

TRABAJO FIN DE MÁSTER

CLASIFICACIÓN DE MODELOS COMBUSTIBLES A PARTIR DEL MODELO DE TRANSFERENCIA RADIA- TIVA ANISOTRÓPICA DISCRETA (DART)

Autor: Sergio Revilla Grau

***Directoras: María Teresa Lamelas Gracia
Darío Domingo Ruiz***

Máster Universitario en

**Tecnologías de la información geográfica para la ordenación del te-
rritorio: sistemas de información geográfica y teledetección**

Noviembre de 2019



Universidad
Zaragoza

**Departamento de Geografía
y Ordenación del Territorio**



Resumen

Uno de los factores clave que permite analizar el potencial de ignición y de propagación del fuego en entornos agrícolas-forestales es el tipo de combustible presente. En los últimos años ha aumentado el interés por los datos proporcionados por sensores activos, como el LiDAR (Light Detection And Ranging). El objetivo de este trabajo es validar una metodología basada en el modelo de transferencia radiativa anisotrópica discreta (Discrete Anisotropic Radiative Transfer, DART) que permitiría clasificar tipos de combustible forestal. El poder de generalización y la alta automatización que permitiría esta aproximación podrían ayudar a las tareas de prevención, pero sobre todo a las labores de extinción en caso de incendio, ya que posibilitaría la simulación de situaciones concretas de tipos de combustible en cualquier momento. Esto es posible gracias a la creación previa de una muestra con la respuesta LiDAR de los diferentes tipos de combustible. La metodología propuesta es totalmente novedosa porque hace uso de modelos de transferencia radiativa (Radiative transfer models, RTM) para la simulación de la respuesta LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA). Además, se realiza una validación de las simulaciones a partir de los coeficientes de correlación y el error cuadrático medio de diferentes métricas LiDAR extraídas de las simulaciones y la información real LiDAR de los años 2011 y 2016. Se ha utilizado una muestra de calibración/validación compuesta por 85 parcelas de campo (localizadas en Aragón) para la simulación de los modelos combustibles en DART. Posteriormente, se ha llevado a cabo un proceso de clasificación de modelos de combustible a partir de las métricas simuladas de 2011, utilizando el método de inteligencia artificial SVM, obteniendo una fiabilidad global de la clasificación tras la validación cruzada del 60% y un índice de kappa de 0,50. Finalmente, se ha evaluado la transferibilidad de las simulaciones, aplicando el modelo generado a partir de las métricas de 2011 a los datos reales de 2016, obteniendo una fiabilidad global de clasificación tras la validación cruzada del 53% y un índice de kappa de 0,44.

Palabras Clave: combustible forestal, modelo de transferencia radiativa anisotrópica discreta (DART), clasificación, LiDAR, coeficiente de correlación y clasificación de combustibles.

Abstract

One of the key factors in analysing the ignition and propagation potential of fire in agricultural-forestry environments is the type of fuel present. In recent years there has been increasing interest in the data provided by active sensors, such as LiDAR (Light Detection And Ranging). The aim of this work is to validate a methodology based on the Discrete Anisotropic Radiative Transfer (DART) model that would allow to classify types of forest fuel. The power of generalization and the high automation that this approach would allow could help in prevention tasks, but above all in extinction tasks in case of fire, since it would make possible the simulation of specific situations of fuel types at any time. This is possible thanks to the previous creation of a sample with the LiDAR response of the different types of fuel. The proposed methodology is totally novel because it makes use of LiDAR and RTM data, as well as the validation of the simulations with the real information of the LiDAR of the National Air Orthophotography Plan (PNOA) of the year 2011 and 2016, through the correlation coefficients and the average quadratic error habitually used in the study of the forest area. A calibration/validation sample consisting of 85 field plots (located in Aragon) will be used for the simulation of DART fuel models. Subsequently and as an effect of having guided good validation results (correlation and RMSE calculated from the average between the simulated value and the value of the PNOA), a classification process of fuel models will be carried out from the simulated metrics, this classification will be carried out using SVM artificial intelligence methods, obtaining an overall reliability of the classification after cross validation of 60% and a kappa index of 0.50 using 2011 simulated data and an overall reliability of the classification after cross validation of 53% and a kappa index of 0.44 using 2016 real data.

Key Words: forest fuel, Anisotropic Discrete Radiative Transfer Model (DART), classification, LiDAR, correlation coefficient and fuel classification.

Índice

1. Introducción	1
1.1. Antecedentes	1
1.2. Hipótesis y objetivos	4
2. Materiales y métodos	5
2.1. Área de estudio	5
2.2. Materiales	6
2.2.1. Datos LiDAR-PNOA.....	6
2.2.2. Parcelas de campo	7
2.2.3. Datos de espectroradiometría.....	8
2.2.4. Imágenes Sentinel-2	9
2.3. Métodos.....	9
2.3.1 Proceso metodológico.....	9
2.3.2. Fase 1: simulación en DART.....	10
2.3.3. Fase 2: Validación y análisis de transferibilidad temporal de las simulaciones.....	16
2.3.4. Fase 3: Selección de variables y clasificación.....	17
3. Resultados.....	18
3.1. Evaluación de las simulaciones generadas	18
3.2. Correlación entre las métricas LiDAR de las nubes simuladas y las reales del PNOA	19
3.3. Análisis de la transferibilidad temporal de las simulaciones.....	19
3.4. Selección de métricas LiDAR y clasificación de modelos combustibles	24
4. Discusión.....	27
5. Conclusiones.....	29
6. Bibliografía.	30
7. Anexos.....	34
Anexo 1: Datos inventario de las parcelas de campo	34
Tabla A1: Ejemplo parcela de sotobosque.	34
Tabla A2: Ejemplo inventario de los árboles de las parcelas de campo. 34	
Anexo 2: Datos introducidos en la simulación.....	36
A3: Parámetros necesarios para la simulación de las parcelas para el año 2011.	36

A4: Parámetros necesarios para la simulación de las parcelas para el año 2016.	46
A5: Parámetros necesarios para la simulación de árboles con una forma de copa truncal.	56
A6: Parámetros necesarios para la simulación de árboles con una forma de copa elipsoidal.	58
Anexo 3: Estadísticas obtenidas	59
A7: Comparación de los datos DART simulados y datos del PNOA 2011 - 2016 para el conjunto de parcelas analizadas.	59
A8: Correlación de las métricas de la nube de puntos simulada y real del PNOA para 2011 y 2016, RMSE y % RMSE sobre el valor medio del PNOA real.	61
A9: Correlación entre los estadísticos de la nube de puntos simulada en 2011 y las del PNOA real de 2016.	64
A10: Correlación entre los estadísticos de la nube de puntos simulada en 2011 y las del PNOA real de 2011.	66
A11: Correlación entre las variables simuladas con DART (año 2011 y año 2016) y el modelo de combustible.	68

Índice de figuras

Figura 1:Área de estudio, localización de las parcelas de campo.....	5
Figura 2: Fotografías de los modelos de combustible.	8
Figura 3:Diagrama de flujos del proceso metodológico.....	10
Figura 4: Escenas clasificadas según el modelo de combustible Prometheus.	11
Figura 5:Número de pulsos del LiDAR PNOA en la 1 ^a Cobertura en una malla de 1x1 m.	15
Figura 6: Número de pulsos del LiDAR PNOA en la 1 ^a Cobertura en una malla de 2x2 m.	15
Figura 7: Número de pulsos del LiDAR PNOA en la 2 ^a Cobertura en una malla de 2x2 m.	16
Figura 8: Comparativa escena, nube de puntos simulada, nube de puntos PNOA (año 2011).	18

Índice de tablas

Tabla 1: Especificaciones técnicas del vuelo del proyecto LiDAR-PNOA.	6
Tabla 2:Valores de LAI asignados a los tipos de cobertura.....	12
Tabla 3: Valores de reflectividad y transmitancia asignados a los grandes tipos de coberturas presentes en las parcelas.	12
Tabla 4: Valores tipo de reflectividad y transmitancia asignados a cada especie presente en la zona de estudio.	13
Tabla 5: Parámetros asignados en DART para simular cada una de las coberturas del LiDAR del PNOA.	13
Tabla 6: Comparación de los datos DART simulados y datos del PNOA 2011 - 2016 para el conjunto de parcelas analizadas.	20

Tabla 7: Correlación de las métricas de la nube de puntos simulada y real del PNOA para 2011 y 2016, RMSE y % RMSE sobre el valor medio del PNOA real.	21
Tabla 8: Correlación entre los estadísticos de la nube de puntos simulada en 2011 y las del PNOA real de 2016.	22
Tabla 9: Correlación entre los estadísticos de la nube de puntos simulada en 2016 y los datos reales del PNOA de 2011.....	23
Tabla 10: Correlación entre las variables simuladas con DART (año 2011 y año 2016) y el modelo de combustible.	25
Tabla 11: Métricas de la simulación de 2011 seleccionadas mediante el método de selección de todos los subconjuntos. P es percentil de altura de los retornos.	26
Tabla 12: Métricas de la simulación de 2016 seleccionadas mediante el método de selección de todos los subconjuntos. P es percentil de altura de los retornos.	26
Tabla 13: Comparación de los modelos preliminares de clasificación obtenidos con las cuatro variables seleccionadas: la mediana entre los intervalos 0 a 0.6 (Mediana_ 0 a 0.6), la elevación media (EM), el L momento del coeficiente de variación (L_CV) y el percentil 99 (año 2011).	26
Tabla 14: Comparación de los modelos preliminares de clasificación obtenidos con las cuatro variables seleccionadas: la mediana entre los intervalos 0 a 0.6 (Mediana_ 0 a 0.6), la elevación media (EM), el L momento del coeficiente de variación (L_CV) y el percentil 99 (año 2011).	26

1. INTRODUCCIÓN

1.1. Antecedentes

La estructura de la vegetación describe el tamaño, la forma y la distribución de los componentes del dosel, como son los fustes, las ramas y las hojas. Estas características no son estáticas; sino que varían según factores como la fenología de la especie, el estrés ambiental, la dinámica del ecosistema y las perturbaciones naturales o antrópicas. En este contexto, los incendios forestales son calificados como uno de los factores de perturbación más importantes en los ecosistemas naturales (Lasaponara *et al.*, 2006). Especialmente en el entorno de la Cuenca Mediterránea, el fuego ha sido históricamente considerado un elemento natural modelador del paisaje, con el cual las sociedades han aprendido a coexistir y han llegado a utilizarlo como una herramienta de gestión tradicional.

No obstante, en las últimas décadas, ha aumentado la recurrencia, magnitud y severidad de los incendios. Una de las principales causas ha sido el aumento de la combustibilidad (cantidad, superficie, volumen, continuidad espacial y materia muerta) de las masas vegetales, resultado de un cambio en los usos del suelo. Además, hay que tener en cuenta el gran reto tanto medioambiental como socioeconómico que conlleva el cambio climático, caracterizado por condiciones meteorológicas extremas y períodos prolongados de sequías (Solomon *et al.*, 2007; González-De Vega *et al.*, 2016).

Por otra parte, también influye el tipo de especie forestal presente en el ecosistema. Los bosques de pino propios de la Cuenca Mediterránea, los cuales se han adaptado a las condiciones de sequía y a los suelos pobres, conllevan un problema añadido, son de naturaleza muy inflamable (Pausas *et al.*, 2009). Por todo esto, el régimen de incendios de estos ecosistemas se distingue por su alta intensidad, sumado a un intervalo de ocurrencia promedio aproximado de 30 a 50 años. Sin embargo, a pesar de la alta resiliencia post-fuego, puede ocurrir un problema en la regeneración de estos bosques de pinos cuando los intervalos de tiempo entre los incendios son más cortos que el tiempo necesario para la acumulación de un banco de semillas suficiente (Tanase *et al.*, 2015; González-De Vega *et al.*, 2016).

En este ámbito, la cartografía de tipos de combustible cobra un papel esencial para la estimación de la ignición y de las condiciones de propagación y, por consiguiente, para la valoración del peligro de incendio forestal. Un tipo de combustible forestal es una asociación identificable de elementos caracterizados por su forma, tamaño, disposición y continuidad que exhibirán un comportamiento característico ante el fuego en condiciones de combustión definidas (Merrill y Alexander, 1987).

Los primeros trabajos para cartografiar los tipos de combustible se iniciaron a mediados de la década de 1930 en EEUU, cuando todavía no se hablaba de “tipos de combustible”, sino de tipos de vegetación o cobertura y únicamente se contaba con el trabajo de campo. Con la llegada de la fotografía aérea a comienzos de 1940 se dio un salto cualitativo, al poder llevar a cabo técnicas de fotointerpretación para identificar el combustible y así reducir el intenso trabajo de campo (Chuvieco y Martín, 2004).

En la literatura científica pueden encontrarse diferentes clasificaciones de tipos de combustible basadas en las ecuaciones de propagación de Rothermel (1972). Una de las más conocidas es la propuesta por Albini (1976) para los Estados Unidos, denominada NFFL (Northern Forest Fire Laboratory), que se diseñó para simular incendios de superficie a través del programa informático BEHAVE. Así, en los modelos 1 a 3, el elemento propagador es el pasto, en los modelos 4 a 7 es el matorral, en los modelos 8 a 9 es la hojarasca bajo arbolado y en los modelos 10 a 13 son los restos de corta.

La aparición de nuevos sensores remotos en la década de los setenta del siglo XX fue lo que verdaderamente revolucionó la cartografía de modelos de combustibles, coincidiendo con la publicación de Albini (1976) y del primer trabajo de Rothermel (1972) sobre el comportamiento del fuego. La posibilidad de disponer de imágenes en cortos intervalos de tiempo, la reducción de costes frente a la fotografía aérea, la interrelación entre el dato observado en el campo y la información de la imagen, la toma de datos homogénea para grandes áreas, la captura de información no visible del espectro electromagnético (infrarrojo cercano, infrarrojo medio, infrarrojo térmico y micro-ondas), la naturaleza digital de los datos

de teledetección y la posibilidad de incluir otras variables espaciales en el análisis, son algunas de las ventajas frente a los métodos tradicionales para la cartografía de modelos de combustibles. Por todas estas razones, las imágenes ópticas multiespectrales captadas con sensores pasivos han sido asiduamente utilizadas en la cartografía de tipos de combustible a escala local y regional, como un procedimiento alternativo frente a los costosos métodos de identificación a partir de fotografías aéreas o directamente en campo (Burgan *et al.*, 1998; Tian *et al.*, 2005; Lasaponara y Lanorte, 2007).

En el contexto español, a finales de la década de 1980, el ICONA (Instituto para la Conservación de la Naturaleza) realizó una traducción de los trece modelos que componen el NFFL para poderlos aplicar en España (Chuvieco y Martín, 2004). Los primeros mapas de modelos de combustible que se realizaron en España se basaron en el Mapa Forestal escala 1:50.000, los cuales no cumplían con el tiempo de renovación adecuado, provocando resultados ineficaces para la correcta gestión de los incendios a escala local. Como cualquier simplificación de la realidad, los sistemas de clasificación de tipos de combustibles presentan ciertas limitaciones, ya que son únicamente aplicables en localizaciones geográficas con características similares a aquellas en las que fueron desarrolladas (Arroyo *et al.*, 2008). Por ese motivo, en el marco del proyecto europeo Prometheus (2000), se intentaron adaptar a las características particulares de la vegetación mediterránea, definiéndose siete tipologías (García *et al.*, 2011) que tienen en cuenta la altura y la densidad de los elementos propagadores, los cuales se pueden agrupar en: pastos, matorral y hojarasca/restos de cortas (Riaño *et al.*, 2002; Arroyo *et al.*, 2008; Ramírez *et al.*, 2013).

En lo que se refiere a los sensores más empleados para este objetivo, predominan en primer lugar los embarcados en los satélites Landsat, debido a su media-alta resolución espacial (30 m), a su resolución espectral (cuenta con una banda en el infrarrojo próximo y dos en el infrarrojo medio de onda corta, muy útiles para diferenciar la vegetación) y a una resolución temporal que supera los requerimientos de este tipo de cartografía. En menor medida se ha empleado el sensor NOAA-AVHRR (1 km de resolución espacial), los datos obtenidos con SPOT (20-10 m) y los sensores hiperespectrales aeroportados, como AVIRIS, que proveen una altísima resolución espectral (210 bandas entre 0,4 y 2,4 μm y 20 m de resolución espacial) muy eficaz para discriminar las cubiertas (Chuvieco y Martín, 2004).

No obstante, estos sistemas de teledetección pasiva presentan ciertas limitaciones, dada su incapacidad para detectar el combustible localizado bajo el dosel arbóreo (sotobosque y estratos inferiores), el cual resulta imprescindible para poder conocer el comportamiento del fuego (Vosselman y Maas, 2010). Además, la reflectividad que es captada por estos sensores, la cual debe someterse a correcciones radiométricas del efecto topográfico y atmosférico, no puede relacionarse con variables estructurales como la altura de la vegetación, a pesar de ser un parámetro imprescindible para la clasificación tipos de combustible (Salas y Chuvieco, 1995; Riaño *et al.*, 2002). En relación a esto, los sensores de teledetección activos sí facilitan información relacionada con la estructura vertical de la vegetación (Chuvieco, 2010). Estos sensores emiten pulsos de energía y registran el tiempo y la amplitud del retorno para derivar la estructura tridimensional de la vegetación (Andersen *et al.*, 2006).

En el caso de los sensores SAR (Synthetic Aperture Radar), existen relaciones estadísticas significativas entre el tamaño de los componentes de la cubierta vegetal y el coeficiente de retrodispersión obtenido, siendo también posible el uso de técnicas polarimétricas e interferométricas para modelizar esta cuestión (Chuvieco, 2010). No obstante, las reflexiones en la longitud de onda de las microondas se ven afectadas por el efecto topográfico, que es especialmente complejo de corregir en zonas de orografía montañosa, lo que implica una reducción en la precisión frente a otros sensores activos como el LiDAR (Light Detection And Ranging). En este caso, los escáner láser aeroportados (ALS) se han utilizado con éxito para la obtención de cartografía de modelos de combustible (Riaño *et al.*, 2007; Mutlu *et al.*, 2008) y el modelado de otras variables necesarias para la predicción del comportamiento del fuego: la densidad aparente del dosel de copas (Riaño *et al.*, 2004; Andersen *et al.*, 2005), la altura de la base del dosel (Riaño *et al.*, 2003), la cubierta de copas (Hall *et al.*, 2005), o la densidad de los combustibles de escalera (Platt, 2014).

Mientras que la precisión de las estimaciones realizadas con datos LiDAR normalmente supera a las obtenidas por los sensores SAR, los ALS están en desventaja en lo que se refiere a su resolución temporal y espacial (Andersen *et al.*, 2006).

A pesar de que existe una amplia aceptación científica sobre el uso de la tecnología ALS para la estimación de variables estructurales forestales (García *et al.*, 2011), no proliferan estudios centrados en el uso de datos ALS de baja densidad de puntos, como los proporcionados por el Plan Nacional de Ortofotografía Aérea (PNOA) (Montealegre *et al.*, 2016). Este tipo de datos es característico en campañas de vuelo diseñadas para coberturas parciales o completas a una escala nacional: los Países Bajos, Noruega, Austria, Suiza, Finlandia y España son pioneros en el uso esta tipología de datos (Rosette *et al.*, 2012).

En lo que se refiere a las técnicas empleadas para la elaboración de cartografía de tipos de combustible, la clasificación digital de bandas de información ha sido la metodología más utilizada frente a la interpretación visual de las imágenes, especialmente la clasificación supervisada con el algoritmo de máxima probabilidad, la clasificación no supervisada, los clústeres o conglomerados y la clasificación mixta, aunque en estos últimos años han cobrado importancia otros métodos basados en redes neuronales, árboles de decisión, etc. Particularmente se aprecia una tendencia orientada a la combinación de datos LiDAR e imágenes ópticas y SAR, con el fin de aprovechar las ventajas propias de cada fuente de información, mostrándose una clara mejora en la precisión de la cartografía de combustibles en escenarios complejos (Mutlu *et al.*, 2008; García *et al.*, 2011; Montealegre *et al.*, 2015b).

Sin embargo, la problemática de estas aproximaciones es que solo se ajustan a las condiciones locales donde se ha calibrado el modelo, por lo que es difícil extrapolarlos a regiones diferentes o a diferentes escalas (De Santis y Chuvieco, 2007). Además, carecen del potencial cada vez más demandado para generar y/o actualizar mapas de tipo de combustible en tiempo real. Por otro lado, la posibilidad de penetración del pulso láser a través del dosel y la intensidad retornada dependen de la configuración de la misión y del sensor, así como de propiedades como la reflectividad de la vegetación y de su estructura (Hopkinson *et al.*, 2004).

Ante esto han surgido metodologías pioneras basadas en desarrollar modelos físicos, los cuales proporcionan un mejor conocimiento de los procesos responsables de la respuesta espectral capturada por el sensor, independientemente del área de estudio (Gastellu-Etchegorry *et al.*, 2004). Los modelos de transferencia radiativa (RTM) pueden utilizarse para describir la interacción entre la radiación y los elementos del dosel vegetal y así poder relacionar explícitamente los parámetros de la vegetación con la respuesta espectral (Sun y Ranson, 2000; North *et al.*, 2010; Bye *et al.*, 2017). Además, varios estudios han aplicado inversiones de transferencia radiativa a las ondas LiDAR (Koetz *et al.*, 2006; Bye *et al.*, 2017). La simulación de retornos LiDAR con diferentes configuraciones de sensores láser y en distintos escenarios es fundamental para evaluar e interpretar la señal y el ruido en los datos. Existen diferentes tipos de modelos que son capaces de simular formas de onda LiDAR. Por un lado, los modelos semi-empíricos y geométricos, los cuales pueden ser imprecisos ya que se basan en simulaciones simplificadas de la superficie terrestre y de los mecanismos de interacción de la luz, y por otro lado los modelos de trazado de rayos Monte Carlo (MCRT) que por el contrario son potencialmente precisos, aunque necesitan un elevado tiempo de computación (Gastellu-Etchegorry *et al.*, 2016).

Recientemente, se ha diseñado una nueva herramienta que simula la forma de onda LiDAR basándose en un enfoque de trazado de rayos quasi-Monte Carlo dentro del modelo de transferencia radiativa anisotrópica discreta (DART) (Gastellu-Etchegorry *et al.*, 2016; Yin *et al.*, 2016).

El modelo DART fue desarrollado en 1992 por el CESBIO (Centre d'Etudes Spatiales del BIOsphère) y patentado en 2003 como un software específico para simular mediciones de sensores de teledetección pasivos y activos en entornos naturales y urbanos. Estas simulaciones se pueden calcular en cualquier entorno experimental (atmósfera, terreno, tipo de cubierta, fecha, etc.) e instrumental (resoluciones espaciales y espectrales, ángulo de visión, etc.), por lo que tiene un enorme potencial para el estudio y monitorización de cubiertas. Estas propiedades han hecho de DART una herramienta puntera y novedosa para modelar con precisión espacios forestales.

Sin embargo, hasta la fecha se han publicado muy pocos trabajos relacionados con la simulación con DART para la generación de cartografía de tipos de combustibles para distintos lugares, dentro de un contexto medioambiental mediterráneo, que año tras año sufre las nefastas consecuencias de los incendios. Por lo tanto, la investigación resulta pionera y ambiciosa ya que se pretende poder utilizar los datos LiDAR del PNOA con un doble objetivo: justificación de su elaboración (ya que los datos son públicos y gratuitos) y demostrar el uso de nubes de puntos de baja densidad para proyectos cooperativos y cofinanciados entre las diferentes administraciones públicas responsables.

La metodología que aquí se muestra está a la vanguardia del modelado de datos de teledetección, dado que es una alternativa a la modelización con parcelas de campo que sólo se ajustan a las condiciones locales donde se ha calibrado el modelo, por lo que nos permitiría replicarlos en otros lugares o a una escala más amplia. A esto hay que añadirle el potencial para generar y/o actualizar cartografía de tipo de combustible en tiempo real.

El objetivo final sería poder producir una cartografía automatizada y precisa de tipos de combustible que se pudiera utilizar como una herramienta objetiva a la hora de gestionar incendios activos y además permitiera la optimización de los recursos humanos y económicos. En este sentido, los simuladores de propagación utilizados durante las labores de extinción se pueden beneficiar de la mejora en la precisión de la cartografía de los tipos de combustible, reduciéndose así los errores en el modelado y ayudando a la toma de decisiones. Esta cuestión es primordial especialmente para las administraciones y organismos públicos cuando se trata de proteger a la sociedad de las consecuencias del fuego.

1.2. Hipótesis y objetivos

La hipótesis de partida es la posibilidad de simular la respuesta LiDAR del PNOA y clasificar modelos de combustible forestal mediante la utilización del modelo de transferencia radiativa anisotrópica discreta (Discrete Anisotropic Radiative Transfer, DART).

Por ende, el objetivo general de este trabajo es diseñar una metodología basada en la simulación con el modelo de transferencia radiativa anisotrópica discreta DART que permita clasificar tipos de combustible forestal definidos en el proyecto Prometheus (2000).

Constituyen objetivos específicos:

- Validar y analizar la transferibilidad temporal de las simulaciones en la zona piloto con datos reales capturados por el LiDAR del PNOA en las dos fechas de adquisición disponibles (año 2011 y 2016).
- Evaluar que métricas LiDAR son más explicativas para la discriminación de modelos de combustible.
- Analizar la transferibilidad temporal de la clasificación realizada utilizando métodos no paramétricos.

2. MATERIALES Y MÉTODOS

2.1. Área de estudio

La zona de estudio se localiza al noroeste de la ciudad de Zaragoza y se aproxima a la extensión del Centro de Adiestramiento (CENAD) “San Gregorio” (ver figura 1). La elección de la zona está motivada por la existencia de un proyecto de investigación en el seno del grupo de investigación GEO-FOREST-IUCA (Proyecto UZCUD2018-HUM-01). Este centro se localiza dentro de la Comunidad Autónoma de Aragón, concretamente se encuentra dentro de la depresión del Ebro ($41^{\circ} 56' N$, $0^{\circ} 56' W$) (Peña y Lozano, 2004), sobre un territorio que desde una perspectiva litológica se caracteriza por ser yesífero (IGME, 2003).

En lo que se refiere al clima se enmarca dentro de un clima continentalizado, con inviernos fríos y veranos calurosos y secos, no obstante, las características orográficas del territorio alteran los rasgos propios del clima mediterráneo. Destacando característica como: la aridez, la irregularidad pluviométrica, el cierzo y el acusado contraste térmico (Cuadrat, 2004).

Por otro lado, el área objeto de estudio se encuentra dentro de la región Mediterránea (dentro del reino Holártico) (Longares, 2004). Dominado por especies como gramíneas, arbustos de *Juniperus oxycedrus* L., *Querqus coccifera* L. *Rosmarinus officinalis* L., *Pinus Halepensis* Mill... (Montealegre *et al.*, 2015b).

Todos estos factores naturales sumado a las acciones antrópicas han conllevado a que tanto Aragón como la zona de estudio se caracterice por tener una significativa peligrosidad estructural ante el fuego (López del Ríos y Bardají en Montealegre, 2017).

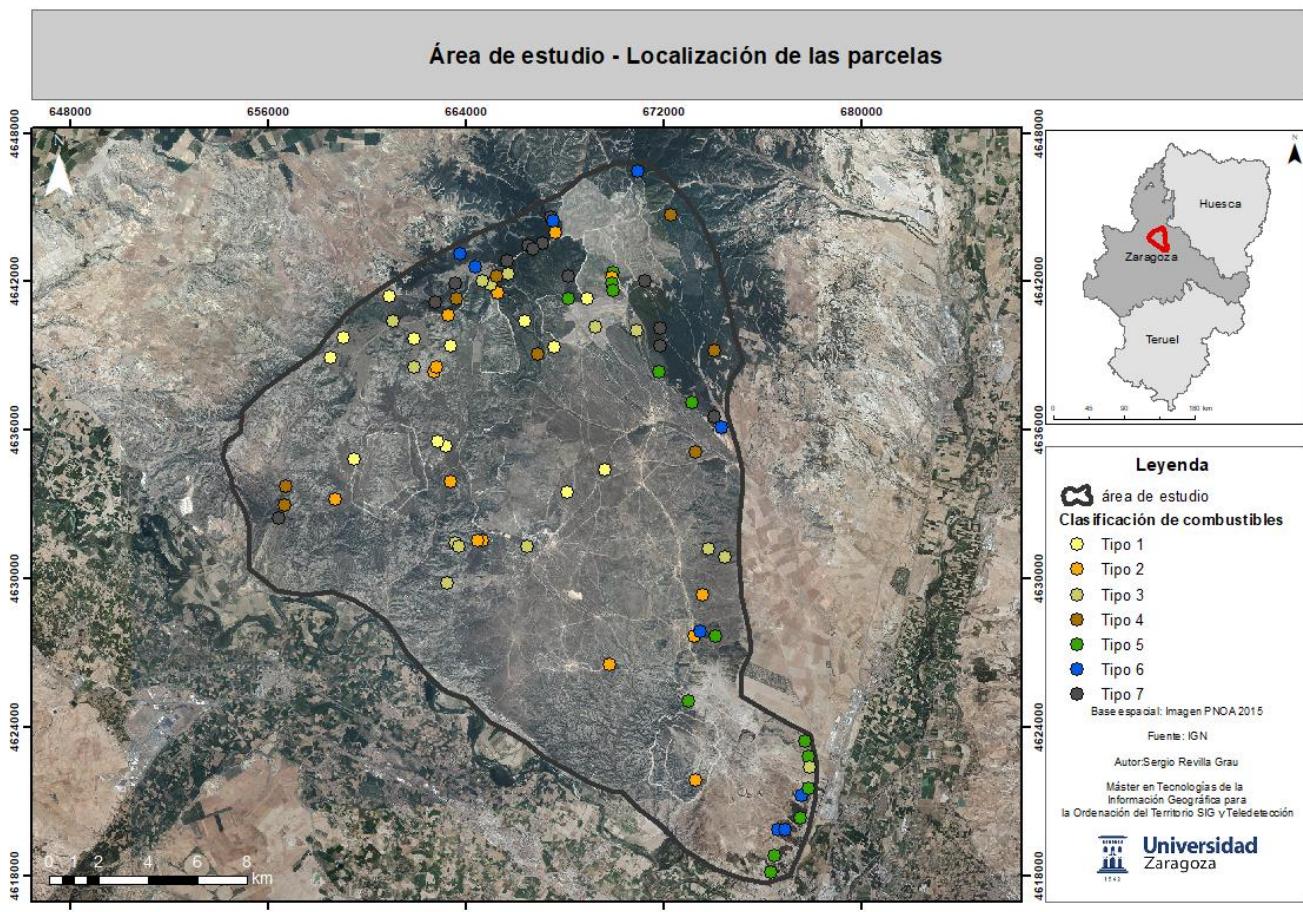


Figura 1: Área de estudio, localización de las parcelas de campo.

2.2. Materiales

2.2.1. Datos LiDAR-PNOA

El Plan Nacional de Ortografía Aérea (PNOA) arrancó en el año 2004 con el objetivo de conseguir Ortofotografías aéreas digitales con una resolución de 25 o 50 m y modelos digitales de elevaciones (MDE), de alta precisión espacial, con un periodo de actualización dependiendo de la zona de 2 o 3 años. Se trata de un proyecto cooperativo y cofinanciado entre la Administración General del Estado y las Comunidades Autónomas, este proyecto se enmarca dentro del Plan Nacional de Observación del Territorio (PNOT) llevado a cabo por el Consejo Superior Geográfico. Este plan se engloba entre los ámbitos de la Fotogrametría, la Teledetección y la ocupación del suelo. El PNOT surgió con la meta de impulsar la coordinación en la obtención y difusiones de la información geográfica en España entre los distintos organismos competentes o entre los diferentes organismos públicos.

La dirección del proyecto PNOA es asumida por el Ministerio de Fomento, a través de la Dirección General del Instituto Geográfico Nacional (IGN) y el Centro Nacional de Información Geográfica (CNIG), que a su vez se coordina con los demás agentes interesados como Ministerios, Comunidades Autónomas o Consejerías competentes. La producción se realiza de manera descentralizada por cada autonomía, siendo el IGN el responsable de la validación, así como de la integración y difusión de los productos finales. Esta metodología de trabajo rigurosa y común entre todas las Administraciones públicas participantes está acorde al espíritu de la [Directiva Inspire \(2007\)](#).

En este contexto, el PNOA impulsó la recogida de datos LiDAR en 2008, con el objetivo de cubrir todo el territorio de España mediante nubes de puntos con coordenadas X, Y, Z y atributos como clasificación o color. Actualmente el proyecto PNOA-LiDAR se compone de dos coberturas, la primera de ellas se inició en 2008 y finalizó en el año 2015, año en el cual se comienza simultáneamente la toma de datos de la segunda cobertura, en proceso de captura actualmente.

En este estudio se han utilizado datos de la primera y segunda cobertura. Los datos de la primera cobertura fueron tomados entre enero y febrero de 2011 con el sensor LEICA ALS60, de pulsos discretos y espejos oscilantes. Por otro lado, los datos de la segunda cobertura fueron captados entre septiembre y noviembre de 2016, con la ayuda del sensor LEICA ALS80, de pulsos discretos y espejos oscilantes (PNOA, 2019), ambos se ajustan a las especificaciones técnicas para vuelos Fotogramétricos Digitales con LiDAR determinadas por el PNOA. En la tabla 1 se recogen las principales especificaciones técnicas de ambas capturas.

A partir de 26 de diciembre de 2015 se instauró la orden ministerial FOM2807/2015, por la cual toda la información geográfica elaborada por el IGN se distribuirá de forma gratuita para cualquier usuario a través del centro de descargas del CNIG. Tanto las nubes de puntos como los productos derivados se distribuyen en formato LAZ (compresión formato LAS) de 2X2 km de extensión.

Tabla 1: Especificaciones técnicas del vuelo del proyecto LiDAR-PNOA.

Principales especificaciones técnicas vuelos LiDAR-PNOA	
1 ^a cobertura	2 ^a cobertura
Sensor ALS60	Sensor ALS80
Diámetro rayo (1/e and 1/e2, mm): 5.6, 8.0	Diámetro rayo (1/e and 1/e2, mm): 6.2
Divergencia rayo (1/e and 1/e2, mr): 0.15, 0.22	Divergencia rayo (1/e and 1/e2, mr): 0.23
Ancho del pulso (máximo, máximo de la mitad del ancho entero, ns): 9	Ancho de pulso (máximo, máximo de la mitad del ancho entero, ns): 3
Máximo de energía pulso único (mJ): 0.2	Máximo de energía pulso único (mJ): 0.5
Onda emitida (nm): 1064	Onda emitida (nm): 1064
El máximo campo de visión transversal (FOV) permitido es de 50° efectivos.	El máximo campo de visión transversal (FOV) permitido es de 50° efectivos.

El sensor debe tener una frecuencia de escaneado mínima de 70 Hz, debiendo de alcanzar un mínimo de 40 Hz con un FOV de 50°.	El sensor debe tener una frecuencia de escaneado mínima de 70 Hz, debiendo de alcanzar un mínimo de 40 Hz con un FOV de 50°.
La frecuencia de pulso mínima es de 45 kHz, asumiendo un FOV de 50° y un máximo alcance de hasta 3000 metros.	La frecuencia de pulso mínima es de 45 kHz, asumiendo un FOV de 50° y un máximo alcance de hasta 3000 metros.
La densidad promedio exigida es de 0,5 puntos del primer retorno por metro cuadrado. En ningún caso se admitirá una densidad inferior a 0,40 por m ²	La densidad promedio exigida es de 0,5 puntos del primer retorno por metro cuadrado. En ningún caso se admitirá una densidad inferior a 0,50 por m ²
El sensor debe estar calibrado, probado y certificado por el fabricante o por un centro autorizado con una antigüedad menor a 12 meses	El sensor debe estar calibrado, probado y certificado por el fabricante o por un centro autorizado con una antigüedad menor a 12 meses
La resolución radiométrica debe ser de un rango dinámico mínimo de 8 bits	La resolución radiométrica debe ser de un rango dinámico mínimo de 8 bits
Uso obligatorio de equipo GPS doble frecuencia de al menos de 2 Hz	Uso obligatorio de equipo GPS doble frecuencia de al menos de 2 Hz
Capaz de detectar y registrar hasta 4 parámetros por cada pulso con una discriminación en distancia vertical de al menos 4 m.	Capaz de detectar y registrar hasta 4 retornos para cada pulso con una discriminación en distancia vertical de al menos 4 m.
Sistema inercial con frecuencia de registro de datos mayor o igual a 200 Hz; y una deriva inferior a 0,1°/hora.	Sistema inercial con frecuencia de registro de datos mayor o igual a 200 Hz; y una deriva inferior a 0,1°/hora.
El espacio promedio entre punto debe ser inferior o igual a 1,41 m	El espacio promedio entre punto debe ser inferior o igual a 1,41 m
El recubrimiento transversal debe ser mayor o igual a 15 % en zonas de poca orografía, con un margen de recubrimiento mínimo del 15% en el extremo superior e inferior de la zona de trabajo.	El recubrimiento transversal debe ser mayor o igual a 15 % en zonas de poca orografía, con un margen de recubrimiento mínimo del 15% en el extremo superior e inferior de la zona de trabajo.
La longitud máxima de una pasada longitudinal debe ser de 3 hojas MTN50	La longitud máxima de una pasada longitudinal debe ser de 3 hojas MTN50.
La precisión general altimétrica del error cuadrático medio (RMSE) debe ser menor o igual a 0,40 m.	La precisión general altimétrica del error cuadrático medio (RMSE) debe ser menor o igual a 0,20 m
La discrepancia altimétrica entre pasadas debe ser inferior o igual a 0,80 m	La discrepancia altimétrica entre pasadas debe ser inferior o igual a 0,40 m
La precisión del Postproceso de la trayectoria deber tener un RMSE inferior o igual a 10cm	La precisión del Postproceso de la trayectoria deber tener un RMSE inferior o igual a 10cm

2.2.2. Parcelas de campo

Los datos de inventario de parcelas utilizados en el presente trabajo han sido obtenidos de un proyecto de investigación del grupo GEOFOREST-IUCA, el Proyecto CUD 2013-04 (Montealegre, 2017). El objetivo del proyecto era la cartografía de modelos de combustibles mediante combinación de imágenes LiDAR, SAR y ópticas, obtuvieron un total de 108 parcelas, de 15 m de radio, con una precisión en planimetría de 0,33 m (coordenadas tomadas con un GPS-GNSS modelo GS15 de LEICA) durante una campaña de trabajo de campo trascurrida entre julio y septiembre de 2014. En lo que concierne a este trabajo, se ha realizado un proceso de selección de 85 parcelas, respetando una variabilidad de la cobertura vegetal, altura y pendiente topográfica de la zona de estudio (Montealegre, 2017).

Como ya se ha mencionado, las parcelas de campo se han clasificado en 7 categorías (García *et al.*, 2011) en función del tipo y la altura de los elementos propagadores (Riaño *et al.*, 2002; Arroyo *et al.*, 2008; Ramírez *et al.*, 2013):

- Tipo 1: pastizales agrícolas y vegetación herbácea con un porcentaje de cubrimiento >60%.
- Tipo 2: pastizales y arbustos pequeños de 0,3-0,6 m con un 30-40% de herbáceas. La cobertura de arbustos es >60% y la arbórea <50%.

- Tipo 3: arbustos medianos de 0,6-2,0 m, así como árboles jóvenes resultantes de una regeneración natural o una reforestación. La cobertura de arbustos es >60% y la arbórea <50%.
- Tipo 4: arbustos altos de 2,0-4,0 m y árboles regenerados. La cobertura de arbustos es >60% y la arbórea <50%.
- Tipo 5: arbolado de más de 4 m sin sotobosque. La cobertura de arbustos <30% y la arbórea >50%.
- Tipo 6: arbolado de más de 4 m con sotobosque, donde la distancia de éste con la base del dosel arbóreo es superior a 0,5 m. La cobertura de arbustos es >30% y la arbórea >50%.
- Tipo 7: arbolado de más de 4 m con sotobosque alto y muy denso, donde la distancia de éste con la base del dosel arbóreo es inferior a 0,5 m. La cobertura de arbustos es >30% y la arbórea >50%.

Las 85 parcelas se han distribuido de la siguiente manera: 9 pertenecen al tipo 1, 14 pertenecen al tipo 2, 14 pertenecen al tipo 3, 8 pertenecen al tipo 4, 14 pertenecen al tipo 5, 9 pertenecen al tipo 6 y 13 pertenecen al tipo 7. Cabe señalar que se ha intentado en la medida de lo posible contar con el mismo número de parcelas para cada tipología, sin embargo, como se ve existen pequeñas diferencias consecuencia de no disponer de más parcelas de esas categorías, dado que cuando se tomaron las medidas en el Proyecto CUD 2013-04 no se había planeado utilizarlos para este proyecto. A continuación, en la figura 2 se pueden ver algunos ejemplos de cada tipo.

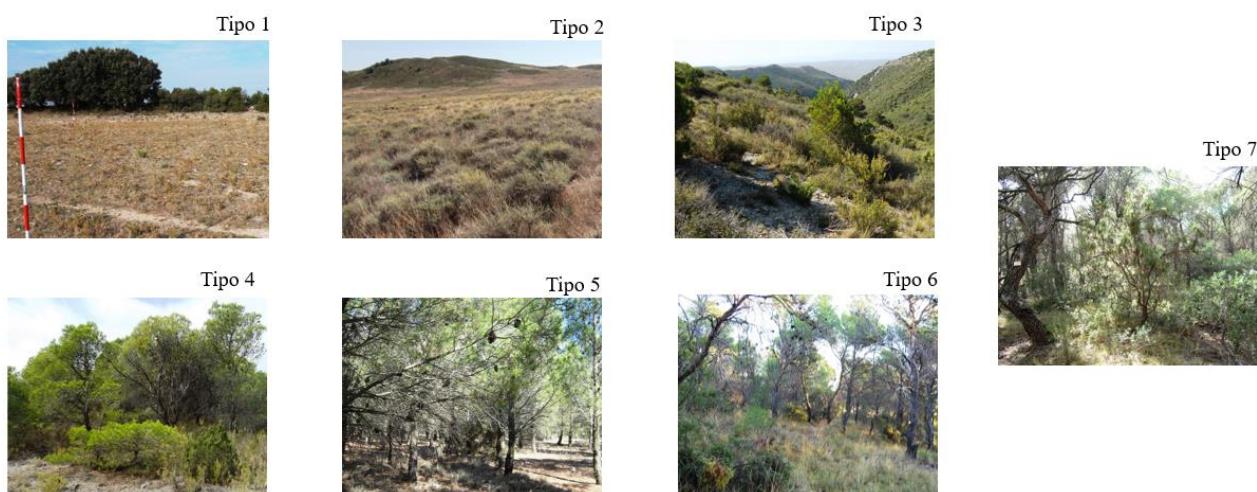


Figura 2: Fotografías de los modelos de combustible. Fuente: Proyecto CUD 2013-04.

En cuanto a los datos del inventario de parcelas de campo, se ha trabajado por un lado con los porcentajes de cubrimiento de sotobosque y la altura (m) de cada especie. Y, por otro lado, se ha trabajado con los datos de altura a la primera rama (m), la altura del árbol (m) y el diámetro del tronco (cm) de las diferentes especies arbóreas localizadas en las parcelas. Acudiendo al anexo 1, en las tablas A1 y A2 se puede observar dos ejemplos de los datos recogidos de campo sobre unas parcelas de sotobosque y el inventariado de árboles, respectivamente.

2.2.3. Datos de espektoradiometría

Durante el verano de 2014 (entre el 16 de julio de 2014 y el 3 de septiembre de 2014) los miembros del proyecto coordinado UZCUD2014-HUM-01 llevaron a cabo la campaña de espektro-radiometría de campo para la adquisición de las firmas espectrales de las especies vegetales del área de estudio. Estas mediciones se realizaron con el equipamiento disponible en el laboratorio de Espectro-Radiometría y Teledetección Ambiental (ERTAlab, GEOFOREST-IUCA) de la Universidad de Zaragoza:

- Espectro-radiómetro de campo ASD FieldSpec SR4, que mide en el continuo espectral entre 400-2500 nm con una resolución espectral de 3-10 nm FWHM y un intervalo de muestreo de 1 nm;
- Panel de referencia calibrado Spectralon para el registro de la energía incidente y el cálculo de la reflectividad absoluta.

Como establecen los protocolos oficiales de espectro-radiometría de campo (Milton, 1987; McCoy, 2005), todas estas medidas de reflectividad se realizaron en días despejados y en el periodo de máxima estabilidad del ángulo de incidencia del sol (± 2 en torno al máximo solar), para asegurar unas perfectas condiciones de iluminación. Cada una de las medidas fue adquirida previa corrección de la señal de la corriente oscura, optimización del equipo en función de las condiciones de iluminación y promediado de 25 espectros en cada muestra para reducir la variabilidad aleatoria asociada a posibles errores del detector o del procedimiento de medida. Para cada especie de recogieron entre 5 y 10 medidas de reflectividad diferentes con el objetivo de recoger toda su variabilidad espacial. El resultado de la campaña de campo se tradujo en un total de 330 espectros de reflectividad absoluta (factor de reflectividad hemisférico cónico, HCRF por sus siglas en inglés (Schaeepman-Strub *et al.*, 2006) con una elevada ratio señal-ruido.

2.2.4. Imágenes Sentinel-2

El satélite europeo Sentinel-2 forma parte de una serie de misión dirigidas por la Agencia Espacial Europea (ESA) dentro del programa espacial Copernicus. A grandes rasgos las características generales del satélite 2-A son: una cámara multiespectral de alta resolución, un sistema de barrido push-broom (barrido a lo largo de la trayectoria) y una cámara que cuenta con dos grandes planos focales (uno orientada al visible y al infrarrojo próximo y otro en el infrarrojo medio) (Sentinel Online). En el presente estudio se han utilizado dos escenas de Sentinel 2-A para la estimación del valor del índice de área foliar (Leaf Area Index, LAI), requerido en las simulaciones. La primera escena, utilizada en las simulaciones de 2011, fue capturada en enero de 2016. Esta escena era la primera disponible para la estación del año de captura del LiDAR-PNOA de 2011. La segunda escena utilizada fue de octubre de 2016, coincidente en fecha con la adquisición del LiDAR PNOA.

2.3. Métodos

2.3.1 Proceso metodológico

En la figura 3 se presenta un diagrama de todo el proceso metodológico aplicado que consta de tres fases principales. En primer lugar, se detalla el proceso seguido para realizar la simulación en DART. A continuación, se realiza una validación de las simulaciones mediante la comparación de las estadísticas de las nubes de puntos obtenidas con la simulación con las provenientes de las nubes de puntos reales capturadas por el PNOA. En esta fase se analizará también la transferibilidad de las simulaciones para su posible utilización en futuras capturas. Finalmente, se evalúa la capacidad de los estadísticos de las nubes de puntos simuladas para la clasificación de modelos de combustible y su posible transferibilidad temporal.

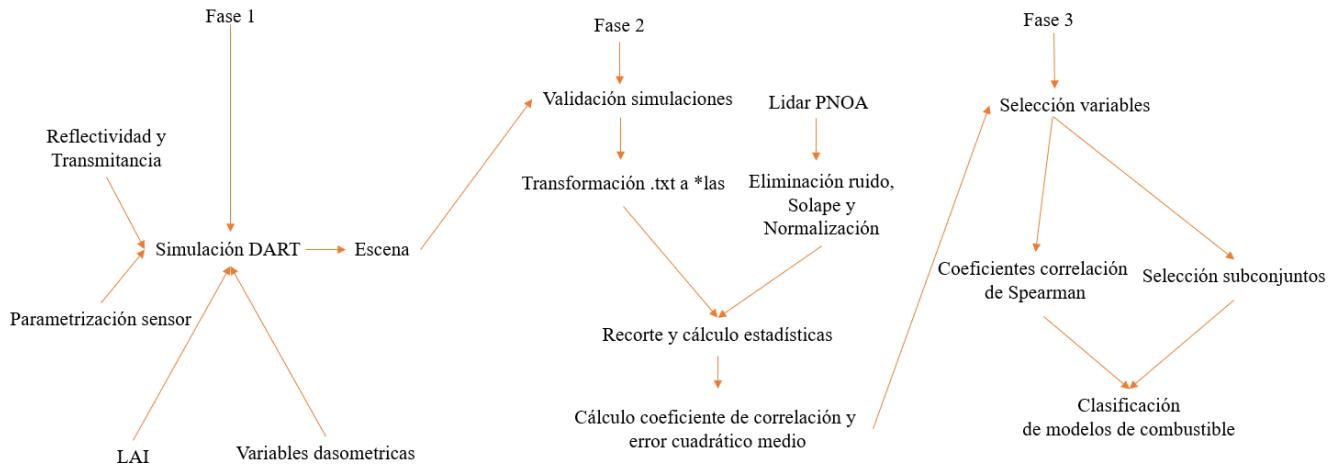


Figura 3: Diagrama de flujos del proceso metodológico.

2.3.2. Fase 1: simulación en DART

La parametrización de las características de las escenas y del sensor a simular es una de las etapas esenciales a la hora de elaborar simulaciones con DART. En el caso de la parametrización de la escena, si bien es cierto que se ha tenido acceso a los datos de la campaña de campo realizada para el proyecto CUD 2013-04 mencionado con anterioridad, ha sido indispensable realizar análisis adicionales dado que la información disponible era insuficiente para poder llevar a cabo las simulaciones.

En DART, la simulación consiste en la generación de una escena o "maket" que representa una parcela con un tipo de combustible en concreto. En este trabajo, las simulaciones se realizaron asumiendo una superficie plana de 30 x 30 m para ajustarse al diámetro de 30 m de las parcelas.

Una escena se define como un conjunto de celdas 3D (voxels) en el que los elementos se pueden confeccionar siguiendo dos aproximaciones, bien utilizando un conjunto de celdas que contienen medios turbidos, bien mediante formas geométricas (triángulos) denominados "facetas" (CESBIO, 2016). En este trabajo, tras realizar diversas pruebas comparando distintos tamaños de voxel se acabó seleccionado un voxel de 0.5 m, dado que maximizaba la relación entre los resultados y el tiempo de computación. Además, se utilizaron tanto medios turbidos para la vegetación de matorral como "facetas" para el estrato arbóreo (ver figura 4).

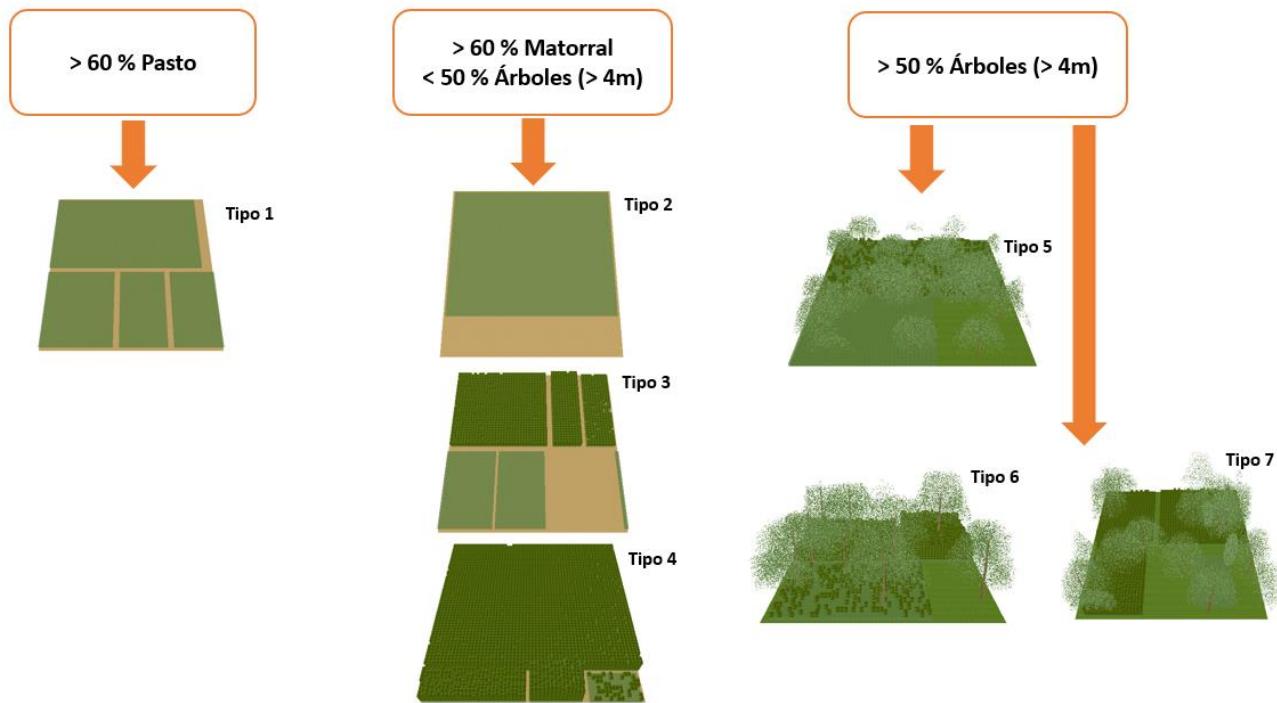


Figura 4: Escenas clasificadas según el modelo de combustible Prometheus.

Otro aspecto importante son los denominados “módulos”. Dart es un programa con un claro carácter multidisciplinar, es decir, posee diferentes módulos (suelo, generador de MDE, imagen inversa, LiDAR...) relacionados con diferentes ramas científicas con el objetivo de ser una herramienta multitemática. En este trabajo se ha utilizado el módulo específico LiDAR, ya que ofrece un rango de productos orientados a este tipo de información, un ejemplo es la capacidad que tiene para trabajar con pulsos únicos o como en el caso del presente trabajo con multipulsos (CESBIO, 2016). Por ende, todos los parámetros exigidos dentro de este módulo están relacionados a los datos LiDAR.

En lo referente a los parámetros estructurales, tales como densidades de cobertura y altura de matorrales, número de pies arbóreos, su altura, diámetro, etc., fueron de gran utilidad los datos de campo para intentar ajustar las simulaciones lo mejor posible a la realidad. Para la representación de los pastizales y matorrales se hizo uso de parcelas en la simulación (ver anexo 2) se pueden consultar los datos introducidos en las simulaciones), cuyo tamaño se ajustó al porcentaje de cobertura y altura medida en campo, siempre y cuando el porcentaje de cobertura superara 4% sino dicha especie se sumaba a otra de aspecto y altura similar. Los árboles se parametrizaron utilizando los valores medios y desviación estándar de capa parcela. Es interesante mencionar que dependiendo de la especie arbórea introducida en la simulación DART posibilita elegir la forma de la copa (se ha utilizado la forma truncal para los pinos, coníferas, sabinas y la forma elipsoidal para las encinas y las coscojas). La única variable que presentó cierta dificultad fue el ancho de copa que al no haber sido medida en campo tuvo que ser estimada a partir del diámetro y altura de los árboles, utilizando las ecuaciones de Condés y Sterba (2005) (ver ecuación 1).

$$\ln CW = -a_2 c_0 + d_0 + (d_1 - a_2 c_1) \ln d + a_2 \ln h \quad (1)$$

En la Figura 4 se observa un ejemplo de simulación para cada tipo de modelo de combustible. Como se puede observar, la localización de las parcelas y los pies de arbolado no siguen una reproducción fiel de la realidad, ya que no se tomó información al respecto en el campo y sería una tarea inabordable. No obstante, se asume que esta imprecisión no tiene influencia en los resultados ya que la metodología empleada utiliza la distribución vertical en altura de los retornos y no su distribución horizontal.

Siguiendo esta aproximación, a cada elemento incluido en la simulación es necesario asignarle un valor de LAI. Al no disponer de esta información en el trabajo de campo realizado, los valores de índice

de área foliar (LAI) se estimaron en el marco del proyecto CUD-UNIZAR (Proyecto UZCUD2018-HUM-01), a partir de Sentocor (herramienta integrada en SNAP que permite el cálculo del LAI a partir de imágenes Sentinel-2). Se han seleccionado los píxeles puros, característicos de cada tipo de cubierta presente en las parcelas de campo (pastizales, matorrales, arbolado), en dos escenas de Sentinel 2-A (enero y octubre de 2016). Se debe señalar que lo ideal hubiera sido disponer de dos imágenes, una de enero de 2011 y otra de octubre de 2016 (fechas de captura del LiDAR PNOA). Sin embargo, dado el inicio de las capturas de la misión en 2015, no fue disponible tener imagen en 2011, por lo que se seleccionó la primera disponible para la estación del año en la que fue capturado el LiDAR PNOA, en este caso enero. En este sentido, consideramos que la diferencia temporal entre la primera cobertura y la imagen no repercute negativamente en los valores de LAI, ya que en este parámetro es más importante la estación del año que el año de captura. Además, tal y como se comprobó en los trabajos de campo realizados en el verano de 2014, no existen diferencias sustanciales con respecto a los datos de 2011, por lo que, se asume que el estado de las parcelas en el año 2011 y 2016 no ha variado significativamente. En la tabla 2 se muestran los valores asignados de LAI para las dos coberturas del LiDAR PNOA.

Con respecto a los valores de reflectividad y transmitancia que deben asignarse a las cubiertas, en un primer momento se planteó utilizar el valor medio para cada especie de las reflectividades tomados en campo. No obstante, tras un análisis más profundo de los parámetros a incluir en DART, se comprobó como este modelo incorpora valores medidos en laboratorio. En ausencia de esta información se contactó con Mariano García, de la Universidad de Alcalá, que tiene una amplia experiencia en el uso de estos modelos y que proporcionó los datos de reflectividad y transmitancia de los grandes grupos de vegetación presentes en la zona (ver tabla 3). La información de reflectividad proviene de medidas realizada con pinza en laboratorio y los valores de transmisividad, fueron estimados usando PROPECT y LIBERTY, ajustándolos a la curva de la reflectividad medida. Posteriormente, los valores de los grandes grupos se asignaron a las diferentes especies localizadas en la zona, tomando como referencia la reflectividad medida en campo (ver tabla 4). Los valores de reflectividad y transmitancia del suelo, fueron suministrados por Olga Rosero Vlassova, del grupo GEOFOREST-IUCA, estos datos se pueden consultar también en la tabla 3.

Tabla 2: Valores de LAI asignados a las dos coberturas del PNOA.

Tipo de Cobertura	Simulación 1 ^a Cobertura	Simulación 2 ^a Cobertura
Pastizal	0,15141	0,26382
Matorral bajo	0,22866	0,28694
Matorral medio	0,35018	0,50572
Matorral alto	0,72953	1,01277
Pinar	0,85264	1,13845

Tabla 3: Valores de reflectividad y transmitancia asignados a los grandes tipos de coberturas presentes en las parcelas.

Tipo de Cobertura	Reflectancia	Transmitancia
Encina	0,52	0,35
Pino	0,59	0,25
Suelo	0,40	0
Pastizal	0,27	0
Madera	0,28	0

Tabla 4: Valores tipo de reflectividad y transmitancia asignados a cada especie presente en la zona de estudio.

Especies	Media de reflectividad medida en campo	Valor tipo asignado
Acículas	0,32	Pino
Aliaga	0,21	Pastizal
Avena loca	0,21	Pastizal
Cardo	0,23	Pastizal
Coscoja	0,29	Encina
Encina	0,34	Encina
Enebro	0,35	Pino
Espino negro	0,32	Encina
Gramínea	0,23	Pastizal
Lastón	0,24	Pastizal
Tomillo	0,28	Pastizal
Necromasa	0,25	Pastizal
Ontina	0,27	Pastizal
Piedras	0,46	Suelo

Con respecto a la parametrización del sensor, que debe ajustarse lo máximo posible al utilizado en las coberturas del LiDAR PNOA, se consultó la información requerida por el modelo tanto al Instituto Geográfico Nacional (IGN) como al Instituto Geográfico de Aragón (IGEAR), así como a la empresa Leica Biosystems, propietaria de los sensores utilizados en ambas coberturas.

Como se puede ver en la tabla 5 se presentan los parámetros introducidos en el modelo, tanto para la primera como para la segunda cobertura. Algunos de los parámetros necesarios no fueron proporcionados por las fuentes comentadas con anterioridad (e.g. área del sensor LiDAR), por lo que se consultó al desarrollador de DART, Tiangang Yin, quien propuso los valores a utilizar en base a su conocimiento y experiencia.

Tabla 5: Parámetros asignados en DART para simular cada una de las coberturas del LiDAR del PNOA.

Parámetros de sensor en DART	Simulación 1 ^a Cobertura	Simulación 2 ^a Cobertura
Atmosphere radiative transfer	No atmosphere RT (TOA = BOA)	No atmosphere RT (TOA = BOA)
LDAR mode	Imagen (multiple pulse)	Imagen (multiple pulse)
LiDAR Type	Discrete Return	Discrete Return
Minumum Target Reflectance for detection	0,1	0,1
Number of Points per pulse	4	4
Output Intensity Value type	Gaussian Descomp Integral	Gaussian Descomp Integral
Area of LIDAR sensor (m ²)	0,001	0,001
Diameter of laser beam	5,6	6,2

Parámetros de sensor en DART	Simulación 1 ^a Cobertura	Simulación 2 ^a Cobertura
generated (mm)		
Laser scanning mode	ALS	ALS
Definition of footprint range option	Half angles	Half angles
Stored waveform height range	Height above/below scene minimum altitude	Height above/below scene minimum altitude
Height above scene minimum altitude	50	50
Height below scene minimum altitude	5	5
LIDAR platform altitude (km)	3	3
Platform azimuth (°)	0	0
Swath width (m)	29	29
Start point of the swath region central axis X (m)	0	0
Start point of the swath region central axis Y (m)	15	15
End point of the swath region central axis X (m)	30	30
End point of the swath region central axis Y (m)	15	15
Ground position X (m)	15	15
Ground position X (m)	15	15
Look angle	0	0
Grid parameters - azimuthal resolution (m)	2	1,5
Grid parameters - Range resolution (m)	2	1,5
Footprint	0,000075	0,000085
Fiel of view	0,00009	0,000095
Energy of each pulse (mj)	0,2	0,5
Half pulse duration (effective)	3	3
Pulse relative power	0,5	0,5
Half pulse duration at relative power (ns)	8	2
Photons number (kHz)	1000	1000
Minimum phtons number per sub-center	1	1
The axial subcenter división of ilumination	7	7
Fraction of photons at LIDAR radius	0,368	0,368
LIidar acquisition rate (period)	2	2
Maximum order os scattering	5	5
Maximum RAM of calculator	1000	1000
Atmosphere brightness temperatura (K)	260	260

DART simula un pulso en cada uno de los píxeles definidos por los parámetros denominados “Grid parameters - azimuthal resolution (m)” y “Grid parameters - Range resolution (m)”. Para poder ajustar este parámetro es necesario conocer la densidad de pulso de cada cobertura. Esta información tampoco se encuentra disponible, por lo se realizó un análisis sobre los datos del PNOA utilizando la herramienta

“Las point statistics as raster” de ArcGIS, la cual devuelve el número de pulsos por pixel. En las figuras 5 y 6 se presenta, a modo de ejemplo, la cartografía resultado de contar el número de pulsos de la nube de puntos del LiDAR PNOA de la primera cobertura en una malla de 1 y 2 m, respectivamente. Como se observa, en la malla de 1 m (ver figura 5) existen muchos píxeles sin pulsos (en blanco), siendo la mayoría píxeles que presentan un único pulso (color verde). En el caso de la malla de 2 m se ajusta mejor el número de pulsos, con la mayoría de píxeles que presentan un único pulso y algunos dos (color amarillo), por lo que se decidió utilizar esta malla finalmente en la modelización. En el caso de la segunda cobertura se utilizó la malla de 1,5 metros ya que esta información presenta una mayor densidad de puntos (ver figura 7).

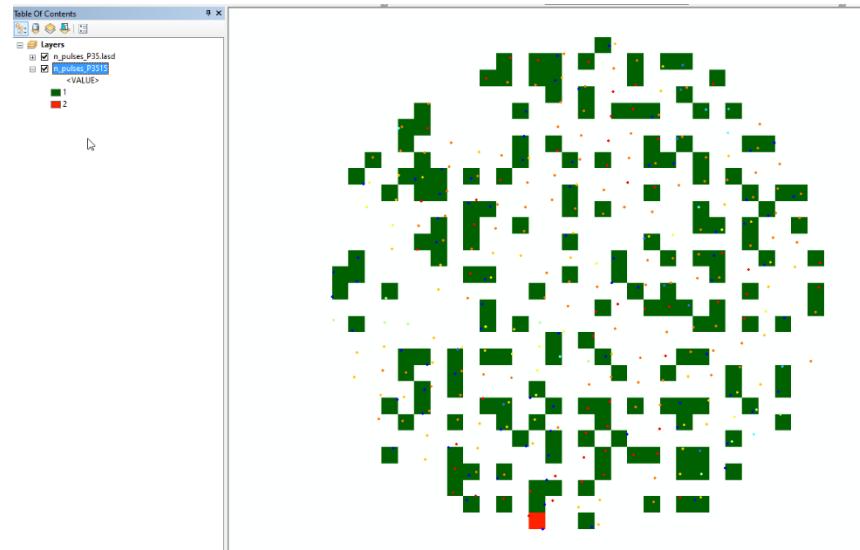


Figura 5: Número de pulsos del LiDAR PNOA en la 1^a Cobertura en una malla de 1x1 m.

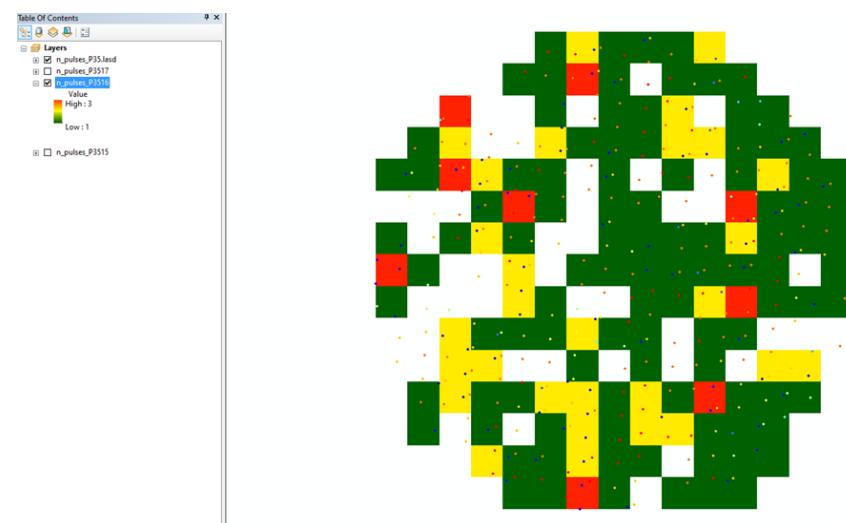


Figura 6: Número de pulsos del LiDAR PNOA en la 1^a Cobertura en una malla de 2x2 m.

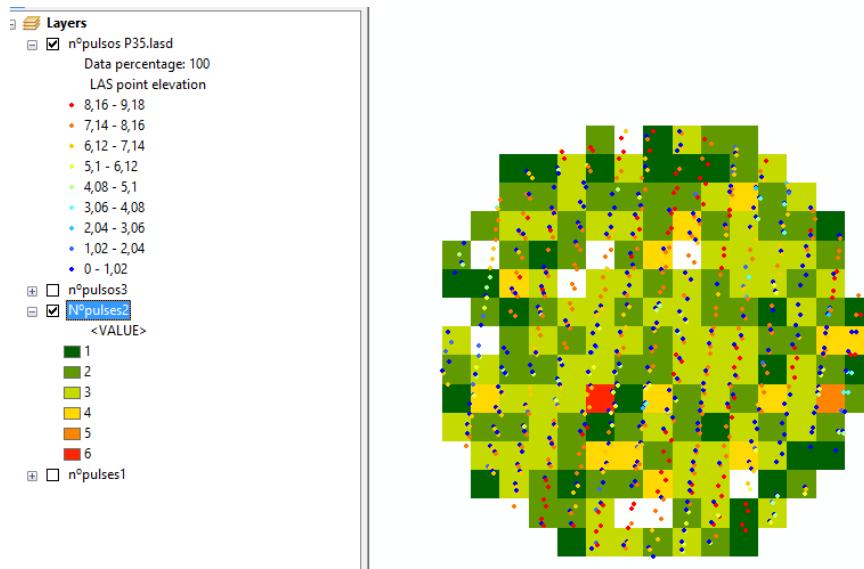


Figura 7: Número de pulsos del LiDAR PNOA en la 2^a Cobertura en una malla de 2x2 m.

2.3.3. Fase 2: Validación y análisis de transferibilidad temporal de las simulaciones

DART genera dos tipos de salidas. Por un lado, genera la onda continua del LiDAR, que refiere a la representación del número de fotones que retornan al sensor por unidad de tiempo y pulso emitido. Y, por otro lado, también es capaz de generar nubes de puntos. En el primero de los casos lo que se obtiene es la onda por cada pulso emitido, pero en este caso cada parcela tiene varios pulsos (del orden de 200). Para la representación de modelos de combustible interesa obtener la energía que retorna en toda la parcela que manifiesta un determinado tipo. Por ese motivo se decidió trabajar con la segunda de las opciones que, además de proporcionar nubes de puntos más fácilmente comparables a la nube de puntos del PNOA, tiene un coste computacional mucho menor (Yin, *et al.*, 2018).

En DART, las nubes de puntos se generan en formato *.txt, por lo tanto, deben ser transformadas al formato de archivo *.las para poder seguir con el tratamiento de la información. Para su transformación se ha utilizado la herramienta “txt2las” disponible dentro del software LAStools.

Con respecto a la nube de puntos del LiDAR PNOA ha sido necesario realizar una serie de procesos. En primer lugar, eliminar los puntos de ruido y de solape entre pasadas, ya que en DART únicamente se simula una pasada del avión. Para la normalización de las alturas de los puntos se ha hecho uso del MDE de 1 m de resolución disponible del proyecto CUD 2013-04. La realización de este último paso de procesamiento no ha sido necesario para las nubes de puntos simuladas ya que las alturas vienen referidas al nivel del suelo. Finalmente, tanto en el caso de las nubes simuladas como en las del LiDAR PNOA ha sido necesario el recorte de las mismas utilizando el software FUSION 3.30, con el objeto de ajustarlas a la geometría circular de las parcelas de campo.

Para poder realizar la validación de las simulaciones, se han calculado una serie de estadísticas comúnmente utilizadas como variables independientes en ámbito forestal, descriptoras de la altura de la nube de puntos (percentiles, alturas media, máxima y moda, L momentos, etc.), de su variabilidad (desviación estándar, curtosis, coeficiente de variación, etc.), y de su densidad (proporción de puntos sobre la altura media, moda, canopy relief ratio, porcentajes de retornos a distintas alturas de la nube de puntos LiDAR, considerando rangos de altura de los modelos de combustible, etc.). Estas variables fueron obtenidas a través del software FUSION 3.30 para la muestra de 85 parcelas tanto de la nube simulada en las dos fechas como para las nubes reales del PNOA capturadas en 2011 y 2016. Para la comparación de las diferentes muestras se ha utilizado el coeficiente de correlación de Spearman, el error cuadrático medio (RMSE) y el porcentaje de error (%RMSE) calculado sobre la media tanto del valor simulado como del PNOA real. La totalidad de los estadísticos han sido calculados en el software R.

Estos mismos estadísticos se han utilizado para analizar la transferibilidad de las simulaciones. Se trata de evaluar si las nubes de puntos simuladas con unos parámetros determinados de sensor, adjuntas en el primero de los casos a la captura del año 2011, se correlacionan con las nubes de puntos del LiDAR PNOA capturadas en 2016 con un sensor diferente, y viceversa, si las nubes generadas con la simulación en 2016, se correlacionan con las capturadas en 2011. Este análisis es de interés ya que unos resultados positivos permitirían la utilización de las simulaciones realizadas para la clasificación de sucesivas capturas de características similares.

2.3.4. Fase 3: Selección de variables y clasificación

Con respecto a la selección de las métricas LiDAR más explicativas para la discriminación de modelos combustibles se utilizaron dos métodos de selección comúnmente usados en clasificación: i) selección basada en los coeficientes de correlación de Spearman; ii) selección de todos los subconjuntos, mediante cuatro enfoques distintos: exhaustivo, hacia delante, hacia atrás y remplazo secuencial.

Tanto los coeficientes de correlación de Spearman como la selección de todos los subconjuntos (desde cuatro perspectivas diferentes) han sido calculados a través del software R. El coeficiente de correlación de Spearman establece la fuerza y la dirección de la relación entre dos variables que se llevan a cabo utilizando la función "cor.spearman" en el entorno R. Si bien es cierto que existen otros coeficientes de correlación, el coeficiente de Spearman es el más utilizado en aplicaciones forestales. Este coeficiente (rho) oscila entre +1 y -1, siendo +1 el grado de asociación positivo perfecto y -1 el grado de asociación negativo perfecto (Spearman, 1904).

La selección de todos los subconjuntos permite seleccionar las mejores variables de un grupo, sin tener en cuenta el resto de las variables (Miller, 2002). Se han realizado varios enfoques en la búsqueda del mejor método de selección, en concreto se probaron 4 técnicas de búsqueda diferentes: reemplazo exhaustivo, hacia atrás, hacia adelante y secuencial. Los cuatro enfoques utilizados se implementaron utilizando el paquete R "leaps" y específicamente la función "regsubsets".

Posteriormente, se realizó la clasificación partiendo de las variables previamente seleccionadas por ambos métodos de selección e incluyendo en el modelado aquellas que mostraban un mejor ajuste final de la clasificación. La clasificación se entrenó y parametrizó utilizando los datos simulados para 2011 y se validó usando los datos del PNOA de la primera cobertura (año 2011) y la segunda cobertura (año 2016), utilizando en ambas fechas las mismas métricas y parametrización de los modelos generados a partir de la simulación de 2011. De este modo, la obtención de resultados similares en las precisiones en la clasificación permite confirmar la fiabilidad y transferibilidad temporal de los modelos.

La clasificación se realizó utilizando el método de inteligencia artificial SVM, que incluye algoritmos de aprendizaje que permiten analizar y reconocer patrones. SVM se basa en la hipótesis de que los datos son separables en clases en el espacio, tratando de buscar la separación óptima entre clases mediante hiperplanos multidimensionales. Los datos localizados en los hiperplanos se denominan support vectors, siendo éstos los más complejos de clasificar, dado que existe una menor separabilidad entre clases. Los modelos SVM con kernel radial y kernel linear se generaron en entorno R mediante el paquete "e1071". Los parámetros cost y gamma se parametrizaron según los intervalos 1-1.000 y 0,01-1, respectivamente. La capacidad de clasificación de los modelos se evaluó mediante una validación cruzada dejando un dato fuera (LOOCV) con objeto de no reducir la muestra. El ajuste y bondad de la clasificación preliminar se expresó mediante porcentajes de acierto global, así como el estadístico Kappa (Domingo, *et al.*, 2019).

3. RESULTADOS

3.1. Evaluación de las simulaciones generadas

A modo de ejemplo en la figura 8 se presenta por un lado una escena simulada de cada tipo de combustible con su correspondiente nube de puntos y por otro lado la nube de puntos del PNOA. Se puede ver como la nube simulada dibuja la silueta de la nube del PNOA, aunque cuenta con una densidad de puntos menor. Es importante resaltar que en DART todos los retornos de un determinado pulso se generan en el centroide del pulso, por lo que todos tienen las mismas coordenadas en planimetría. Esto no es así en una captura de LiDAR real, donde las coordenadas de los múltiples retornos de un mismo pulso son diferentes.

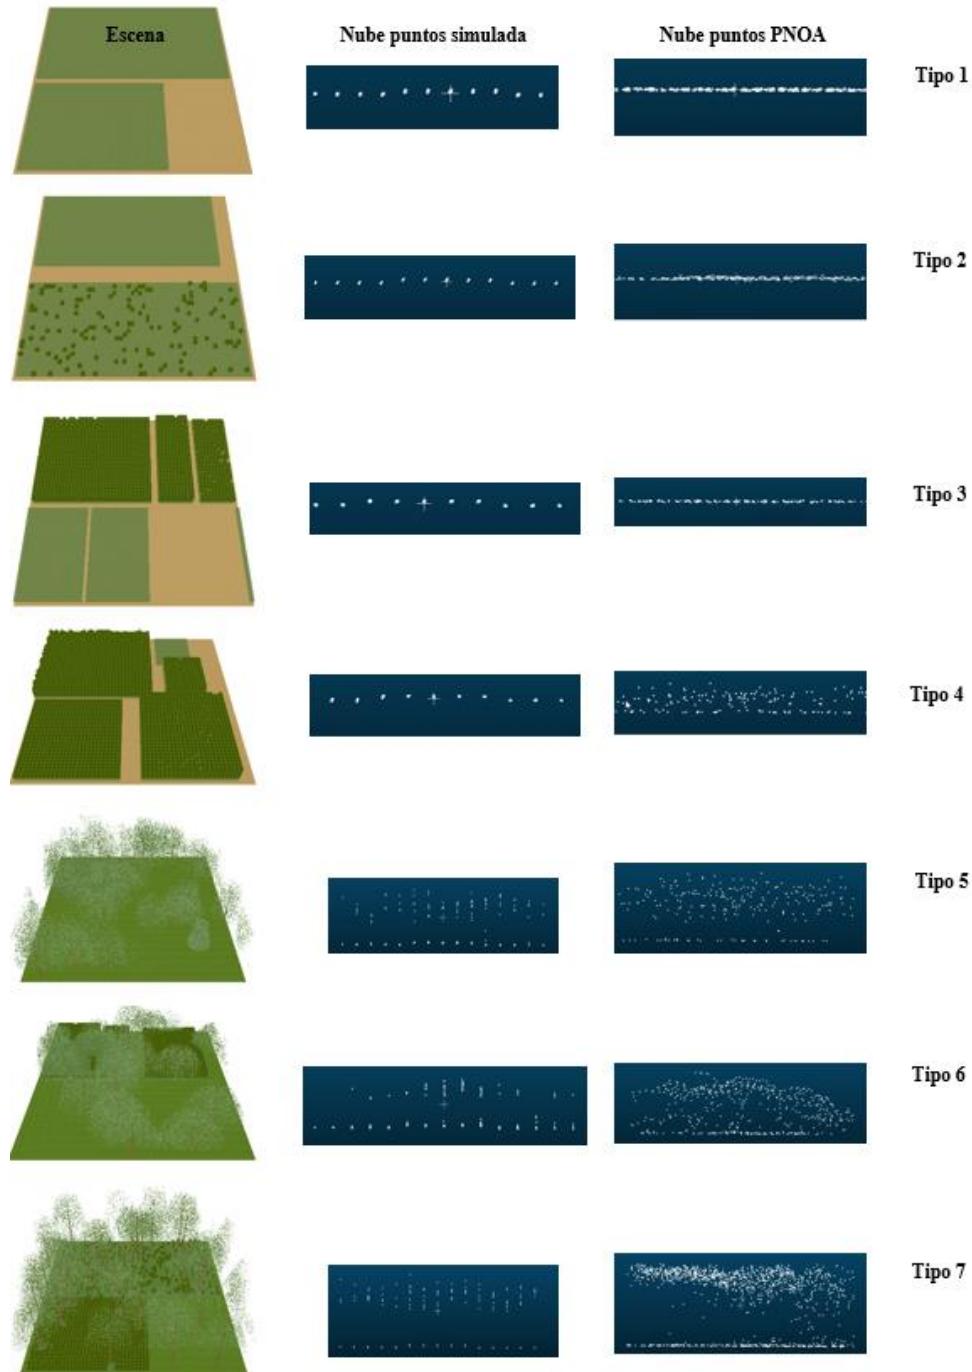


Figura 8: Comparativa entre la escena, la nube de puntos simulada, y la nube de puntos del PNOA (año 2011).

A continuación, se presenta en la tabla 6, a modo de resumen, el promedio de las estadísticas obtenidas de las nubes de puntos de las simulaciones y del PNOA de los años 2011 y 2016. Estos datos se han obtenido como ya se ha mencionado de un total de 85 parcelas. En el anexo 3 se puede consultar la tabla A7, en la que se presenta el total de estadísticos obtenidos.

La tendencia que siguen ambas simulaciones 2011 y 2016 en relación a las nubes reales es similar, lo que indica un buen funcionamiento de DART. No obstante, se observa que las dos simulaciones subestiman el valor promedio de las variables relacionadas con la altura, la variabilidad y la densidad de la nube de puntos, en relación al valor real del PNOA en 2011 y 2016. Por otro lado, se puede afirmar que no existen grandes diferencias entre los datos de 2011 y 2016, tanto simulados como reales.

3.2. Correlación entre las métricas LiDAR de las nubes simuladas y las reales del PNOA

A continuación, se presenta en la tabla 7, a modo de resumen, la correlación, entre las estadísticas de la nube de puntos simulada y del PNOA de los años 2011 y 2016. Se presenta también el RMSE y el porcentaje RMSE calculado sobre el valor medio del PNOA real. En el anexo 3 se encuentra la tabla A8 donde se puede ver el conjunto de estadísticos obtenidos.

Como se observa, existen altos valores de correlación en las estadísticas entre la nube de puntos simulada y la real del PNOA, alcanzando más de 0,95 en varios casos, entre los que destacan los percentiles 75 y 99, la elevación cúbica media, la desviación estándar y la variancia. Del mismo modo, se debe señalar la baja correlación obtenida en los percentiles 25, donde no se supera el 0,2 para el año 2011 y el 0,34 para el año 2016. Por otro lado, no existen grandes diferencias entre los años 2011 y 2016 en los que se observa una tendencia similar. En el caso de los errores obtenidos en cada métrica calculada, por lo general se aprecia unos valores de error bajos (aproximadamente una media de 0,66 con respecto al PNOA del año 2011 y un 0,68 en relación al PNOA del año 2016). También presentan muy buenas correlaciones, superiores al 0,9 algunas variables relacionadas con aquellas variables orientadas a dar información sobre la densidad de los puntos, en particular la proporción de retornos superiores a 4 m, aunque también es cierto que estas variables relacionadas con la densidad de los puntos han obtenido unos valores de correlaciones inferiores a los obtenidos en las variables ligadas a la altura y a la variabilidad de la nube de punto.

3.3. Análisis de la transferibilidad temporal de las simulaciones

En la tabla 8 se presenta la correlación entre las métricas simuladas en 2011 y las obtenidas de la nube del PNOA capturada en 2016. Como se observa, se mantienen altos valores de correlación superiores a 0,95 en varios casos como el percentil 95, la varianza, etc., mientras que las correlaciones y los errores de las métricas relacionadas con la densidad han empeorado ligeramente. Por otra parte, se ha producido un leve aumento en los errores de cada métrica en comparación con los obtenidos con anterioridad en la comparación del PNOA de 2016 con la simulación del mismo año (ver tabla 7).

En el caso de las correlaciones y errores calculados relacionando los datos simulados en 2016 y los capturados por el PNOA en 2011 (ver tabla 9) se observa que se han mantenido las magnitudes, es decir, por lo general se observan correlaciones superiores a 0,90 en las variables de altura y correlaciones ligeramente inferiores para las variables ligadas a las densidades.

Tabla 6: Comparación de los datos simulados con DART y los datos del PNOA 2011 - 2016 para el conjunto de parcelas analizadas.

	Variable	Simulado_2011	PNOA_2011	Simulado_2016	PNOA_2016
		Promedio	Promedio	Promedio	Promedio
Canopy height metrics (CHM)	P25	0,15	0,84	0,16	0,52
	P50	0,72	2,04	1,36	1,88
	P75	1,82	2,86	2,23	2,96
	P95	2,60	3,70	3,12	4,01
	Elevación media	1,01	1,92	1,34	1,85
	Elevación máxima	3,16	4,55	3,90	5,16
	Elevación cuadrática media	1,43	2,35	1,77	2,37
	Elevación cúbica media	1,67	2,60	2,03	2,68
	Desviación absoluta media	0,90	1,09	1,02	1,25
	Distancia intercuartílica	1,67	2,02	2,07	2,45
Canopy height metrics (CHM)	Desviación estándar	0,98	1,31	1,14	1,44
	Varianza	2,43	3,21	2,74	3,72
	Primeros retornos sobre la media	50,41	166,43	104,92	380,12
	Porcentaje de todos los retornos sobre la moda	43,85	94,04	47,87	86,81
	Media de los retornos de 0 a 0,6	0,18	0,07	0,16	0,16
	Proporción de retornos de 0 a 0,6	78,57	57,00	40,96	60,00
	Media de los retornos de 0,6 a 2	0,32	0,97	0,80	0,99
	Proporción de retornos de 0,6 a 2	3,57	8,00	40,96	11,00
	Media de los retornos de 2 a 4	1,29	2,09	1,40	2,09
	Proporción de retornos de 2 a 4	5,36	14,00	7,23	9,00
Canopy density metrics (CDM)	Media de los retornos superiores a 4	2,19	3,20	2,52	3,30
	Proporción de retornos superiores a 4	12,50	21,00	10,85	20,00

Tabla 7: Correlación entre las métricas de la nube de puntos simulada y real del PNOA para 2011 y 2016, RMSE y % RMSE sobre el valor medio del PNOA real.

Variable	2011			2016		
	Correlación	RMSE	%RMSE (PNOA 2011)	Correlación	RMSE	%RMSE (PNOA 2016)
P25	0,11	1,28	1,52	0,34	1,18	2,29
P50	0,69	2,16	1,06	0,75	1,46	0,78
P75	0,94	1,28	0,45	0,92	1,30	0,44
P95	0,94	1,42	0,38	0,95	1,40	0,35
Elevación media	0,92	1,13	0,59	0,92	1,00	0,54
Elevación máxima	0,93	1,92	0,42	0,97	1,62	0,31
Elevación cuadrática media	0,94	1,04	0,44	0,96	0,97	0,41
Elevación cúbica media	0,94	1,03	0,40	0,97	0,95	0,35
Desviación absoluta media	0,95	0,40	0,37	0,95	0,45	0,36
Distancia intercuartílica	0,92	1,16	0,57	0,91	1,19	0,48
Desviación estándar	0,95	0,46	0,35	0,97	0,43	0,30
Varianza	0,95	1,20	0,37	0,97	1,80	0,48
Primeros retornos sobre la media	0,54	169,13	1,02	0,34	429,42	1,13
Porcentaje de todos los retornos sobre la moda	0,35	54,26	0,58	0,59	41,63	0,48
Media de los retornos de 0 a 0,6	0,33	0,11	1,70	0,36	0,07	0,45
Proporción de retornos de 0 a 0,6	0,41	0,39	0,69	0,77	0,36	0,59
Media de los retornos de 0,6 a 2	0,52	0,88	0,91	0,71	0,52	0,53
Proporción de retornos de 0,6 a 2	0,22	0,13	1,70	0,56	0,12	1,07
Media de los retornos de 2 a 4	0,65	1,50	0,72	0,74	1,34	0,64
Proporción de retornos de 2 a 4	0,72	0,17	1,20	0,73	0,12	1,37
Media de los retornos superiores a 4	0,89	1,62	0,51	0,94	1,55	0,47
Proporción de retornos superiores a 4	0,91	0,19	0,91	0,93	0,18	0,89

Tabla 8: Correlación entre los estadísticos de la nube de puntos simulada en 2011 y las del PNOA real de 2016.

	Variable	Correlación	RMSE	%RMSE (PNOA 2016)
Canopy height metrics (CHM)	P25	-0,02	1,19	2,30
	P50	0,59	2,19	1,16
	P75	0,93	1,69	0,57
	P95	0,95	1,87	0,46
	Elevación media	0,92	1,29	0,70
	Elevación máxima	0,97	2,46	0,48
	Elevación cuadrática media	0,96	1,30	0,55
	Elevación cúbica media	0,97	1,32	0,49
Canopy height (CHM)	Desviación absoluta media	0,96	0,55	0,44
	Distancia intercuartílica	0,91	1,49	0,61
	Desviación estándar	0,98	0,60	0,42
	Varianza	0,98	2,09	0,56
Canopy density metrics (CDM)	Primeros retornos sobre la media	0,31	472,17	1,24
	Porcentaje de todos los retornos sobre la moda	0,63	45,79	0,53
	Media de los retornos de 0 a 0,6	0,27	0,08	0,49
	Proporción de retornos de 0 a 0,6	0,28	0,37	0,62
	Media de los retornos de 0,6 a 2	0,50	0,87	0,88
	Proporción de retornos de 0,6 a 2	-0,09	0,17	1,55
	Media de los retornos de 2 a 4	0,69	1,61	0,77
	Proporción de retornos de 2 a 4	0,57	0,13	1,50
	Media de los retornos superiores a 4	0,92	1,90	0,58
	Proporción de retornos superiores a 4	0,91	0,20	1,00

Tabla 9: Correlación entre los estadísticos de la nube de puntos simulada en 2016 y los datos reales del PNOA de 2011.

	Variable	Correlación	RMSE	%RMSE (PNOA 2011)
Canopy height metrics (CHM)	P25	0,21	1,27	1,52
	P50	0,87	1,31	0,64
	P75	0,94	0,93	0,33
	P95	0,95	1,07	0,29
	Elevación media	0,93	0,81	0,42
	Elevación máxima	0,94	1,35	0,30
	Elevación cuadrática media	0,94	0,72	0,31
	Elevación cúbica media	0,93	0,69	0,27
Canopy height (CHM)	Desviación absoluta media	0,95	0,34	0,31
	Distancia intercuartílica	0,91	1,14	0,57
	Desviación estándar	0,95	0,34	0,26
	Varianza	0,95	1,24	0,39
Canopy density metrics (CDM)	Primeros retornos sobre la media	0,63	136,18	0,82
	Porcentaje de todos los retornos sobre la moda	0,49	49,00	0,52
	Media de los retornos de 0 a 0,6	0,49	0,09	1,35
	Proporción de retornos de 0 a 0,6	0,85	0,38	0,66
	Media de los retornos de 0,6 a 2	0,63	0,54	0,56
	Proporción de retornos de 0,6 a 2	0,80	0,07	0,90
	Media de los retornos de 2 a 4	0,67	1,24	0,59
	Proporción de retornos de 2 a 4	0,86	0,12	0,89
	Media de los retornos superiores a 4	0,92	1,28	0,40
	Proporción de retornos superiores a 4	0,94	0,17	0,81

3.4. Selección de métricas LiDAR y clasificación de modelos combustibles

A continuación, en la tabla 10 se muestran a modo de resumen las variables que tienen una mayor correlación de Spearman, teniendo en consideración la clasificación por tipo de combustible, para los años 2011 y 2016. En el anexo 3 se presentan las tablas A11, donde se puede ver el conjunto de correlaciones obtenidas.

En lo que se refiere a la correlación entre las variables simuladas con DART en el año 2011 y el modelo de combustible (ver tabla 10) se observan altas correlaciones, superiores a 0,8, en aquellas variables ligadas a la altura y a la variabilidad, como la elevación cúbica media o la desviación estándar entre otros. Por el contrario, la variable percentil 25 posee un valor de correlación de Spearman muy bajo en torno al 0,23. Además, si bien es cierto que la mayoría de las variables relacionadas con la densidad poseen datos de correlación aceptables, en torno a 0,7, como es la media de retornos superior a 4 m, además existe un evidente descenso de la correlación general en las métricas de densidad, que presentan correlaciones menores de 0,5 en el caso de la proporción de retorno de 0 a 0,6 y el número de primeros retornos sobre la media.

En el caso de la correlación entre las variables simuladas con DART para el año 2016 y el modelo de combustible (ver tabla 10) se muestran altas correlaciones superiores a 0,80 en algunas variables relacionadas con la elevación máxima o la varianza, entre otros, mientras que la variable percentil 25 posee un valor de correlación de Spearman muy bajo entorno al 0,35. En segundo lugar, la mayoría de las variables relaciones con la densidad tienen datos de correlación aceptables en torno a 0,7, como es el caso de la media de los retornos superiores a 4 m.

A continuación, en las tablas 11 y 12 aparece el resultado de la selección por métodos de selección de todos los subconjuntos para los años 2011 y 2016. Tal y como se aprecia la variables coeficientes de variación, la proporción de retornos entre 0 y 0,6 están presenten en la mayoría de los métodos de selección.

El modelo con mejores resultados en la fase de entrenamiento fue el SVM con kernel linear, con una fiabilidad global de la clasificación tras la validación cruzada de 60% y una índice kappa de 0,53 (para la simulación de 2011). Las cuatro métricas de las nubes de puntos simuladas con DART con mayor capacidad explicativa fueron la mediana del intervalo de altura de retornos entre 0 y 0,6, la elevación media, el L momento del coeficiente de variación y el percentil 99. La clasificación utilizando los datos simulados muestra resultados muy similares a los generados utilizando datos reales del PNOA de la primera cobertura que obtuvieron una fiabilidad global de la clasificación tras la validación cruzada de 58% y un índice kappa de 0,50. La similitud de resultados en la comparación realizada muestra la fiabilidad de la clasificación.

Como se ha comentado con anterioridad, para la clasificación de los datos reales procedentes del PNOA del año 2016, se han vuelto a utilizar las mismas variables explicativas y parametrización del modelo simulado de 2011, obteniéndose una fiabilidad global de la clasificación tras la validación cruzada de 53% y una índice kappa de 0,44. La similitud de resultados en la comparación realizada muestra que el modelo con datos simulados en 2011 es transferible a 2016 (ver tabla 13).

Por último, señalar que tras realizar varias pruebas lo mejores resultados se han obtenido con un total de 25 repeticiones, con un valor de cost de 50 y un gamma de 0,15.

Tabla 10: Correlación entre las variables simuladas con DART (año 2011 y año 2016) y el modelo de combustible.

	Variable	Correlación 2011	Correlación 2016
Canopy height metrics (CHM)	P25	0,23	0,35
	P50	0,71	0,83
	P75	0,85	0,84
	P95	0,85	0,84
	Elevación media	0,84	0,84
	Elevación máxima	0,85	0,86
	Elevación cuadrática media	0,85	0,84
	Elevación cúbica media	0,86	0,84
	Desviación absoluta media	0,86	0,84
	Distancia intercuartílica	0,85	0,84
Canopy height variability metrics (CHVM)	Desviación estándar	0,86	0,85
	Varianza	0,86	0,85
	Primeros retornos sobre la media	0,49	0,63
	Porcentaje de todos los retornos sobre la moda	0,78	0,72
	Media de los retornos de 0 a 0,6	0,44	0,07
	Proporción de retornos de 0 a 0,6	-0,41	-0,82
	Media de los retornos de 0,6 a 2	0,47	0,60
	Proporción de retornos de 0,6 a 2	0,47	0,50
	Media de los retornos de 2 a 4	0,65	0,67
	Proporción de retornos de 2 a 4	0,63	0,65
Canopy density metrics (CDM)	Media de los retornos superiores a 4	0,73	0,78
	Proporción de retornos superiores a 4	0,74	0,77

Tabla 11: Métricas de la simulación de 2011 seleccionadas mediante el método de selección de todos los subconjuntos. P es percentil de altura de los retornos.

Selección mediante todos los subconjuntos 2011	
Remplazo secuencial	Coeficiente de variación + Porcentaje de primero retornos por encima de la moda+ todos los retornos por encima de 0+moda de retornos de 0,0 a 0,6
Exhaustivo	Coeficiente de variación + total de retornos por encima de 0...total de primeros retornos...100 +proporción de retorno de 0,6 a 2
Hacia adelante	L momento del coeficiente de variación +P40+primero retornos por encima de 0+ total de retornos entre 0,6 y 2
Hacia atrás	L momento del coeficiente de variación + primeros retornos por encima de la moda +moda de elevación entre 0 y 0,6 + porcentaje de todos los retornos por encima de 0

Tabla 12: Métricas de la simulación de 2016 seleccionadas mediante el método de selección de todos los subconjuntos. P es percentil de altura de los retornos.

Selección mediante todos los subconjuntos 2016	
Remplazo secuencial	Elevación máxima +proporción de retornos entre 0 y 0,6 +mediana de elevación entre 0 y 0,6 + proporción de retornos entre 2 y 4
Exhaustivo	Elevación máxima + varianza +media entre 0 y 0,6
Hacia adelante	Elevación cuadrática media+ Elevación cúbica media+ proporción de retornos de 0,6 a 2+ total de retornos entre 2 y 4
Hacia atrás	P20+ proporción de retornos entre 0 y 0,6 + mediana de elevación entre 0 y 0,6+ elevación media por encima de 4

Tabla 13: Comparación de los modelos de clasificación con datos simulados y reales obtenidos con las cuatro variables seleccionadas: la mediana entre los intervalos 0 a 0,6 (Mediana_ 0 a 0,6), la elevación media (EM), el L momento del coeficiente de variación (L_CV) y el percentil 99 (año 2011).

	Variables	Fiabilidad global	Kappa
Datos simulados	Mediana_0 a 0,6 + EM + L_CV + P99	0,60	0,53
Datos PNOA		0,58	0,50

Tabla 14: Fiabilidad de la clasificación obtenida con las cuatro variables seleccionadas: la mediana entre los intervalos 0 a 0,6 (Mediana_ 0 a 0,6), la elevación media (EM), el L momento del coeficiente de variación (L_CV) y el percentil 99 (año 2011).

	Variables	Fiabilidad global	Kappa
Datos PNOA	Mediana_0 a 0,6 + EM + L_CV + P99	0,53	0,44

4. DISCUSIÓN.

Los resultados de este trabajo evidencian el potencial que tiene la simulación con modelos de transferencia radiativa con el fin de poder explotar de una manera más eficaz un recurso ya existente, como los datos LiDAR PNOA, que no tiene una periodicidad temporal elevada. Autores como Lamelas *et al.* (2019), Yin *et al.* (2016, 2018), Gastellu *et al.* (2004, 2012, 2016), Wagner *et al.* (2006) han corroborado el potencial que tienen estos modelos para simular datos LiDAR y su utilidad en diversas aplicaciones. Este tipo de información ofrece multitud de oportunidades para diferentes ramas científicas, centrándose el trabajo presente en la cartografía de modelos de combustible.

Para la realización de simulaciones lo más ajustadas posible a la realidad es necesario disponer de una gran cantidad de información, como la relativa a las características del sensor, de la vegetación de la zona a simular, su reflectividad y transmitancia, etc. En este sentido, el programa realizará simulaciones más ajustadas a la realidad cuanto más precisa sea la información de partida introducida. En todo caso, no hay que olvidar que la simulación no es más que una simplificación de la realidad, por lo que en muchos casos es necesario realizar ciertas asunciones.

Como ya se ha comentado, para realizar la simulación en DART es necesario asignar valores de reflectividad y transmitancia a las diferentes cubiertas y al no disponer de esta información para el área de estudio se obtuvieron valores lo más aproximados a la realidad basándose en aquellos propuestos previamente por expertos en la materia. En este sentido, la disponibilidad de valores de reflectividad y transmitancia precisos para las cubiertas podría haber mejorado las correlaciones entre las variables simuladas y las reales.

Otra información importante para las simulaciones es la relativa a las características del sensor. Sin embargo, no es sencillo obtener información detallada sobre sus parámetros más técnicos. En nuestro caso, en ausencia de algunos datos en los certificados de calibración de los sensores, han sido fundamentales las aportaciones realizadas por investigadores como Gastellu-Etchegorry y Yin, desarrolladores de DART.

Uno de los datos requeridos por DART para la simulación de los árboles que no estaba disponible en los inventarios de campo es la anchura de copa. Como se ha comentado con anterioridad esta variable se estimó a partir de la ecuación de Condés y Sterba (2005), obteniendo resultados acordes a los valores tipo por especie estimados por los mismos autores. Los buenos resultados obtenidos en las correlaciones indican que la ausencia de esta información no ha supuesto un gran inconveniente para obtener simulaciones ajustadas a la realidad.

Aunque en general se han obtenido unos promedios bastante similares entre el valor simulado y el valor real, se debe mencionar que algunas de las diferencias encontradas entre las simulaciones y el dato real el PNOA como por ejemplo el número de retornos o la altura máxima se deben contextualizar y entenderlas como lógicas, ya que, las simulaciones de las parcelas no son más que una simplificación de las parcelas y pueden verse afectadas por factores como: la aleatoriedad en la distribución de los árboles, la eliminación de algunas cubiertas vegetales por tener datos de cobertura menores al 5%, la pendiente de la zona, el lugar exacto donde rebota el pulso emitido, etc.

En relación a la comparación de las nubes simuladas en un determinado año con las nubes capturadas en otra fecha con otro sensor, se debe señalar que las correlaciones no sufren un importante descenso ni aumentan significativamente los errores, por lo que, se considera que los parámetros relacionados con la escena podrían tener una mayor influencia que los relacionados con el sensor en el ajuste de las simulaciones a la realidad, lo que permitiría la transferibilidad de las simulaciones.

Las métricas que presentan una mayor capacidad explicativa en la discriminación de modelos combustibles según los resultados obtenidos, concuerdan con las obtenidas en estudio previos realizados en ambientes mediterráneos (Montealegre, *et al.*, 2017, Domingo, *et al.*, 2019).

En cuanto a las altas correlaciones obtenidas en numerosas métricas se concluye que, las simulaciones obtenidas en DART son fiables y válidas para ser utilizadas en la discriminación de modelos combustibles.

Finalmente, y atendiendo a los datos de fiabilidad global de la clasificación tras la validación cruzada y a los índices de kappa se afirma la validez de las variables explicativas para la clasificación de modelos (Domingo, *et al.*, 2019)

5. CONCLUSIONES.

Los resultados aquí presentados validan la metodología propuesta, es decir, se ha constatado la posibilidad de disponer de variables derivadas de nubes de puntos LiDAR simuladas de baja densidad, para su posterior utilización en procesos automatizados de clasificación de modelos de combustibles.

Actualmente los datos LiDAR PNOA son públicos y gratuitos, sin embargo, ha resultado difícil la adquisición de algunos parámetros relacionados, especialmente relativos a la configuración del sensor, los cuales son necesarios para la elaboración de las simulaciones, en este caso en un modelo de transferencia radiativa anisotrópica discreta como DART.

A partir de los resultados obtenidos se han confirmado dos aspectos muy importantes: Por un lado, la capacidad de transferibilidad de las simulaciones y por otro se ha validado que las variables simuladas son capaces de modelar tipos de combustible con un acierto similar a los datos reales, por lo que posibilitaría una reducción del trabajo de campo.

La investigación presentada se ha focalizado en analizar si los modelos de transferencia radiativa son de utilidad para simular puntos LiDAR de baja densidad. Una vez que se ha comprobado dicha hipótesis, las posibles propuestas a futuro podrían ser las siguientes:

- Automatizar el proceso de elaboración de la simulación, ya que cuando se trabaja con muchas simulaciones el proceso exige demasiado tiempo de elaboración. En este sentido, existen posibilidades de automatización mediante generación de scripts que en DART denominan, “secuencias”.
- Simular datos LiDAR para otros sensores no tripulados y a bordo de satélites dado el incremento previsible de datos en la próxima década. Dichas misiones espaciales repercutirán positivamente en la capacidad para realizar observaciones de parámetros de la vegetación, en comparación con la misión inicial ICESat LiDAR 2003-2009. Además, existen otras misiones como biomass de Sentinel y la perteneciente a la Agencia Espacial Japonesa iLOVE (Murooka *et al.*, 2013), que se focalizarán en las latitudes medias y bajas (<+ 50°).

6. BIBLIOGRAFÍA.

Albini, F. A. (1976). Estimating wildfire behavior and effects. *Gen. Tech. Rep. INT-GTR-30. Ogden, UT: US Department of Agriculture, Forest Service, Intermountain Forest and Range Experiment Station.* 92 p., 30.

Andersen, H. E., McGaughey, R. J., & Reutebuch, S. E. (2005). Estimating forest canopy fuel parameters using LiDAR data. *Remote sensing of Environment*, 94(4), 441-449.

Andersen, H. E., Reutebuch, S. E., & McGaughey, R. J. (2006). A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. *Canadian Journal of Remote Sensing*, 32(5), 355-366.

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), 1239-1252.

Burgan, R. E., Klaver, R. W., & Klaver, J. M. (1998). Fuel models and fire potential from satellite and surface observations. *International journal of wildland fire*, 8(3), 159-170.

Bye, I. J., North, P. R., Los, S. O., Kljun, N., Rosette, J. A. B., Hopkinson, C., ... & Mahoney, C. (2017). Estimating forest canopy parameters from satellite waveform LiDAR by inversion of the FLIGHT three-dimensional radiative transfer model. *Remote sensing of environment*, 188, 177-189.

CESBIO. 2016. DART Tools User Manual. Toulouse. France.

CESBIO. 2016. DART User's Manual (V5.6.3). Toulouse. France.

Chuvieco, E. (2010). Teledetección ambiental: la observación de la tierra desde el espacio (Ariel Cien

Chuvieco, E., Martín, M.P. (2004). *Nuevas tecnologías para la estimación del riesgo de incendios forestales*. Colección de Estudios Ambientales y Socioeconómicos. Consejo Superior de Investigaciones Científicas, Instituto de Economía y Geografía, Madrid, 190 pp.

Condés, S., & Sterba, H. (2005). Derivation of compatible crown width equations for some important tree species of Spain. *Forest Ecology and Management*, 217(2-3), 203-218.

Cuadrat, J.M. (2004). El clima de Aragón. Geografía Física de Aragón, Aspectos Generales Y Temáticos, 15-26.

De Santis, A., & Chuvieco, E. (2007). Burn severity estimation from remotely sensed data: performance of simulation versus empirical models. *Remote Sensing of Environment*, 108(4), 422-435.

Domingo, D., (2015). Estimación de variables dasométricas en masas de *pinus Halepensis* mil. Mediante datos LiDAR y trabajo de campo

Domingo, D., Alonso, R., Lamelas, M. T., Montealegre, A. L., Rodríguez, F., & de la Riva, J. (2019). Temporal transferability of pine forest attributes modeling using low-density airborne laser scanning data. *Remote Sensing*, 11(3), 261.

Domingo, D., de la Riva, J., Lamelas, M.T., Hoffré, R., Ibarra, P., Echeverría, M.T., García-Martín, A. (2019). Clasificación de modelos de combustible mediante datos LiDAR en masas mediterráneas afectadas por incendios forestales. En Ruiz, L.A., Estornell, J., Calle, A. y Antuña-Sánchez, J.C. *Teledetección: hacia una visión global del cambio climático. Ediciones Universidad de Valladolid*, Valladolid, 451-454.

Domingo, D., de la Riva, J., Lamelas, M.T., Hoffré, R., Ibarra, P., Echeverría, M.T., García-Martín, A. (2019). Clasificación de modelos de combustible mediante datos LiDAR en masas mediterráneas afectadas por incendios forestales. En Ruiz, L.A., Estornell, J., Calle, A. y Antuña-Sánchez, J.C. *Teledetección: hacia una visión global del cambio climático. Ediciones Universidad de Valladolid*, Valladolid, 451-454.

García, M., Riaño, D., Chuvieco, E., Salas, J., & Danson, F. M. (2011). Multispectral and LiDAR data fusion for fuel type mapping using Support Vector Machine and decision rules. *Remote Sensing of Environment*, 115(6), 1369-1379.

Gastellu-Etchegorry, J. P., Grau, E., & Lauret, N. (2012). DART: A 3D model for remote sensing images and radiative budget of earth surfaces. *Modeling and simulation in Engineering*, 1-40.

Gastellu-Etchegorry, J. P., Grau, E., & Lauret, N. (2012). DART: A 3D model for remote sensing images and radiative budget of earth surfaces. *Modeling and simulation in Engineering*, 1-40.

Gastellu-Etchegorry, J. P., Martin, E., & Gascon, F. (2004). DART: a 3D model for simulating satellite images and studying surface radiation budget. *International journal of remote sensing*, 25(1), 73-96.

Gastellu-Etchegorry, J. P., Yin, T., Lauret, N., Cajgfinger, T., Gregoire, T., Grau, E., ... & Malenovský, Z. (2015). Discrete anisotropic radiative transfer (DART 5) for modeling airborne and satellite spectroradiometer and LIDAR acquisitions of natural and urban landscapes. *Remote Sensing*, 7(2), 1667-1701.

Gastellu-Etchegorry, J. P., Yin, T., Lauret, N., Grau, E., Rubio, J., Cook, B. D., ... & Sun, G. (2016). Simulation of satellite, airborne and terrestrial LiDAR with DART (I): Waveform simulation with quasi-Monte Carlo ray tracing. *Remote Sensing of Environment*, 184, 418-435.

González-De Vega, S., De las Heras, J., & Moya, D. (2016). Resilience of Mediterranean terrestrial ecosystems and fire severity in semiarid areas: Responses of Aleppo pine forests in the short, mid and long term. *Science of the Total Environment*, 573, 1171-1177.

González-De Vega, S., De las Heras, J., & Moya, D. (2016). Resilience of Mediterranean terrestrial ecosystems and fire severity in semiarid areas: Responses of Aleppo pine forests in the short, mid and long term. *Science of the Total Environment*, 573, 1171-1177.

Hall, S. A., Burke, I. C., Box, D. O., Kaufmann, M. R., & Stoker, J. M. (2005). Estimating stand structure using discrete-return lidar: an example from low density, fire prone ponderosa pine forests. *Forest Ecology and Management*, 208(1-3), 189-209.

Hopkinson, C., Chasmer, L. E., Zsigovics, G., Creed, I. F., Sitar, M., Treitz, P., & Maher, R. V. (2004). Errors in LiDAR ground elevation and wetland vegetation height estimates. *International Archives of Photogrammetry, Remote Sensing, and Spatial Information Sciences*, 36(8), 108-113.

IGME (2003) Mapa Geológico de España Escala 1:200.000 (2^a serie)

Koetz, B., Morsdorf, F., Sun, G., Ranson, K. J., Itten, K., & Allgower, B. (2006). Inversion of a lidar waveform model for forest biophysical parameter estimation. *IEEE Geoscience and Remote Sensing Letters*, 3(1), 49-53.

Lamelas-Gracia, M. T., Riaño, D., & Ustin, S. (2019). A LiDAR signature library simulated from 3-dimensional Discrete Anisotropic Radiative Transfer (DART) model to classify fuel types using spectral matching algorithms. *GIScience & Remote Sensing*, 1-36.

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.

Lasaponara, R., Lanorte, A., & Pignatti, S. (2006). Characterization and mapping of fuel types for the Mediterranean ecosystems of Pollino National Park in southern Italy by using hyperspectral MIVIS data. *Earth Interactions*, 10(13), 1-11.

Longares, L. A. (2004). Variedad biogeográfica del territorio aragonés. Peña, JL; Longares, LA y Sánchez, M.(coords.): Geografía Física de Aragón. Aspectos generales y temáticos. Zaragoza: Inst. Fernando El Católico, 27-40.

López del Ríos, R., & Bardají, M. (2009). Estrategia de extinción en los grandes incendios del verano. Natural de Aragón, 35, 32-33.

McCoy, R. M. (2005). *Field methods in remote sensing*. Guilford Press. pp. 42-58.

Merrill, D. F., & Alexander, M. E. (1987). Glossary of fire management terms. *Canadian Committee on Forest Fire Management, NRCC N°26516, Ottawa, Canada*.

Miller, A. (2002). *Subset selection in regression*. Chapman and Hall/CRC.

Milton, E. J. (1987). Review article principles of field spectroscopy. *Remote Sensing*, 8(12), 1807-1827.

Montealegre, A. L., Lamelas, M. T., de La Riva, J., García-Martín, A., & Escribano, F. (2016). Use of low point density ALS data to estimate stand-level structural variables in Mediterranean Aleppo pine forest. *Forestry: An International Journal of Forest Research*, 89(4), 373-382.

Montealegre, A.L., Lamelas, M.T., de la Riva, J., García-Martín, A., Escribano, F. (2015a). Cartografía de la biomasa aérea total en masas de *Pinus halepensis* Mill. en el entorno de Zaragoza mediante datos LiDAR-PNOA y trabajo de campo. XXIV Congreso de la Asociación de Geógrafos Españoles.

Montealegre, A.L., Lamelas, M.T., de la Riva, J., García-Martín, A., Escribano, F. (2015b). Cartografía de modelos de combustible mediante combinación de imágenes LiDAR, SAR y ópticas en el Centro de adiestramiento “San Gregorio”. In Asorey Cacheda, R., Devesa Rey, R., Solla Carracel, M.M., Pousada Carballo, J.M. (Eds), *Congreso Nacional de i+d en Defensa y Seguridad, DESEi+d 2015*. Centro Universitario de la Defensa de Marín, Marín, pp. 1185-1192 (ISBN:978-84-944537-0-0).

Murooka, J., Kobayashi, T., Imai, T., Suzuki, K., Sakaizawa, D., Yamakawa, S., ... & Asai, K. (2013, October). Overview of Japan's spaceborne vegetation lidar mission. In *Lidar Technologies, Techniques, and Measurements for Atmospheric Remote Sensing IX* (Vol. 8894, p. 88940B). International Society for Optics and Photonic

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(1), 274-285.

North, P. R. J., Rosette, J. A. B., Suárez, J. C., & Los, S. O. (2010). A Monte Carlo radiative transfer model of satellite waveform LiDAR. *International Journal of Remote Sensing*, 31(5), 1343-1358.

Pausas, J. G., Llovet, J., Rodrigo, A., & Vallejo, R. (2009). Are wildfires a disaster in the Mediterranean basin? –A review. *International Journal of wildland fire*, 17(6), 713-723.

Peña, J. L., & Lozano, M. V. (2004). Las unidades del relieve aragonés. Geografía Física de Aragón, Aspectos Generales Y Temáticos, 3-14.

Platt, R. V. (2014). Wildfire hazard in the home ignition zone: An object-oriented analysis integrating LiDAR and VHR satellite imagery. *Applied Geography*, 51, 108-117.

PNOA (2019). Presentación PNOA-LiDAR. Disponible en: <http://pnoa.ign.es/presentacion> (último acceso, 23 de agosto de 2019).

Prometheus, S. V. (2000). Management techniques for optimization of suppression and minimization of wildfire effects. *System validation. European Commission–contract number ENV4-CT98-0716*.

Ramírez, J., Blanco, J., Cerrillo, A., Marqués, G., Valcarce, R., & Llordén, J.M. (2013). Generación de cartografía de modelos de combustible a partir de datos LiDAR y análisis de imágenes orientado a objetos para su integración en Wildfire Analyst. In: Sociedad Española de Ciencias Forestales (Ed.), *Montes: Servicios y desarrollo rural. Actas del 6o Congreso Forestal Español*, Vitoria-Gasteiz, pp. 2–14.

Riaño, D., Chuvieco, E., Condés, S., González-Matesanz, J., & Ustin, S. L. (2004). Generation of crown bulk density for *Pinus sylvestris* L. from lidar. *Remote Sensing of Environment*, 92(3), 345-352.

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(8), 1301-1315.

Riaño, D., Chuvieco, E., Ustin, S. L., Salas, J., Rodríguez-Pérez, J. R., Ribeiro, L. M., ... & Fernández, H. (2007). Estimation of shrub height for fuel-type mapping combining airborne LiDAR and simultaneous color infrared ortho imaging. *International Journal of Wildland Fire*, 16(3), 341-348.

Riaño, D., Meier, E., Allgöwer, B., Chuvieco, E., & Ustin, S. L. (2003). Modeling airborne laser scanning data for the spatial generation of critical forest parameters in fire behavior modeling. *Remote Sensing of Environment*, 86(2), 177-186.

Rosette, J., Suárez, J., Nelson, R., Los, S., Cook, B., & North, P. (2012). Lidar remote sensing for biomass assessment. *Remote Sens. Biomass—Princ. Appl*, 24, 3-27.

Rothermel, R. C. (1972). A mathematical model for predicting fire spread in wildland fuels. *Res. Pap. INT-115. Ogden, UT: US Department of Agriculture, Intermountain Forest and Range Experiment Station.* 40 p., 115.

Ruiz Fernández, L. Á., Estornell Cremades, J., & ERENA ARRABAL, M. A. N. U. E. L. (2017, October). Teledetección. Nuevas plataformas y sensores aplicados a la gestión del agua, la agricultura y el medio ambiente. In Colección Congreso. Editorial Universitat Politècnica de València.

Salas, F. J., & Chuvieco, E. (1995). Aplicación de imágenes Landsat-TM a la cartografía de modelos combustibles. *Revista de Teledetección*, 5, 18-28.

Schaepman-Strub, G., Schaepman, M. E., Painter, T. H., Dangel, S., & Martonchik, J. V. (2006). Reflectance quantities in optical remote sensing—Definitions and case studies. *Remote sensing of environment*, 103(1), 27-42.

Sentinel Online (en línea). Sentinel mission (consultado el 03/08/2019). Disponible en: <<https://sentinel.copernicus.eu/web/sentinel/missions>>

Solomon, S., Qin, D., Manning, M., Averyt, K., Marquis, M., & Tignor, M. M. (Eds.). (2007). *Climate change 2007-the physical science basis: Working group I contribution to the fourth assessment report of the IPCC* (Vol. 4). Cambridge university press.

Spearman, C. (1904). The Proof and Measurement of Association between Two Things. *The American Journal of Psychology*, 15(1), 72.

Sun, G., & Ranson, K. J. (2000). Modeling lidar returns from forest canopies. *IEEE Transactions on geoscience and remote sensing*, 38(6), 2617-2626.

Tanase, M. A., Kennedy, R., & Aponte, C. (2015). Radar Burn Ratio for fire severity estimation at canopy level: An example for temperate forests. *Remote Sensing of Environment*, 170, 14-31.

Tian, X., Douglas J., M., Shu, L., & Wang, M. (2005). Fuel classification and mapping from satellite imagines. *Journal of Forest Research*, 16, 311–316.

Vosselman, G., & Maas, H. G. (2010). *Airborne and terrestrial laser scanning*. CRC press.

Wagner, W., Ullrich, A., Ducic, V., Melzer, T., & Studnicka, N. (2006). Gaussian decomposition and calibration of a novel small-footprint full-waveform digitising airborne laser scanner. *ISPRS journal of Photogrammetry and Remote Sensing*, 60(2), 100-112.

Yin, T., Lauret, N., & Gastellu-Etchegorry, J. P. (2016). Simulation of satellite, airborne and terrestrial LiDAR with DART (II): ALS and TLS multi-pulse acquisitions, photon counting, and solar noise. *Remote Sensing of Environment*, 184, 454-468.

Yin, T., Qi, J., Gastellu-Etchegorry, J. P., Wei, S., Cook, B. D., & Morton, D. C. (2018, July). Gaussian Decomposition of LiDAR Waveform Data Simulated by Dart. In *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium* (pp. 4300-4303). IEEE.

7. ANEXOS.

Anexo 1: Datos inventario de las parcelas de campo

Tabla A1: Ejemplo parcela de sotobosque.

FID Parcela	Especies de sotobosque/pasto	FCC (%)	Altura (m)
P35	Enebro	32	1,5-3
	Lastón	23	0.4
	Encina	35	0,5-1
	Suelo y acículas	10	
	TOTAL	100	
P34	Enebro	12	1,5-2
	Encina	25	2 a 3
	Romero	18	0,5-1
	Lastón	30	0.7
	Suelo y acículas	15	
	TOTAL	100	
P33	Coscoja	20	0.3
	Lastón	20	0.2
	Suelo y acículas con restos de poda	60	
	TOTAL	100	

Tabla A2: Ejemplo inventario de los árboles de las parcelas de campo.

Nº	Pies mayores				FID Parcela: P34
	Especie / Forma	Dn (cm)	H (m)	H 1º rama v. (m)	
1	Pino/1	26,6	10,3	4,8	
2	Pino/1	10,5	5,8	3,4	
3	Pino/1	22,4	9,6	4,2	
4	Pino/1	29,8	11,9	6,7	
5	Pino/1	24	8,7	4,1	
6	Pino/1	6,2	6,9	5,2	
7	Pino/1	26,5	8,7	3,9	
8	Pino/1	25,3	7,7	3,9	
9	Pino/1	14,2	6	3	
10	Pino/1	18,3	9,2	5	
11	Pino/1	32,6	10,6	4,2	
12	Pino/1	14,2	6	3,3	
13	Pino/1	25,7	9,8	4,2	
14	Pino/1	18,5	7,9	4,6	
15	Pino/1	7,7	3,7	2,2	
16	Pino/1	21,5	6,7	2,1	
17	Pino/1	5,9	4	2,6	
18	Pino/1	11,8	6,6	3,3	
19	Pino/1	17,6	8,7	3,9	
20	Pino/1	26,5	8,4	1,9	

21	Pino/1	16,3	9,5	5,1	
22	Pino/1	15,6	9,5	5,4	
23	Pino/1	23,6	9,1	4,5	
24	Pino/1	16,1	9,6	5	
25	Pino/1	23,9	10,1	5,4	
26	Pino/1	16,8	8,3	5,7	
27	Pino/1	17,3	8,4	4,5	
28	Pino/1	12,7	7,4	4,1	
29	Pino/1	15,8	7,9	3,3	
30	Pino/1	17,9	7,5	2,8	
31	Pino/1	19,6	8,5	4,8	
32	Pino/1	25,8	8,5	4,4	
33	Pino/1	21,9	9,4	2,8	
34	Pino/1	4,5	4,8	1,3	
35	Pino/1	27,7	9,4	4,1	
36	Pino/1	22,3	8,9	3,2	
37	Pino/1	22,8	7,8	4	
38	Pino/1	23,9	7,8	4,1	
39	Pino/1	17	7,4	4,5	
40	Pino/1	17,6	7	2,7	
41	Pino/1	28,3	9,1	4,3	
42	Pino/1	5,5	3,9	2,3	
43	Pino/1	7,7	5,6	3,8	
44	Pino/1	22,7	9,1	4,3	
45	Pino/1	30,6	9,4	4,7	
46	Pino/1	25,1	8	4,8	

Anexo 2: Datos introducidos en la simulación.

A3: Parámetros necesarios para la simulación de las parcelas para el año 2011.

Scene										
	Earth	Plot					Tree			
		Soil	Vegetation				Spectra			
Fuel model	Spectra	Spectra	Mean	Std	LAI	Trunk	Leaves	LAI	Estimated number of trees	
			height	deviation						
			(m)	height						
				(m)						
P 7 (P35)	0,40	0,59	0,59	2,50	0,50	0,72	0,28	0,59	0,85	72
			0,27	0,40	0,10	0,22				
			0,52	0,75	0,25	0,22				
			NA	NA	NA	NA				
P 7 (P34)	0,40	0,59	0,59	1,75	0,25	0,35	0,28	0,59	0,85	46
			0,52	2,50	0,50	0,72				
			0,52	0,75	0,25	0,22				
			0,27	0,70	0,10	0,22				
			NA	NA	NA	NA				
P 5 (P33)	0,40	0,59	0,27	0,20	0,10	0,15	0,28	0,59	0,85	50
			0,52	0,30	0,10	0,15				
			NA	NA	NA	NA				
P5(P32)	0,40	0,60	0,53	0,30	0,15	0,15	0,28	0,60	0,85	54
			0,27	0,50	0,10	0,23				
			NA	NA	NA	NA				
P7 (P31)	0,40	0,60	0,27	0,50	0,10	0,23	0,28	0,60	0,85	105
			0,60	1,50	0,10	0,35				
			0,53	1,00	0,10	0,35				

			0,53	1,75	0,25	0,35				18
			NA	NA	NA	NA				
P6 (P30)	0,40	0,60	0,27	0,80	0,20	0,35	0,28	0,60	0,85	44
			0,60	2,00	0,50	0,35				
			NA	NA	NA	NA				
			0,27	0,10	0,05	0,15				
P5 (P29)	0,40	0,60	NA	NA	NA	NA	0,28	0,60	0,85	65
			0,27	0,10	0,05	0,15				4
P6 (P28)	0,40	0,60	0,53	0,40	0,15	0,23	0,28	0,60	0,85	63
			0,27	0,40	0,10	0,23				
			NA	NA	NA	NA				
P6 (P27)	0,40	0,60	0,27	0,30	0,10	0,15	0,28	0,60	0,85	62
			0,53	0,30	0,15	0,15				
			0,27	0,40	0,10	0,23				
			NA	NA	NA	NA				
P5 (P26)	0,40	0,60	0,53	0,30	0,15	0,15	0,28	0,60	0,85	60
			NA	NA	NA	NA				2
P6 (P25)	0,40	0,60	0,27	0,30	0,10	0,15	0,28	0,60	0,85	72
			NA	NA	NA	NA				
P5 (P24)	0,40	0,60	NA	NA	NA	NA	0,28	0,60	0,85	93
			0,53	0,50	0,10	0,23				5
P7 (P23)	0,40	0,60	0,60	1,00	0,10	0,35	0,28	0,60	0,85	78
			NA	NA	NA	NA				
			0,53	0,75	0,25	0,23				
P6 (P22)	0,40	0,60	0,60	0,75	0,25	0,23	0,28	0,60	0,85	16
			0,27	0,50	0,10	0,23				
			NA	NA	NA	NA				
			0,53	1,50	0,10	0,35				
P7 (P21)	0,40	0,60	0,53	2,75	0,25	0,73	0,28	0,60	0,85	44
			0,53	1,50	0,10	0,35				

			0,27	0,40	0,10	0,23				
			0,53	2,25	0,75	0,35				
			NA	NA	NA	NA				
							0,53			5
P7 (P20)	0,40	0,60	0,53	0,75	0,30	0,23	0,28	0,60	0,85	30
			0,53	1,75	0,25	0,35				
			0,60	1,50	0,50	0,35				
			NA	NA	NA	NA				
P7 (P19)	0,40	0,60	0,53	1,00	0,10	0,35	0,28	0,60	0,85	37
			0,53	1,00	0,20	0,35				
			0,53	2,50	0,10	0,73				
			0,27	0,30	0,10	0,15				
			NA	NA	NA	NA		0,53		4
P7 (P18)	0,40	0,60	0,60	2,00	0,10	0,35	0,28	0,60	0,85	30
			0,53	2,25	0,25	0,35				
			0,53	0,60	0,30	0,23				
			NA	NA	NA	NA				
P1 (P17)	0,40	0,60	0,27	0,30	0,10	0,15	0,28	0,60	0,85	14
			NA	NA	NA	NA				
P5 (P16)	0,40	0,60	0,27	0,20	0,10	0,15	0,28	0,60	0,85	56
			0,60	NA	NA	NA				
P7 (P15)	0,40	0,60	0,53	1,75	0,25	0,35	0,28	0,60	0,85	59
			0,60	2,00	0,30	0,35				
			NA	NA	NA	NA				3
P5 (P14)	0,40	0,60	0,27	0,30	0,10	0,15	0,28	0,60	0,85	56
			NA	NA	NA	NA				
P2 (MAT12)	0,40	0,60	0,60	2,25	0,25	0,35	NA	NA	NA	NA
			0,27	0,30	0,10	0,15				
P5 (P13)	0,40	0,60	0,27	0,30	0,10	0,15	0,28	0,60	0,85	63
			NA	NA	NA	NA				

P5 (P12)	0,40	0,60	0,60	2,25	0,25	0,35	0,28	0,60	0,85	46
			0,27	0,30	0,10	0,15				
			NA	NA	NA	NA				
P7 (P10)	0,40	0,60	0,60	5,00	1,00	0,85	NA	NA	NA	NA
			0,53	0,90	0,10	0,35				
			0,53	1,25	0,25	0,35				
			0,27	0,40	0,10	0,23				
			NA	NA	NA	NA				
P4 (R57)	0,40	0,60	0,60	2,50	0,50	0,73	NA	NA	NA	NA
			0,53	2,00	0,10	0,35				
			0,53	1,00	0,10	0,35				
			NA	NA	NA	NA				
P4 (R53)	0,40	0,60	0,60	0,30	0,10	0,15	NA	NA	NA	NA
			0,60	3,00	1,00	0,73				
			0,53	0,75	0,25	0,23				
			0,53	1,25	0,25	0,35				
			NA	NA	NA	NA				
P5 (R86)	0,40	0,60	0,27	0,20	0,10	0,15	0,28	0,60	0,85	45
			NA	NA	NA	NA				
P5 (R82)	0,40	0,60	0,53	2,00	0,30	0,35	0,28	0,60	0,85	62
			NA	NA	NA	NA				
P3 (R70)	0,40	NA	0,53	0,50	0,20	0,23	NA	NA	NA	NA
			0,53	2,00	0,50	0,35				
			0,60	1,00	0,50	0,35				
			0,27	0,50	0,10	0,23				
P3 (MAT11)	0,40	NA	0,53	0,50	0,20	0,23	NA	NA	NA	NA
			0,60	1,50	0,50	0,35				
			0,60	5,00	0,10	0,85				
P3 (R62)	0,40	NA	0,53	0,90	0,10	0,35	NA	NA	NA	NA

			0,53	0,75	0,25	0,23				
			0,27	0,50	0,10	0,23				
			0,27	0,20	0,05	0,15				
			0,60	2,50	0,50	0,73				
			0,53	1,50	0,20	0,35				
P2 (R66)	0,40	NA	0,27	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	1,00	0,20	0,35				
			0,27	0,30	0,10	0,15				
			0,27	0,50	0,20	0,23				
P2 (R69)	0,40	NA	0,53	0,75	0,25	0,23	NA	NA	NA	NA
			0,53	0,75	0,25	0,23				
P2 (R52)	0,40	NA	0,27	0,60	0,10	0,23	NA	NA	NA	NA
			0,27	0,60	0,10	0,23				
			0,27	0,40	0,10	0,23				
P2 (R56)	0,40	NA	0,27	0,30	0,10	0,15	NA	NA	NA	NA
			0,27	0,40	0,10	0,23				
			0,27	0,40	0,10	0,23				
P1 (R49)	0,40	NA	0,27	0,30	0,10	0,15	NA	NA	NA	NA
P1 (MAT10)	0,40	NA	0,27	0,50	0,10	0,23	NA	NA	NA	NA
			0,27	0,40	0,10	0,23				
			0,27	0,40	0,10	0,23				
P1 (R47)	0,40	NA	0,27	0,30	0,10	0,15	NA	NA	NA	NA
			0,27	0,75	0,25	0,23				
P2 (R41)	0,40	0,27	0,27	0,10	0,05	0,15	NA	NA	NA	NA
			NA	NA	NA	NA				
			0,53	0,40	0,20	0,23				
P2 (R42)	0,40	0,27	0,27	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	0,20	0,05	0,15				
			NA	NA	NA	NA				

			0,53	1,00	0,10	0,35				
P1 (R36)	0,40	NA	0,27	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	0,30	0,10	0,15				
			0,53	2,50	0,50	0,73				
P2 (R8)	0,40	NA	0,60	2,25	0,25	0,35	NA	NA	NA	NA
			0,53	1,25	0,25	0,35				
			0,27	0,30	0,10	0,15				
			0,27	0,30	0,10	0,15				
			0,27	0,30	0,10	0,15				
			0,53	3,00	0,10	0,73				
P6 (R15)	0,40	0,60	0,60	1,50	0,10	0,35	0,28	0,60	0,85	31
			0,53	1,00	0,30	0,35				
			0,27	0,30	0,10	0,15				
			NA	NA	NA	NA				
			0,53	4,00	2,00	0,73				
P6 (E1)	0,40	NA	0,53	1,00	0,50	0,35	NA	NA	NA	NA
			0,27	0,30	0,20	0,15				
			0,60	4,00	2,00	0,73				
P3 (R19)	0,40	NA	0,60	1,50	0,10	0,35	NA	NA	NA	NA
			0,53	1,00	0,10	0,35				
			0,53	0,50	0,10	0,23				
			0,27	0,30	0,10	0,15				
			0,60	4,00	2,00	0,73				
P3 (R22)	0,40	NA	0,53	0,80	0,20	0,35	NA	NA	NA	NA
			0,60	1,00	0,50	0,35				
			0,53	0,80	0,20	0,35				
			0,27	0,25	0,05	0,15				
P4 (R20)	0,40	NA	0,53	1,50	0,50	0,35	NA	NA	NA	NA
			0,53	5,00	1,00	0,85				
			0,60	2,00	0,10	0,35				

			0,60	5,00	1,00	0,85				
			0,27	0,30	0,10	0,15				
			0,27	0,20	0,05	0,15				
P2(R24)	0,40	NA	0,53	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	0,30	0,10	0,15				
P3 (R23)	0,40	NA	0,60	1,80	0,20	0,35	NA	NA	NA	NA
			0,53	1,25	0,25	0,35				
			0,27	0,30	0,10	0,15				
P7 (R21)	0,40	NA	0,53	1,20	0,50	0,35	0,28	0,60	0,85	55
			0,53	0,70	0,20	0,23				
			0,60	1,50	0,50	0,35				
			0,27	0,30	0,05	0,15				
P4 (P8)	0,40	NA	0,53	2,25	0,25	0,35	NA	NA	NA	NA
			0,60	2,00	0,50	0,35				
			0,60	4,00	0,50	0,73				
			0,27	0,50	0,20	0,23				
P7 (P7)	0,40	0,60	0,53	1,25	0,50	0,35	0,28	0,60	0,85	4
			0,27	0,30	0,05	0,15				
			NA	NA	NA	NA				
P1 (P6)	0,40	NA	0,60	0,75	0,25	0,23	NA	NA	NA	NA
			0,27	0,10	0,05	0,15				
P2 (MQ2)	0,40	NA	0,53	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	0,20	0,05	0,15				
			0,27	0,10	0,05	0,15				
P3 (MQ1)	0,40	0,27	0,27	0,50	0,35	0,23	NA	NA	NA	NA
			NA	NA	NA	NA				
			0,53	0,75	0,25	0,23				
			0,53	0,75	0,25	0,23				
P1 (R35)	0,40	NA	0,27	0,10	0,05	0,15	NA	NA	NA	NA

			0,27	0,60	0,40	0,23				
			0,27	0,20	0,05	0,15				
P3 (R28)	0,40	0,27	0,53	1,25	0,25	0,35	NA	NA	NA	NA
			0,53	1,75	0,25	0,35				
			NA	NA	NA	NA				
			0,60	0,75	0,25	0,23				
			0,27	0,30	0,10	0,15				
			0,27	0,10	0,05	0,15				
			0,27	0,10	0,05	0,15				
P1 (R34)	0,40	NA	0,27	0,10	0,05	0,15	NA	NA	NA	NA
			0,27	0,20	0,05	0,15				
P1 (R40)	0,40	NA	0,27	0,10	0,05	0,15	NA	NA	NA	NA
			0,27	0,20	0,05	0,15				
P3 (P5)	0,40	NA	0,60	1,50	0,50	0,35	NA	NA	NA	NA
P5 (R85)	0,40	0,60	0,53	0,50	0,25	0,23	0,28	0,60	0,85	51
			NA	NA	NA	NA				
P2 (R87)	0,40	NA	0,53	0,50	0,10	0,23	NA	NA	NA	NA
			0,27	0,20	0,10	0,15				
P5 (R90)	0,40	0,60	0,27	0,20	0,10	0,15	0,28	0,60	0,85	49
			0,53	0,30	0,10	0,15				
			NA	NA	NA	NA				5
P2 (R78)	0,40	NA	0,53	0,50	0,10	0,23	NA	NA	NA	NA
			0,27	0,50	0,10	0,23				
			0,53	0,50	0,10	0,23				
P5 (P4)	0,40	0,60	0,60	1,75	0,25	0,35	0,28	0,60	0,85	65
			NA	NA	NA	NA				
P6 (P3)	0,40	0,60	0,53	2,25	0,25	0,35	0,28	0,60	0,85	30
			0,60	1,75	0,25	0,35				
			0,53	1,25	0,25	0,35				
			NA	NA	NA	NA				

P2 (R74)	0,40	NA	0,27	0,30	0,10	0,15	NA	NA	NA	NA
P2 (R72)	0,40	NA	0,53	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	0,15	0,05	0,15				
P3 (R64)	0,40	NA	0,53	0,50	0,10	0,23	NA	NA	NA	NA
			0,60	1,75	0,25	0,35				
P6 (P2)	0,40	0,60	0,53	1,50	0,50	0,35	0,28	0,60	0,85	26
			0,27	0,50	0,10	0,23				
			0,53	3,00	1,00	0,73				
			NA	NA	NA	NA				
P4 (R2)	0,40	0,60	0,53	1,50	0,10	0,35	NA	NA	NA	NA
			0,60	2,70	0,50	0,73				
			NA	NA	NA	NA				
P4 (R38)	0,40	NA	0,53	2,00	0,20	0,35	NA	NA	NA	NA
			0,53	0,90	0,10	0,35				
			0,27	0,15	0,05	0,15				
			0,60	2,25	0,25	0,35				
			0,53	2,25	0,25	0,35				
P4 (R39)	0,40	0,60	0,60	1,25	0,50	0,35	0,28	0,60	0,85	22
			0,53	0,75	0,25	0,23				
			0,60	NA	NA	NA				16
P1 (R37)	0,40	NA	0,27	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	0,25	0,05	0,15				
			0,60	2,00	0,50	0,35				
P3 (R31)	0,40	NA	0,60	1,25	0,25	0,35	NA	NA	NA	NA
			0,53	1,50	0,10	0,35				
			0,60	0,75	0,25	0,23				
			0,53	0,75	0,25	0,23				
			0,27	0,25	0,05	0,15				
P3 (R33)	0,40	NA	0,60	3,50	0,50	0,73	NA	NA	NA	NA

			0,53	1,75	0,25	0,35				
			0,53	0,75	0,25	0,23				
			0,27	0,25	0,05	0,15				
			0,60	1,00	0,10	0,35				
P7 (R30)	0,40	0,60	0,60	1,25	0,25	0,35	0,28	0,60	0,85	68
			0,53	1,25	0,25	0,35				
			0,53	0,50	0,10	0,23				
			NA	NA	NA	NA				
P1 (R51)	0,40	NA	0,27	0,25	0,05	0,15	NA	NA	NA	NA
			0,27	0,25	0,05	0,15				
P1 (R55)	0,40	NA	0,27	0,25	0,05	0,15	NA	NA	NA	NA
			0,53	1,75	0,25	0,35				
			0,53	0,75	0,25	0,23				
			0,60	0,80	0,20	0,35				
			0,53	0,50	0,10	0,23	NA	NA	NA	NA
P3 (R61)	0,40	NA	0,53	1,25	0,25	0,35				
			0,60	2,00	0,50	0,35	NA	NA	NA	NA
P3 (R67)	0,40	NA	0,53	1,00	0,10	0,35				
			0,27	0,25	0,05	0,15				
P4 (R48)	0,40	NA	0,53	2,50	0,10	0,73	0,28	0,60	0,85	7
			0,60	2,00	0,10	0,35				
			0,53	0,50	0,10	0,23				2
P1 (R29)	0,40	NA	0,27	0,15	0,05	0,15	NA	NA	NA	NA
			0,27	0,25	0,05	0,15				
			0,27	0,25	0,05	0,15				
			0,27	0,40	0,10	0,23				

A4: Parámetros necesarios para la simulación de las parcelas para el año 2016.

Scene									
	Earth	Plot				Tree			
		Soil	Vegetation			Spectra			
Fuel model	Spectra	Spectra	Spectra	Mean	Std	LAI	Trunk	Leaves	Estimated number of trees
				height	deviation				
				(m)	height				
					(m)				
P 7 (P35)	0,40	0,60		0,60	2,50	0,50	1,01	0,28	1,13
				0,27	0,40	0,10	0,29		
				0,53	0,75	0,25	0,29		
				NA	NA	NA	NA		
P 7 (P34)	0,40	0,60		0,60	1,75	0,25	0,51	0,28	46
				0,53	2,50	0,50	1,01		
				0,53	0,75	0,25	0,29		
				0,27	0,70	0,10	0,29		
				NA	NA	NA	NA		
P 5 (P33)	0,40	0,60		0,27	0,20	0,10	0,26	0,28	50
				0,53	0,30	0,10	0,26		
				NA	NA	NA	NA		
				0,53	0,30	0,15	0,15		
P5(P32)	0,40	0,60		0,27	0,50	0,10	0,29	0,28	54
				NA	NA	NA	NA		
				0,27	0,50	0,10	0,29		
P7 (P31)	0,40	0,60		0,60	1,50	0,10	0,51	0,28	105
				0,53	1,00	0,10	0,51		

			0,53	1,75	0,25	0,51				18
			NA	NA	NA	NA				
P6 (P30)	0,40	0,60	0,27	0,80	0,20	0,51	0,28	0,60	1,13	44
			0,60	2,00	0,50	0,51				
			NA	NA	NA	NA				
P5 (P29)	0,40	0,60	0,27	0,10	0,05	0,26	0,28	0,60	1,13	65
			NA	NA	NA	NA				4
P6 (P28)	0,40	0,60	0,53	0,40	0,15	0,29	0,28	0,60	1,13	63
			0,27	0,40	0,10	0,29				
			NA	NA	NA	NA				
P6 (P27)	0,40	0,60	0,27	0,30	0,10	0,26	0,28	0,60	1,13	62
			0,53	0,30	0,15	0,26				
			0,27	0,40	0,10	0,23				
			NA	NA	NA	NA				
P5 (P26)	0,40	0,60	0,53	0,30	0,15	0,26	0,28	0,60	1,13	60
			NA	NA	NA	NA				2
P6 (P25)	0,40	0,60	0,27	0,30	0,10	0,26	0,28	0,60	1,13	72
			NA	NA	NA	NA				
P5 (P24)	0,40	0,60	NA	NA	NA	NA	0,28	0,60	1,13	93
			NA	NA	NA	NA				5
P7 (P23)	0,40	0,60	0,53	0,50	0,10	0,29	0,28	0,60	1,13	78
			0,60	1,00	0,10	0,51				
			NA	NA	NA	NA				
P6 (P22)	0,40	0,60	0,53	0,75	0,25	0,29	0,28	0,60	1,13	16
			0,60	0,75	0,25	0,29				
			0,27	0,50	0,10	0,29				
			NA	NA	NA	NA				

P7 (P21)	0,40	0,60	0,53	1,50	0,10	0,51	0,28	0,60 0,53	1,13	44 5
			0,53	2,75	0,25	1,01				
			0,27	0,40	0,10	0,29				
			0,53	2,25	0,75	0,51				
			NA	NA	NA	NA				
P7 (P20)	0,40	0,60	0,53	0,75	0,30	0,29	0,28	0,60	1,13	30
			0,53	1,75	0,25	0,51				
			0,60	1,50	0,50	0,51				
			NA	NA	NA	NA				
P7 (P19)	0,40	0,60	0,53	1,00	0,10	0,51	0,28	0,60 0,53	1,13	37 4
			0,53	1,00	0,20	0,51				
			0,53	2,50	0,10	1,01				
			0,27	0,30	0,10	0,26				
			NA	NA	NA	NA				
P7 (P18)	0,40	0,60	0,60	2,00	0,10	0,51	0,28	0,60	1,13	30
			0,53	2,25	0,25	0,51				
			0,53	0,60	0,30	0,23				
			NA	NA	NA	NA				
P1 (P17)	0,40	0,60	0,27	0,30	0,10	0,26	0,28	0,60	1,13	14
			NA	NA	NA	NA				
P5 (P16)	0,40	0,60	0,27	0,20	0,10	0,26	0,28	0,60	1,13	56
			0,60	NA	NA	NA				
P7 (P15)	0,40	0,60	0,53	1,75	0,25	0,51	0,28	0,60	1,13	59 3
			0,60	2,00	0,30	0,51				
			NA	NA	NA	NA				

P5 (P14)	0,40	0,60	0,27	0,30	0,10	0,26	0,28	0,60	1,13	56
			NA	NA	NA	NA				
P2 (MAT12)	0,40	0,60	0,60	2,25	0,25	0,51	NA	NA	NA	NA
			0,27	0,30	0,10	0,26				
P5 (P13)	0,40	0,60	0,27	0,30	0,10	0,26	0,28	0,60	1,13	63
			NA	NA	NA	NA				
P5 (P12)	0,40	0,60	0,60	2,25	0,25	0,51	0,28	0,60	1,13	46
			0,27	0,30	0,10	0,26				
			NA	NA	NA	NA				
P7 (P10)	0,40	0,60	0,60	5,00	1,00	1,13	NA	NA	NA	NA
			0,53	0,90	0,10	0,51				
			0,53	1,25	0,25	0,51				
			0,27	0,40	0,10	0,29				
			NA	NA	NA	NA				
P4 (R57)	0,40	0,60	0,60	2,50	0,50	1,01	NA	NA	NA	NA
			0,53	2,00	0,10	0,51				
			0,53	1,00	0,10	0,51				
			NA	NA	NA	NA				
P4 (R53)	0,40	0,60	0,27	0,30	0,10	0,26	NA	NA	NA	NA
			0,60	3,00	1,00	1,01				
			0,53	0,75	0,25	0,29				
			0,53	1,25	0,25	0,51				
			NA	NA	NA	NA				
P5 (R86)	0,40	0,60	0,27	0,20	0,10	0,26	0,28	0,60	1,13	45
			NA	NA	NA	NA				
P5 (R82)	0,40	0,60	0,53	2,00	0,30	0,51	0,28	0,60	1,13	62
			NA	NA	NA	NA				
P3 (R70)	0,40	NA	0,53	0,50	0,20	0,29	NA	NA	NA	NA

			0,53	2,00	0,50	0,51				
			0,60	1,00	0,50	0,51				
			0,27	0,50	0,10	0,29				
P3 (MAT11)	0,40	NA	0,53	0,50	0,20	0,29	NA	NA	NA	NA
			0,60	1,50	0,50	0,51				
			0,60	5,00	0,10	1,13				
P3 (R62)	0,40	NA	0,53	0,90	0,10	0,51	NA	NA	NA	NA
			0,53	0,75	0,25	0,29				
			0,27	0,50	0,10	0,29				
			0,27	0,20	0,05	0,26				
			0,60	2,50	0,50	1,01				
			0,53	1,50	0,20	0,51				
P2 (R66)	0,40	NA	0,27	0,40	0,10	0,29	NA	NA	NA	NA
			0,27	1,00	0,20	0,51				
			0,27	0,30	0,10	0,26				
			0,27	0,50	0,20	0,29				
P2 (R69)	0,40	NA	0,53	0,75	0,25	0,29	NA	NA	NA	NA
			0,53	0,75	0,25	0,29				
P2 (R52)	0,40	NA	0,27	0,60	0,10	0,29	NA	NA	NA	NA
			0,27	0,60	0,10	0,29				
			0,27	0,40	0,10	0,29				
P2 (R56)	0,40	NA	0,27	0,30	0,10	0,26	NA	NA	NA	NA
			0,27	0,40	0,10	0,29				
			0,27	0,40	0,10	0,29				
P1 (R49)	0,40	NA	0,27	0,30	0,10	0,26	NA	NA	NA	NA
P1 (MAT10)	0,40	NA	0,27	0,50	0,10	0,29	NA	NA	NA	NA
			0,27	0,40	0,10	0,29				
			0,27	0,40	0,10	0,29				

P1 (R47)	0,40	NA	0,27	0,30	0,10	0,26	NA	NA	NA	NA
			0,27	0,75	0,25	0,29				
P2 (R41)	0,40	0,27	0,27	0,10	0,05	0,26	NA	NA	NA	NA
			NA	NA	NA	NA				
			0,53	0,40	0,20	0,29				
P2 (R42)	0,40	0,27	0,27	0,40	0,10	0,29	NA	NA	NA	NA
			0,27	0,20	0,05	0,26				
			NA	NA	NA	NA				
			0,53	1,00	0,10	0,51				
P1 (R36)	0,40	NA	0,27	0,40	0,10	0,29	NA	NA	NA	NA
			0,27	0,30	0,10	0,26				
P2 (R8)	0,40	NA	0,53	2,50	0,50	1,01	NA	NA	NA	NA
			0,60	2,25	0,25	0,51				
			0,53	1,25	0,25	0,51				
			0,27	0,30	0,10	0,26				
			0,27	0,30	0,10	0,26				
			0,27	0,30	0,10	0,26				
P6 (R15)	0,40	0,60	0,53	3,00	0,10	1,01	0,28	0,60	1,13	31
			0,60	1,50	0,10	0,51				
			0,53	1,00	0,30	0,51				
			0,27	0,30	0,10	0,26				
			NA	NA	NA	NA				
P6 (E1)	0,40	NA	0,53	4,00	2,00	1,01	NA	NA	NA	NA
			0,53	1,00	0,50	0,51				
			0,27	0,30	0,20	0,26				

P3 (R19)	0,40	NA	0,60	4,00	2,00	1,01	NA	NA	NA	NA
			0,60	1,50	0,10	0,51				
			0,53	1,00	0,10	0,51				
			0,53	0,50	0,10	0,29				
			0,27	0,30	0,10	0,26				
P3 (R22)	0,40	NA	0,53	0,80	0,20	0,51	NA	NA	NA	NA
			0,60	1,00	0,50	0,51				
			0,53	0,80	0,20	0,51				
			0,27	0,25	0,05	0,26				
P4 (R20)	0,40	NA	0,53	1,50	0,50	0,51	NA	NA	NA	NA
			0,53	5,00	1,00	1,13				
			0,60	2,00	0,10	0,51				
			0,60	5,00	1,00	1,13				
			0,27	0,30	0,10	0,26				
			0,27	0,20	0,05	0,26				
P2(R24)	0,40	NA	0,53	0,40	0,10	0,29	NA	NA	NA	NA
			0,27	0,30	0,10	0,26				
P3 (R23)	0,40	NA	0,60	1,80	0,20	0,51	NA	NA	NA	NA
			0,53	1,25	0,25	0,51				
			0,27	0,30	0,10	0,26				
P7 (R21)	0,40	NA	0,53	1,20	0,50	0,51	0,28	0,60	1,13	55
			0,53	0,70	0,20	0,29				
			0,60	1,50	0,50	0,51				
			0,27	0,30	0,05	0,26				
P4 (P8)	0,40	NA	0,53	2,25	0,25	0,51	NA	NA	NA	NA
			0,60	2,00	0,50	0,51				
			0,60	4,00	0,50	1,01				
			0,27	0,50	0,20	0,29				

P7 (P7)	0,40	0,60	0,53	1,25	0,50	0,51	0,28	0,60	1,13	4
			0,27	0,30	0,05	0,26				
			NA	NA	NA	NA				
P1 (P6)	0,40	NA	0,60	0,75	0,25	0,29	NA	NA	NA	NA
			0,27	0,10	0,05	0,26				
P2 (MQ2)	0,40	NA	0,53	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	0,20	0,05	0,26				
			0,27	0,10	0,05	0,26				
P3 (MQ1)	0,40	0,27	0,27	0,50	0,35	0,29	NA	NA	NA	NA
			NA	NA	NA	NA				
			0,53	0,75	0,25	0,29				
			0,53	0,75	0,25	0,29				
P1 (R35)	0,40	NA	0,27	0,10	0,05	0,26	NA	NA	NA	NA
			0,27	0,60	0,40	0,29				
			0,27	0,20	0,05	0,26				
P3 (R28)	0,40	0,27	0,53	1,25	0,25	0,51	NA	NA	NA	NA
			0,53	1,75	0,25	0,51				
			NA	NA	NA	NA				
			0,60	0,75	0,25	0,29				
			0,27	0,30	0,10	0,26				
			0,27	0,10	0,05	0,26				
P1 (R34)	0,40	NA	0,27	0,10	0,05	0,26	NA	NA	NA	NA
			0,27	0,20	0,05	0,26				
P1 (R40)	0,40	NA	0,27	0,10	0,05	0,26	NA	NA	NA	NA
			0,27	0,20	0,05	0,26				
P3 (P5)	0,40	NA	0,60	1,50	0,50	0,51	NA	NA	NA	NA
P5 (R85)	0,40	0,60	0,53	0,50	0,25	0,29	0,28	0,60	1,13	51
			NA	NA	NA	NA				
P2 (R87)	0,40	NA	0,53	0,50	0,10	0,29	NA	NA	NA	NA

			0,27	0,20	0,10	0,26				
P5 (R90)	0,40	0,60	0,27	0,20	0,10	0,26	0,28	0,60	1,13	49
			0,53	0,30	0,10	0,26				5
			NA	NA	NA	NA				
			0,53	0,50	0,10	0,29				
P2 (R78)	0,40	NA	0,27	0,50	0,10	0,29	NA	NA	NA	NA
			0,53	0,50	0,10	0,29				
			NA	NA	NA	NA				
P5 (P4)	0,40	0,60	0,60	1,75	0,25	0,51	0,28	0,60	1,13	65
			NA	NA	NA	NA				
P6 (P3)	0,40	0,60	0,53	2,25	0,25	0,51	0,28	0,60	1,13	30
			0,60	1,75	0,25	0,51				
			0,53	1,25	0,25	0,51				
			NA	NA	NA	NA				
P2 (R74)	0,40	NA	0,27	0,30	0,10	0,26	NA	NA	NA	NA
P2 (R72)	0,40	NA	0,53	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	0,15	0,05	0,26				
P3 (R64)	0,40	NA	0,53	0,50	0,10	0,29	NA	NA	NA	NA
			0,60	1,75	0,25	0,51				
P6 (P2)	0,40	0,60	0,53	1,50	0,50	0,51	0,28	0,60	1,13	26
			0,27	0,50	0,10	0,29				
			0,53	3,00	1,00	1,01				
			NA	NA	NA	NA				
P4 (R2)	0,40	0,60	0,53	1,50	0,10	0,51	NA	NA	NA	NA
			0,60	2,70	0,50	1,01				
			NA	NA	NA	NA				
P4 (R38)	0,40	NA	0,53	2,00	0,20	0,51	NA	NA	NA	NA
			0,53	0,90	0,10	0,51				
			0,27	0,15	0,05	0,26				
			0,60	2,25	0,25	0,51				

			0,53	2,25	0,25	0,51				
P4 (R39)	0,40	0,60	0,60	1,25	0,50	0,51	0,28	0,60	1,13	22
			0,53	0,75	0,25	0,29				16
			0,60	NA	NA	NA				
P1 (R37)	0,40	NA	0,27	0,40	0,10	0,23	NA	NA	NA	NA
			0,27	0,25	0,05	0,26				
			0,60	2,00	0,50	0,51				
P3 (R31)	0,40	NA	0,60	1,25	0,25	0,51	NA	NA	NA	NA
			0,53	1,50	0,10	0,51				
			0,60	0,75	0,25	0,29				
			0,53	0,75	0,25	0,29				
			0,27	0,25	0,05	0,26				
P3 (R33)	0,40	NA	0,60	3,50	0,50	1,01	NA	NA	NA	NA
			0,53	1,75	0,25	0,51				
			0,53	0,75	0,25	0,29				
			0,27	0,25	0,05	0,26				
			0,60	1,00	0,10	0,51				
P7 (R30)	0,40	0,60	0,60	1,25	0,25	0,51	0,28	0,60	1,13	68
			0,53	1,25	0,25	0,51				
			0,53	0,50	0,10	0,29				
			NA	NA	NA	NA				
P1 (R51)	0,40	NA	0,27	0,25	0,05	0,26	NA	NA	NA	NA
			0,27	0,25	0,05	0,26				
P1 (R55)	0,40	NA	0,27	0,25	0,05	0,26	NA	NA	NA	NA
			0,53	1,75	0,25	0,51				
			0,53	0,75	0,25	0,29				
			0,60	0,80	0,20	0,51				
P3 (R61)	0,40	NA	0,53	0,50	0,10	0,29	NA	NA	NA	NA
			0,53	1,25	0,25	0,51				

P3 (R67)	0,40	NA	0,60	2,00	0,50	0,51	NA	NA	NA	NA
			0,53	1,00	0,10	0,51				
			0,27	0,25	0,05	0,26				
P4 (R48)	0,40	NA	0,53	2,50	0,10	1,01	0,28	0,60	1,13	7
			0,60	2,00	0,10	0,51		0,53		2
			0,53	0,50	0,10	0,29				
P1 (R29)	0,40	NA	0,27	0,15	0,05	0,26	NA	NA	NA	NA
			0,27	0,25	0,05	0,26				
			0,27	0,25	0,05	0,26				
			0,27	0,40	0,10	0,29				

A5: Parámetros necesarios para la simulación de árboles con una forma de copa truncal.

Scene	Scene												
	Trunk					Crown							
	Crown truncated cone												
Fuel model-Plot	Height below crown: mean (m)	Height below crown: std dev (m)	Diameter below crown: mean (m)	Diameter below crown: std dev (m)	Height within the tree crown (m)	Crown height: mean (m)	Crown height: std dev (m)	Crown intrinsic rotation: mean (deg)	Crown intrinsic rotation: std dev (deg)	Bottom radius: mean (m)	Bottom radius: std mean (m)	Top radius: mean (m)	Top radius: std dev (m)
P 7 (P35)	5,02	1,19	0,17	0,06	4,49	4,49	2	0	0	3,25	0,5	1,62	0,25
P 7 (P34)	3,96	1,09	0,19	0,07	4,05	4,05	1,31	0	0	4,06	0,5	2,03	0,25
P 5 (P33)	3,46	0,72	0,17	0,05	4,61	4,61	0,94	0	0	3,58	0,5	1,79	0,25
P5 (P32)	2,55	0,41	0,14	0,03	3,07	3,07	0,72	0	0	3,58	0,5	1,79	0,25
P7 (P31)	0,1	0	0,037	0,01	2,32	2,32	0,59	0	0	1,36	0,5	0,68	0,25
	1,43	0,45	0,09	0,03	2,76	2,76	0,7	0	0	2,62	0,5	1,31	0,25
P7 (P30)	2,59	0,59	0,16	0,05	4,12	4,12	1,14	0	0	3,73	0,5	1,86	0,25
P5 (P29)	2,65	1,03	0,13	0,03	5,51	5,51	1,1	0	0	2,65	0,5	1,32	0,25
	0,1	0	0,05	0,005	3,65	3,65	0,5	0	0	1,46	0,5	0,73	0,25
P6 (P28)	1,84	0,23	0,09	0,03	3,16	3,16	0,7	0	0	2,36	0,5	1,18	0,25

P6 (P27)	1,78	0,38	0,11	0,003	4,14	4,14	0,92	0	0	2,66	0,5	1,33	0,25
P5 (P26)	4,34	0,9	0,18	0,5	6,21	6,21	1,35	0	0	3,26	0,5	1,63	0,25
	0,1	0	0,069	0	4,9	4,9	0	0	0	1,76	0,5	0,88	0,25
P6 (P25)	1,25	0,4	0,09	0,03	3,8	0,38	1,12	0	0	4,54	0,5	2,27	0,25
P5 (P24)	2,56	0,43	0,13	0,03	4,22	4,22	0,93	0	0	2,96	0,5	1,48	0,25
	0,1	0	0,06	0,001	3,86	3,86	0,09	0	0	1,73	0,5	0,86	0,25
P7 (P23)	5,22	1,4	0,19	0,06	5,61	5,61	1,7	0	0	3,41	0,5	1,70	0,25
P6 (P22)	4,29	1,09	0,28	0,07	6,68	6,68	1,37	0	0	5,17	0,5	2,58	0,25
P7 (P21)	3,74	0,82	0,22	0,08	6,3	6,3	2,68	0	0	4,18	0,5	2,09	0,25
P7 (P20)	0,94	0,5	0,14	0,04	4,86	4,86	0,81	0	0	3,51	0,5	1,75	0,25
P7 (P19)	3,1	1,16	0,22	0,08	6,03	6,03	1,76	0	0	4,42	0,5	2,21	0,25
P7 (P18)	2,9	1,41	0,22	0,08	5,86	5,86	2,17	0	0	4,53	0,5	2,26	0,25
P1 (P17)	0,9	0,15	0,16	0,05	5,37	5,37	0,94	0	0	3,88	0,5	1,94	0,25
P5 (P16)	1,33	0,29	0,14	0,03	5,88	5,88	0,77	0	0	3,09	0,5	1,54	0,25
P7 (P15)	0,78	0,32	0,09	0,03	4,97	4,97	0,92	0	0	2,17	0,5	1,08	0,25
	0,1	0	0,05	0,005	3,57	3,57	0,57	0	0	1,48	0,5	0,74	0,25
P5 (P14)	1,9	0,76	0,17	0,04	6,37	6,37	1,26	0	0	3,53	0,5	1,76	0,25
P5 (P13)	1,56	0,31	0,14	0,03	5,75	5,75	0,75	0	0	3,07	0,5	1,53	0,25
P5 (P12)	1,33	0,19	0,14	0,04	5,37	5,37	0,7	0	0	3,23	0,5	1,61	0,25
P5 (R86)	0,73	0,2	0,1	0,03	4,18	4,18	0,62	0	0	2,68	0,5	1,34	0,25
P5 (R82)	2,24	0,82	0,14	0,06	3,53	3,53	1,32	0	0	3,52	0,5	1,76	0,25
P6 (R15)	4,22	0,94	0,24	0,06	5,94	5,94	2,62	0	0	4,57	0,5	2,28	0,25
P7 (R21)	0,25	0	0,1	0,02	4,68	4,68	1,01	0	0	2,67	0,5	1,33	0,25
P7 (P7)	2,23	1,1	0,11	0,05	6,13	6,13	1,1	0	0	2,18	0,5	1,09	0,25
P5 (R85)	1,01	0,24	0,11	0,04	5,36	5,36	1,2	0	0	2,55	0,5	1,27	0,25
P5 (R83)	1,36	0,21	0,14	0,03	5,4	5,4	0,77	0	0	3,21	0,5	1,60	0,25
	0,78	0,2	0,1	0,01	5,04	5,04	0,5	0	0	2,42	0,5	1,21	0,25
P5 (R90)	1,15	0,25	0,11	0,03	4,51	4,51	0,912	0	0	2,73	0,5	1,36	0,25
	0,42	0,11	0,035	0,005	2,08	2,08	0,29	0	0	1,26	0,5	0,63	0,25
P5 (P4)	1	0,64	0,12	0,03	5,41	5,41	0,94	0	0	2,80	0,5	1,40	0,25

P6 (P3)	1,92	0,79	0,17	0,11	4,17	4,17	1,72	0	0	4,22	0,5	2,11	0,25
P6 (P2)	5,2	1,47	0,3	0,1	5,3	5,3	1,99	0	0	5,72	0,5	2,86	0,25
P5 (P1)	1,6	0,3	0,4	0,04	5,8	5,8	0,7	0	0	9,62	0,5	4,81	0,25
P4 (R39)	0,2	0,37	0,34	0,14	4,4	4,4	1,13	0	0	10,63	0,5	5,31	0,25
	0	0	0,03	0,01	1,91	1,91	0,67	0	0	1,24	0,5	0,62	0,25
P7(R30)	2,18	0,84	0,12	0,06	3,9	3,9	1,82	0	0	2,88	0,5	1,44	0,25
P5 (R80)	0,5	0,36	0,08	0,03	3,45	3,45	0,46	0	0	2,38	0,5	1,19	0,25
P5 (R76)	1,04	0,66	0,11	0,03	4,56	4,56	1,4	0	0	2,75	0,5	1,37	0,25
P5 (R50)	0,92	0,44	0,13	0,03	6,23	6,23	0,89	0	0	2,86	0,5	1,43	0,25
	0,56	0,18	0,11	0,03	4,7	4,7	0,79	0	0	2,85	0,5	1,42	0,25
P4 (R48)	0,5	0,29	0,08	0,06	2,87	2,87	0,4	0	0	2,61	0,5	1,30	0,25
	0	0	0,04	0,01	2,52	2,52	0,25	0	0	1,45	0,5	0,72	0,25

A6: Parámetros necesarios para la simulación de árboles con una forma de copa elipsoidal.

Scene													
Scene	Trunk							Crown					
Fuel model-Plot	Crown ellipsoid												
	Height below crown: mean (m)	Height below crown: std dev (m)	Diameter below crown: mean (m)	Diameter below crown: std dev (m)	Height within the tree crown (m)	Crown height: mean (m)	Crown height: std dev (m)	Crown intrinsic rotation: mean (deg)	Crown intrinsic rotation: std dev (deg)	First axis: mean (m)	First axis: std dev (m)	Second axis: mean (m)	Second axis: std dev (m)
P7 (P21)	2,12	0,39	0,14	0,06	4,43	4,43	1,29	0	0	3,08	0,2	1,54	0,5
P7 (P19)	0,97	0,89	0,16	0,02	6,73	6,73	1,44	0	0	3,21	0,2	1,60	0,5

Anexo 3: Estadísticas obtenidas

A7: Comparación de los datos DART simulados y datos del PNOA 2011 - 2016 para el conjunto de parcelas analizadas.

Variable	Simulado_2011	PNOA_2011	Simulado_2016	PNOA_2016
	Promedio	Promedio	Promedio	Promedio
All returns above 0,00	112,86	335	217,89	828,61
All returns above mean	50,41	166,43	104,92	383,12
All returns above mode	91,29	322,29	188,16	732,79
Canopy relief ratio	0,4	0,32	0,34	0,28
Elev AAD	0,9	1,09	1,02	1,25
Elev CURT mean CUBE	1,67	2,6	2,03	2,68
Elev CV	0,62	0,96	0,65	0,92
Elev IQ	1,67	2,02	2,07	2,45
Elev kurtosis	5,92	8,07	10,08	6,4
Elev L CV	0,31	0,45	0,31	0,45
Elev L kurtosis	0,09	0,12	0,16	0,1
Elev L skewness	0,12	0,13	0,17	0,2
Elev L1	1,01	1,92	1,34	1,85
Elev L2	0,51	0,69	0,62	0,77
Elev L3	0,12	-0,04	0,08	0,05
Elev L4	-0,03	0,02	-0,04	-0,02
Elev MAD median	0,47	0,58	0,93	0,89
Elev MAD mode	0,6	2,04	1,21	1,78
Elev maximum	3,16	4,55	3,9	5,16
Elev mean	1,01	1,92	1,34	1,85
Elev minimum	0,07	0	0,14	0,01
Elev mode	0,13	0	0,14	0,13
Elev P01	0,09	0	0,14	0,02
Elev P05	0,12	0,01	0,15	0,06

Elev P10	0,13	0,1	0,15	0,11
Elev P20	0,15	0,38	0,15	0,37
Elev P25	0,15	0,84	0,16	0,52
Elev P30	0,16	1,27	0,19	0,71
Elev P40	0,18	1,79	0,66	1,22
Elev P50	0,72	2,04	1,36	1,88
Elev P60	1,23	2,45	1,74	2,36
Elev P70	1,67	2,72	2,06	2,73
Elev P75	1,82	2,86	2,23	2,96
Elev P80	2,01	3	2,42	3,16
Elev P90	2,35	3,37	2,83	3,64
Elev P95	2,6	3,7	3,12	4,01
Elev P99	2,94	4,24	3,64	4,65
Elev skewness	0,3	0,99	0,73	1,09
Elev SQRT mean SQ	1,43	2,35	1,77	2,37
Elev stddev	0,98	1,31	1,14	1,44
Elev strata (0,00 to 0,60) mean	0,18	0,07	0,16	0,16
Elev strata (0,00 to 0,60) median	0,17	0,04	0,15	0,14
Elev strata (0,00 to 0,60) return proportion	0,44	0,57	0,34	0,6
Elev strata (0,60 to 2,00) CV	-7646,23	-2856,65	-4470,01	-1881,94
Elev strata (0,60 to 2,00) mean	0,32	0,97	0,8	0,99
Elev strata (0,60 to 2,00) return proportion	0,02	0,08	0,07	0,11
Elev strata (2,00 to 4,00) mean	1,29	2,09	1,4	2,09
Elev strata (2,00 to 4,00) return proportion	0,03	0,14	0,06	0,09
Elev strata (above 4,00) mean	2,19	3,2	2,52	3,3
Elev strata (above 4,00) median	-6350,35	-4282,09	-5879,48	-4466,89
Elev strata (above 4,00) return proportion	0,07	0,21	0,09	0,2
Elev strata (above 4,00) skewness	-6352,09	-4285,18	-5881,59	-4470,03
Elev variance	2,43	3,21	2,74	3,72

First returns above 0,00	112,86	312,32	217,89	736,67
First returns above mean	50,41	166,43	104,92	380,12
First returns above mode	91,29	300,14	188,16	649,85
Percentage all returns above 0,00	55,59	99,39	56,06	98,52
Percentage all returns above mean	24,69	46,97	26,37	43,27
Percentage all returns above mode	43,85	94,04	47,87	85,93
Percentage first returns above 0,00	55,59	99,39	56,06	98,65
Percentage first returns above mean	24,69	50,7	26,37	49,73
Percentage first returns above mode	43,85	94,16	47,87	86,81
Total return count	198,98	336,46	375,34	837,59
(All returns above 0,00) / (Total first returns) * 100	55,59	105,32	56,06	111,55
(All returns above mean) / (Total first returns) * 100	24,69	50,7	26,37	50,11
(All returns above mode) / (Total first returns) * 100	43,85	99,91	47,87	98,46

A8: Correlación de las métricas de la nube de puntos simulada y real del PNOA para 2011 y 2016, RMSE y % RMSE sobre el valor medio del PNOA real.

Variable	2011			2016		
	Correlación	RMSE	%RMSE (PNOA 2011)	Correlación	RMSE	%RMSE (PNOA 2016)
All returns above 0,00	0,56	297,45	0,89	0,13	854,14	1,03
All returns above mean	0,54	169,15	1,02	0,34	434,72	1,13
All returns above mode	0,58	302,82	0,94	0,3	774,47	1,06
Canopy relief ratio	-0,25	0,32	1,01	0,19	0,21	0,74
Elev AAD	0,95	0,4	0,37	0,95	0,45	0,36
Elev CURT mean CUBE	0,94	1,03	0,4	0,97	0,95	0,35
Elev CV	-0,35	1,08	1,12	0,32	0,65	0,71
Elev IQ	0,92	1,16	0,57	0,91	1,19	0,48
Elev kurtosis	NA	20,99	2,6	0,61	21,13	3,3

Elev L CV	-0,27	0,37	0,83	0,34	0,26	0,57
Elev L kurtosis	NA	0,29	2,4	0,54	0,33	3,39
Elev L skewness	NA	0,51	3,8	0,33	0,36	1,82
Elev L1	0,92	1,13	0,59	0,92	1	0,54
Elev L2	0,95	0,25	0,37	0,96	0,27	0,35
Elev L3	-0,3	0,28	-7,91	0,34	0,19	3,96
Elev L4	0,23	0,12	8,04	0,51	0,11	-6,61
Elev MAD median	0,79	1	1,73	0,79	0,88	0,99
Elev MAD mode	0,83	2,2	1,08	0,83	1,46	0,82
Elev maximum	0,93	1,92	0,42	0,97	1,62	0,31
Elev mean	0,92	1,13	0,59	0,92	1	0,54
Elev minimum	-0,3	0,09	85,76	0,06	0,13	8,91
Elev mode	0,08	0,3	89,32	0,44	0,39	3,02
Elev P01	-0,4	0,1	40,01	-0,08	0,12	5,04
Elev P05	-0,41	0,12	11,71	-0,19	0,11	1,81
Elev P10	-0,32	0,28	2,92	-0,19	0,15	1,39
Elev P20	-0,11	0,72	1,88	0,2	0,9	2,45
Elev P25	0,11	1,28	1,52	0,34	1,18	2,29
Elev P30	0,21	1,77	1,39	0,44	1,51	2,14
Elev P40	0,5	2,41	1,34	0,55	1,67	1,37
Elev P50	0,69	2,16	1,06	0,75	1,46	0,78
Elev P60	0,83	1,61	0,66	0,87	1,35	0,57
Elev P70	0,93	1,28	0,47	0,89	1,4	0,51
Elev P75	0,94	1,28	0,45	0,92	1,3	0,44
Elev P80	0,94	1,27	0,42	0,92	1,31	0,41
Elev P90	0,95	1,31	0,39	0,93	1,38	0,38
Elev P95	0,94	1,42	0,38	0,95	1,4	0,35
Elev P99	0,93	1,76	0,42	0,98	1,33	0,29
Elev skewness	NA	3,11	3,12	0,33	2,48	2,28

Elev SQRT mean SQ	0,94	1,04	0,44	0,96	0,97	0,41
Elev stddev	0,95	0,46	0,35	0,97	0,43	0,3
Elev strata (0,00 to 0,60) mean	0,33	0,11	1,7	0,36	0,07	0,45
Elev strata (0,00 to 0,60) return proportion	0,41	0,39	0,69	0,77	0,36	0,59
Elev strata (0,60 to 2,00) mean	0,52	0,88	0,91	0,71	0,52	0,53
Elev strata (0,60 to 2,00) return proportion	0,22	0,13	1,7	0,56	0,12	1,07
Elev strata (2,00 to 4,00) mean	0,65	1,5	0,72	0,74	1,34	0,64
Elev strata (2,00 to 4,00) return proportion	0,72	0,17	1,2	0,73	0,12	1,37
Elev strata (above 4,00) mean	0,89	1,62	0,51	0,94	1,55	0,47
Elev strata (above 4,00) return proportion	0,91	0,19	0,91	0,93	0,18	0,89
Elev variance	0,95	1,2	0,37	0,97	1,8	0,48
First returns above 0,00	0,47	263,71	0,84	-0,04	731,72	0,99
First returns above mean	0,54	169,13	1,02	0,34	429,42	1,13
First returns above mode	0,5	269,83	0,9	0,19	658,19	1,01
Percentage all returns above 0,00	0,36	45,53	0,46	0,22	43,81	0,44
Percentage all returns above mean	0,35	25	0,53	0,49	21,38	0,49
Percentage all returns above mode	0,59	54,26	0,58	0,59	41,63	0,48
Percentage first returns above 0,00	0,38	45,54	0,46	0,31	43,91	0,45
Percentage first returns above mean	0,37	28,8	0,57	0,53	28,72	0,58
Percentage first returns above mode	0,61	54,31	0,58	0,62	42,39	0,49
Total return count	0,49	245,56	0,73	0,11	758,54	0,91
(All returns above 0,00) / (Total first returns) * 100	0,61	49,75	0,47	0,77	56,88	0,51
(All returns above mean) / (Total first returns) * 100	0,37	28,8	0,57	0,52	29,18	0,58
(All returns above mode) / (Total first returns) * 100	0,68	58	0,58	0,66	55,8	0,57

A9: Correlación entre los estadísticos de la nube de puntos simulada en 2011 y las del PNOA real de 2016.

Variable	Correlación	RMSE	%RMSE (PNOA 2016)
All returns above 0.00	0,13	937,15	1,13
All returns above mean	0,31	477,56	1,25
All returns above mode	0,31	853,95	1,17
Canopy relief ratio	-0,08	0,29	1,03
Elev AAD	0,96	0,55	0,44
Elev CURT mean CUBE	0,97	1,32	0,49
Elev CV	0,15	0,73	0,80
Elev IQ	0,91	1,49	0,61
Elev kurtosis	NA	13,93	2,18
Elev L CV	0,29	0,29	0,65
Elev L kurtosis	NA	0,27	2,76
Elev L skewness	NA	0,41	2,08
Elev L1	0,92	1,29	0,70
Elev L2	0,96	0,36	0,47
Elev L3	0,10	0,25	5,14
Elev L4	0,32	0,13	-7,97
Elev MAD median	0,73	1,14	1,28
Elev MAD mode	0,79	2,19	1,23
Elev maximum	0,97	2,46	0,48
Elev mean	0,92	1,29	0,70
Elev minimum	0,13	0,09	6,08
Elev mode	0,28	0,39	3,00

Elev P01	-0,05	0,09	3,61
Elev P05	-0,17	0,11	1,75
Elev P10	-0,32	0,16	1,53
Elev P20	-0,16	0,91	2,46
Elev P25	-0,02	1,19	2,30
Elev P30	0,14	1,56	2,21
Elev P40	0,34	2,24	1,84
Elev P50	0,59	2,19	1,16
Elev P60	0,78	1,93	0,82
Elev P70	0,88	1,73	0,64
Elev P75	0,93	1,69	0,57
Elev P80	0,94	1,68	0,53
Elev P90	0,96	1,76	0,48
Elev P95	0,95	1,87	0,46
Elev P99	0,97	2,18	0,47
Elev skewness	NA	2,60	2,39
Elev SQRT mean SQ	0,96	1,30	0,55
Elev stddev	0,98	0,60	0,42
Elev strata (0.00 to 0.60) mean	0,27	0,08	0,49
Elev strata (0.00 to 0.60) return proportion	0,28	0,37	0,62
Elev strata (0.60 to 2.00) mean	0,50	0,87	0,88
Elev strata (0.60 to 2.00) return proportion	-0,09	0,17	1,55
Elev strata (2.00 to 4.00) mean	0,69	1,61	0,77
Elev strata (2.00 to 4.00) return proportion	0,57	0,13	1,50
Elev strata (above 4.00) mean	0,92	1,90	0,58
Elev strata (above 4.00) return proportion	0,91	0,20	1,00
First returns above mean	0,31	472,17	1,24
First returns above mode	0,16	735,70	1,13
Percentage all returns above 0.00	0,21	44,74	0,45

Percentage all returns above mean	0,47	22,34	0,52
Percentage all returns above mode	0,63	45,79	0,53
Percentage first returns above 0,00	0,30	44,84	0,45
Percentage first returns above mean	0,43	30,78	0,62
Percentage first returns above mode	0,67	46,42	0,53
Total return count	0,17	880,40	1,05
(All returns above 0,00) / (Total first returns) * 100	0,71	57,80	0,52
(All returns above mean) / (Total first returns) * 100	0,43	31,28	0,62
(All returns above mode) / (Total first returns) * 100	0,73	58,29	0,59

A10: Correlación entre los estadísticos de la nube de puntos simulada en 2011 y las del PNOA real de 2011.

Variable	Correlación	RMSE	%RMSE (PNOA 2011)
All returns above 0,00	0,52	231,90	0,69
All returns above mean	0,63	136,20	0,82
All returns above mode	0,55	239,93	0,74
Canopy relief ratio	0,22	0,23	0,71
Elev AAD	0,95	0,34	0,31
Elev CURT mean CUBE	0,93	0,69	0,27
Elev CV	-0,03	0,97	1,00
Elev IQ	0,91	1,14	0,57
Elev kurtosis	NA	24,01	2,97
Elev L CV	-0,13	0,33	0,73
Elev L kurtosis	NA	0,36	2,89
Elev L skewness	NA	0,39	2,90
Elev L1	0,93	0,81	0,42

Elev L2	0,95	0,20	0,29
Elev L3	-0,01	0,22	-6,11
Elev L4	0,22	0,11	7,00
Elev MAD median	0,84	0,90	1,56
Elev MAD mode	0,88	1,36	0,66
Elev maximum	0,94	1,35	0,30
Elev mean	0,93	0,81	0,42
Elev minimum	-0,11	0,14	123,80
Elev mode	0,14	0,29	87,48
Elev P01	-0,27	0,14	54,47
Elev P05	-0,08	0,13	13,47
Elev P10	-0,07	0,28	2,91
Elev P20	0,14	0,71	1,87
Elev P25	0,21	1,27	1,52
Elev P30	0,40	1,77	1,39
Elev P40	0,74	1,71	0,95
Elev P50	0,87	1,31	0,64
Elev P60	0,93	0,98	0,40
Elev P70	0,94	0,95	0,35
Elev P75	0,94	0,93	0,33
Elev P80	0,94	0,94	0,31
Elev P90	0,93	1,05	0,31
Elev P95	0,95	1,07	0,29
Elev P99	0,95	1,15	0,27
Elev skewness	NA	2,54	2,56
Elev SQRT mean SQ	0,94	0,72	0,31
Elev stddev	0,95	0,34	0,26
Elev strata (0.00 to 0.60) mean	0,49	0,09	1,35
Elev strata (0.00 to 0.60) return proportion	0,85	0,38	0,66

Elev strata (0,60 to 2,00) mean	0,63	0,54	0,56
Elev strata (0,60 to 2,00) return proportion	0,80	0,07	0,90
Elev strata (0,60 to 2,00) total return count	0,77	31,33	1,13
Elev strata (2,00 to 4,00) mean	0,67	1,24	0,59
Elev strata (2,00 to 4,00) return proportion	0,86	0,12	0,89
Elev strata (above 4,00) mean	0,92	1,28	0,40
Elev strata (above 4,00) return proportion	0,94	0,17	0,81
Elev strata (above 4,00) skewness	0,68	3067,70	-0,72
Elev variance	0,95	1,24	0,39
First returns above 0,00	0,44	200,78	0,64
First returns above mean	0,63	136,18	0,82
First returns above mode	0,50	207,37	0,69
Percentage all returns above 0,00	0,39	44,61	0,45
Percentage all returns above mean	0,55	22,94	0,49
Percentage all returns above mode	0,49	48,94	0,52
Percentage first returns above 0,00	0,42	44,62	0,45
Percentage first returns above mean	0,56	26,46	0,52
Percentage first returns above mode	0,53	49,00	0,52
Total return count	0,50	212,98	0,63
(All returns above 0,00) / (Total first returns) * 100	0,67	48,74	0,46
(All returns above mean) / (Total first returns) * 100	0,56	26,47	0,52
(All returns above mode) / (Total first returns) * 100	0,60	53,32	0,53

A11: Correlación entre las variables simuladas con DART (año 2011 y año 2016) y el modelo de combustible.

Variable	Correlación 2011	Correlación 2016
All,returns,above,0,00	0,8	0,8

All,returns,above,mean	0,49	0,63
All,returns,above,mode	0,79	0,75
Canopy,relief,ratio	-0,33	-0,19
Elev,AAD	0,86	0,84
Elev,CURT,mean,CUBE	0,86	0,84
Elev,CV	0,82	0,56
Elev,IQ	0,85	0,84
Elev,kurtosis	NA	-0,62
Elev,L,CV	0,82	0,73
Elev,L,kurtosis	NA	-0,63
Elev,L,skewness	NA	-0,04
Elev,L1	0,84	0,84
Elev,L2	0,86	0,85
Elev,L2,1	0,87	0,6
Elev,L3	0,68	-0,65
Elev,L3,1	-0,37	0,85
Elev,L4	-0,32	0,84
Elev,L4,1	-0,15	0,86
Elev,MAD,median	0,81	0,84
Elev,MAD,mode	0,81	-0,28
Elev,maximum	0,85	-0,61
Elev,mean	0,84	-0,3
Elev,minimum	-0,63	-0,05
Elev,mode	-0,52	-0,09
Elev,P01	-0,53	0,21
Elev,P05	-0,36	0,35
Elev,P10	-0,26	0,52
Elev,P20	0,03	0,71
Elev,P25	0,23	0,83

Elev,P30	0,36	0,86
Elev,P40	0,59	0,85
Elev,P50	0,71	0,84
Elev,P60	0,78	0,84
Elev,P70	0,84	0,82
Elev,P75	0,85	0,84
Elev,P80	0,84	0,86
Elev,P90	0,85	-0,09
Elev,P95	0,85	0,84
Elev,P99	0,85	0,85
Elev,skewness	NA	0,35
Elev,SQRT,mean,SQ	0,85	-0,29
Elev,stddev	0,86	0,15
Elev,strata,,0,00,to,0,60,,mean	0,44	-0,14
Elev,strata,,0,00,to,0,60,,return,proportion	-0,41	-0,75
Elev,strata,,0,60,to,2,00,,mean	0,47	0,43
Elev,strata,,0,60,to,2,00,,return,proportion	0,47	0,52
Elev,strata,,2,00,to,4,00,,mean	0,65	0,6
Elev,strata,,2,00,to,4,00,,return,proportion	0,63	0,65
Elev,strata,,above,4,00,,mean	0,73	0,73
Elev,strata,,above,4,00,,return,proportion	0,74	0,78
Elev,variance	0,86	0,75
First,returns,above,0,00	0,8	0,79
First,returns,above,mean	0,49	0,4
First,returns,above,mode	0,79	0,72
Percentage,all,returns,above,0,00	0,78	0,79
Percentage,all,returns,above,mean	0,3	0,4

Percentage,all,returns,above,mode	0,78	0,72
Percentage,first,returns,above,0,00	0,78	0,78
Percentage,first,returns,above,mean	0,3	0,79
Percentage,first,returns,above,mode	0,78	0,4
Total,return,count	0,75	0,72