the short-term burn severity from remotely sensed data. Remote Sens. Environ.* 113: 554–562.
- Deeming, J.E.; Lancaster, J.W.; Fosberg, M.A.; Furman, R.W.; Schroeder, M.J. (1972). *The National Fire-Danger Rating System*. Rep. No. RM-84. USDA Forest Service, Ogden, UT.
- Deeming, J.E.; Burgan, R.E.; Cohen, J.D. (1977). *The National Fire Danger Rating System*. Rep. No. GTR INT-39. USDA Forest Service, Intermountain Forest and Range Experiment Station, Ogden, UT.
- Erdody T.; Moskal, L.M. (2010). *Fusion of LiDAR and Imagery for Estimating Forest Canopy Fuels. Remote Sensing of Environment*, 114(4); 725-737.
- Falkowski, M.; Gessler, P.; Morgan, P.; Hudak, A.; Smith, A. (2005). *Characterizing and mapping forest fire fuels using ASTER imagery and gradient modeling. Forest Ecology and Management* 217, 129–146.
- Finney, M.A. (2004). *FARSITE: Fire Area Simulator—model development and evaluation*. Research Paper RMRS-RP-4 Revised. Ogden, UT: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station, pp. 47. Accesible online <http://goo.gl/WplQb7>, último acceso octubre 2015.
- Finney, M.A. (2006). *An overview of FlamMap fire modeling capabilities*. In: Fuels management—how to measure success: conference proceedings. 2006 March 28-30; Portland, Oregon. Proceedings RMRS-P-41. Fort Collins, CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station: 213-220. Accesible online <http://goo.gl/ARqhtD>, último acceso octubre 2015.
- Finney, M.A. (1998). *FARSITE: Fire Area Simulator-Model Development and Evaluation*. USDA Forest Service Rocky Mountain Research

- Station (Fort Collins, CO) 52 pp. Research Paper RMRS-RP-4 Revised. Accesible online <http://goo.gl/2Zbrjv>, último acceso octubre 2015.
- Ferraz, A.; Bretar, F.; Jacquemoud, S.; Gonçalves, G. (2009). *The role of LiDAR systems in fuel mapping*. Instituto de Engenharia de Sistemas e Computadores de Coimbra, Research Report Nº 13, pp. 37. Accesible online <http://goo.gl/Drd7VS>, último acceso octubre 2015.
- Forestry Canada (1992). *Development and structure of the Canadian Forest Fire Behavior Prediction System*. Rep. No. ST-X-3. Forestry Canada, Ottawa. Accesible online <http://goo.gl/d7Bwus>, último acceso octubre 2015.
- Food and Agriculture Organization (FAO) (2012). *About the Global Fire Information Management System (GFIMS)*. Disponible en <http://www.fao.org/nr/gfims/about/en/>, ultimo acceso octubre 2015.
- Foody, G.M. (2004). *Thematic map comparison: evaluating the statistical significance of differences in classification accuracy*. *Photogrammetric Engineering and Remote Sensing*, 70, pp. 627-633.
- Foody, G.M. (2009). *Sample size determination for image classification accuracy assessment and comparison*. *International Journal of Remote Sensing*, Volume 30, Issue 20, pp. 5273-5297. DOI: 10.1080/01431160903130937.
- GAO (2003). *Geospatial information technologies hold promise for wildland fire management, but challenges remain*. United States General Accounting Office. Report to Congressional Requesters GAO-03-1047.
- Gao, B.C.; Goetz, A.F.H. (1990). *Column atmospheric water vapor and vegetation liquid water retrievals from Airborne Imaging Spectrometer data*. *Journal of Geophysical Research*, Volume 95, Issue D4, 3549-3564. [doi: 10.1029/JD095iD04p03549](https://doi.org/10.1029/JD095iD04p03549).
- García, M.; Riaño, D.; Chuvieco, E.; Salas, J.; Mark Danson, F. (2011). *Multispectral and LiDAR data fusión for fuel type mapping using*

-
- Support Vector Machine and decision rules. *Remote Sensing of Environment*, 115 (6), pp. 1369-1379.
- Ghosh, A.; Fassnacht, F.E.; Joshi, P.K.; Koch, B.(2014). *A framework for mapping tree species combining hyperspectral and LiDAR data: Role of selected classifiers and sensor across three spatial scales*. *Int. J. Appl. Earth Obs. Geoinf.* 2014, 26, pp. 49–63.
- Giglio, L.; Descloitres, J.; Justice, C.O.; Kaufman, Y.J. (2003). *An Enhanced Contextual Fire Detection Algorithm for MODIS*. *Remote Sensing of Environment*, Volume 87, Issues 2–3, 15 October 2003, Pages 273-282.
- Giglio, L.; Randerson, J.T.; van der Werf, G.R. (2013). *Analysis of daily, monthly, and annual burned area using the fourth-generation global fire emissions database (GFED4)* *J. Geophys. Res. Biogeosci.*, 118, 317–328, doi:10.1002/jgrg.20042.
- Green, A.A.; Berman, M.; Switzer, P.; Craig, M.D. (1988). *A Transform for Ordering Multispectral Data in terms of Image Quality with Implications for Noise Removal*. *IEEE Trans. Geosci. Remote Sens.*, vol. 26, No. 1, pp. 65-74.
- Goldammer, J.G. (2006). *Fire ecology of the recent Anthropocene*. In Ehlers E, Kraft T (eds) *Earth system science in the Anthropocene*. Springer. Berlin/Heidelberg/New York, pp. 63-85.
- Hagner, O.; Reese, H. (2007). *A method for calibrated maximum likelihood classification of forest types*. *Remote Sensing of Environment* 110(4), pp. 438-444.
- Hermosilla, T.; Ruiz, L.A.; Kazakova, A.N.; Coops N.C.; Moskal, L.M. (2014). *Estimation of forest structure and canopy fuel parameters from small-footprint full-waveform LiDAR data*. *International Journal of Wildland Fire* 23(2), 224–233. <http://dx.doi.org/10.1071/WF13086>
- Hernández-Leal, P.; Arbelo, M.; González-Calvo, A. (2006). *Fire risk assessment using satellite data*. *Advances in Space Research*, Vol. 37, Issue 4, 2006, pp. 741-746.
- Hernández-Leal, P. A.; González-Calvo, A.; Arbelo, M.; Barreto, A.; Alonso-Benito, A. (2008). *Synergy of GIS and Remote Sensing data*
-

- in forest fire danger modeling*. Special Issue on Wildland Fires and Biomass Burning. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing (IEEE J-STARS). Volume: 1, Issue: 4. Pp 240 – 247.
- Holmgren, J.; Persson, A. (2004). *Identifying species of individual trees using airborne laser scanner*. Remote Sensing of Environment 90: 415–423.
- Huang, C.; Davis, L.S.; Townshend, J.R.G. (2002). *An assessment of support vector machines for land cover classification*. International Journal of Remote Sensing 23(4), pp. 725-749.
- Huang, X.; Zhang, L. (2010). *Comparison of vector stacking, multi-SVMs fuzzy output, and multi-SVMs voting methods for multiscale VHR urban mapping*. IEEE Geoscience and Remote Sensing Letters, 2010, 7(2): 262–266.
- Huang, X.; Zhang, L.; Gong, W. (2011). *Information fusion of aerial images and LIDAR data in urban areas: vector stacking, re-classification, and post-processing approaches*.
- Huang, X.; Zhang, L. (2012). *A multilevel decision fusion approach for urban mapping using very-high-resolution multi/hyper-spectral imagery*. International Journal of Remote Sensing, 2012, 33(11): 3354-3372.
- Huete, A.R. (1989). *Soil influences in remotely-sensed vegetation canopy spectra*. In 'Theory and Applications of Optical Remote Sensing.' Ed. G Asrar pp. 107-141. (John Wiley & Sons: New York).
- Hyyppa, J.; Hyyppa, H.; Leckie, D.; Gougeon, F.; Yu, X.; Maltamo, M. (2008). *Review of methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests*. International Journal of Remote Sensing 29, 1339–1366.
- Jakubowski, M.K.; Li, W.; Guo, Q.; Kelly, M. (2013). *Delineating individual trees from LiDAR data: a comparison of vector and raster based segmentation approaches*. Remote Sens. 2013, 5(9), 4163-4186. Accesible online <http://goo.gl/7dlHyc>, último acceso octubre 2015.

-
- Jensen, J.R. (2005). *Introductory digital image processing: a remote sensing perspective*. Upper Saddle River, N.J: Prentice Hall.
- Jiang, Z.; Huete, A.R.; Didan, K.; Miura, T. (2008). *Development of a two-band enhanced vegetation index without a blue band*. *Remote Sensing of Environment* 112(10), pp. 3833-3845.
- Justice, C.O.; Townshend, J.R.G.; Vermote, E.F.; Masuoka, E.; Wolfe, R.E.; Saleous, N.; Roy, D.P.; Morisette, J.T. (2002). *An overview of MODIS land data processing and product status*. *Remote Sensing of Environment*, 83, 244 – 262.
- JRC (Joint Research Centre) (2014). *Forest fires in Europe, Middle East and North Africa 2013*. Joint report of JRC and Directorate-General Environment EUR 25483 EN. Accesible online <http://goo.gl/pVmspW>, ultimo acceso octubre 2015.
- Kaufman, Y.J.; Justice, C.O.; Flynn, L.P.; Kendall, J.D.; Prins, E.M.; Giglio, L.; Ward, D.E.; Menzel, W.P.; Setzer, A.W. (1998). *Potential global fire monitoring from EOS-MODIS*. *J. Geophys. Res.*, 103(D24), pp. 32315 – 32338.
- Kavzoglu, T.; Colkesen, I. (2009). *A kernel functions analysis for support vector machines for land cover classification*. *International Journal of Applied Earth Observation and Geoinformation*, 11, pp. 352-359.
- Keane, R.E.; Burgan, R.E.; Wagtendonk, J.V. (2001). *Mapping wildland fuels for fire management across multiple scales: Integrating remote sensing, GIS, and biophysical modeling*. *International Journal of Wildland Fire*, 10(4), pp. 301–319.
- Keane, R.E.; Reeves, M. (2012). *Use of expert knowledge to develop fuel maps for Wildland fire management [chapter 11]*. In: Perera, A.H.; Drew, C.A.; Johnson, C.J., eds. *Expert knowledge and its application in landscape ecology*. Springer New York. Pp. 211-228.
- Keane, R.E.; Reeves, M. (2012). *Use of expert knowledge to develop fuel maps for wildland fire management*. In *Expert Knowledge and Its Application in Landscape Ecology*. A.H. Perera, A. Drew, and C.J. Johnson (eds.), Springer Science+Business Media, New York, pp. 211-228.
-

- Keane, R.E. (2013). *Describing Wildland surface fuel loading for fire management: a review of approaches, methods and systems*. International Journal of Wildland Fire, 22(1), pp. 51-62.
- Kourtz, P.H. (1977). *An application of Landsat digital technology to forest fire fuel type mapping*. 11th International Symposium on Remote Sensing of Environment. Ann Arbor: 1111-1115.
- Lasaponara, R.; Lanorte, A. (2007). *Remotely sensed characterization of forest fuel types by using satellite ASTER data*. International Journal of Applied Earth Observation and Geoinformation 9, 225–234.
- Leblon, B.; Bourgeau-Chavez, L.; San-Miguel-Ayanz, J. (2012). *Use of remote sensing in wildfire management*. Sime Curkovic (ed.) Sustainable Development - Authoritative and Leading Edge Content for Environmental Management, cap. 3, pp. 55-82. Accesible online <http://goo.gl/KnyT1u>, último acceso octubre 2015.
- Leverington, D.W.; Schindler, M. (2016). *Detection and mapping of Black Rock coatings using Hyperion images: Sudbury, Ontario, Canada*. Remote Sensing, 2016, 8(4) 301. 01; doi: [10.3390/rs8040301](https://doi.org/10.3390/rs8040301).
- Li, J.; Carlson, B.E.; Laci, A.A. (2014). *Application of spectral analysis techniques in the inter-comparison of aerosol data, Part 4: Synthesized analysis of multisensor satellite and ground-based AOD measurements using combined maximum covariance analysis*. Atmos. Meas. Tech., 7, pp. 2531-2549, doi:10.5194/amt-7-2531-2014.
- Li, Z.; Kaufman, Y.J.; Ithoku, C.; Fraser, R.; Trishchenko, A.; Giglio, L.; Jin, J.; Yu, X. (2001). *A review of AVHRR-based active fire detection algorithms: Principles, limitations, and recommendations, in Global and Regional Vegetation Fire Monitoring From Space: Planning and Coordinated International Effort*. edited by F. Ahern, J. G. Goldammer, and C. Justice, pp. 199 – 225, SPB Acad., The Hague, 2001.
- Lillesand, T.; Kiefer, R.W.; Chipman, J.W. (2004). *Remote Sensing and Image Interpretation*. Fifth Edition, International Edition, John Wiley & Sons, New York, 2004.

- Liu, C.; Frazierb, P.; Kuma, L. (2007). *Comparative assessment of the measures of thematic classification accuracy*. Remote Sensing of Environment, 107, pp. 606-616.
- Lorenzo Gil, A.; Núñez-Casillas, L.; Isenburg, M.; Alonso-Benito, A.; Rodrigo Bello, J.L.; Arbelo, M. (2013). *A comparison between LiDAR and photogrammetry digital terrain models in a forest area on Tenerife Island*. Canadian Journal of Remote Sensing, 2013, 39:396-409, [DOI: 10.5589/m13-047](https://doi.org/10.5589/m13-047).
- Lu, D.; Weng, Q. (2007). *A survey of image classification methods and techniques for improving classification performance*. International Journal of Remote Sensing. 2007, 28(5), pp. 823–870.
- Lucieer, A. (2004). *Uncertainties in segmentation and their visualization*. Tesis Doctoral, Universiteit Utrecht.
- Mallinis G.; Koutsias, N. (2012). *Comparing ten classification methods for burned area mapping in a Mediterranean environment using Landsat TM satellite data*. International Journal of Remote Sensing, Vol, 33m No. 14, pp. 4408-4433.
- Mallinis, G.; Galidaki, G.; Gitas, I. (2014). *A Comparative Analysis of EO-1 Hyperion, Quickbird and Landsat TM Imagery for Fuel Type Mapping of a Typical Mediterranean Landscape*. Remote Sens. 2014, 6, 1684-1704. Accesible online <http://goo.gl/7Vbrmi>, último acceso octubre 2015.
- Malone S.L.; Kobziar L.N.; Staudhammer C.L.; Abd-Elrahaman A. (2011). *Modeling relationships among 217 fires using remote sensing of burn severity in southern Pine Forests*. Remote Sensing. 2011; 3(9):2005-2028.
- Maselli, F.; Rodolfi, A.; Bottai, L.; Romanelli, S.; Conese, C. (2000). *Classification of Mediterranean vegetation by TM and ancillary data for the evaluation of fire risk*. International Journal of Remote Sensing, Vol. 21, No 17, pp. 3303-3313.
- MdMA (Ministerio de Medio Ambiente) (2002). *Mapa forestal de España a escala 1:50.000 de la provincia de Santa Cruz de Tenerife*. Trabajos de campo realizados en el año 2.002 con soporte de ortofoto digital procedente de la Comunidad Autónoma de

- Canarias. Ed. MdMA Organismo Autónomo de Parques Nacionales, Pesca y Alimentación). Soporte CD-Rom.
- Mercier, G.; Lennon, M. (2003). *Support vector machines for hyperspectral image classification with spectral-based kernels*. In 'Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International', 21-25 July 2003 2003, Toulouse, France, pp. 288-290 vol.1.
- Merrill, D.F.; Alexander, M.E. (1987). *Glossary of Forest Fire Management Terms, fourth edn*. National Research Council of Canada, Canadian Committee on Forest Fire Management, Ottawa, Ontario.
- Michalek, J.L.; French, N.H.F.; Kasischke, E.S.; Johnson, R.D.; Colwell, J.E. (2000). *Using Landsat TM data to estimate carbon release from burned biomass in an Alaskan spruce forest complex*. International Journal of Remote Sensing, 2000, Vol. 21, Nº 2, pp. 323-338.
- Miller, J.D.; Knapp, E.E.; Key, C.H.; Skinner, C.N.; Isbell, C.J. Creasy, R.M.; Sherlock, J.W. (2009). *Calibration and validation of the relative difference Normalized Burn Ratio (RdNBR) to three measure of fire severity in the Sierra Nevada and Klamath Mountains, California, USA*. Remote Sensing of Environment, 113 (2009), pp. 645-656.
- Moreno-Ruíz, J.A.; Riaño, D.; Arbelo, M.; French, N.H.F.; Ustin, S.L.; Whiting, M.L. (2012). *Burned area mapping time series in Canada (1984-1999) from NOAA-AVHRR LTDR: A comparison with other remote sensing products and fire perimeters*. Remote Sensing of Environment, Vol 117, pp. 407-414.
- Moreno-Ruiz, J.; García-Lázaro, J.R.; Águila-Cano, I.; Hernández-Leal, P. (2014). *Burned area mapping in the North American boreal forest using Terra-MODIS LTDR (2001-2011): A comparison with the MCD45A1, MCD64A1 and BA GEOLAND-2 products*. Remote Sensing, 2014, 6(1), pp. 815-840.
- Morsdorf, F.; Meier, E.; Koetz, B.; Itten, K.I.; Dobbertin, M.; Allgower, B. (2004). *LIDAR-based geometric reconstruction of boreal type*

- forest stands at single tree level for forest and wildland fire management*. Remote Sensing of Environment, 92(3), 353–362.
- Mouillot, F.; Field, C.B. (2005). *Fire history and the global carbon budget: A 1° × 1° fire history reconstruction for the 20th century*. Global Change Biol., 11, pp. 398–420.
- Mutlu, M.; Popescu, S.C.; Stripling, C.; Spencer, T. (2008). *Mapping surface fuel models using lidar and multispectral data fusion for fire behavior*. Remote Sensing of Environment 112, 274–285.
- Núñez-Casillas, L.; García-Lozano, J.R.; Moreno-Ruíz, J.A.; Arbelo, M. (2013). *A comparative analysis of burned area datasets in Canadian Boreal Forests in 2000*. The Scientific World Journal, Vol, 2013, pps. 13.
- Olofsson, P.; Foody, G.M.; Herold, M.; Stehmand, S.V.; Woodcock, C.E.; Wulder, M.A. (2014). *Good practices for estimating area and assessing accuracy of land change*. Remote Sensing of Environment, 148, pp. 42-57.
- Ortuño Pérez, S.F.; Fernández-Cavada Labat, J.L. (2007). *Evaluación Económica de los Daños por Incendios Forestales*. En los proceedings 4th International Wildland Fire, 13-17 may, Sevilla, España. Accesible online <http://goo.gl/QIKxr6>, último acceso octubre 2015.
- Pal, M. (2009). *Kernel methods in remote sensing: a review*. ISH Journal of Hydraulic Engineering 01/2009, 15(1), pp. 194-215. DOI: 10.1080/09715010.2009.10514975.
- Pal, N.R.; Bhandari, D. (1992). *On Object Background Classification*. International Journal of Systems Science, 23, pp. 1903-1920. doi: <http://dx.doi.org/10.1080/00207729208949429>
- Pausas, J.G. (2004). *Changes in fire and climate in the eastern Iberian Peninsula (Mediterranean basin)*. Climatic Change 63: 337-350.
- Pedergrnana, M.; Marpu, P.R.; Dalla Mura, M.; Benediktsson, J.A.; Bruzzone, L. (2011). *Fusion of hyper-spectral and LiDAR data using morphological profiles*. Image and Signal Processing for Remote Sensing XVII, Proc. SPIE, Vol. 8180.

- Pereira, J.M.C. (1999). *A comparative evaluation of NOAA/AVHRR vegetation indexes for burned surface detection and mapping*. In Geoscience and Remote Sensing, IEEE Transactions on , vol.37, no.1, pp.217-226.
- Pesonen, A.; Maltamo, M.; Eerikäinen, K.; Packalèn, P. (2008). *Airborne laser scanning based prediction of coarse woody debris volumes in a conservation area*. Forest Ecology and Management 255, 3288–3296.
- Peterson, S.H.; Franklín, J.; Roberts, D.A.; van Wagtendonk, J.W. (2013). *Mapping fuels in Yosemite National Park*. Canadian Journal of Forest Research, 2013, 43(1): 7-17.
- Piñol, J.; Terradas, J; Lloret, F. (1998). *Climate warming, wildfire hazard, and wildfire occurrence in coastal eastern Spain*. Climatic Change 38: 345-357.
- Prometheus (2000). *Management techniques for optimization of suppression and minimization of wildfire effects*. System validation. European Commission, DG XII, ENVIR & CLIMATE, ENV4-CT98-0716, 1998-2000 (Ed. CnEVE European Commission).
- Pontius Jr, R.G. (2000). *Quantification error versus location error in comparison of categorical maps*. Photogrammetric Engineering and Remote Sensing, 66, pp. 1011-1016.
- Pontius, R.G.; Millones, M. (2011). *Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment*. International Journal of Remote Sensing 32(15), pp. 4407-4429.
- Pontius Jr, R.G.; Santacruz, A. (2014). *Quantity, Exchange, and Shift Components of Difference in a Square Contingency Table*. International Journal of Remote Sensing 35(21): 7543-7554.
- Popescu, S.C.; Zhao, K. (2008). *A voxel-based LiDAR method for estimating crown base height for deciduous and pine trees*. Remote Sensing of Environment 112: 767–781.
- Pyne, S.J. (2001). *Year of the fires: The story of the great fires of 1910*. New York: Viking Penguin Books. 322 pp.

- Quatrini, A.; Barbati, A.; Piermaria, C.; Marchetti, M.; Bottalico, F.; Travaglini, D. (2014). *Are low-density airborne lidar data suitable to map Mediterranean fuel types?* In proceedings ForestSAT2014 Open Conference System, Riva de Garda, Italy, July 2014. Accessible online <http://goo.gl/9Suxuh>, último acceso octubre 2015.
- Qi, J.; Chehbouni, A.; Huete, A.R.; Kerr, Y.H.; Sorooshian, S. (1994). *A modified soil adjusted vegetation index*. Remote Sensing of Environment 48(2), pp. 119-126.
- Riaño, D.; Chuvieco, E.; Salas, J.; Palacios-Orueta, A.; Bastarrika, A. (2002). *Generation of fuel type maps from Landsat TM images and ancillary data in Mediterranean ecosystems*. Canadian Journal of Forest Research 32, 1301–1315.
- Riaño, D.; Meier, E.; Allgower, B.; Chuvieco, E.; Ustin, S.L. (2003). *Modeling airborne laser scanning data for the spatial generation of critical forest parameters in fire behaviour modeling*. Remote Sensing of Environment 86: 177–186.
- Riaño, D.; Chuvieco, E.; Condes, S.; González-Matesanz, J.; Ustin, S. (2004). *Generation of crown bulk density for Pinus sylvestris L. from LiDAR*. Remote Sensing of Environment, 92:345-352.
- Richardson, J.; Moskal, L. M.; Kim, S. (2009). *Modeling Approaches to Estimate Effective Leaf Area Index from Aerial Discrete-Return LIDAR*. Agricultural and Forest Meteorology 149, 1152-1160.
- Rothermel R.C. (1972). *A mathematical model for predicting fire spread in wildland fuels*. USDA Intermountain Forest and Range Experiment Station Res. Pap. INT-115 (Ogden, UT). 40 pp. Accessible online <http://goo.gl/WgxxYH>, último acceso octubre 2015.
- Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W. (1973). *Monitoring vegetation systems in the Great Plains with ERTS*. In 3rd ERTS Symposium, NASA SP-351 I, pp. 309–317.
- Roy, D.P.; Boschetti, L.; Trigg, S.N. (2006). *Remote sensing of fire severity: Assessing the performance of the Normalized Burn Ratio*. IEEE

- Geoscience and Remote Sensing Letters, Vol. 3, No. 1, pp. 112-116.
- Rumelhart, D.E.; Hinton, D.E.; Williams, R.J. (1986). *Learning Internal Representations by Error Propagation*. In 'Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. Vol. 1.' (Eds DE Rumelhart and JL Mc-Clelland) pp. 318-364. (MIT Press: Cambridge, MA).
- Salas, F. J. y Chuvieco, E. (1995). *Aplicación de imágenes Landsat-TM a la cartografía de modelos combustibles*. *Revista de Teledetección* 5: 18-28.
- San-Miguel-Ayanz, J.; Moreno, J.M.; Camia, A. (2013). *Analysis of large fires in European Mediterranean landscapes: Lessons learned and perspectives*. *Forest Ecology and Management*, Volume 294, 15 April 2013, Pages 11-22.
- Scott, J.H.; Reinhardt, E.D. (2001). *Assessing crown fire potential by linking models of surface and crown fire behavior*. Res. Pap. RMRS-RP-29. Fort Collins, CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. Pp. 59.
- Scott, J.H.; Burgan, R.E. (2005). *Standard fire behavior fuel models. A comprehensive set for use with Rothermel's surface fire spread model*. USDA Forest Service Rocky Mountain Research Station (Fort Collins, CO) 72 pp. Accesible online <http://goo.gl/R3LkJa>, último acceso octubre 2015.
- Simon, M.; Plummer, S.; Fierens, F.; Hoelzemann, J.J.; Arino, O. (2004). *Burnt area detection at global scale using ATSR-2: The GLOBSCAR products and their qualification*. *J. Geophys. Res.*, 109, D14S02.
- Smith A.M.S. (2007). *How to convert ASTER radiance values to reflectance*. (University of Idaho: Moscow, ID) Available at <https://goo.gl/VUPJgW> [último acceso septiembre 2016].
- Smith, L.I. (2002). *A tutorial on principal components analysis*. Accesible en <http://goo.gl/fqufn>. Último acceso febrero de 2016.
- Stavrakoudis, D.G.; Dragozi, E.; Gitas, I.Z.; Karydas, C. (2014). *Decision fusion based on hyperspectral and multispectral satellite imagery for accurate forest species mapping*. *Remote Sensing* 2014, 6, pp.

-
- 6897-6928. *International Journal of Remote Sensing*, 2011, 32(1): 69–84.
- Swatantran, A.; Dubayah, R.; Roberts, D.; Hofton, M.; Blair, J.B. (2011). *Mapping biomass and stress in the Sierra Nevada using LiDAR and hyperspectral data fusion*. *Remote Sensing of Environment* 115(2011), pp. 2917-2930.
- Szuster, B.W.; Chen, Q.; Borger, M. (2011). *A comparison of classification techniques to support land cover and land use analysis in tropical coastal zones*. *Applied Geography* 31 (2011), pp. 525-532.
- Tanase, M.A.; Gitas, I.Z. (2008). *An examination of the effects of spatial resolution and image analysis technique on indirect fuel mapping*. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 1, 220–229.
- Tansey, K.; Grégoire, J.M.; Defourny, P.; Leigh, R.; Pekel, J.F.; van Bogaert, E.; Bartholomé, E. (2008). *A new, global, multi-annual (2000–2007) burnt area product at 1 km resolution*. *Geophys. Res. Lett.*, 35, L01401.
- Teillet, P.M.; Guindon, B.; Goodenough, D.G. (1982). *On the slope-aspect correction of multispectral scanner data*. *Canadian Journal of Remote Sensing*, 8(2), pp. 1537-1540.
- Tymstra, C.; Bryce, R.W.; Wotton, B.M.; Taylor, S.W.; Armitage, O.B. (2010). *Development and structure of Prometheus: the Canadian wildland fire growth simulation model*. Information Report NOR-X-417, Canadian Forest Service Northern Forestry Centre, Edmonton, Alberta. Accesible online <http://goo.gl/elo7L3>, último acceso octubre 2015.
- Updike, T.; Comp, C. (2010). *Radiometric Use of WorldView-2 Imagery*. Technical note. Digital Globe Inc., Longmont, Colorado, U.S.A.
- van Wagner, C.E.; Pickett, T.L. (1985). *Equations and FORTRAN program for the Canadian Forest Fire Weather Index System*. Rep. No. Forestry Technical Report 33. Canadian Forestry Service, Ottawa. Accesible online <http://goo.gl/UP7Qwd>, último acceso octubre 2015.
-

- Vapnik, V.N. (1999). *The Nature of Statistical Learning*. 2nd edition. (Springer-Verlag New York, Inc.) 314 pp.
- VVAA (2002). *Mapa 1:25.000 de usos del suelo*. GRAFCAN S.A. (Santa Cruz de Tenerife, España).
- Warrens, M.J. (2015). *Relative quantity and allocation disagreement measures for category-level accuracy assessment*. International Journal of Remote Sensing, Volume 36, Issue 23, pp. 5959-5969. DOI: 10.1080/01431161.2015.1110265.
- Xie, Yichun; Sha, Zongyao; Mei, Yu (2008). *Remote sensing imagery in vegetation mapping: a review*. Journal of Plant Ecology, Volume 1, Number 1, pp. 9-23.
- Yang, Y.; Wang, Y.; Wu, K.; Yu, X. (2016). *Classification of complex urban fringe land cover using evidential reasoning based on fuzzy rough set: A case study of Wuhan City*. Remote Sensing, 2016, 8(4), 304. [doi: 10.3390/rs8040304](https://doi.org/10.3390/rs8040304).
- Yebra, Marta; Dennison, Philip E.; Chuvieco, Emilio; Riaño, David; Zylstra, Philip; Hunt, E. Raymond Jr.; Danson, F. Mark; Qi, Yi; Jurdao, Sara (2013). *A global review of remote sensing of live fuel moisture content for fire danger assessment: Moving towards operational products*. Remote Sensing of Environment, Volume 136, September 2013, Pages 455-468.

Anexo A

Artículo “Pixel and object-based classification approaches for mapping forest fuel types in Tenerife Island from ASTER data”

Este artículo ha sido publicado en International Journal of Wildland Fire en octubre de 2012. Esta revista tiene un factor de impacto de **2,506** y ocupa la quinta posición de las 64 revistas forestales indexadas en el Journal of Citation Report Science Edition 2013.

Pixel and object-based classification approaches for mapping forest fuel types in Tenerife Island from ASTER data

Alfonso Alonso-Benito^{A,C}, Lara A. Arroyo^B, Manuel Arbelo^A,
Pedro Hernández-Leal^A and Alejandro González-Calvo^A

^AGrupo de Observación de la Tierra y la Atmósfera (GOTA), Departamento de Física FEES, Universidad de La Laguna, E-38206 La Laguna (S/C Tenerife), Spain.

^BCentre for Human and Social Sciences, Spanish Council for Scientific Research, Albasanz 26–28, E-28037 Madrid, Spain.

^CCorresponding author. Email: aaloben@ull.es

Abstract. Four classification algorithms have been assessed and compared with mapped forest fuel types from Terra-ASTER sensor images in a representative area of Tenerife Island (Canary Islands, Spain). A BEHAVE fuel-type map from 2002, together with field data also obtained in 2002 during the Third Spanish National Forest Inventory, was used as reference data. The BEHAVE fuel types of the reference dataset were first converted into the Fire Behaviour Fuel Types described by Scott and Burgan, taking into account the vegetation of the study area. Then, three pixel-based algorithms (Maximum Likelihood, Neural Network and Support Vector Machine) and an Object-Based Image Analysis were applied to classify the Scott and Burgan fire behaviour fuel types from an ASTER image from 3 March 2003. The performance of the algorithms tested was assessed and compared in terms of quantity disagreement and allocation disagreement. Within the pixel-based classifications, the best results were obtained from the Support Vector Machine algorithm, which showed an overall accuracy of 83%; 14% of disagreement was due to allocation and 3% to quantity disagreement. The Object-Based Image Analysis approach produced the most accurate maps, with an overall accuracy of 95%; 4% disagreement was due to allocation and 1% to quantity disagreement. The object-based classification achieved thus an overall accuracy of 12% above the best results obtained for the pixel-based algorithms tested. The incorporation of context information to the object-based classification allowed better identification of fuel types with similar spectral behaviour.

Additional keywords: allocation disagreement, Maximum Likelihood, Neural Network, Object-Based Image Analysis, quantity disagreement, Support Vector Machine.

Received 13 May 2011, accepted 16 July 2012, published online 3 October 2012

Introduction

Numerous forest fires occur annually in Spain. According to the Ministry of Agriculture, Food and Environment (MMARM 2011), the number of forest fires between 1961 and 2011 averaged 10 634 year⁻¹, and they burned on average 145 400 ha year⁻¹. Moreover, the recorded number of fires per year shows an increasing tendency, and is expected to increase more in the future under projected climate change scenarios (Moreno *et al.* 2009; Martínez-Chamorro 2011).

To reduce damage from forest fires, forest managers usually make use of different tools to improve the effectiveness in fire fighting tasks in real time and to generate fire-risk maps. Among these tools are the decision-support systems such as FARSITE (Finney 2003, 2004), BehavePlus (Andrews 2009), FlamMap (Finney 2006) and Prometheus (Tymstra *et al.* 2010). These decision-support systems require a large amount of input data for modelling fire behaviour (Keane *et al.* 1998). One of the

essential data inputs is accurate fuel-type maps. Because the description of fuel properties is quite complex, groups of vegetation types with similar fire-behaviour characteristics (so-called fuel types) are usually considered (Riaño *et al.* 2002). A fuel type is defined as an identifiable group of fuel elements of an individual plant species, form, size, spatial arrangement or other characteristics that will contribute to a predictable rate of fire spread or severity (Pyne *et al.* 1996; Burgan *et al.* 1998; Andrews and Queen 2001). A wide variety of fuel classification systems has been defined according to the specific environment conditions and the aim of the classification system (Arroyo *et al.* 2008). A classification system based on the BEHAVE fuel types (Rothermel 1972, 1983, 1991) has been used in Spain since the 1980s (MAPA 1989).

Nowadays, fuel-type mapping requires intensive field work, which causes considerable outlay in time and money. Partly for this reason, many maps of forest fuel types can be over 10 years

old, which become problematic for fire-management officials, because updated maps are essential for their work.

Remote sensing from satellite images is an alternative to traditional methodology. Remotely sensed data more quickly and economically provide updated information, such as land use, land cover, vegetation or fuel-type maps. Several studies have successfully used remotely sensed images of different spatial and spectral resolutions for mapping fuel types in different regions of the planet. Some authors have used pixel-based classification algorithms. Lasaponara and Lanorte (2007) applied the Maximum Likelihood (ML) algorithm over ASTER images, to classify Prometheus fuel types (Prometheus, unpubl. data, 2000) in southern Italy, obtaining an overall accuracy of 90.73%. In the same region, and using the same imagery, Coluzzi *et al.* (2007) achieved an overall accuracy of 78.09% with the Neural Network (NN) algorithm. Falkowski *et al.* (2005) applied classification trees to map the BEHAVE fuel types in a mountainous area of Idaho (USA), and obtained an overall accuracy of 63.20%. In Cabaneros National Park (Central Spain), Riaño *et al.* (2002) used Landsat-Thematic Mapper (TM) imagery and the ML algorithm to map Prometheus fuel types and achieved an overall accuracy of 82.80%. More recently, Mutlu *et al.* (2008) combined light detection and ranging (LiDAR) data and multispectral QuickBird data from a region of Texas (USA) with ML and Mahalanobis algorithms to map fuel types. They obtained overall accuracies of 76.52 using multispectral information alone and 87.17% using both LiDAR and multispectral information.

The Object-Based Image Analysis (OBIA) approach has shown good classification performance for high spatial resolution imagery, when the pixel size is smaller than the objects of interest, and it has made considerable progress in the last decade (Blaschke 2010). This approach has also been tested for mapping fuel types from remotely sensed data. For example, Tanase and Gitis (2008) made a fuel map of the island of Crete (Greece), and compared the results obtained by OBIA and pixel-based ISODATA (a clustering algorithm) using QuickBird images. Their results showed an increase of 10% in overall accuracy for the OBIA. In a region of Madrid (Spain), the OBIA approach also provided better results than did pixel-based techniques when mapping Prometheus fuel types from very high spatial resolution images (QuickBird). The OBIA classification achieved an overall accuracy of 81.5%, compared with the 75.3% obtained with a ML classification (Arroyo *et al.* 2006). The incorporation of context features to the analysis allowed more accurate identification of fuel types. Less is known regarding the potential for applying OBIA to medium or coarse spatial resolution imagery for mapping fuel types.

In summary, previous studies have shown that fuel types can be mapped from remotely sensed data. However, the accuracy of the maps obtained heavily depends on factors such as the imagery and mapping technique employed, as well as the complexity of the study area. This is a key issue in the case of Tenerife Island (Canary Islands, Spain) owing to the abundance of endemic species, the wide variation of vegetation and the very complex topography of the area, which ranges from 0 to 3718 m above sea level. The aim of this study was to assess the potential of pixel-based and object-based classification techniques for mapping fuel types on Tenerife from ASTER imagery.

Materials and methods

Study area

The study area is the municipality of La Orotava in the northern part of Tenerife Island, Canary Islands (28°23'N, 16°31'W) (Fig. 1). It covers an area of 212 km² and its altitude ranges from 0 to 3718 m above sea level. The topography of the study area is quite complex, with steep slopes and large ravines. A wide representation of the Canarian vegetation is included in this study site.

The dominant species is the Canary pine (*Pinus canariensis* C.Sm. ex DC.). It is found in pure stands or mixed with another pine species (e.g. radiata pine, *P. radiata* D. Don) or evergreen trees (tree heath, *Erica arborea* L., and wax myrtle, *Myrica faya* Ait.), or next to laurel forest (laurisilva: consisting of *Laurus azorica* (Seub.) Franco, *Persea indica* (L.) Spreng. or *Ilex canariensis* Poir., among others).

The study area was divided into three zones as a function of altitude. Each zone had specific characteristics and different fuel types, as described below (Fig. 2): (1) agricultural lands (below 600 m), mostly occupied by agricultural and urban land covers, and with halophytic shrubs (i.e. shrubs adapted to living in a saline environment) in the coastal zone, (2) forests (between 600 and 2000 m), where the pine forest is the dominant vegetation type (most of it included in the natural protected areas of Corona Forestal Natural Park and La Resbala Protected Landscape) and (3) Teide-high mountain area (above 2000 m), dominated by high mountain brushes (*Spartocytisus supranubius* (L.f) G. Kunkel ex Christ) up to 3100 m and rocky vegetation (*Viola cheiranthifolia* Humb. & Bonpl.) above 3100 m. The Teide-high mountain zone is entirely located within the Teide National Park. Human activity is considerable in the entire study area, with high population density (especially in the lower part) and tourism-related activities (mainly in the higher part).

ASTER data

A Level 1B ASTER image acquired on 3 March 2003 (Fig. 2) was used in this study. The ASTER sensor is on board Terra satellite, in orbit since December 1999. ASTER imagery has 14 spectral bands on three independent subsystems: visible and near infrared (VNIR), short-wavelength-infrared (SWIR) and thermal infrared (TIR). The VNIR has three bands in the visible part of the spectrum (0.52–0.86 µm), six bands in the SWIR (1.60–2.43 µm) and five bands in the TIR (8.125–11.650 µm). The spatial resolution is 15 m for VNIR bands 1, 2 (RED) and 3 (NIR), 30 m for SWIR bands 4, 5, 6, 7, 8 and 9, and 90 m for TIR bands 10, 11, 12, 13 and 14. This image was chosen because it was nearest the date of completion of fieldwork and free of clouds.

The pre-processing consisted of the determination of TOA (top of atmosphere) reflectance, using the method proposed by Smith (2007) for the original VNIR and SWIR bands. The thermal bands were not used. Then, the six SWIR bands were resampled to 15 m using the nearest-neighbour interpolation. Thus, a new image with nine bands (VNIR+SWIR) of 15-m spatial resolution was obtained. This image was georeferenced and orthorectified to UTM (Universal Transverse Mercator) WGS 84 (Zone 28N). Topographic correction was performed using the method-c correction (Teillet *et al.* 1982), and a Digital




Fig. 1. Location of the study area: (a) location of Tenerife Island within the Canary Islands and (b) location of the study area (municipality of La Orotava, outlined in red) within Tenerife Island (source: Orthoexpress from GRAFCAN).




Fig. 2. (a) Study zones within the study area (municipality of La Orotava) showing altitude in metres above sea level. (b) ASTER image used for the study (in false colour: RGB 321), acquired on 3 March 2003.

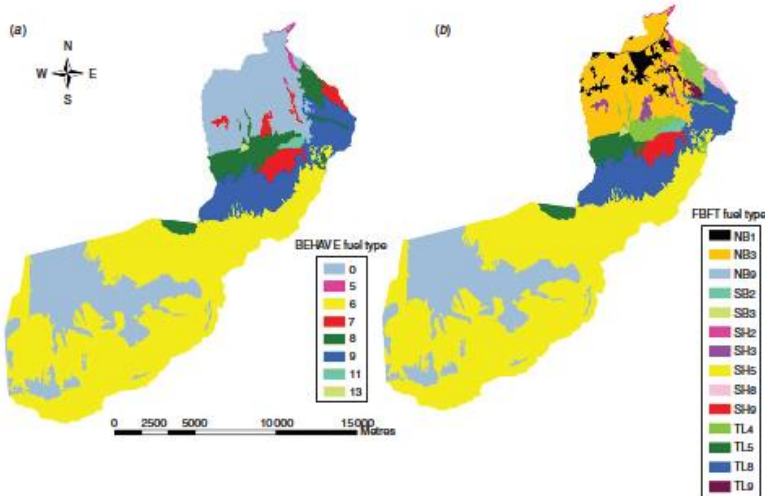


Fig. 3. The reference fuel-type map of the study area: (a) original BEHAVE fuel type map, derived from the III NFI, and (b) adapted FBFT fuel type map.

Elevation Model (DEM) obtained from the GRAFCAN (Cartográfica de Canarias SA) cartography (scale 1:5000).

Given the importance of adding synthetic bands, such as vegetation indices or principal components to the original dataset to improve classification results (up to 5% improvement, according to Lasaponara and Lanorte 2007, Falkowski *et al.* 2005, Bagan *et al.* 2008 and Riaño *et al.* 2002), the following synthetic bands were estimated: (1) first principal component (PC1), estimated for the VNIR and SWIR bands, PC1 explained 96.7% of the total variance; (2) Normalised Difference Vegetation Index (NDVI) (Rouse *et al.* 1973); (3) Soil Adjusted Vegetation Index (SAVI) (Huete 1989); (4) Modified Soil Adjusted Vegetation Index (MSAVI) (Qi *et al.* 1994) and (5) Enhanced Vegetation Index Two-band (EVI2) (Jiang *et al.* 2008). The vegetation indices were calculated as follows:

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

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

$$\text{MSAVI} = \text{NIR} + 0.5 - \sqrt{(\text{NIR} + 0.5)^2 - 2(\text{NIR} - \text{RED})} \quad (3)$$

$$\text{EVI2} = 2.5 \frac{\text{NIR} - \text{RED}}{\text{NIR} + 2.4 \text{RED} + 1} \quad (4)$$

Reference fuel type map

The National Forest Inventory (NFI) is a Spanish project whose aim is to obtain as much information as possible about the situation, ownership, level of protection, legal status, likely developments and capacities to produce all kinds of goods from the Spanish forested areas. The Third National Forest Inventory (III NFI) was carried out for the study area during the second half of 2002. As part of that inventory, each plot was assigned visually to one BEHAVE fuel type. However, the BEHAVE classification scheme disregards the peculiarity of the Canarian vegetation. A more recent classification scheme, the Fire Behaviour Fuel Types (FBFT) developed by Scott and Burgan (2005), was adopted for this study. This classification improves the forecasting of fire behaviour and its simulation, and it comprises seven groups: (1) non-burnable (NB), with five subgroups; (2) grass (GR), with ten subgroups; (3) grass-shrub (GS), with four subgroups; (4) shrub (SH), with nine subgroups; (5) timber-understorey (TU), with five subgroups; (6) timber-litter (TL), with 10 subgroups and (7) slash-blowdown (SB), with six subgroups. We updated the BEHAVE fuel type map derived from the III NFI to a FBFT map for the study area (Fig. 3). The fieldwork data collected during the III NFI were crossed with the Vegetation Map of the Canary Islands (Arco *et al.* 2003), the Forest Map of Spain (MdMA 2002), the Land Use Map of the Canary Islands (VVAA 2002) and aerial orthophotos from 2002 (scale 1:5000). A total of 14 FBFT, belonging to four groups (SB, SH, TL and NB) were identified in the study area (Table 1).

Table 1. Correspondence between the BEHAVE fuel types and the FBFT fuel types for the study area, and their description (BEHAVE fuel type description extracted from Rothermel 1983, p. 9)

BEHAVE fuel type	BEHAVE fuel type description	FBFT fuel type	FBFT fuel type description (adapted to the vegetation in study area)
5	Bush	SH2	Coastal bush formed by different species
6	Dormant brush, hardwood slash	SH5	High mountain bush
13	Heavy logging slash	SH3	<i>Erica arborosa</i> discontinuous and irregular thicket stage and <i>E. arborosa</i> with <i>Castanea sativa</i> discontinuous and irregular upper-stem
7	Southern rough	SH8	<i>Pinus canariensis</i> uniform upper-stem with <i>E. arborosa</i> and <i>P. radiata</i> uniform pole stage
7	Southern rough	SH9	<i>E. arborosa</i> uniform pole stage with <i>P. radiata</i> and <i>P. canariensis</i> upper-stem
9	Hardwood litter	TL8	<i>P. canariensis</i> uniform upper-stem
8	Closed timber litter	TL4	<i>E. arborosa</i> thicket stage with <i>C. sativa</i> upper-stem, evergreen pole stage, <i>Eucalyptus</i> sp. upper-stem and <i>P. canariensis</i> pole stage
8	Closed timber litter	TL5	<i>P. radiata</i> and <i>P. canariensis</i> uniform upper-stem
9	Hardwood litter	TL9	<i>C. sativa</i> , <i>P. canariensis</i> and <i>E. arborosa</i> uniform upper-stem
11	Light logging slash	SB2	<i>P. canariensis</i> and <i>P. radiata</i> discontinuous strip upper-stem
13	Heavy logging slash	SB3	Mixed <i>E. arborosa</i> and <i>Myrica faya</i> formation
0	Non described	NB1	Highways and city
0	Non described	NB3	Rural areas and crops
0	Non described	NB9	High mountain area

In the Teide-high mountain zone, two fuel types are found: high mountain area (NB9) and high mountain bush (SH5). Lower down in the forest zone, nine types of fuel can be identified, which cover the gamut from Canary pine forest (TL8) to laurel forest (TL4) or wax myrtle-tree heath (SB3). In the agricultural zone there exist three FBFT: highways and city (NB1), rural areas and crops (NB3), and coastal bush (SH2). The SB (slash-blowdown) fuel subgroups SB2 (Canary and radiata pine) and SB3 cover 0.49% of the study area. There are five fuel types within group SH (shrub): subgroup SH2, comprising coastal halophytic shrub; SH3, formed by a discontinuous mass of tree heath, wax myrtle, and chestnut (*Castanea sativa*); SH5, consisting of highly flammable brush; SH8, composed of a uniform mass of Canary pine mixed with masses of tree heath and radiata pine; and SH9, consisting of a uniform mass of tree heath with mixed areas of Canary and radiata pines. SH fuel types cover 50.65% of the study area. The group timber litter (TL), which occupies 16.09% of the study area, includes four fuel types: TL4, made up of a complex mixed mass of laurel; TL5 and TL8, fuel types with pruning remains; and fuel TL9, consisting of a uniform mass of chestnut, Canary pine and tree heath. Finally, there are three fuel types of group NB (non-burnable) in the study area: NB1 consists of urban areas; NB3 is composed of the agricultural zone crops; and NB9 corresponds to the areas of very high mountains on Mount Teide. This group occupies 32.78% of the study area.

Fuel type classifications

Three widely used supervised pixel-based classification algorithms – Maximum Likelihood (ML), Neural Network (NN) and Support Vector Machine (SVM), plus an OBIA – were tested for this study. For all the classification methods, the VNIR and SWIR ASTER bands were used together with the PC1, the four vegetation indices and the DEM.

For the pixel-based algorithms, the selection of training areas was made by taking into account the variability of each class (fuel type) and avoiding areas of transition between fuel types. All training areas were rectangular (with variable size) and randomly distributed within the study area. Training areas were independent of the validation dataset and were identified by visual interpretation from the orthophotos, which was supported with the thematic information. Training areas covered 7.53% of the whole study area. Fuel type SB3 from the forest zone, which only occupies 0.09% of the total study area, had the highest relative area of training sites (25.85%). The average relative area covered by training sites was 6.98% for the Teide-high mountain zone; 12.97% for the forest zone and 7.15% for the agricultural zone (Table 2).

Maximum Likelihood algorithm

The ML algorithm is considered one of the most important classifiers, owing to its simplicity and robustness. It has been widely used for mapping vegetation and land cover (Hagner and Reese 2007). The following equation is applied:

$$g_i(x) = \ln p(\omega_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^T \Sigma_i^{-1} (x - m_i) \quad (5)$$

where i is the class or fuel type; x is n -dimensional data, where n is the number of bands used; $p(\omega_i)$ is the probability that each class or fuel type ω_i resulting from the classification is assumed for the other classes; $|\Sigma_i|$ is the covariance matrix of the data in each class or fuel type ω_i and Σ_i^{-1} is the inverse of the previous matrix.

This algorithm calculates for each class (fuel type) the probability that a pixel x belongs to it from the multivariate density. This calculation was performed for the 14 fuel types

Table 2. Fuel types found within each zone of the study area; area occupied by each one in ha, and as a percentage of the total study area, and; surface area occupied by the training areas for each fuel type

Study zone Fuel type	Surface area (ha)	Percentage of study area	Area covered by the training sites (ha)
Teide			
NB9	3802.59	18.06%	256.32
SH5	10035.18	47.66%	725.06
Forest			
SB2	83.99	0.40%	13.43
SB3	18.45	0.09%	4.77
SH3	149.51	0.71%	16.02
SH8	113.83	0.54%	15.57
SH9	300.17	1.43%	33.08
TL4	667.44	3.17%	68.85
TL5	576.81	2.74%	70.45
TL8	2079.34	9.88%	203.00
TL9	63.86	0.30%	4.61
Agricultural			
NB1	452.77	2.15%	25.97
NB3	2646.16	12.57%	140.90
SH2	65.14	0.31%	6.77
Total	21 055.23	100.00%	1584.79

present in the study area, and each pixel was assigned to the fuel type that maximised the probability function.

Neural Network algorithm

The NN algorithm is composed of a set of elements arranged in layers of nodes: input nodes (one for each band used), hidden nodes (same number as the input layer) and output nodes (one for each class or model tested). The set layers of nodes are linked by functions (defined by weights) that are calculated iteratively during the learning process of the algorithm.

If we consider x as the input nodes (x_1, \dots, x_n), z as the hidden nodes (z_1, \dots, z_m) and y as the output nodes (y_1, \dots, y_k), taking i, j and k as subscripts of the input, hidden and output layers, the function to calculate the NN algorithm is expressed as:

$$y_k = g_k \left(\sum_{j=1}^m z_j \beta_{jk} + \phi_k \right) \quad (6)$$

$$z_j = f_j \left(\sum_{i=1}^n x_i w_{ij} + \tau_j \right) \quad (7)$$

where τ_j is the bias of node z_j ; ϕ_k is the bias of node y_k ; w_{ij} is the weight of the connection between the neuron x_i and z_j ; β_{jk} is the weight of the connection between the neuron z_j and y_k , and g_k and f_j are activation functions that are continuous, bounded, and non-decreasing.

During the training phase of the algorithm, the optimum was found using the back-propagation algorithm (Rumelhart *et al.* 1986).

Table 3. Segmentation parameters used for each zone in the study area

Segmentation parameters	Teide	Forest	Agricultural
Bands (weight)	NDVI (1)	B4 (2)	B4 (2)
	PCI (1)	NDVI (1)	NDVI (1)
Shape weight	0.0005	0.005	0.005
	0.7	0.7	0.7
Scale parameter	4	3	3

Support Vector Machine algorithm

The SVM algorithm (Vapnik 2000) considers a set of training areas as a starting point and represents the image as a set of points that are assigned to the different existing classes depending on the proximity to the training areas. In order to make this classification, the pixel is classified according to the kernel, or core functions (Mercier and Lennon 2003), which can be local or global type. Local functions only consider the closer data, and in the global, the furthest ones are the most determinant. For this work the Radial Basis Function kernel (RBF) was used, represented as:

$$K(x_i, y_j) = \exp(-\gamma \|x_i - y_j\|^2), \quad \gamma > 0 \quad (8)$$

where x_i and y_j are the training pixels and pixels to be classified. The kernel parameter γ has a great influence on the classification, and was assigned a value 2.0 because higher values did not represent significant improvements (Huang and Townshend 2002) and greatly increased the processing time.

Object-Based Image Analysis algorithm

The OBIA analysis was conducted using eCognition Developer software, version 8.4. Several steps of segmentation and classification were applied in order to produce two hierarchical levels of segmentation that allowed transfer of context information among them.

Segmentation. From a management point of view, it is important to preserve the administrative boundaries of the protected natural areas existing within the study area (Corona Forestal Natural Park, La Restalga Protected Landscape and Teide National Park). For this reason, besides all ASTER VNIR bands, a thematic layer including the boundaries of the previous fuel-type map was used for the segmentation of the upper level. This thematic layer was only used for this step, in order to ensure that the boundaries of the segmented objects did not cut the boundaries of the existing management units. The previous fuel-type map was not used for the classification steps. PCI, NDVI and B4 were used for the segmentation of this lower level, where specific segmentation settings were considered for each altitudinal zone (see Table 3 for further details).

The segmentation parameters (scale parameter and relative weights of each band, smoothness and compactness) were determined using a trial and error approach, validated by visual inspection of the image objects and based on our own experience. The image segmentation process was considered complete

once the obtained image objects visually corresponded to meaningful objects of interest.

Classification. The classification phase took place in a stepwise manner, with over 50 individual processes and loops. A stepwise approach was chosen in order to gradually increase the context information available within the hierarchical classification system, thus facilitating the identification of fuel types. The amount of context information increased with each individual step, and the contextual information gained in this way aided in the later identification of those fuel types that were difficult to classify based solely on their spectral behaviour. Thus, although the first steps of the classification were based solely on the properties of each object (so called object-based features), context-based features were gradually incorporated into the analysis.

Each altitudinal zone was considered independently during the classification. Objects from the agricultural zone were classified first, followed by the objects belonging to the forest zone. The objects for the Teide-high mountain zone were classified last. The same stepwise approach was taken for the three altitudinal zones: those fuel types that could be identified based on spectral information and non-context features were first classified, and the context information gained during the first classification steps aided in the classification of those fuel types that could not be identified solely based on spectral information. For example, for the forest zone, fuel types SH8 and TL5 were first classified based on the mean values of band 9, band 1 and MDT. Then more complex classes, such as fuel type TL4, were classified using loops and classification-related features (e.g. 'Relative border to class SH8' or 'Relative border to class TL5'). For the agricultural zone, class NB1 (highways and cities) was mapped considering the following object-based features: the mean value of band 2, the total number of pixels within the object, and the 'roundness' of the object (very long objects were more likely to be classified as roads than were the rounded ones); and class NB3 (rural areas and crops) was identified in a later step, using the context-based features 'the relative border to class NB2' in combination with other object-based features.

Accuracy assessment

The accuracy of the four maps obtained was calculated from the confusion matrix, estimated from the total study area (~940 000 pixels). An up-to-date fuel type map of the entire area, obtained by aerial-photo interpretation, was used as reference data. From this matrix we derived:

- (1) Quantity disagreement, defined as the amount of difference between the reference map and the comparison map that is due to the less-than-perfect match in the proportions of the categories; see Pontius and Millones (2011) for further details.
- (2) Allocation disagreement, defined as the amount of difference between the reference map and the comparison map that is due to the less-optimal match in the spatial allocation of the categories; see Pontius and Millones (2011) for further details.
- (3) Total disagreement, defined as the proportion of disagreement between the reference map and the comparison map (the reverse of the overall accuracy).

The performance of the classification algorithms tested was thus compared in terms of errors, rather than accuracies. Further, the classification's error was divided into two components: errors due to quantity disagreement and errors due to allocation disagreement (as suggested by Pontius and Millones 2011). This allowed analysis of whether a particular classification technique was properly detecting the total number of fuel types, but showing them in the wrong place on the map (allocation disagreement); or conversely properly allocating the fuel types to the right locations on the map but detecting too many or too few of them (quantity disagreement). This approach is particularly relevant to this study, where fuel types and quantities are important components of fire-behaviour modelling.

Results and discussion

Four maps were obtained, one for each classification method (Fig. 4). All 14 fuel types were identified by the four tested classification algorithms, but not in the same proportion or the same spatial distribution. The main differences between the classification systems compared are detectable by simple visual analysis of the maps obtained. The maps obtained using pixel-based algorithms showed a marked salt-and-pepper effect, owing to a random distribution of pixels that occurs in each algorithm studied, which did not occur in the case of the OBIA approach.

In order to visualise and analyse the quantity and distribution of disagreement, Fig. 5 shows the results of crosses between the four obtained maps and the reference map. Grey represents pixels in agreement with the reference map and the areas of disagreement are presented in colours, where the colour represents the fuel type of that pixel according to the reference map. For example, areas in yellow (fuel type SH5) correspond to those areas of fuel type SH5 (according to the reference map) that were misclassified as another fuel type. Fig. 6 summarises the results of the disagreement displayed in Fig. 5. The total disagreement is presented as two components: errors due to quantity disagreement and errors due to allocation disagreement. With regard to the allocation disagreement, the best pixel-based classification algorithm was the NN, which produced 12% allocation disagreement, compared to 14 and 15% for the SVM and the ML. The OBIA produced the lowest allocation disagreement of all the classification approaches tested (4%). With regard to the quantity disagreement, the best pixel-based classifier was the SVM, with a quantity disagreement of 3%, compared to 5 and 8% for the NN and ML algorithms. The OBIA approach also produced the best results in terms of quantity disagreement (1%), which gave this approach the lowest total disagreement (5%). Generally, the four algorithms have displayed disagreement mainly due to allocation. These higher values of allocation disagreement indicate errors were mainly due to wrong location of the fuel types; that is, that the fuel types were incorrectly mapped. In contrast, the lower values for quantity disagreement indicate that the number of pixels that were misclassified was low. In other words, the proportion of classified fuel types was similar to the proportion of fuel types in the reference map. In terms of quantity disagreement, SVM and OBIA produced similar results, showing difference in terms of quantity of only 2% of the study area. In that sense, the SVM

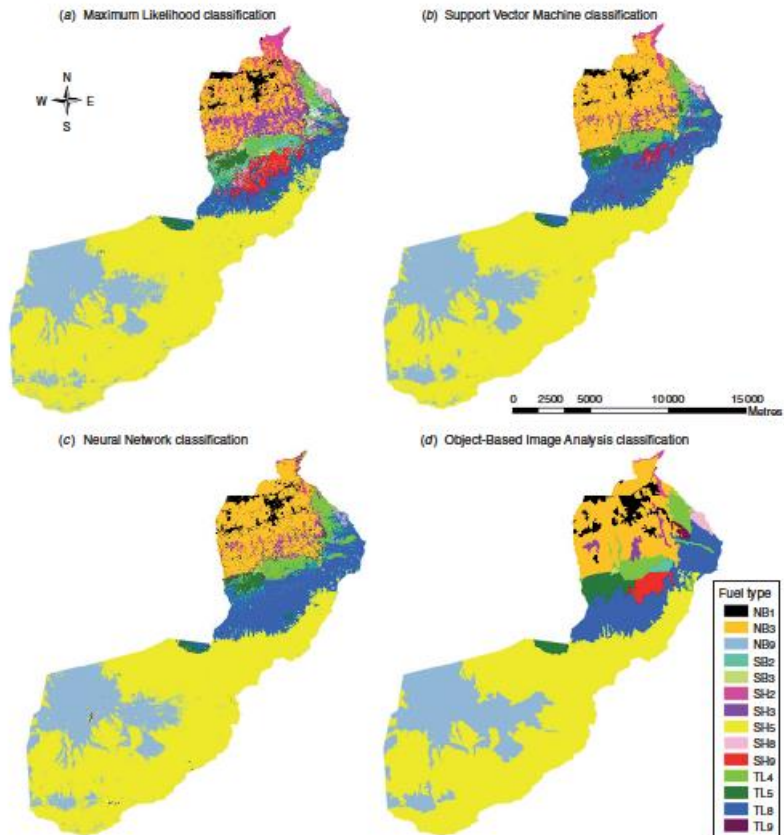


Fig. 4. (a) Maximum Likelihood, (b) Support Vector Machine, (c) Neural Network and (d) Object-Based Image Analysis fuel-type classifications obtained for the study area.

method was able to accurately estimate the relative areas of the fuel types in the study area. The main difference between the SVM and OBIA was owing to the larger proportion of fuel types inaccurately distributed within the study area for the SVM classification.

Fig. 7 shows the quantity and allocation disagreement by fuel type and altitudinal zone. Presenting the results by zone is

important for several reasons. First of all, these zones are managed differently from the administrative perspective. Furthermore, from the vegetation perspective, the internal structure among them is very different and disagreements were not homogeneously distributed among them, as described above. Finally, the majority of fires that occur on the island start in the boundary areas between zones, in particular in the

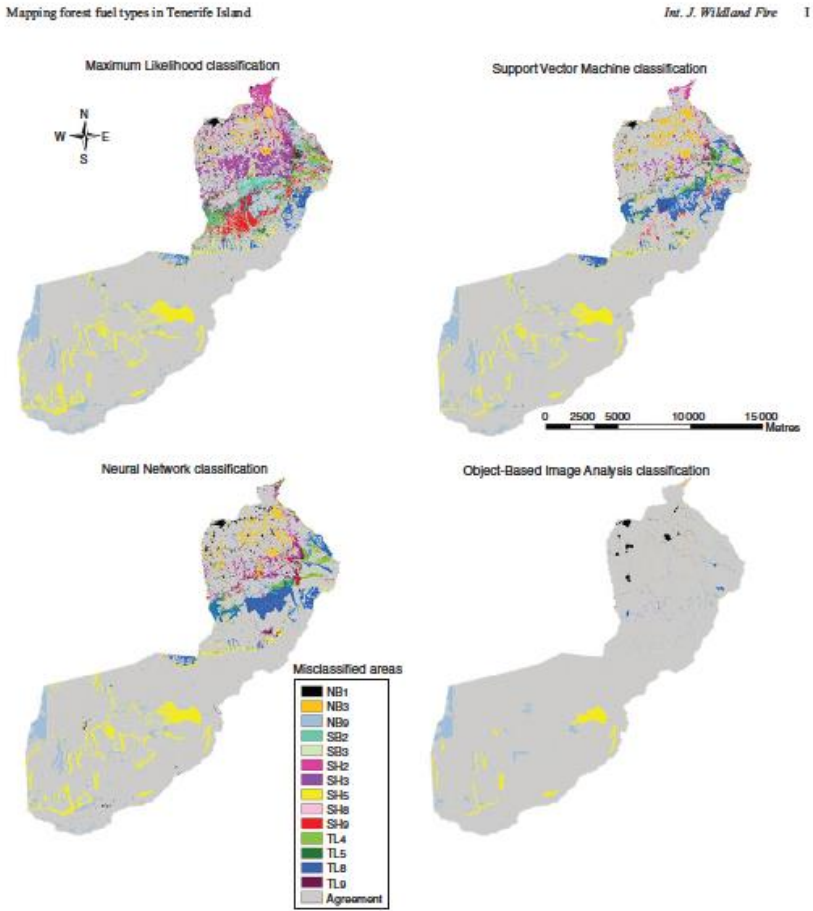


Fig. 5. Comparison between the reference and fuel-type classification maps. The colour grey indicates the degree of agreement. The colours corresponding to each fuel type indicate the disagreement for each fuel type, as the sum of quantity and allocation disagreements.

wildland-urban interface (the area where the agricultural zone meets the forest zone).

For the Teide-high mountain zone, the predominant errors are those that refer to allocation disagreement, the ML algorithm providing the worst results (6.7% for type NB9 and almost 9.0% for SH5). It is worth mentioning that fuel type SH5 accounts for

almost half of the total surface and is the one that shows the largest errors in terms of allocation. As regards quantity disagreement, NN displays the largest errors, ~2% for each of fuel types NB9 and SH5. All the tested algorithms misclassified mountain areas with sparse vegetation (fuel type NB9) as high mountain bush (SH5). In some areas the bush is very thinly




Fig. 6. Quantity and allocation disagreement for the four algorithms studied.

spread and adopts a creeping system of growth that produces a very similar spectral response in these cases. High mountain bush (fuel type SH5) was also misclassified as Canary pine forest (TL8) in areas of transition between these fuel types (2000 m above sea level). In these areas the Canary pine takes the form of stunted trees (2.5–5.0 m in height) and is much more widely dispersed, resulting in mixed formations at the boundary of both zones.

In the agricultural zone, the principal component of disagreement depends on the classifier used. Fuel type NB3 (rural areas and crops) showed the highest disagreements, with a maximum of 3.1% in quantity disagreement for ML and 3.3% in allocation disagreement for NN. All algorithms tested produced uncertainty between classes NB1 and NB3, whose spectral behaviour is very similar when crops have been harvested or the land is not cultivated. There was also confusion between fuel type NB3 and SH3 (wax myrtle-tree heath), and to a lesser degree between fuel

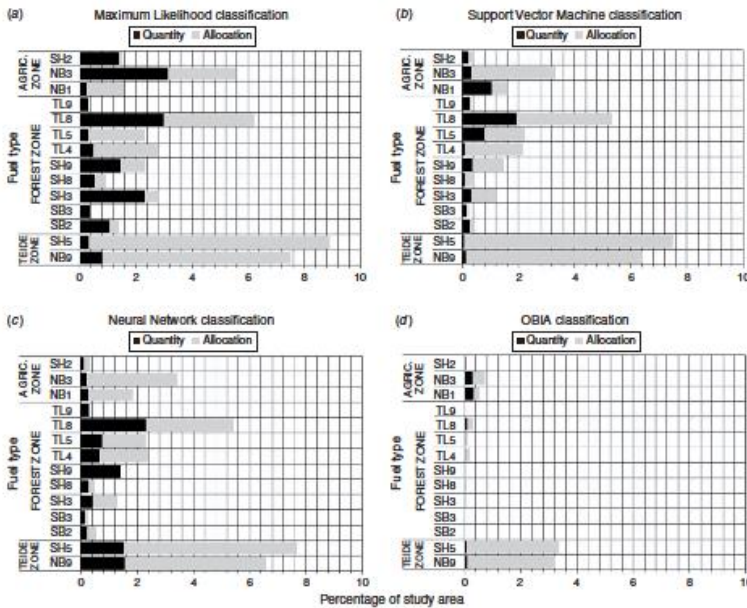


Fig. 7. Quantity and allocation disagreement for the four algorithms studied, (a) Maximum Likelihood, (b) Support Vector Machine, (c) Neural Network and (d) Object-Based Image Analysis, separated by zones and fuel types identified in the study area.

type NB3 and TL5 (Canary pine forest mixed with Monterey pine), particularly in the wildland-urban interface.

Finally, in the forest zone, fuel type TL8 (Canary pine forest) shows the highest values both of allocation and of quantity disagreement with maximum values of 3.4% (SVM) and 3.0% (ML). The high values of allocation disagreement obtained for fuel types TL5 (Canary pine forest mixed with Monterey pine) and TL4 (laurel forest) are very noticeable in the pixel-based algorithms, with a range varying between 2.5% for ML and 2.9% for SVM. Likewise, for the ML and NN algorithms fuel type SH9 (Canary pine forest mixed with Monterey pine and heath tree) showed values of quantity disagreement of 1.8 and 2.0%. In general, for the pixel-based classification algorithms, fuel type SB2 (Canary pine forest mixed with Monterey pine) was misclassified as fuel type TL8 (Canary pine forest). In fact, these classes showed very similar spectral behaviour. The ML algorithm also misclassified fuel type SB2 as fuel type TL4 (heath tree mixed with chestnut). The fuel type TL9 (chestnut mixed with Canary pine and heath tree) was in some cases misclassified as TL5 (Monterey pine mixed with Canary pine) and TL8 (Canary pine forest), because they have very similar spectral behaviour in the visible bands. This fact, together with its reduced area, suggests that all the disagreement must have been because of the quantity for algorithms ML and SVM, whereas for NN and OBIA the disagreement must have been because of allocation. Fuel type SB3 (wax myrtle-tree heath) was misclassified as fuel type NB3 for all the pixel-based algorithms. In fact, fuel type SB3 is usually located next to crops, where there is a gradual change from fuel type SB3 to fuel type NB3.

The pixel-based algorithms are conditioned by the quantity and spectral difference between classes, which are intended to be discriminated, and this explains their greater values of quantity disagreement.

Conclusions

The fuel-type map of the municipality of La Orotava (in the north of Tenerife Island, Spain) has been updated using an ASTER image and four different classification approaches, obtaining overall accuracies above 75% for all the tested approaches.

The OBIA approach achieved the lowest level of allocation and quantity disagreement when mapping fuel types from ASTER image data. This was partly because of the OBIA's ability to incorporate context information into the analysis, which was a key element for distinguishing fuel types with similar spectral behaviour. Besides, the OBIA approach allowed us to set the scale of work according to the aims of the study, depicting the elements of interest (fuel types) and aiding the incorporation of context information to the analysis.

For all the algorithms tested, the main source of disagreement was the incorrect allocation of fuel type. In contrast, all classifications tested showed accurate estimations of the proportion of fuel types within the study area (quantity disagreement ranging between 8 and 1%). The majority of the misclassified areas occurred within the forest zone (dominated by fuel types of group TL), where the spectral signatures were in some cases not sufficiently differentiated to allow discrimination among them.

The results are particularly relevant because they show that the classification approaches employed (1) can be applied to periodically update fuel type maps of Tenerife Island (this being essential for efficient fire management of the region) and (2) produce accurate results in areas of complex topography, where fieldwork is especially difficult and time consuming.

Acknowledgements

The authors of this article thank the two anonymous proofreaders whose efforts have helped to improve the text with their comments. We also express our gratitude to Dr Robert Gil Pontius for his suggestions and arguments regarding the evaluation of the results obtained. This work has been supported by Ministerio de Ciencia e Innovación (MICINN) of Spain for the project CGL2010-22189-C02. Thanks also to PCT-MAC 2007-2013 MAC/1/CD55, called SATELMAAC Project, co-financed with FEDER funds.

References

- Andrews PL (2009) BehavePlus fire modeling system, version 5.0: variables. Department of Agriculture, Forest Service, Rocky Mountain Research Station, General Technical Report RMRS-GTR-213/WWW-Revised, (Fort Collins, CO)
- Andrews PL, Queen LLP (2001) Fire modeling and information system technology. *International Journal of Wildland Fire* 10(4), 343-352. doi:10.1071/WF01033
- Aroo Md, Wildpoet W, Pérez de Paz PL, Rodríguez O, Acebes JR, García A, Martín VE, Reyes JA, Salas M, Díaz MA, Bermejo JA, González R, Cabrem MV, García S (2008) Cartografía 1:25 000 de la Vegetación Canaria. GRAFCAN S.A. (Santa Cruz de Tenerife, Spain)
- Arroyo LA, Healey SP, Cohen WB, Cocero D, Manzanera JA (2006) Using object-oriented classification and high-resolution imagery to map fuel types in a Mediterranean region. *Journal of Geophysical Research* 111, G04S04. doi:10.1029/2005JG000120
- Arroyo L, Pascual C, Manzanera J (2008) Fire models and methods to map fuel types: the role of remote sensing. *Forest Ecology and Management* 256(6), 1239-1252. doi:10.1016/j.foreco.2008.06.048
- Bagan H, Wang Q, Watanabe M, Kameyama S, Bao Y (2008) Land-cover classification using ASTER multi-band combinations based on wavelet fusion and SOM Neural Network. *Photogrammetric Engineering and Remote Sensing* 74(3), 333-342.
- Blaschke T (2010) Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65(1), 2-16. doi:10.1016/j.isprsjprs.2009.06.004
- Bugan RE, Klaver RW, Klaver JM (1998) Fuel models and fire potential from satellite and surface observations. *International Journal of Wildland Fire* 8(3), 159-170. doi:10.1071/WF990159
- Cohuzi R, DiDonna I, Lanzetta A, Lasaponara R (2007) Mapping forest fuel types by using satellite ASTER data and neural nets. *Proceedings of the Society for Photo-Instrumentation Engineers* 6742(1), 67420T. doi:10.1117/12.748033
- Falkowski M, Gestler P, Morgan P, Hudak A, Smith A (2005) Characterizing and mapping forest fire fuels using ASTER imagery and gradient modeling. *Forest Ecology and Management* 217(2-3), 129-146. doi:10.1016/j.foreco.2005.06.013
- Finney MA (2003) Calculation of fire spread rates across random landscapes. *International Journal of Wildland Fire* 12(2), 167-174. doi:10.1071/WF03010
- Finney MA (2004) FAR SITE: Fire Area Simulator - model development and evaluation. USDA Forest Service, Rocky Mountain Research Station, Research Paper RMRS-RP-4, (Ogden, UT)
- Finney MA (2006) An overview of FlamMap fire modeling capabilities. In 'Fuels management - How to Measure Success: Conference Proceedings', 28-30 March 2006, Portland, OR. (Eds PL Andrews, BW Butler)

- USDA Forest Service, Rocky Mountain Research Station, Proceedings RMRS-P-41, pp. 213–220. (Fort Collins, CO)
- Hagner O, Reese H (2007) A method for calibrated maximum likelihood classification of forest types. *Remote Sensing of Environment* 110(4), 438–444. doi:10.1016/j.rse.2006.08.017
- Huang C, Townshend JRG (2002) An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing* 23(4), 725–749. doi:10.1080/01431160110040323
- Huete AR (1989) Soil influences in remotely sensed vegetation canopy spectra. In 'Theory and Applications of Optical Remote Sensing'. (Ed. G Asar) pp. 107–141. (Wiley: New York)
- Jiang Z, Huete A, Didan K, Mian T (2008) Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment* 112(10), 3833–3845. doi:10.1016/j.rse.2008.06.006
- Keane RE, Garner JL, Schmidt KM, Long DG, Menakis JP, Finney MA (1998) Development of input data layers for the FARSITE fire growth model for the Selway-Bitterroot Wilderness Complex, USA. USDA Forest Service, Rocky Mountain Research Station, General Technical Report RMRS-GTR-3 (Ogden, UT)
- Lasaponara R, Lanorte A (2007) Remotely sensed characterization of forest fuel types by using satellite ASTER data. *International Journal of Applied Earth Observation and Geoinformation* 9(3), 225–234. doi:10.1016/j.jag.2006.08.001
- MAPA (1989) Clave fotográfica para la identificación de modelos de combustibles. ICONA, Ministerio de Agricultura, Pesca y Alimentación. (Madrid, Spain) [in Spanish]
- Martínez Chamorro J (2011) Plan de Adaptación de Canarias al Cambio Climático. (Ed. G de Canarias), Agencia Canaria de Desarrollo Sostenible y Cambio Climático (Las Palmas de Gran Canaria, Spain) [in Spanish]
- MdMA (2002) Mapa forestal de España a escala 1:50 000 de la provincia de Santa Cruz de Tenerife. Trabajos de campo realizados en el año 2002 con soporte de ortofoto digital procedente de la Comunidad Autónoma de Canarias. Ministerio de Medio Ambiente, Organismo Autónomo de Parques Nacionales, Pesca y Alimentación, Soporte CD-Rom [in Spanish]
- Mercier G, Lennon M (2003) Support vector machines for hyperspectral image classification with spectral-based kernels. In 'Geoscience and Remote Sensing Symposium, 2003. IGARSS '03. Proceedings. 2003 IEEE International', 21–25 July 2003, Toulouse, France. Vol. 1, pp. 288–290. (CNRS: Brest, France)
- MMARM (2011) Los incendios forestales en España. Área de Defensa Contra Incendios, Ministerio del Medio Ambiente, Rural y Marino. (Madrid) [in Spanish]
- Moreno JM, Rodríguez-Ubieta I, Zabala G, Martín M (2009) Cambio Climático y Riesgo de Incendios Forestales en Castilla-La Mancha. In 'Impactos del Cambio Climático en Castilla-La Mancha. Primer Informe', pp. 340–362. (Fundación General de Medio Ambiente, Junta de Comunidades de Castilla-La Mancha: Toledo) [in Spanish]
- Mutha M, Popescu SC, Zhao K (2008) Sensitivity analysis of fire behavior modeling with LiDAR-derived surface fuel maps. *Forest Ecology and Management* 256(3), 289–294. doi:10.1016/j.foreco.2008.04.014
- Pontius RG, Millones M (2011) Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing* 32(15), 4407–4429. doi:10.1080/01431161.2011.552923
- Pyne SJ, Andrews PL, Laven PD (1996) 'Introduction to Wildland Fire', 2nd edn. (Wiley: New York)
- QJ, Chehbouni A, Huete AR, Keir YH, Somoshian S (1994) A modified soil adjusted vegetation index. *Remote Sensing of Environment* 48(2), 119–126. doi:10.1016/0034-4257(94)90134-1
- Riaho D, Chuvpilo E, Salas J, Palacios-Oveta A, Bastarrika A (2002) Generation of fuel type maps from Landsat TM images and ancillary data in Mediterranean ecosystems. *Canadian Journal of Forest Research* 32(8), 1301–1315. doi:10.1139/X02-052
- Rothermel RC (1972) A mathematical model for predicting fire spread in wildland fuels. USDA Intermountain Forest and Range Experiment Station, Research Paper INT-115 (Ogden, UT)
- Rothermel RC (1983) How to predict the spread and intensity of forest and range fires. USDA Intermountain Forest and Range Experiment Station, Research Paper INT-143 (Ogden, UT)
- Rothermel RC (1991) Predicting behavior and size of crown fires in the Northern Rocky Mountains. USDA Intermountain Forest and Range Experiment Station, Research Paper INT-438 (Ogden, UT)
- Rouse JW, Haas RH, Schell JA, Deering DW (1973) Monitoring vegetation systems in the Great Plains with ERTS. In 'Third Earth Resources Technology Satellite-1 Symposium – Volume I: Technical Presentations', 10–14 December 1973, Washington, DC. (Eds SC Preiden, EP Merzanti, MA Becker) NASA, Scientific and Technical Information Office, SP-351, pp. 309–317. (Washington, DC)
- Rumelhart DE, Hinton DE, Williams RJ (1986) Learning internal representations by error propagation. In 'Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1.' (Eds DE Rumelhart, JL McClelland) pp. 318–364. (MIT Press: Cambridge, MA)
- Scott JH, Burgan RE (2005) Standard fire behavior fuel models: a comprehensive set for use with Rothermel's surface fire spread model. USDA Forest Service, Rocky Mountain Research Station, General Technical Report RMRS-GTR-153. (Fort Collins, CO)
- Smith AMS (2007) How to convert ASTER radiance values to reflectance. (University of Idaho: Moscow, ID) Available at www.cmhome.uidaho.edu/default.aspx?pid=85984 [Verified 28 August 2012]
- Tanase MA, Gitas IZ (2008) An examination of the effects of spatial resolution and image analysis technique on indirect fuel mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 1(4), 220–225. doi:10.1109/JSTARS.2009.2012475
- Tillett PM, Guindon B, Goodenough DG (1982) On the slope-aspect correction of multispectral scanner data. *Canadian Journal of Remote Sensing* 8(2), 84–106.
- Tymstra C, Bryce RW, Wotton BM, Taylor SW, Armitage OB (2010) Development and structure of Prometheus: the Canadian wildland fire growth simulation model. Natural Resources Canada, Canadian Forest Service, Northern Forestry Centre, Information Report NOR-X-417. (Edmonton, AB)
- Vapnik VN (2000) 'The Nature of Statistical Learning' 2nd edn. (Springer-Verlag Inc: New York)
- VVAA (2002) Mapa 1: 25 000 de usos del suelo. GRAFCAN S.A. (Santa Cruz de Tenerife, Spain) [in Spanish]

Anexo B

Artículo *“Fusion of WorldView-2 and LiDAR data to map fuel types in the Canary Islands”*

Este artículo ha sido publicado en Remote Sensing en agosto de 2016. Esta revista tiene un factor de impacto de **3,036** y ocupa la quinta posición de las 28 revistas de teledetección indexadas en el Journal of Citation Report Science Edition 2015.

Article

Fusion of WorldView-2 and LiDAR Data to Map Fuel Types in the Canary Islands

Alfonso Alonso-Benito ¹, Lara A. Arroyo ^{2,*}, Manuel Arbelo ¹ and Pedro Hernández-Leal ¹

¹ Earth and Atmospheric Observation Group (GOYA), Departamento de Física, Universidad de La Laguna (ULL), 38200 La Laguna, Spain; aaloben@ull.es (A.A.-B.); marbelo@ull.es (M.A.); pealvarez@ull.edu.es (P.H.-L.)

² Institute of Economy, Geography and Demography (IEGD), Spanish Council for Scientific Research (CSIC), Calle Albasanz 26-28, 28037 Madrid, Spain

* Correspondence: laranola@hotmail.com; Tel: +34-916-022-874

Academic Editors: Guoqing Zhou, Xiaofeng Li and Prasad S. Thenkabail

Received: 6 June 2016; Accepted: 16 August 2016; Published: 18 August 2016

Abstract: Wildland fires are one of the factors causing the deepest disturbances on the natural environment and severely threatening many ecosystems, as well as economic welfare and public health. Having accurate and up-to-date fuel type maps is essential to properly manage wildland fire risk areas. This research aims to assess the viability of combining Geographic Object-Based Image Analysis (GEOBIA) and the fusion of a WorldView-2 (WV2) image and low density Light Detection and Ranging (LiDAR) data in order to produce fuel type maps within an area of complex orography and vegetation distribution located in the island of Tenerife (Spain). Independent GEOBIAs were applied to four datasets to create four fuel type maps according to the Prometheus classification. The following fusion methods were compared: Image Stack (IS), Principal Component Analysis (PCA) and Minimum Noise Fraction (MNF), as well as the WV2 image alone. Accuracy assessment of the maps was conducted by comparison against the fuel types assessed in the field. Besides global agreement, disagreement measures due to allocation and quantity were estimated, both globally and by fuel type. This made it possible to better understand the nature of disagreements linked to each map. The global agreement of the obtained maps varied from 76.23% to 85.43%. Maps obtained through data fusion reached a significantly higher global agreement than the map derived from the WV2 image alone. By integrating LiDAR information with the GEOBIAs, global agreement improvements by over 10% were attained in all cases. No significant differences in global agreement were found among the three classifications performed on WV2 and LiDAR fusion data (IS, PCA, MNF). These study's findings show the validity of the combined use of GEOBIA, high-spatial resolution multispectral data and low density LiDAR data in order to generate fuel type maps in the Canary Islands.

Keywords: image-fusion; LiDAR; WorldView-2; fuel types; GEOBIA; Canary Islands

1. Introduction

Wildland fires are one of the factors causing the deepest disturbances on the natural environment and severely threatening many ecosystems, as well as economic welfare and public health [1–4]. Having up-to-date and accurate fuel type maps is fundamental to properly manage wildland fire risk areas [5,6]. Fuel types can be any part of the vegetation vulnerable to catching fire in the event of a fire. In order to define such fuels, it is necessary to know the quantity and proportion of living and dead biomass, their distribution by size, branches, leaves, trunks, etc., and their horizontal and vertical spatial distribution [7,8]. The challenge of getting this information for the entirety of the forested area makes it necessary to simplify reality through the use of fuel type classifications. Fuel types

are described as those plant associations showing the same behavior in the event of a wildland fire, including characteristic species, shapes, sizes and continuity [9]. The process of creating fuel type maps is highly complex [10–12] due to the great spatial and seasonal variability shown, which favors confusion and makes their description and classification more complicated [13]. Traditionally, this was done through field works, requiring intensive efforts in terms of means and time, as well as costs [14]. The use of aerial photography, originally used as supporting material, has been gradually adopted. In the last few decades, the integration of images and remote sensing techniques has allowed for increased updating capabilities.

Numerous works dealing with the use of images gathered from low or medium spatial resolution passive sensors for fuel type mapping have been published. Images collected from both multispectral sensors, such as Landsat-TM [15,16] or MODIS-ASTER [17–20], and hyperspectral sensors, such as Hyperion [21,22], AVIRIS [23] or MIVIS (Multispectral Infrared Visible Imaging Spectrometer) [24], have been studied. All cases show global success rates ranging from 70% to 90%. Subsequently, and after the launching of Very High spatial Resolution (VHR) commercial satellites, such as IKONOS, QuickBird or GeoEye, obtaining local fuel type maps has also been tackled, alongside the description of the wildland-urban interface [19,21,25,26]. The authors have not found any previous study on the use of WorldView-2 (WV2) towards the compilation of fuel type maps that have been published to date. This is a relatively new sensor (it was launched at the end of 2009) equipped with four new spectrum bands (coastal, red-edge, yellow and near-IR2), allowing for an enhanced sensitivity to monitor vegetation.

Passive sensors' main limitation is that they show major issues in discriminating the vertical structure of the vegetation, given their inability to go through the canopy [10,15]. The LiDAR (Light Detection and Ranging) active sensor has the ability to gather information on the vertical distribution of vegetation. It has successfully been used to assess various characteristics of forest inventories: tree height [27], timber volume [28], basal area and planting density [29], amongst others. LiDAR data have also been used to draft individual trees [30–32] and to make estimates on biomass [33] and other fuel type-related features, such as canopy height, height to the first live branch, canopy cover density or understory height [34–38].

With a view toward making the most of them and combining the perks offered by passive (both multispectral and hyperspectral) and active (primarily LiDAR) sensors separately, several works have been conducted revolving around the fusion of both types of information. Through such fusion, it becomes possible to incorporate data that are different in nature, but that complement the rest of the information in order to increase confidence, reduce ambiguity and enhance reliability on the mapping or classification [39]. Previous studies have fused multispectral (GeoEye 1, QuickBird) and hyperspectral (HyMAP, Hyperion, AISA—Airborne Imaging Spectrometer for Applications) images with LiDAR data used to map forest vegetation [40–44]. Their authors found global agreement improvements by up to 13% when working on fused images against the use of the images alone. Image-fusion has also been used to produce land use maps, resulting in increased levels of agreement by up to 18% [45–48]. AVIRIS and LiDAR images have been fused for biomass mapping purposes [49]. A disagreement reduction by 12% was found when working on fused images. Regarding LiDAR and multispectral data fusion towards fuel type mapping, certain studies have managed to improve classification agreement concerning the use of a single type of data by at least 10% [50–52]. All of the abovementioned instances used pixel-based classification algorithms.

Object-Based Image Analysis (GEOBIA) is a remote sensing technique that analyses images on the basis of groups of pixels, known as objects [53]. Despite the fact of this analysis method is rather old, its use has considerably increased in recent years as a result of the greater availability of VHR imagery. GEOBIA has proven to deliver satisfactory results when working with VHR imagery, since it makes it easier to identify elements of interest against the high spectral heterogeneity of these images [53]. Moreover, through the integration of contextual variables, it facilitates the identification of the elements

of a complex nature. Accordingly, several studies have concluded that fuel type identification is easier on objects than it is on individual pixels [19,25,54].

The main purpose of this study was to assess the potential of combining image-fusion techniques and GEOBIA on low density LiDAR data and VHR multispectral data from the WV2 sensor in order to map fuel types in a study area located on the Island of Tenerife (Canary Islands, Spain). To that end, independent GEOBIA were developed and used to generate four fuel type maps in the study area. Three GEOBIA were applied on fused LiDAR and WV2 data through the use of three image-fusion methods: Image Stack (IS), Principal Component Analysis (PCA) and Minimum Noise Fraction (MNF). The fourth map was produced from the non-fused WV2 image alone (no LiDAR data). The resulting maps were subsequently analyzed to: (1) assess and compare the quality of the various image-fusion methods in use; and (2) to compare the results obtained through the use of fused LiDAR and WV2 datasets against the use of WV2 image data on its own. The findings of this research furthermore allow us to determine the viability of using low density LiDAR and WV2 imagery towards updating fuel maps in the Canarian archipelago.

2. Study Area

The study area (Figure 1), with coordinates $28^{\circ}20'10''\text{N}$ – $16^{\circ}29'36''\text{W}$ and $28^{\circ}22'11''\text{N}$ – $16^{\circ}33'44''\text{W}$ (WGS_1984_UTM_Zone_28N), is located on the north face of the Island of Tenerife (Canary Islands, Spain). The vegetation on Tenerife Island is a climatophilous one [55]. This means that vegetation is conditioned by the dominant climatic factors in the region. Additionally, there is a direct relation between the type of vegetation and the height at which it is found and, so, of the forest fuels present, as well. The prevailing trade winds' regime blowing from NE transfer heavily humid air from the ocean to the north face of the island, where it is forced to ascend, due to the mountains, and forms clouds around a thermal inversion located on average between 800 and 1200 m above sea level (masl). Above this height, the air is drier, and the typical vegetation, mainly pine tree forests, is the same as that found on the south slope of the island at the same height.

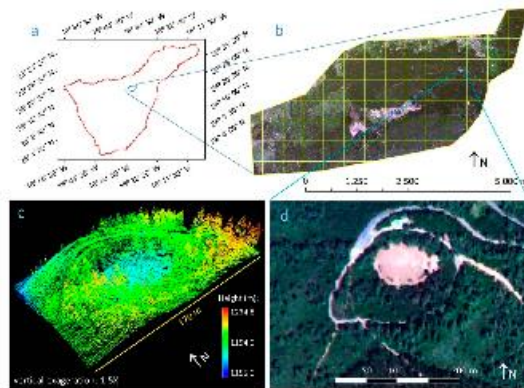


Figure 1. Study area and image datasets: (a) location of the study area within the Island of Tenerife (Canary Islands, Spain); (b) WorldView-2 (WV2) image (true color composition) of the study area; the yellow grid and red dots show the location of LiDAR scenes and field plots, respectively; the panels below show the details of the study area (a caldera formation) using (c) LiDAR; and (d) WV2 data (true color composition).

The study area belongs to La Orotava municipality and it covers 15 km². La Orotava municipality stretches from sea level to the top of Teide volcano (the highest Spanish point, at 3718 m). In other words, it is the Spanish municipality with the highest variation in height. Regarding land cover, most of La Orotava is covered by natural areas (89%), of which approximately 30% correspond to forest areas. Showing an elevation range between 800 and 1650 masl, the study area is characterized by a highly rugged terrain and the presence of numerous ravines. It covers mostly forested areas, including 38% of the total forested area of La Orotava municipality and showing the highest vegetation diversity in the region. Vegetation is distributed within two altitudinal levels: Myrica-Erica evergreen forest (*Myrica fayae-Ericion arboreae* Oberd.) and laurel forest (*Prunus hixae-Lauretalia novocanariensis* Oberd. Ex Rivas-Martínez, Amaiz, Barreno & Crespo) up to 1100 masl; altitudes above 1100 masl are dominated by formations of autochthonous Canary Pine (*Pinus canariensis* C.Sm. ex DC.), occasionally combined with stands of an introduced species, Monterey pine (*Pinus radiata* D. Don.).

3. Materials and Methods

3.1. LiDAR Data

Discrete, small-footprint and multiple-return LiDAR data were gathered by means of a Leica ALS60 sensor from July to August 2010. The sensor was mounted on a Cessna 421 Golden Eagle light aircraft, reaching a maximum flying height of 2000 m above the ground. This system received four returns per laser pulse and recorded return time and intensity (8-bit radiometric resolution). The field of vision varied between 35° and 45° with a 20% sidelap and a 1660-m full swath width. Point density by square meter averaged 2.43, showing a horizontal and vertical spatial accuracy of 60 and 20 cm, respectively. LiDAR information was provided by GRAFCAN (the company responsible for the cartography of the Canary Islands). The points provided were not classified.

A total number of 83 LiDAR scenes was used (Figure 1). Each scene was 500 × 500 m in size. The code set out by the American Society of Photogrammetry and Remote Sensing (ASPRS) was used to filter the point cloud, resulting in two point groups, (1) ground points and (2) non-ground points, shaping the vegetation.

Based on ground points, a Digital Elevation Model (DEM) with 2-m spatial resolution was derived. The DEM (Figure 2) represents the bare ground surface of the study area. The procedure used to derive the DEM is explained in detail in [56]. A Digital Surface Model (DSM) with the same spatial resolution was produced with the points corresponding to the first return. This layer represents the surface of the study area, but it also includes the top of the canopy in areas with vegetation. Next, the Canopy Height Model (CHM) was estimated as the subtraction of DSM and DEM. Thus, CHM represents the height of the canopy, estimated as the difference between the top canopy surface and the underlying ground topography [57] (Figure 2). Furthermore, 13 relative density bins of non-ground points by altitude range were calculated. Relative densities by range were estimated as the quotient between the number of non-ground points for each altitude range and the total number of non-ground points for such pixel. Eight 0.5-m altitude ranges (between 0 and 4 m), four 1.0-m ranges (from 4 to 8 m), plus one range for all points above 8 m were taken into consideration. These layers were produced with rapidlasso LAStools [58].




Figure 2. LiDAR-derived models for the study area: (left) DEM; and (right) Canopy Height Model (CHM).

3.2. Spectral Data

A WV2 satellite image was used. WV2 is a Very High spatial Resolution (VHR) commercial sensor orbiting since 2009. This sensor captures eight multispectral bands (2-m spatial resolution) and a 0.5-m panchromatic band (Table 1).

Table 1. WV2 spatial and spectral resolution (adapted from [59]).

Spectral Band	Centre Wavelength (nm)	Spectral Range (nm)	Spatial Resolution (m)
Panchromatic	632	450–800	0.5
Coastal	427	400–450	2
Blue	478	450–510	2
Green	546	510–580	2
Yellow	608	585–625	2
Red	659	630–690	2
Red Edge	724	705–745	2
NIR 1	831	770–895	2
NIR 2	908	860–1040	2

An image acquisition window was fixed over the time of duration of the field work. The WV2 image was captured on 23 June 2011. A product known as a standard “ortho-ready product” was purchased and distributed through radiometric correction, projecting over a fixed-height base plan that enabled its orthorectification. Top-of-atmosphere radiance was estimated using the method described by [59]. Next, atmospheric effects were corrected through the application of the FLAASH (Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes) [60] algorithm. Lastly, the resulting image was orthorectified using the DEM obtained from the LiDAR data (2-m spatial resolution). We used ENVI 5.3 software for the WV2 image data preprocessing. The panchromatic band was not used for the purposes of this study.

3.3. Field Data

Field work was conducted between May and August 2011. A total 83 field plots were analyzed and randomly separated into two groups: 40 training field plots and 43 validation field plots. Plots were located in each LiDAR scene’s centroid, making up a square netting of plots occurring each 500 m (Figure 1). Since vegetation in this study area is strongly influenced by bioclimatic belts and they show a clear pattern from north to south, linked to differences in elevation (see the DEM in Figure 2), this systematic sampling design is representative of the vegetation of this region. Certain plots were moved in order to cover all fuel types.

Circular plots with a 10-m radius and a 314-m² area were defined (Figure 3). A GeoExplorer GPS was used to measure the coordinates of the center of each plot, with a minimum 60 positions. A 2.5 m-high antenna was used to improve signal reception under the canopy cover. Within each plot, four 10-m transects were taken, according to the N, S, E and W directions. For each transect, measurements of each meter were taken, detailing: the presence/lack of vegetation cover, the species found, the vegetation height and the presence/lack of gaps between the understory and the canopy. Heights were measured using a Vertex Laser II digital hypsometer from Haglöf Sweden AB. Photographs of each transect were also taken as ancillary information for the identification of fuel types.




Figure 3. Field data collection: (left) photograph of a field plot; (right) diagram of a field plot. Each field plot had 4 transects according to the N, S, E and W directions. Measurements were taken at each m within these transects. The location of each field plot was assessed at its center (red cross).

Using the information collected in the field, the fuel type corresponding to each plot was determined. The Prometheus Fuel Type (PFT) classification [14] was used as a model to identify the following fuel types according to horizontal and vertical vegetation structure:

- PFT1 (grass cover >50%): this category is primarily comprised by herbaceous vegetation and agricultural vegetation.
- PFT2 (shrub cover >60%, tree cover <50%): this category includes herbaceous vegetation and brushwood under 60 cm in height, as well as logging zones, where there are still remains of them.
- PFT3 (shrub cover >60%, tree cover <50%): areas showing medium-sized shrubs at or under 2 m in height
- PFT4 (shrub cover >60%, tree cover <50%): areas showing big shrubs over 2 m tall and under the 4-m mark. This fuel type includes areas where young trees resulting from natural or artificial regeneration (by repopulation) occur.
- PFT5 (shrub cover <30%, tree cover >50%): forested areas dominated by tree cover with little or no understory.
- PFT6 (shrub cover >30%, tree cover >50%): forested areas showing either understory or logging residues where vertical distance between these and the trees' first live branch is less than 0.5 m.
- PFT7 (shrub cover >30%, tree cover >50%): forested areas showing either understory or logging residues where vertical distance between these and the trees' first live branch goes beyond 0.5 m, thus facilitating the vertical continuity of fires and favoring canopy fires.

For the study area, PFT1 was allocated in the areas where grasses start to take over bare grounds, agricultural vegetation and ravine beds with the occurrence of rupicolous vegetation comprised by species of the *Aeonium* spp., *Aichryson* spp. and *Sonchus* spp. genus. PFT2 was connected to areas of higher human impact, with an abundance of grass pastures dominated by buffelgrass (*Cenchrus ciliaris* L.), common thatching grass (*Hyparrhenium hirta* (L.) Stapf), sage bush (*Artemisia thussulae* Cav.) and tree sorrel (*Rumex lunaria* L.). PFT3 corresponded to areas with a dominating presence of wild blackberry (*Rubus inermis* Pourr.) and bracken (*Pteridium aquilinum* (L.) Kuhn in Kersten) forming transitional communities towards more complex shrub formations. PFT4 was linked to brushwoods mainly formed by Montpellier cistus (*Cistus monspeliensis* L.), Canary Island flatpod (*Adenocarpus foliolosus* (Ait.) DC.) and bracken (*Pteridium aquilinum* (L.) Kuhn in Kersten), amongst other species. PFT5 matched the masses of Canary Pine (*Pinus canariensis* C.Sm. ex DC.) with no understory. Finally, PFT6 and PFT7 were found to be connected to Canary Pine forest formations showing a Myrica-Erica evergreen forest understory, laurel forests and natural regeneration of the pine forest itself. The difference between these two fuel types depended on whether or not there was

vertical continuity from the understory to the tree layer. Figure 4 shows examples of PFT identified within the study area.



Figure 4. Examples of Prometheus Fuel Types (PFT) found for the study area: (a) PFT1; (b) PFT2; (c) PFT3; (d) PFT4; (e) PFT5; (f) PFT6; (g) PFT7.

3.4. Image Data Fusion and GEOBIA Fuel Type Mapping

After data acquisition and pre-processing, three fusion methods were applied to combine the information from the LiDAR and WV2 imagery. The following fusion methods were used: IS, PCA and MNE. Then, the created image-fusion datasets, plus the WV2 image alone, were incorporated into four independent GEOBIAs to map the PFTs of the study area. Field work data were used for training the GEOBIA classifications and assessing the accuracies of the obtained fuel type maps. Field plots used for training were not used for validation. The classification of the field plots into those used for training and those used for validation was done randomly. Figure 5 displays the workflow used in the completion of this research work.

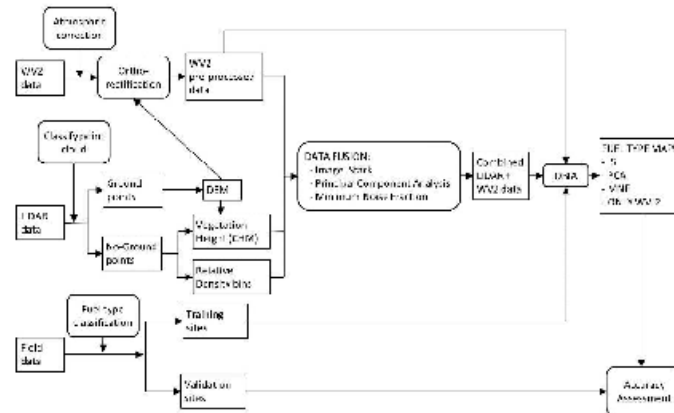


Figure 5. Workflow used in the completion of this study. OBIA, Object-Based Image Analysis; MNF, Minimum Noise Fraction.

We used the software ENVI (Version 5.3) for image-fusion. An image dataset showing 22 bands and a spatial resolution of 2 m was produced for the IS fusion. Bands resulting from LiDAR information were directly merged with the pre-processed bands from the WV2 sensor. This way, the new image comprised 8 multispectral bands derived from the WV2 image and 14 bands obtained from the LiDAR data (13 for relative density by altitude range bins and the CHM).

The PCA method makes it possible to decrease the number of bands in the IS image dataset, in exchange for a small loss of information [61]. Statistics show that PCA will seek to accurately represent, whenever possible, the original information through a lesser number of bands, built as linear combinations of the original [62]. This allows the new bands to explain as much total variability as possible, where there is no correlation. The fused PCA image was comprised of the first 5 PCA bands, which explained 99.47% of the total variability of the IS image dataset.

The MNF method also attempted to reduce the number of bands in the IS image dataset by transforming its original bands. In this case, fused bands were estimated as the linear combinations maximizing the signal-to-noise ratio, thus minimizing existing noise [63]. For the MNF image-fusion, the first eight MNF bands were selected. These explained 99.3% of the variance in the IS image dataset.

Three fuel type maps were independently obtained from the three-image dataset created in the data fusion processes (IC, PCA and MNF). A further fourth fuel map was produced from the WV2 image in order to enable the comparison of results found against the classifications obtained from non-merged information.

All classifications were conducted with GEOBIA, using Definiens 8.64 software. First, the image was divided into objects. This process started with one-pixel objects and gradually moved on to their attachment to adjacent objects [64]. Object internal heterogeneity was estimated by allocating weights equivalent to 0.8 for the color parameter and 0.2 for the shape parameter (0.3 and 0.7 for smoothness and compactness, respectively). The most suitable scale parameter was assessed through trial and error testing conducted until segmentation according to the features of each fuel type was achieved. Scale parameter values of 45, 45, 90 and 100 were set up for the IS, MNF, WV2-alone and PCA datasets,

respectively. Image segmentation of the four datasets is shown in Figure 6. Segmentation included a thematic layer demarcating the testing plots so as to ensure their observation.




Figure 6. Results of image segmentation for the four datasets: (a) WV2; (b) Image Stack (IS); (c) PCA; and (d) MNE. All results are shown on top of the WV2 image (false color).

The next step was to classify the fuel types. Seven thematic classes were defined, in accordance with the fuel types included in the Prometheus classification. The Nearest Neighbor (NN) classifier implemented on eCognition software was used during the allocation phase. The GEOBIA NN classifier performs a supervised classification. It applies the same strategy as the pixel-based NN classifier. The only difference is that it uses objects instead of pixels; this means that object-based features, such as those related to internal variability within the object, can be considered for the classification. First, the classifier was trained with the 40 field plots set aside for this task. The same field plots were used for the four classifications. Then, the classifier assigned each object in the image to a Prometheus fuel type, based on its minimum distance to the training samples. Distances were estimated taking into consideration the following objects-based features: average values in all bands, standard deviation in all bands, brightness and maximum difference. The same features were used for the four classifications. Lastly, adjacent objects allocated to the same fuel type were merged in order to homogenize the final map.

3.5. Accuracy Assessment

Accuracy of the resulting maps was assessed through overall agreement analyses and the estimation of overall quantity and allocation disagreements, as suggested by [65–67]. The field plots reserved for accuracy assessment were used for this part of the analysis. Quantity disagreement refers to the differences between the obtained map and the reference data (i.e., field data) in the surface covered by the fuel types. Allocation disagreement is related to the differences between the obtained

map and the reference data in the spatial distribution of fuel types. Overall disagreement is the sum of overall quantity disagreement and overall allocation disagreement; and is complementary to the overall agreement. Map accuracy was also analyzed per category. Thus, relative allocation disagreement and relative quantity disagreement were estimated for each fuel type. These per-category disagreement measures are similar to those used to assess the maps' global accuracies. The only difference lies in the fact that such by-category estimations were related (i.e., they were assessed considering the total area covered by each category in the map), so as to enable comparison of results across categories. See [67] for more details.

From the 83 field plots, 43 were set aside and used for disagreement estimation tasks. Each plot was linked to a 10×10 pixel window. Fuel types are complex elements, and so, they cannot be assessed for very small areas, or individual pixels. The vertical and horizontal structure of vegetation needs to be taken into consideration. For that reason, fuel types were estimated on field plots larger than the pixel size. Although the field plots size was slightly smaller than 10×10 pixels (314 m^2 instead of 400 m^2), we deemed it appropriate to use such a window size, since boundaries between fuel types are fuzzy, meaning that the inclusion of a small buffer around each field plot would not affect the results of the accuracy assessment. Fuel types identified in the field for these plots were compared to the results corresponding to the four maps obtained.

Finally, we used McNemar's test [68,69] to assess whether the differences observed in overall accuracy were significant. This statistical test was chosen because it is suitable for comparing thematic maps when the same set of field sites is used for the accuracy assessment. We used the following test equation:

$$\chi^2 = \frac{(|f_{CI} - f_{IC}| - 1)^2}{f_{CI} + f_{IC}}$$

where:

- f_{CI} is the number of sites correctly assigned in Map 1 and incorrectly assigned in Map 2
- f_{IC} is the number of sites incorrectly assigned in Map 1 and correctly assigned in Map 2

The derived values were compared against the chi-squared distribution and a statistical significant value of 0.05.

4. Results

Four fuel type maps were created, three resulting from image-fusion datasets (IS, PCA and MNF) and another one from the WV2 image alone (Figure 7). Figure 8 shows the relative surface covered by each fuel type in all four maps.

Results are similar across all classifications. PFT7 is the fuel type covering a greater surface, taking up a relative surface of over 30% in all cases. This fuel type corresponds to the greenwood and Myrica-Erica evergreen forest bordering agricultural vegetation areas found in the northeastern segment of the study area and to canary pine forests in the central segment. Higher altitude areas, located in the southern segment of the study area, are primarily covered in canary pine forests with no understory, largely allocated to PFT5. This fuel type takes up from 22% to 30% of the field of study, according to the various classifications. The remaining fuel types are less abundant and more or less disaggregated over the study area. Visually, the most remarkable differences can be identified in the map resulting from MNF image-fusion, which shows a more homogeneous appearance, with larger polygons. Thus, the average size of polygons in the map resulting from MNF image-fusion virtually doubles that of the rest of the maps. Furthermore, surfaces covered by PFT4 and PFT5 in the MNF-derived map are larger than those in the other maps, whereas the surface allocated to PFT7 is noticeably smaller.




Figure 7. Fuel type maps obtained for the four image datasets: (a) WV2; (b) IS; (c) PCA; (d) MNE.




Figure 8. Relative area covered by each PFT for the four fuel type maps (WV2, IS, PCA and MNE).

Global agreement for maps obtained varies from 76.23% to 85.43% (Table 2). The lowest global agreement obtained corresponded to the map produced from the WV2 image alone, totaling 76.23%. McNemar's tests confirmed that differences found in global agreement for the WV2-derived map and the ones obtained from the three image-fusion databases were significant in all cases (p -value of 0.05). Maps produced by means of image-fusion showed a global agreement ranging from 84.27% to 85.43%. Differences in global agreement across the three tested fusion methods were not significant in any case, according to McNemar's tests. Allocation and quantity components of error were estimated so as to enable the analysis of any disagreements found (Table 2). The overall quantity disagreement tells us the extent to which the proportions of fuel types found for each map differ from the real proportion of fuel types (based on field assessment); and overall allocation disagreement shows the degree to which geographical distribution of fuel types by maps is different from the actual location of fuel types in the study area (based on field measurements). Maps produced from MNE and IS datasets showed less quantity disagreement than allocation disagreement, with almost double error due to the wrong allocation of fuel types. This uneven distribution of error components was not seen in maps produced from PCA and WV2.

Table 2. Overall and per-fuel type measures of accuracy (overall and relative quantity disagreement; overall and relative allocation disagreement) for the four fuel type maps (values in %).

	WV2		IS		PCA		MNF	
	Quantity	Allocation	Quantity	Allocation	Quantity	Allocation	Quantity	Allocation
PFT1	0.61	1.50	0.08	1.95	2.03	2.45	0.11	0.00
PFT2	1.86	2.61	0.92	5.28	3.25	1.11	0.47	0.00
PFT3	5.92	0.00	2.03	3.39	0.64	2.06	3.11	0.00
PFT4	3.59	1.11	0.14	2.45	1.64	6.51	1.70	1.06
PFT5	1.78	12.18	3.28	1.56	2.28	0.00	1.75	6.62
PFT6	5.81	2.11	2.67	0.44	2.98	0.00	0.78	5.56
PFT7	3.89	4.56	1.50	5.78	0.36	4.84	1.81	6.17
Overall	11.73	12.04	5.31	10.42	6.59	8.48	4.87	9.71

Besides global disagreement measures, quantity and allocation disagreement for each fuel type were estimated across all four maps (Table 2). Rather than absolute measures, we used their relative versions in order to be able to compare fuel types [67]. PFT1 was the fuel type showing fewer disagreements, with values under 2.5% in all cases. This fuel type is basically comprised of herbaceous vegetation and agricultural vegetation, which was identified accurately both in the WV2 image alone and in the three LiDAR-fused datasets. At the other end of the spectrum, the fuel type showing a higher disagreement rate was PFT7, corresponding to dense canary pine formations and *Myrica-Erica* evergreen understory. Disagreement in PFT7 identification occurred across all maps, both in the WV2 image alone and in the three fusion datasets. Regarding classification on the WV2 image, optical information did not lead to obtaining information on vegetation occurring under the tree cover. In terms of classifications on image-fusion, this can probably be explained by the low point density of LiDAR data, which proved insufficient in certain cases. In areas of dense canopy cover, the number of returns originated in the ground and lower strata noticeably decreased, making it difficult to tell these different fuel types apart.

By analyzing disagreement by categories, a more detailed study of the selective goodness-of-fit of each method for each fuel type was possible. When comparing the results of the WV2 classification against the WV2 and LiDAR fusions, the biggest differences in disagreement were found in Fuel Types 5 to 7. Differences were not as marked in remaining fuel types. Indeed, they were non-existent in certain cases. This way, PFT1 and PFT2 showed similar or lower disagreement rates on the map derived from the WV2 image than on those from IS and PCA datasets. Based on this finding, optical information gathered by the WV2 was enough to identify those fuel types without canopy cover. Contextual information, entered in the system through GEOBIA, made this possible. In order to identify other fuel types, on the other hand, the lack of information on the vertical distribution of the vegetation proved particularly limiting. Another noteworthy fact is that agreement reached by the classification on the MNF dataset was biased towards herbaceous or shrub fuel types. For the MNF fusion, LiDAR information provided the identification for fuel types without tree cover, but it barely showed any improvements on the WV2-based classification concerning the rest of the fuel types. Thus, when comparing the three fusions, the classification on the MNF image-fusion resulted in the lowest disagreement rates across all fuel types without tree cover (PFT 1 to 4) and the highest disagreement rates for fuel types including tree cover (PFT 5 to 7). Given that all three fusion methods are initially based on the same information, this difference can only be due to the merging process itself. Nonetheless, the knowledge of the disagreement distribution in the produced maps is vital: (1) when choosing the most suitable mapping method, according to the specific objectives of each project; and (2) towards learning about the disagreements that can be expected with each method.

5. Discussion

The results of this study corroborate the ability of GEOBIA to differentiate complex elements, such as fuel types, on high spectral heterogeneity data, such as VHR imagery. Introducing context features into the analysis aided in the identification of PFT. Image segmentation further allowed converting the original working scale, imposed by the image's spatial resolution, into a working scale suited for the purposes of this research (i.e., fuel type identification). Previous similar researches conducted on different types of images and fields of study have nonetheless led to much the same conclusions [19,25,54].

Global agreement values across all maps improved by at least 10% once information on the vertical distribution of vegetation was incorporated by means of fusion with LiDAR data. It should be noted that this significant improvement in the maps' accuracy was achieved through the use of medium-to-low density LiDAR data (2.43 points/m²) gathered in a study area of highly complex orography. Previous studies had shown that the combined use of optical and LiDAR information allows for improved fuel type identification [50–52]. Generally speaking, global agreement values were similar and, on occasion, even higher than those reached in this study. Nonetheless, for the most part, these were obtained with better-quality information (i.e., higher spatial and spectral resolution of optical images and higher point density in LiDAR data). In the study presented by [50], for example, a support vector machine classification combining imagery from Airborne Thematic Mapper (10 spectral bands with 2-m spatial resolution) and LiDAR imagery produced fuel maps showing 89% accuracy when using fusing. Similar improvement in results were found by other authors when classifying fuel types on image-fused QuickBird and LiDAR datasets rather than against the QuickBird image alone [51]. The abovementioned researchers obtained a 90% global agreement in the classification of an MNF image-fusion; an edge of almost 5% as compared to this research's results. However, as pointed out by [52], such positive results might be explained by the characteristics of the study area, an area of no orographic complexity and the fewer fuel types occurring within it. For an orographically-complex region, 76% global agreement has been obtained by combining four-band multispectral imagery from the National Agricultural Imagery Program with low point density LiDAR data [52].

The developed methodology could be applied to larger areas on the north face of Tenerife Island and with similar elevation, where vegetation is strongly influenced by the climatic conditions imposed by elevation and the trade winds. This situation actually affects the entire forest surface on the island of Tenerife, as well as the remaining occidental islands of the Canary archipelago (Gran Canaria, La Palma, La Gomera and El Hierro). In other words, this methodology could potentially be used to generate fuel type maps of the forested areas of all of these islands. For those areas not influenced by trade winds, vegetation is very different due to the lack of humidity. For those areas, this methodology might not be suitable. Variability in vegetation may become too large, and the systematic sampling design for field plots may not be representative.

The results of this study could become a very important tool for fire fighters and other forest managers in the region. Accurate and up-to-date fuel type maps are a very valuable source of information for the forest fire prevention planning (e.g., preventive silvicultural treatments), as well as for the firefighting implementation systems. For all of the above-mentioned islands, fuel maps have not been updated in more than 10 years. Moreover, these maps do not show the spatial resolution obtained through the fusion of WV-2 and LiDAR, nor do they cover the whole area that could be affected by the great forest fires that ravage our islands, such as the concurrent ones in the summer of 2007 in Tenerife and Gran Canaria, which burnt 16,820 and 18,762 ha, respectively.

No evidence has been found pointing at a fusion method prevailing over the others in terms of global agreement reached. We can therefore assume that the differences found are simply due to chance. Consequently, choosing the best fusion method for any given research may essentially depend on the specific purposes of each project, as well as on the means available to it (i.e., processing time and software required for each fusion technique). However, when allocation and quantity components of error were estimated, the differences were most evident. Maps created from MNF and IS (i.e., with a

lower overall quantity disagreement) would be especially suitable for studies aiming to analyze the evolution of fuels over time, for instance. The PCA fusion method would be recommended when the exact spatial location of the various fuel types is needed. This would be the case of any study targeting decision-making on early detection and active fire control, in order to determine the appropriate location for watchtowers, for example. In line with factors discussed in previous sections, LiDAR fusion would be recommended in all cases, since maps produced by the WV2 image alone cause a higher disagreement rate both in quantity and allocation.

6. Conclusions

In the course of this study, we have assessed the viability of combining GEOBIA and VHR multispectral imagery (WV2) and discrete low-density LiDAR data aiming to obtain fuel type maps in the Canary Islands. To that end, four independent GEOBIAs were produced by means of three fused images (IS, PCA and MNF) and one non-fused WV2 image. Global agreement of the resulting maps has exceeded 75% in all cases. These results corroborate the ability of GEOBIA to differentiate complex elements, such as fuel types, on high spectral heterogeneity imagery.

Maps obtained through WV2 and LiDAR data fusion reached a significantly higher global agreement versus those generated by the WV2 image alone. By integrating LiDAR information with the GEOBIAs, global agreement improvements by over 10% were attained in all cases. Such results are especially relevant when considering the nature of the LiDAR information used. In contrast with other studies conducted with full-wave, higher point density LiDAR information, this research has been based on low point density LiDAR data. This information was used due to it being a database accessible and free of charge throughout the Canarian territory. Therefore, we did not incur any costs to use it.

All three fusion methods used in this study (IS, PCA and MNF) provide similar results, and we were unable to identify major differences in global agreement values. Any of the above can be used with an expected disagreement rate of approximately 15%. Concerning the choice of any of them for a specific project, the particular purposes of each specific project should be taken into consideration. For that purpose, we suggest a detailed assessment of per-fuel type quantity and allocation disagreement.

One of the main limiting factors facing the production of fuel maps in the Canary Islands is the presence of areas of great orographic complexity paired with dense canopy covers of over 30 m in height. Such characteristics decrease the efficacy of LiDAR data to represent the vertical structure of vegetation, especially when working with low point density data. What is more, the occurrence of ravines and highly rugged terrain causes shading effects, which are also difficult to correct in the optical imagery, besides impacting image geometric correction. All of the above negatively affect fuel type identification. The findings of this research work show that it is possible to minimize such limitations through the combined use of GEOBIA and WV2 and LiDAR fusion. This methodology could potentially be used to generate fuel type maps of the forested areas of all of the occidental islands of the Canary Archipelago.

Acknowledgments: We thank Alejandro Lorenzo-Gil for preprocessing the LiDAR data and Laia Núñez for her assistance in the field. Thanks to Mar Brito for editing the manuscript and improving the use of English. LiDAR data were coded by GRAFCAN. We wish to thank the peer reviewers for their valuable comments and suggestions. This work has been funded by the Ministerio de Economía y Competitividad CGL2013-48202-C2 project. The research of L. A. Aroyo was supported by the JAE-Doc Program (Junta para la Ampliación de Estudios), financed by the Spanish National Research Council (CSIC) and the European Social Fund (ESF).

Author Contributions: A.A., L.A., M.A. and P.H. conceived of and designed the experiments. A.A. carried out the field work. A.A., L.A. and M.A. analyzed the data. A.A., L.A., M.A. and P.H. wrote the paper.

Conflicts of Interest: The authors declare no conflict of interest. The founding sponsors had no role in the design of the study; in the collection, analyses or interpretation of the data; in the writing of the manuscript; nor in the decision to publish the results.

References

- Bond, W.J.; van Wilgen, B.W. *Surviving Fires-Vegetative and Reproductive Responses*; Springer Science & Business Media: London, UK, 1996; pp. 34–51.
- Pyne, S.J. *Year of the Fires: The Story of the Great Fires of 1910*; Mountain Press Publishing Company: New York, NY, USA, 2001; p. 325.
- Moore, P. Fire management: Imbalanced and misunderstood? In Proceedings of the Forests, Wood and Livelihoods: Finding a Future for All Conference, Canberra, Australia, 16 August 2005; pp. 67–73.
- Goldammer, J.G. Fire ecology of the recent Anthropocene. In *Earth System Science in the Anthropocene: Emerging Issues and Problems*; Ehlers, E., Kraft, T., Eds.; Springer: Berlin/Heidelberg, Germany; New York, NY, USA, 2006; pp. 63–85.
- Chuvieco, E.; Congalton, R.G. Application of remote sensing and geographic systems to forest fire hazard mapping. *Remote Sens. Environ.* **1989**, *29*, 147–159. [[CrossRef](#)]
- Chuvieco, E.; Wagtendok, J.; Riaño, D.; Yebra, M.; Ustin, S. Estimation of fuel conditions for fire danger assessment. In *Earth Observation of Wildland Fires in Mediterranean Ecosystems*; Chuvieco, E., Ed.; Springer: Berlin/Heidelberg, Germany, 2009; pp. 83–96.
- Burgan, R.E.; Klaver, R.W.; Klaver, J.M. Fuel model and fire potential from satellite and surface observations. *Int. J. Wildland Fire* **1998**, *8*, 159–170. [[CrossRef](#)]
- Andrews, P.L.; Queen, L.P. Fire modeling and information system technology. *Int. J. Wildland Fire* **2001**, *10*, 343–352. [[CrossRef](#)]
- Merrill, D.F.; Alexander, M.E. *Glossary of Forest Fire Management Terms*, 4th ed.; National Research Council of Canada, Canadian Committee on Forest Fire Management: Ottawa, ON, Canada, 1987.
- Keane, R.E.; Burgan, R.E.; van Wagtendok, J. Mapping wildland fuel for fire management across multiple scales: Integrating remote sensing, GIS, and biophysical modeling. *Int. J. Wildland Fire* **2001**, *10*, 301–319. [[CrossRef](#)]
- Sandberg, D.V.; Ottmar, R.D.; Cushor, G.H. Characterizing fuels in the 21st century. *Int. J. Wildland Fire* **2001**, *10*, 381–387. [[CrossRef](#)]
- Ottmar, R.D.; Alvarado, E. *Linking Vegetation Patterns to Potential Smoke Production and Fire Hazard*; General Technical Report. Department of Agriculture: Albany, CA, USA, 2004; pp. 93–96.
- Keane, R.E.; Reeves, M. Use of expert knowledge to develop fuel maps for Wildland fire management. In *Expert Knowledge and Its Application in Landscape Ecology*; Perera, A.H., Drew, C.A., Johnson, C.J., Eds.; Springer: New York, NY, USA, 2012; pp. 211–228.
- Arroyo, L.A.; Pascual, C.; Manzanera, J.A. Fire models and methods to map fuel types: The role of remote sensing. *For. Ecol. Manag.* **2008**, *256*, 1239–1252. [[CrossRef](#)]
- Riaño, D.; Chuvieco, E.; Salas, J.; Palacios-Orueta, A.; Bastarrica, A. Generation of fuel type maps from Landsat TM images and ancillary data in Mediterranean ecosystems. *Can. J. For. Res.* **2002**, *32*, 1301–1315. [[CrossRef](#)]
- Rollins, M.G.; Frame, C.K. *The LANDFIRE Prototype Project: Nationally Consistent and Locally Relevant Geospatial Data for Wildland Fire Management*; U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station: Fort Collins, CO, USA, 2006; p. 416.
- Falkowski, M.J.; Gessler, P.E.; Morgan, P.; Hudak, A.T.; Smith, A.M.S. Characterizing and mapping forest fire fuels using ASTER imagery and gradient modeling. *For. Ecol. Manag.* **2005**, *217*, 129–146. [[CrossRef](#)]
- Lasaponara, R.; Lanorte, A. Remotely sensed characterization of forest fuel types by using satellite ASTER data. *Int. J. Appl. Earth Obs. Geoinf.* **2007**, *9*, 225–234. [[CrossRef](#)]
- Alonso-Benito, A.; Arroyo, L.A.; Arbelo, M.; Hernández-Lea, P.; González-Calvo, A. Pixel and object-based classification approaches for mapping forest fuel types in Tenerife Island from ASTER data. *Int. J. Wildland Fire* **2013**, *22*, 306–317. [[CrossRef](#)]
- Bajocco, S.; Dragoz, E.; Gitas, I.; Smiraglia, D.; Salvati, L.; Ricotta, C. Mapping Forest Fuels through Vegetation Phenology: The Role of Coarse-Resolution Satellite Time-Series. *PLoS ONE* **2015**, *10*, e0119811. [[CrossRef](#)] [[PubMed](#)]
- Mallinis, G.; Galidaki, G.; Gitas, I. A Comparative Analysis of EO-1 Hyperion, Quickbird and Landsat TM Imagery for Fuel Type Mapping of a Typical Mediterranean Landscape. *Remote Sens.* **2014**, *6*, 1684–1704. [[CrossRef](#)]

22. Keramitsoglou, I.; Kontoes, C.; Sykioti, O.; Sifakis, N.; Xofis, P. Reliable, accurate and timely forest mapping for wildfire management using ASTER and Hyperion satellite imagery. *For. Ecol. Manag.* **2008**, *255*, 3556–3562. [[CrossRef](#)]
23. Jia, G.J.; Burke, I.C.; Goetz, A.F.H.; Kaufmann, M.R.; Kindel, B.C. Assessing spatial patterns of forest fuel using AVIRIS data. *Remote Sens. Environ.* **2006**, *102*, 318–327. [[CrossRef](#)]
24. Lasaponara, R.; Lanorte, A.; Pignatti, S. Multiscale Fuel Type Mapping in Fragmented Ecosystems: Preliminary Results from Hyperspectral MIVIS and Multispectral Landsat TM data. *Int. J. Rem. Sens.* **2006**, *27*, 587–593. [[CrossRef](#)]
25. Arroyo, L.A.; Healey, S.P.; Cohen, W.B.; Cocero, D.; Marzanera, J.A. Using object-oriented classification and high-resolution imagery to map fuel types in a Mediterranean region. *J. Geophys. Res.* **2006**, *111*. [[CrossRef](#)]
26. Gitas, I.Z.; Mitri, G.H.; Kazakis, G.; Ghosh, D.; Xanthopoulos, G. Fuel type mapping in Annapolis, Crete by employing QuickBird imagery and object-based classification. *For. Ecol. Manag.* **2006**, *234*. [[CrossRef](#)]
27. Hollaus, M.; Wagner, W.; Eberhöfer, C.; Karel, W. Accuracy of large-scale canopy heights derived from LiDAR data under operational constraints in a complex alpine environment. *ISPRS J. Photogramm. Remote Sens.* **2006**, *60*, 323–338. [[CrossRef](#)]
28. Hyypää, J.; Kelle, O.; Lehtikoinen, M.; Inkinen, M. A segmentation-based method to retrieve stem volume estimates from 3-D tree height models produced by laser scanners. *IEEE Trans. Geosci. Remote Sens.* **2001**, *39*, 969–975. [[CrossRef](#)]
29. Hudak, A.T.; Crookston, N.L.; Evans, J.S.; Hall, D.E.; Falkowski, M.J. Nearest neighbor imputation of species-level, plot-scale forest structure attributes from LiDAR data. *Remote Sens. Environ.* **2008**, *112*, 2232–2245. [[CrossRef](#)]
30. Chen, Q.; Baldocchi, D.; Gong, P.; Kelly, M. Isolating individual trees in a savanna woodland using small footprint LiDAR data. *Photogramm. Eng. Remote Sens.* **2006**, *72*, 923–932. [[CrossRef](#)]
31. Kaartinen, H.; Hyypää, J.; Yu, X.; Vastaranta, M.; Hyypää, H.; Kukko, A.; Markus, H.; Heipke, C.; Hirschmugl, M.; Morsdorf, F.; et al. An international comparison of individual tree detection and extraction using airborne laser scanning. *Remote Sens.* **2012**, *4*, 950–974. [[CrossRef](#)]
32. Zhang, C.; Zhou, Y.; Qiu, F. Individual tree segmentation from LiDAR point clouds for urban forest inventory. *Remote Sens.* **2015**, *7*, 7892–7913. [[CrossRef](#)]
33. Naesset, E.; Gobakken, T. Estimation of above- and below-ground biomass across regions of the boreal forest zone using airborne laser. *Remote Sens. Environ.* **2008**, *112*, 3079–3090. [[CrossRef](#)]
34. Riaño, D.; Meier, E.; Allgower, B.; Chuvieco, E.; Ustin, S.L. Modeling airborne laser scanning data for the spatial generation of critical forest parameters in fire behaviour modeling. *Remote Sens. Environ.* **2003**, *86*, 177–186. [[CrossRef](#)]
35. Andersen, H.E.; McGaughey, R.J.; Reutebuch, S.E. Estimating forest canopy fuel parameter using LiDAR data. *Remote Sens. Environ.* **2005**, *94*, 441–449. [[CrossRef](#)]
36. Popescu, S.C.; Zhao, K. A voxel-based LiDAR method for estimating crown base height for deciduous and pine trees. *Remote Sens. Environ.* **2008**, *112*, 767–781. [[CrossRef](#)]
37. Erdody, Y.; Moskal, L.M. Fusion of LiDAR and Imagery for Estimating Forest Canopy Fuels. *Remote Sens. Environ.* **2010**, *114*, 725–737. [[CrossRef](#)]
38. Gatzliolis, D. Dynamic range-based intensity normalization for airborne, discrete return LiDAR data for forest canopies. *Photogramm. Eng. Remote Sens.* **2011**, *77*, 251–259. [[CrossRef](#)]
39. Rogers, R.H.; Wood, L. *The History and Status of Merging Multiple Sensor Data: An Overview*; Technical Report for 1990 ACSMASPRS Annual Conference: Denver, CO, USA, 1990; pp. 352–360.
40. Arroyo, L.A.; Johansen, K.; Armston, J.; Phinn, S. Integration of LiDAR and QuickBird imagery for mapping riparian biophysical parameters and land cover types in Australian tropical savannas. *For. Ecol. Manag.* **2010**, *259*, 598–606. [[CrossRef](#)]
41. Dalponte, M.; Bruzzone, L.; Gianelle, D. Fusion of hyperspectral and LiDAR remote sensing data for classification of complex forest areas. *IEEE Trans. Geosci. Remote Sens.* **2008**, *46*, 1416–1427. [[CrossRef](#)]
42. Dalponte, M.; Bruzzone, L.; Gianelle, D. Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. *Remote Sens. Environ.* **2012**, *123*, 258–270. [[CrossRef](#)]

43. Ghosh, A.; Fassnacht, F.E.; Joshi, P.K.; Koch, B. A framework for mapping tree species combining hyperspectral and LiDAR data: Role of selected classifiers and sensor across three spatial scales. *Int. J. Appl. Earth Obs. Geoinf.* **2014**, *26*, 49–63. [CrossRef]
44. Stavrakoudis, D.G.; Dragozi, E.; Gitas, I.Z.; Karydas, C. Decision fusion based on hyperspectral and multispectral satellite imagery for accurate forest species mapping. *Remote Sens.* **2014**, *6*, 6897–6928. [CrossRef]
45. Huang, X.; Zhang, L. Comparison of vector stacking, multi-SVMs fuzzy output, and multi-SVMs voting methods for multiscale VHR urban mapping. *IEEE Geosci. Remote Sens. Lett.* **2010**, *7*, 262–266.
46. Huang, X.; Zhang, L. A multilevel decision fusion approach for urban mapping using very-high-resolution multi/hyper-spectral imagery. *Int. J. Remote Sens.* **2012**, *33*, 3354–3372. [CrossRef]
47. Huang, X.; Zhang, L.; Gong, W. Information fusion of aerial images and LiDAR data in urban areas: Vector stacking, re-classification, and post-processing approaches. *Int. J. Remote Sens.* **2011**, *32*, 69–84. [CrossRef]
48. Pedergnana, M.; Marpu, P.R.; Dalla Mura, M.; Benediktsson, J.A.; Brazzzone, L. Fusion of hyper-spectral and LiDAR data using morphological profiles. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2015**, *8*, 2971–2983.
49. Swatantran, A.; Dubayah, R.; Roberts, D.; Hofton, M.; Blair, J.B. Mapping biomass and stress in the Sierra Nevada using LiDAR and hyperspectral data fusion. *Remote Sens. Environ.* **2011**, *115*, 2917–2930. [CrossRef]
50. García, M.; Riaño, D.; Chuvieco, E.; Salas, J.; Mark Danson, F. Multispectral and LiDAR data fusion for fuel type mapping using Support Vector Machine and decision rules. *Remote Sens. Environ.* **2011**, *115*, 1369–1379. [CrossRef]
51. Muthu, M.; Popescu, C.S.; Stripling, C.; Spencer, Y. Mapping surface fuel models using LiDAR and multispectral data fusion for fire behavior. *Remote Sens. Environ.* **2008**, *112*, 274–285. [CrossRef]
52. Jakubowski, M.K.; Guo, Q.; Collins, B.; Stephens, S.; Kelly, M. Predicting surface fuel models and fuel metrics using LiDAR and CIR imagery in a dense, mountainous forest. *Photogramm. Eng. Remote Sens.* **2013**, *79*, 37–49. [CrossRef]
53. Blaschke, T. Object based image analysis for remote sensing. *ISPRS J. Photogramm. Remote Sens.* **2010**, *65*, 2–16. [CrossRef]
54. Tanase, M.A.; Gitas, I.Z. An examination of the effects of spatial resolution and image analysis technique on indirect fuel mapping. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2008**, *1*, 220–229. [CrossRef]
55. Del-Arco, M.; Pentez-de-Paz, P.L.; Acebes, J.R.; González-Manabeo, J.M.; Reyes-Betancort, J.A.; Bermejo, J.A.; de-Armas, S.; González-González, R. Bioclimatology and climatophilous vegetation of Tenerife (Canary Islands). *Ann. Bot. Fennici.* **2006**, *43*, 167–192.
56. Loerenz-Gil, A.; Núñez-Casillas, L.; Isenburg, M.; Alonso-Benito, A.; Rodrigo-Bello, J.J.; Arbelo, M. A comparison between LiDAR and photogrammetry digital terrain models in a forest area on Tenerife Island. *Can. J. For. Res.* **2013**, *39*, 396–409.
57. Gaulton, R.; Malthus, T.J. LiDAR mapping of canopy gaps in continuous cover forests: A comparison of canopy height model and point cloud based techniques. *Int. J. Remote Sens.* **2010**, *31*, 1193–1211. [CrossRef]
58. Rapidlasso GmbH. Available online: <http://rapidlasso.com/> (accessed on 5 June 2016).
59. Updike, T.; Comp, C. *Radiometric Use of WorldView-2 Imagery*; Technical Note 2010; Digital Globe Inc.: Longmont, CO, USA, 2010.
60. Matthew, M.W.; Adler-Golden, S.M.; Berk, A.; Richtsmeier, S.C.; Levine, R.Y.; Bernstein, L.S.; Acharya, P.K.; Anderson, G.P.; Felde, G.W.; Hoke, M.P.; et al. Status of Atmospheric Correction Using a MODTRAN4-based Algorithm. In Proceedings of the SPIE 2000, Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI, Orlando, FL, USA, 24 April 2000; Volume 4049, pp. 199–207.
61. Jensen, J.R. *Introductory Digital Image Processing: A Remote Sensing Perspective*, 3rd ed.; Prentice Hall: Upper Saddle River, NJ, USA, 2005; p. 526.
62. Smith, L.I. A Tutorial on Principal Components Analysis. Available online: <http://goo.gl/fqufn> (accessed on 1 June 2016).
63. Green, A.A.; Berman, M.; Switzer, P.; Craig, M.D. A Transform for Ordering Multispectral Data in Terms of Image Quality with Implications for Noise Removal. *IEEE Trans. Geosci. Remote Sens.* **1998**, *26*, 65–74. [CrossRef]
64. Baatz, M.; Schäpe, A. Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation. In *Angewandte Geographische Informationsverarbeitung*; Wichmann-Verlag: Heidelberg, Germany, 2000; Volume 12.

65. Pontius, R.G.; Millones, M. Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. *Int. J. Remote Sens.* **2011**, *32*, 4407–4429. [[CrossRef](#)]
66. Pontius, R.G., Jr.; Santacruz, A. Quantity, Exchange, and Shift Components of Difference in a Square Contingency Table. *Int. J. Remote Sens.* **2014**, *35*, 7543–7554. [[CrossRef](#)]
67. Warrens, M.J. Relative quantity and allocation disagreement measures for category-level accuracy assessment. *Int. J. Remote Sens.* **2015**, *36*, 5959–5969. [[CrossRef](#)]
68. Foody, G.M. Thematic Map Comparison: Evaluating the Statistical Significance of Differences in Classification Accuracy. *Photogramm. Eng. Remote Sens.* **2004**, *70*, 627–633. [[CrossRef](#)]
69. Foody, G.M. Sample size determination for image classification accuracy assessment and comparison. *Int. J. Remote Sens.* **2009**, *30*, 5273–5297. [[CrossRef](#)]



© 2016 by the authors; licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC-BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Anexo C

Durante la realización de la presente tesis, se han presentado los resultados previos en los siguientes congresos nacionales e internacionales. Listados por fecha de celebración.

- Alonso-Benito, A.** (2009) “*Aplicación de la teledetección en los incendios forestales de Canarias*”. Comunicación oral en las Jornadas sobre Gestión Forestal en Canarias, 28-30 de octubre de 2009 organizadas por el Gobierno de Canarias y GESPLAN S.A.U.
- Alonso-Benito, A.** (2010) “Caracterización de los recursos forestales mediante datos de teledetección: Proyecto SATELMAC”. Comunicación oral en las II Jornadas sobre Teledetección en la Región Macaronésica: Proyecto SATELMAC, 11-14 de octubre, organizadas por el Grupo GOTA de la ULL en S/C Tenerife.
- Alonso-Benito, A.; Arbelo, M.; Hernández-Leal, P.; González-Calvo, A.** (2010): “Mapping forest fuel types in Tenerife island using ASTER data”. FORESTSAT 2010: Operational Tools in Forestry Using Remote Sensing Techniques. Laboratorio do Territorio (Lborate). University of Santiago de Compostela, Lugo, Spain, 07-10 september. ISBN: 978-84-693-5600-5.
- Alonso-Benito, A.** (2011) “Mapeamento de combustíveis florestais com o auxílio da DR: Projecto SATELMAC”. Comunicación oral en las III Jornadas sobre Detecção Remota na Macaronésia: Projecto SATELMAC, 5 de abril, organizadas por IROA S.A., en Ilha de São Miguel, Ilhas dos Açores, Portugal.
- Alonso-Benito, A.** (2011) “Cartografiado de recursos forestales con imágenes de satélite”. Comunicación oral en las IV Jornadas sobre Teledetección en la Región Macaronésica: Proyecto SATELMAC, 14 de diciembre, organizadas por la Dirección General de Desarrollo Rural de la Consejería de Agricultura, Ganadería, Pesca y Alimentación del Gobierno de Canarias, celebradas en S/C La Palma.
- Alonso-Benito, A.; Arroyo, L.A.; Arbelo, M.; Hernández-Leal, P.A.; González-Calvo, A.** (2011): “Cartografiado de modelos de combustibles a partir de datos ASTER en La Orotava (Tenerife)”. Teledetección: Bosques y cambio climático. XIV Congreso de la Asociación Española de Teledetección. Mieres del Camino, 21-23 de septiembre de 2011. Editores: Carmen Recondo González y Enrique Pendás Molina. Pp 197-200. AS-3588-2011.

- A. Alonso-Benito**; L.A. Arroyo; M. Arbelo; P.A. Hernández-Leal; L. Núñez-Casillas; L. Arvelo-Valencia (2012) "Object-Based image analysis for mapping fuel types in Tenerife Island using WorldView-2 data". In Proceedings of the 4 Conference on Geographic Object-Bases Image Analysis (GEOBIA 2012), Rio de Janeiro, Brazil, May 7-9. Eds: Feitosa, R.; Costa, G.A.O.P.; Almeida, C.M.; Fonseca, L.M.G.; Kux, H.J.H. Pp 391-395. ISBN 978-85-17-00059-1.
- Alonso-Benito, A.**; Arbelo, M.; Hernández-Leal, P.; Lorenzo-Gil, A. (2012): "Classifying of forest fuel types by using VHR satellite imagery". In Proceeding of 39th COSPAR Assembly 2012. Mysore, India, 14-22 July.
- Lorenzo-Gil, A.; Arbelo, M.; **Alonso-Benito, A.**; Isenburg, M. (2012) "A comparison between digital terrain models in a forest area of the Island of Tenerife". In Proceeding of SILVILASER 2012, Vancouver, Canada. September 16-19.
- Lorenzo-Gil, A.; Isenburg, M.; Arbelo, M.; **Alonso-Benito, A.** (2012) "Comparación entre modelos digitales del terreno en una zona forestal de la Isla de Tenerife". XV Congreso Nacional de Tecnologías de la Información Geográfica 2012, Madrid, España. 19-21 Septiembre.
- Arbelo, M., Hernández-Leal, P., **Alonso-Benito, A.** (2012) "Teledetección e incendios forestales: aplicación al caso de las Islas Canarias". Ponencia invitada en la IV Reunión Internacional FuegoRED, Puerto de la Cruz, España. 24-27 Octubre.
- Alonso-Benito, A.**; Arbelo, M.; Hernández-Leal, P.A.; Arroyo, L.A. (2012) "Forest fuel types mapping with Wordlview-2 imagery in the Canary Islands". 9th International Conference of the African Association of Remote Sensing and the Environment (AARSE), El Jadida, Morocco. October 29 to November 2.
- Alonso-Benito, A.**; Arroyo, L.A.; Arbelo, M.; Lorenzo-Gil, A.; Hernández-Leal, P.A.; Núñez-Casillas, L. (2012): "Fuel type mapping using WorldView-2 and LiDAR data fusión. A case of study in Tenerife Island". XV Simposio Internacional SELPER. Cayena, Guayana Francesa, 19-23 noviembre.

Alonso-Benito, A. & Lorenzo-Gil, A. (2012) “Cartografiado de recursos forestales con imágenes de satélite y datos LiDAR”. Comunicación oral en las V Jornadas sobre Teledetección en la Región Macaronésica: Proyecto SATELMAC, 23 de octubre, organizadas por la Dirección General de Desarrollo Rural de la Consejería de Agricultura, Ganadería, Pesca y Alimentación del Gobierno de Canarias, celebradas en Las Palmas de Gran Canaria.

A. Alonso-Benito; M. Arbelo; A. Lorenzo-Gil; P.Hernández-Leal; M. Labrador-García (2013): “Fusión de WorldView-2 y datos LiDAR para la obtención de un mapa de combustibles forestales”. XV Congreso de la Asociación Española de Teledetección. Torrejón de Ardoz (Madrid), 22-24 de octubre de 2013. Editores: Alix Fernández-Renau González-Anleo y Eduardo de Miguel Llanes. M-29011-2013.

Lorenzo-Gil, L.; **Alonso-Benito, A.**; Arbelo, M.; Hernández-Leal, P.; Núñez-Casillas, L. (2013): “Fuel types mapping using airborne LiDAR data”. In Proceedings of the 34th Asian Conference on Remote Sensing 2013 (ACRS), Bali, Indonesia, October 20-24, ISBN: 978-602-9439-33-5.

Alonso-Benito, A.; Lorenzo-Gil, A.; Arbelo, M.; Hernández-Leal, P. A.; García-Lazaro, J.R.; Moreno-Ruiz, J.A. (2015): “LiDAR data as a tool for forest fuel classification”. In: Free and Open Source Software for Geospatial, FOSS4G Europe 2015, Como (Italy), 15-17 July.

Lorenzo-Gil, A.; Arbelo, M.; **Alonso-Benito, A.**; Hernández-Leal, P. (2015): Evaluation of a canopy height model derived from LiDAR data in Tenerife Island“. In: GI_Forum, Salzburg (Austria), 7-10 July.

Alonso-Benito, A.; Arbelo, M.; Hernández-Leal, P. (2015): “Assessment of spectral índices derived from WorldView-2 data to identify forest fuel types”. In: “. In: GI_Forum, Salzburg (Austria), 7-10 July.

Alonso-Benito, A.; Arbelo, M.; Hernández-Leal, P. (2015). “Tipos de combustibles con datos LiDAR de baja densidad”. En: XVI Congreso de la AET, Sevilla, 21-23 Octubre.

Alonso-Benito, A.; Arbelo, M.; Hernández-Leal, P. (2015). “Evaluación de índices de vegetación para identificar combustibles forestales”. En: XVI Congreso de la AET, Sevilla, 21-23 Octubre.

Alfonso Alonso-Benito, Manuel Arbelo, Pedro A. Hernández-Leal, Alejandro González-Calvo, José A. Moreno-Ruíz, José R. García-Lazaro (2016). Satellite image based methods for forest fuel maps updating. In SPIE Remote Sensing 2016, Edinburgh, 26-29 September.

Alonso-Benito, A. (2016). Los incendios forestales y la teledetección. Comunicación oral en la sesión técnica del Grupo de Trabajo de Teledetección dentro del congreso CONAMA 2016, 28 de noviembre al 1 de diciembre, Madrid.