

Trabajo Fin de Máster

Segmentación de árboles a partir de nube de puntos procedentes de estéreo-imágenes RPAS en el contexto del bosque Mediterráneo

Catalina
SALAZAR PRANCKEVICIUS

Curso | 2020-2021
Convocatoria | Julio / Sept

Director/es:

Fernando J. AGUILAR TORRES
Abderrahim NEMMAOUI

Resumen:

La Segmentación de Árboles Individuales (Individual Tree Segmentation; ITS) se elabora con el motivo de extraer el número y características dendrométricas (posición, altura, diámetro de corona) de los árboles existentes en una zona forestal. La ITS puede obtenerse a partir de un Modelo de Altura de Dosel (Canopy Height Model; CHM) o, directamente, a través de una nube de puntos derivada de estéreo-imágenes RGB o escáner láser. Actualmente existen diversos algoritmos para segmentar árboles de forma automática, aunque se desconoce cuál de ellos es el más preciso según la zona a estudiar. En el presente trabajo se examinan un conjunto de algoritmos de segmentación de árboles, basados tanto en el uso del CHM como de la nube de puntos original, con el propósito de segmentar la capa superior o dominante, compuesta por pino carrasco (*Pinus halepensis* Mill.), de una parcela de 50 x 50 m ubicada en el Parque Natural de Sierra de María-Los Vélez, provincia de Almería, España. La exactitud de los resultados ofrecidos por cada uno de los métodos testados se analizó mediante la comparación con los datos reales (Ground Truth) obtenidos mediante escáner láser terrestre. A partir de estos resultados se pudo comprobar que, específicamente para esta zona, el algoritmo de Li et al. (2012), que trabaja segmentando la nube de puntos original, resultó ser más eficiente que otros métodos basados en la búsqueda de máximos locales en el CHM. Esto significa que, en general, el método de Li et al. podría ser el adecuado para la segmentación automática de árboles en áreas forestales similares (bosque Mediterráneo). Algunos de los otros métodos ensayados también ofrecieron buenos resultados, aunque fueron más dependientes de la correcta calibración local de los parámetros internos del algoritmo. En este sentido, es necesario afinar los parámetros de cada algoritmo mediante una calibración local previa para que pueda adaptarse a su uso en áreas forestales con diversas características (altura de árboles, densidad, cobertura, estructura, labores silvícolas).



RESUMEN

La Segmentación de Árboles Individuales (Individual Tree Segmentation; ITS) se elabora con el motivo de extraer el número y las características dendrométricas (posición, altura, diámetro de corona) de los árboles existentes en una zona forestal. La ITS puede obtenerse a partir de un Modelo de Altura de Dosel (Canopy Height Model; CHM) o, directamente, a través de una nube de puntos derivada de estéreo-imágenes RGB o escáner láser. Actualmente existen diversos algoritmos para segmentar árboles de forma automática, aunque se desconoce cuál de ellos es el más preciso según la zona a estudiar. En el presente trabajo se examinan un conjunto de algoritmos de segmentación de árboles, basados tanto en el uso del CHM como de la nube de puntos original, con el propósito de segmentar la capa superior o dominante, compuesta por pino carrasco (*Pinus halepensis* Mill.), de una parcela de 50 x 50 m ubicada en el Parque Natural de Sierra de María-Los Vélez, provincia de Almería, España. La exactitud de los resultados ofrecidos por cada uno de los métodos testados se analizó mediante la comparación con los datos reales (Ground Truth) obtenidos mediante escáner láser terrestre. A partir de estos resultados se pudo comprobar que, específicamente para esta zona, el algoritmo de Li et al. (2012), que trabaja segmentando la nube de puntos original, resultó ser más eficiente que otros métodos basados en la búsqueda de máximos locales en el CHM. Esto significa que, en general, el método de Li et al. podría ser el adecuado para la segmentación automática de árboles en áreas forestales similares (bosque Mediterráneo). Algunos de los otros métodos ensayados también ofrecieron buenos resultados, aunque fueron más dependientes de la correcta calibración local de los parámetros internos del algoritmo. En este sentido, es necesario afinar los parámetros de cada algoritmo mediante una calibración local previa para que pueda adaptarse a su uso en áreas forestales con diversas características (altura de árboles, densidad, cobertura, estructura, labores silvícolas).

Palabras clave. Segmentación de árboles individuales, Evaluación de la precisión, Nube de puntos, Modelo de altura de dosel, *Pinus halepensis*, Bosque Mediterráneo.



ABSTRACT

Individual Tree Segmentation (ITS) is developed to extract the number and dendrometric characteristics (position, height, crown diameter) of existing trees in a forest area. The ITS can be obtained from a Canopy Height Model (CHM) or, directly, through a point cloud derived from RGB stereo images or laser scanner. Currently there are various algorithms to segment trees automatically, although it is unknown which of them is the most accurate according to the area to be studied. In the present work, a set of tree segmentation algorithms are examined, based both on the use of the CHM and the original point cloud, with the purpose of segmenting the upper or dominant layer, composed of Aleppo pine (*Pinus halepensis* Mill.), of a 50 x 50 m plot located in the Sierra de María-Los Vélez Natural Park, Almería province, Spain. The accuracy of the results offered by each of the tested methods was analyzed by comparison with the real data (Ground Truth) obtained by a terrestrial laser scanner. From these results it was found that, specifically for this area, the algorithm of Li et al. (2012), which works by segmenting the original point cloud, turned out to be more efficient than other methods based on the search for local maximums in the CHM. This means that, in general, the method of Li et al. it could be suitable for automatic tree segmentation in similar forest areas (Mediterranean forest). Some of the other methods tested also gave good results, although they were more dependent on the correct local calibration of the internal parameters of the algorithm. In this sense, it is necessary to refine the parameters of each algorithm through a previous local calibration so that it can be adapted to its use in forest areas with different characteristics (tree height, density, cover, structure, silvicultural work).

Keywords. Individual Tree Segmentation, Accuracy Assessment, Point Cloud, Canopy Height Model, *Pinus halepensis*, Mediterranean forest.



ÍNDICE

1. INTRODUCCIÓN.....	7
2. MARCO TEÓRICO.....	10
3. MARCO APLICADO A LA PROPUESTA DE LA INTERVENCIÓN.....	14
3.1 Zona de Estudio.....	14
3.2 Materiales y Datos.....	14
3.3 Metodología.....	17
3.3.1 Algoritmo implementado en el software Fusion/LDV	18
3.3.2 Digital Forestry Toolbox (DFT)	19
3.3.3 Algoritmo Mean Shift 2D y 3D.....	19
3.3.4 Algoritmo de Li et al. (2012).....	20
3.3.5 Algoritmo de Dalponte & Coomes (2016).....	22
3.3.6 Algoritmo de Silva et al. (2016).....	22
3.3.7 Comparación entre Métodos.....	23
3.4 Resultados.....	24
3.4.1 Algoritmo implementado en el software Fusion/LDV	25
3.4.2 Digital Forestry Toolbox (DFT)	27
3.4.3 Algoritmo Mean Shift 2D y 3D.....	31
3.4.4 Algoritmo de Li et al. (2012).....	34
3.4.5 Algoritmo de Dalponte & Coomes (2016).....	37
3.4.6 Algoritmo de Silva et al. (2016).....	44
3.5 Discusión.....	52
3.4.1 Algoritmo implementado en el software Fusion/LDV	52
3.4.2 Digital Forestry Toolbox (DFT)	52
3.4.3 Algoritmo Mean Shift 2D y 3D.....	53
3.4.4 Algoritmo de Li et al. (2012).....	53
3.4.5 Algoritmo de Dalponte & Coomes (2016).....	54
3.4.6 Algoritmo de Silva et al. (2016).....	54



4. CONCLUSIONES.....	55
5. AGRADECIMIENTOS.....	57
6. REFERENCIAS.....	58



ÍNDICE DE FIGURAS

Figura 1.....	14
Figura 2.....	25
Figura 3.....	27
Figura 4.....	28
Figura 5.....	28
Figura 6.....	29
Figura 7.....	31
Figura 8.....	32
Figura 9.....	34
Figura 10.....	35
Figura 11.....	37
Figura 12.....	38
Figura 13.....	38
Figura 14.....	39
Figura 15.....	39
Figura 16.....	40
Figura 17.....	40
Figura 18.....	41
Figura 19.....	41
Figura 20.....	44
Figura 21.....	45
Figura 22.....	45
Figura 23.....	46



Figura 24.....	46
Figura 25.....	47
Figura 26.....	47
Figura 27.....	48
Figura 28.....	48

ÍNDICE DE TABLAS

Tabla 1.....	26
Tabla 2.....	26
Tabla 3.....	30
Tabla 4.....	30
Tabla 5.....	33
Tabla 6.....	33
Tabla 7.....	37
Tabla 8.....	37
Tabla 9.....	42
Tabla 10.....	43
Tabla 11.....	49
Tabla 12.....	50



1. INTRODUCCIÓN

Los bosques se encuentran entre los ecosistemas más importantes del Mediterráneo debido a la alta biodiversidad que albergan y a los servicios medioambientales que ofrecen. La estabilización y la reducción de la erosión del suelo, mejora de la captación de aguas superficiales, enriquecimiento de los embalses subterráneos, estabilización de los microclimas urbanos, producción de biomasa y fijación de CO₂, y los beneficios económicos directos como opción turística, constituyen una parte de los servicios que nos aportan. El conocimiento de la “arquitectura” de un bosque es particularmente importante para la estimación de su valor medioambiental y económico, así como para el planteamiento de intervenciones que contribuyen a su gestión sostenible. Tradicionalmente, el inventario forestal se basa en muestreos de campo sobre pequeñas parcelas. Las técnicas de inferencia estadística permiten obtener datos a gran escala a partir de estos datos iniciales, aunque el procedimiento resulta lento, costoso y, en general demasiado impreciso. La irrupción de técnicas de captura y análisis de datos basados en la Ingeniería Geomática acaparan gran parte de la investigación y el desarrollo en el área de teledetección de bosques para la realización de inventarios y tareas de supervisión a pequeña y mediana escala, permitiendo estimar con precisión diversos parámetros biofísicos y estructurales de la masa forestal relacionados con la biomasa asociada y, por tanto, con el carbono fijado por el bosque. Su análisis multitemporal permite la estimación de la evolución de la biomasa en el tiempo y el conocimiento de su vulnerabilidad a cambios climáticos, incendios, plagas y enfermedades, períodos de sequía y/o actuaciones antrópicas, habilitando el desarrollo de sistemas de gestión sostenibles para su implementación en ecosistemas especialmente vulnerables al impacto del Cambio Climático, como es el caso del bosque Mediterráneo.

Desde hace unos años ha irrumpido con fuerza un enfoque centrado a escala de árbol (*Tree-centric approach*) (Dalponte & Coomes, 2016) para el mapeado de variables biofísicas de interés forestal, produciéndose un incremento en el desarrollo de métodos de segmentación de árboles individuales (*Individual Tree Segmentation (ITS)*). Esta metodología permite obtener datos específicos a escala de árbol tales como el número total de árboles, las alturas, los diámetros de las coronas, el área basal, el volumen y la biomasa de cada árbol (Li et al., 2012).

En un inicio, para la elaboración de la segmentación de árboles individuales (*ITS*) se utilizaba el método de contabilizar el número total de árboles mediante la realización de un inventario in situ de la vegetación existente, anotando manualmente parámetros dendrométricos como el diámetro normal, el diámetro de corona y la altura del árbol. Este era un método preciso y fiable, pero poco eficiente. En efecto, el método tradicional resulta ser muy laborioso, toma un tiempo excesivo y



el espacio a analizar debe ser limitado (Lee et al., 2010). Más tarde se optó por tomar como referencia las fotografías aéreas (fotointerpretación) para la elaboración del inventario forestal, contabilizando y observando en planta, la morfología de la copa de los árboles (Li et al., 2012). Sin embargo, la fotografía aérea o imagen satelital no es adecuada para obtener un resultado en tres dimensiones del área o estimar la altura del árbol, por lo que se ha desarrollado la tecnología LiDAR (*Light Detection and Ranging*), ubicada tanto en sensores terrestres (Terrestrial Laser Scanning; TLS) como aerotransportados (Airborne Laser Scanning; ALS), que utilizan la luz láser para la medición de distancias y la obtención de densas nubes de puntos 3D (Maas et al., 2008; Wehr & Lohr, 1999). Las nubes de puntos obtenidas se procesan mediante diversos programas o algoritmos que ejecutan eficientemente la segmentación automática o semiautomática de árboles, permitiendo posteriormente la extracción, también de manera automática, de sus variables dendrométricas más relevantes, además de su contabilización y georreferenciación.

En la actualidad existen diferentes algoritmos y software para la detección y segmentación de árboles. La mayoría de ellos también facilitan la geolocalización del árbol y la determinación de la altura máxima de cada uno de los árboles segmentados, así como la delineación del contorno de sus coronas (Roussel et al., 2020). El único punto es que este tipo de análisis requiere de una precisión minuciosa, ya que esta metodología, sea computarizada o manual, tiende a estar bastante expuesta a los errores que comprometen los resultados finales (White et al., 2016). No obstante, aún se desconoce cuál de las técnicas computarizadas es la que ofrece resultados más precisos en el bosque Mediterráneo, por lo que se decidió elaborar una primera aproximación a este análisis y comprobar cuál es el método más preciso a la hora de realizar la ITS de pino carrasco (*Pinus halepensis* Mill.), teniendo como referencia una parcela experimental de 50 x 50 m situada en el Parque Natural de Sierra de María-Los Vélez, en la provincia de Almería, España.

La investigación se basa en la experimentación de seis algoritmos, cinco de ellos desarrollados en código Matlab, RStudio y Python, y el sexto implementado en el software de uso libre denominado Fusion (McGaughey, 2018). El objetivo es determinar cuál de los algoritmos testados resulta más apropiado para la segmentación de los árboles de la parcela experimental y la extracción de su altura y diámetro de corona a partir de nubes de puntos obtenidas a partir de estéreo-imágenes RPAS (*Remotely Piloted Aircraft System*). En este punto, es interesante destacar que la precisión de los datos obtenidos depende mucho de la técnica de ITS empleada (Silva et al., 2016).



Añadir también, que otros investigadores, aparte de los mencionados en este trabajo, desarrollaron sus estudios con el paquete lidR en el software libre RStudio, y a pesar de que las áreas no posean similitudes entre sí pudieron desempeñar efectivamente los algoritmos de Li et al. (2012), Dalponte & Coomes (2016) y Silva et al. (2016) obteniendo resultados óptimos. Áreas que van desde bosques subtropicales (Sothe et al., 2019), bosques tropicales lluviosos (Almeida et al., 2019) y boreales hasta la sabana (Zimbres et al., 2020).

La investigación se centra en encontrar cuál de los métodos examinados es el que mejor podría ajustarse y trabajar de manera eficiente en la parcela experimental, es decir, el que posee una mayor capacidad de detección de todos los árboles presentes (bajo error de omisión o elevado *recall*) con una elevada precisión en la segmentación de estos (bajo error de comisión). Por otro lado, se busca encontrar cuál/es son los parámetros internos (*tuning parameters*) de cada algoritmo que mejor se adaptan a la morfología de la parcela experimental (Wang, 2020). Los resultados de este trabajo constituyen una primera aproximación para la generalización de dichos parámetros de cara a su aplicación en áreas similares de bosque Mediterráneo, representando una contribución de interés para futuros trabajos dirigidos al seguimiento y monitoreo de la dinámica de este tipo de ecosistemas (e.g., fijación de carbono atmosférico y mitigación del cambio climático) (Gómez et al., 2019).



2. MARCO TEÓRICO

Actualmente existe una alarmante falta de datos de seguimiento de masas forestales (**Forest Monitoring**), lo que supone a menudo un obstáculo en la toma de decisiones relativas a las actividades de gestión (vertiente económica) y protección (vertiente ambiental ligada al impacto del cambio climático y la presión antrópica) de los bosques por parte de las entidades públicas y privadas. Los métodos tradicionales del inventario forestal terrestre que aplican procedimientos de muestreo a nivel de parcela ofrecen resultados puntuales que han de ser extendidos mediante inferencia estadística para cubrir toda la masa forestal. Se trata de un procedimiento costoso y poco eficiente que, además, es prácticamente inviable en zonas forestales remotas con difícil acceso. En este sentido, se imponen nuevas estrategias de evaluación y seguimiento de la masa forestal ligada al desarrollo de técnicas geomáticas emergentes, o tecnologías de la información espacial (TIE), basadas en el uso de datos procedentes de sensores remotos como la tecnología TLS (Terrestrial Laser Scanning), ALS (Airborne Laser Scanning), estereofotogrametría aérea de muy alta resolución o las imágenes multiespectrales de satélite (Kershaw et al., 2016; White et al., 2016). Estas estrategias se alinean con el concepto conocido como *Precision Forestry* y el desarrollo de herramientas y procedimientos que incrementan la precisión y eficiencia en la estimación de parámetros estructurales de masas forestales como soporte para la toma de decisiones y estimación de su valor económico-ambiental.

En la última década se ha producido un incremento notable en la aplicación de las TIE para la realización de inventarios forestales a gran escala y la evaluación de la contribución de las masas forestales a la mitigación del cambio climático mediante la elaboración de cartografía de cambios en el uso del suelo y la determinación de tasas de variación del C almacenado (Hirata et al., 2018). Los sistemas de láser escáner TLS y ALS, y la estereofotogrametría aérea de muy alta resolución, tanto a partir de cámaras aerotransportadas de forma convencional o mediante vehículos aéreos no tripulados (RPAS), acaparan gran parte la investigación y desarrollo en el área de monitoreo de bosques a pequeña y mediana escala, permitiendo estimar, mediante el adecuado procesamiento de la “nube de puntos 3D”, diversos parámetros biofísicos y estructurales de la masa forestal relacionados con la biomasa asociada y, por tanto, con la distribución espacial del carbono almacenado por el bosque.

Las características esenciales de la vegetación y segmentación de árboles individuales se suelen extraer en tres pasos. El primer paso sería la localización y segmentación de cada uno de los árboles que componen el área de estudio. El segundo paso corresponde a la comparación de los árboles extraídos con el conjunto de árboles de referencia (ground truth) obtenido mediante



inventario tradicional o escáner láser terrestre o aerotransportado. Finalmente, se procede a la extracción automática de las variables dendrométricas y su comparación con los valores reales ofrecidos por los árboles de referencia (Silva et al., 2016). A su vez, los algoritmos de segmentación de árboles individuales, según las etapas del procesamiento y ejecución, se dividen en dos tipos: aquellos que trabajan con el Modelo de Altura de Dosel, comúnmente denominado, *Canopy Height Model (CHM)*, o los que operan directamente con la nube de puntos (Roussel et al., 2020).

Popescu define el CHM como el modelo digital de superficie (modelo malla o ráster) del área forestal que se ajusta a aquellos puntos de la nube de puntos que presentan una mayor altura normalizada (diferencia entre la cota del punto y la cota del terreno) (Popescu, 2007). En este sentido, se podría entender como el modelo digital de superficie que pasa por los puntos de máximo local en la zona de estudio.

Muchos algoritmos basados en el CHM consideran un factor denominado Suavizado (*Smoothing*), que es el encargado de mitigar las grandes variaciones de cota a nivel local (ruido) debidas, en general, a errores puntuales en la generación fotogramétrica (o LiDAR) de la nube de puntos. Para este factor no existe un valor idóneo de suavizado que pueda funcionar en todos los casos (Paris et al., 2016). Este factor es el que usa el software Fusion LDV/LiDAR como opción predeterminada a la hora de ejecutar el ITS (Roussel et al., 2020).

Algunas diferencias entre los algoritmos basados en la nube de puntos y en el CHM es que aquellos que usan la nube de puntos completa suelen necesitar una mayor capacidad computacional (Paris et al., 2016). Por otra parte, la construcción del CHM necesita de la generación previa del Modelo Digital del Terreno (*Digital Terrain Model; DTM*) para poder obtener las alturas normalizadas. A partir del CHM, y mediante diferentes procedimientos, se procederá a la localización de los árboles y a la segmentación de la corona (Wang, 2020). A pesar de ciertas diferencias, ambos métodos se utilizan en investigaciones forestales para la obtención del diámetro de la corona, la altura del árbol, el número de árboles y su localización espacial, e identificación de los diversos estratos del bosque (estrato dominante y dominado) (Vega et al., 2014).

En este trabajo se evalúan seis algoritmos de segmentación de árboles individuales. Dos de ellos se ejecutan directamente sobre la nube de puntos obtenida, y los cuatro restantes se basan en la elaboración previa del CHM. En la primera opción se utilizan una versión del algoritmo de Li et al. (2012) y el conocido algoritmo de cauterización Mean Shift (tanto en 2D como en 3D). En la



segunda opción se desarrollaron algoritmos basados en la librería de Matlab denominada *DFT (Digital Forestry Toolbox)*, junto con los algoritmos de Dalponte & Coomes (2016) y Silva et al. (2016), y la metodología implementada en el software Fusion.

El escáner láser terrestre (TLS) es una herramienta tecnológica que sirve para escanear y obtener un modelo de puntos 3D, también denominado nube de puntos (*Point-Cloud*). El TLS es una herramienta muy eficiente con la que se pueden obtener resultados precisos e información 3D de la zona trabajada directamente (Liu et al., 2021) . Usualmente se utilizan para zonas boscosas con suficiente vegetación y para motivos de examinación y análisis de ciertas características de las zonas forestales en diversas partes del mundo.

Dentro de las ventajas de estos sensores es que están capacitados para transferir en 3D lo que sería la morfología del área boscosa en un corto tiempo, cuestión que hace unos años atrás no era posible interpretar (Vega et al., 2014). Cabe destacar que, dependiendo de la cantidad de escaneos que se realicen, puede variar notablemente la precisión que se obtenga (oclusiones) y la densidad de la nube de puntos (Wang, 2020). Los pulsos láser pueden penetrar a través de las hojas y ramas y así facilitar informaciones directas del área a evaluar, tales como las alturas que poseen los árboles y las medidas de la cobertura de la zona (Roussel et al., 2020). La tecnología TLS posibilita la recopilación de informaciones específicas tales como el volumen, la biomasa y el área basal de cada uno de los árboles que se encuentran en el área examinada (Vauhkonen et al., 2014).

La obtención de información forestal a través de TLS o ALS, y la detección y segmentación de árboles individuales a partir de la nube de puntos mediante diversos algoritmos, posee el beneficio de que no requiere contacto con el medio físico (sobre todo el ALS), pues se trata de sensores (Dalponte & Coomes, 2016).

Por otro lado, el desarrollo de lenguajes de programación como RStudio permite la elaboración de diversos algoritmos de forma fácil e intuitiva. En efecto, RStudio es un software de múltiples funciones que trabaja junto a diversas herramientas denominadas “paquetes” en la interfaz. Para el caso del análisis de segmentación de árboles individuales, existe un paquete en RStudio denominado “LidR”. Este paquete no es simplemente una herramienta en la cual se ingresa el código y se ejecuta, sino que se trata de *“una herramienta con la que los usuarios pueden generar nuevos instrumentos”* (Roussel et al., 2020). Con esto el autor se refiere a que el instrumento, aparte de tener la opción de segmentar árboles, posee otras múltiples opciones y algoritmos dentro del mismo paquete para desarrollar algoritmos de forma eficiente. Su rapidez y simpleza



es lo que permite que la herramienta sea óptima para trabajarla con los algoritmos evaluados en este trabajo. En este sentido, LidR también ha sido referenciado en múltiples artículos (Dalponte & Coomes, 2016; Popescu, 2007; Roussel et al., 2020; Vega et al., 2014).



3. MARCO APLICADO A LA PROPUESTA DE LA INTERVENCIÓN

3.1 ZONA DE ESTUDIO

La zona de trabajo consiste en una parcela 50 x 50 m, ubicada en el Parque Natural de “Sierra de María-los Vélez”, provincia de Almería, España (Fig. 1). Sus coordenadas geográficas son 37°41'31.17"N y 2°13'39.51"W y el tipo de bosque que compone este tramo es de tipo mediterráneo con clima mediterráneo continental semiárido. La composición morfológica del área, desde un punto de vista forestal, se distribuye en dos capas principales. La primera corresponde a la capa dominante (árboles dominantes), ubicada en la zona superior, representada por pino carrasco (*Pinus halepensis Mill.*). La segunda capa, comúnmente denominada como sotobosque, se compone de pequeños árboles de encina (*Quercus ilex L.*), y diversas especies de arbustos (Aguilar et al., 2019).

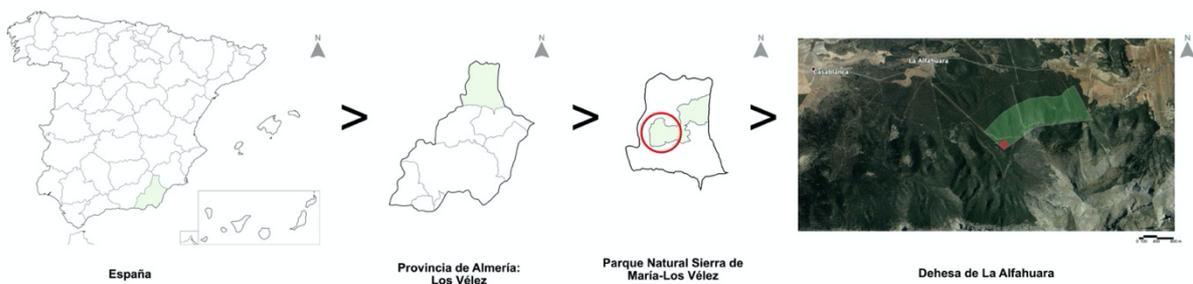


Figura 1. Ubicación del proyecto.

3.2 MATERIALES Y DATOS

El 26 de febrero de 2018 se utilizó el RPAS modelo DJI Phantom 4 Advanced® para obtener estéreo-imágenes RGB de alta resolución de la parcela experimental estudiada en este trabajo. La altura de vuelo con respecto al nivel del terreno fue de 75 metros y la cámara se fijó con una longitud focal de 8,8 mm para así obtener un píxel terreno con un tamaño medio de 2,1 cm (*Ground Sample Distance; GSD*). La cámara disponía de un sensor 1" CMOS (de 2,52 μm /píxel) con una resolución de 20 megapíxeles. Se empleó una planificación de vuelo que aseguraba un solape longitudinal y lateral del 90% y 70% respectivamente, con lo que se pudo obtener un recubrimiento de imágenes elevado de la zona estudiada. Nueve puntos de apoyo fotogramétrico bien distribuidos en campo fueron emplazados mediante dianas circulares y medidos con GPS Topcon HiPer Pro en estático rápido (tiempo de observación mayor de 13 minutos). La Base HiPer Pro, situada en terreno abierto y a menos de 150 m de los puntos de apoyo fotogramétrico, fue referenciada a partir de la estación Huércal-Overa (RAP; Red Andaluza de Posicionamiento

GPS) mediante modo estático (más de 3 horas). El post-procesamiento de las líneas base permitió obtener una estimación en los puntos de apoyo de la precisión horizontal (1,6 cm) y vertical (2,7 cm), medida como la raíz del error medio cuadrático (RMSE).

Con las imágenes aéreas tomadas por el RPAS se generó una nube de puntos (RPAS-DAP; *Digital Aerial Photogrammetry*) y una ortoimagen RGB de 3cm/píxel usando algoritmos SfM-MVS (*Structure from Motion Multiview Stereo*) integrados en el software Photoscan Professional. Los nueve puntos de control de campo se usaron en el proceso de ajuste y de triangulación. La nube de puntos final se expresó en coordenadas absolutas UTM 30 N ETRS 89 y alturas ortométricas EGM08 REDNAP. Los puntos de apoyo fueron utilizados para la auto-calibración de la cámara (Aguilar et al., 2019).

La densidad de la nube de puntos obtenida fue de 580 puntos/m². Los puntos fueron clasificados como puntos terreno y no-terreno mediante la aplicación del algoritmo *Adaptive Triangulated Irregular Network (ATIN)* implementado en Photoscan Professional. Este algoritmo divide los datos en cuadrícula (parámetro del tamaño de la celda) para encontrar los puntos terreno iniciales (semillas) a partir de la búsqueda del mínimo de cada cuadrícula (mínimo local). Los puntos semilla son empleados para construir la superficie de triángulos TIN de referencia, añadiendo iterativamente al modelo TIN puntos candidatos para formar parte del modelo digital del terreno (DTM) o suelo desnudo. Cada punto candidato se clasifica como terreno o no según su distancia al triángulo TIN más cercano y al ángulo que forma con los vértices de dicho triángulo. El punto candidato se clasifica como no-terreno si la distancia y el ángulo son superiores a los umbrales predefinidos (parámetros correspondientes a la distancia y ángulo en Photoscan). Tras un procedimiento de prueba y error, el conjunto de los parámetros seleccionados fueron los siguientes: tamaño de celda en 10 m, distancia de 0,3 m y el ángulo de 30° (Aguilar et al., 2019).

Antes del proceso de filtrado, los posibles valores atípicos o “*outliers*” fueron eliminados automáticamente, adaptando el método estadístico paramétrico para la detección de errores en los DTM publicado por Felicísimo (1994). En este caso la distancia máxima de los puntos más próximos al punto candidato (vecindad) fue fijada en 15 cm (radio de vecindad).

Se aplicó a la nube de puntos RPAS-DAP un algoritmo de filtrado de máximos locales con un radio de 10 cm de vecindad para buscar la altura máxima local y obtener así el Modelo de Superficie del Dosel (*Canopy Surface Model; CSM*). El modelo CSM derivada de los datos RPAS-DAP y la nube de puntos DTM filtrada automáticamente fueron finalmente interpolados en



formato gris con un espaciamiento de 5 cm utilizando el algoritmo Gaussian Markov Random Field (GMRF) (F. J. Aguilar et al., 2016) (código disponible en <https://github.com/3DLAB-UAL/dem-gmrf>). Para obtener el modelo de altura del dosel (CHM) en formato grid de 5 cm se determinó la diferencia, píxel a píxel, del CSM y DTM interpolados. Puesto que en el modelo CHM se excluye la influencia de la topografía, éste representa las alturas normalizadas con referencia al nivel del suelo de todos los objetos superpuestos sobre el terreno (e.g. árboles y arbustos).

El 14 de febrero de 2018 se utilizó el escáner láser FARO Focus 3D X-330 para así obtener una nube de puntos muy precisa y densa que permitiera la realización de un inventario digital. Se hicieron un total de nueve escaneos con el objetivo de obtener la mayor cantidad de información posible del área, ya que la capa vegetal es muy densa. Los escaneos se situaron uno en el centro y el resto en los alrededores, con el fin de cubrir toda la zona de estudio.

Se utilizó el software FARO Scene para co-registrar los nueve escaneos, produciendo así una única nube de puntos TLS usando 7 targets artificiales (esferas de 14 cm de diámetro) que fueron colocados para asegurar que al menos tres esferas fuesen visibles desde cada dos escaneos consecutivos. Una vez co-registrados los nueve escaneos, el primero fue georreferenciado (sistema de referencia ETRS89 UTM 30 N y alturas ortométricas EGM08 REDNAP) aplicando la transformación 3D de coordenadas basada en las coordenadas de 3 esferas medidas mediante GPS con el método estático rápido (tiempo de observación superior a 10 minutos).

Las nubes de puntos terrestre y aérea fueron fusionadas, permitiendo obtener una nube muy densa, capaz de describir con precisión todo el rango de puntos en el bosque, desde la base del tronco hasta el ápice de la corona. La nube de puntos original fue extraída para los 50 por 50 m del área de trabajo, a la que se añadió un *buffer* de 12 m de distancia para evitar el efecto borde a la hora de extraer las propiedades biométricas de los árboles, proporcionando más de 114 millones de puntos. Este número inicial de puntos fue reducido para facilitar su manejo mediante la realización del re-muestreo espacial con una distancia mínima de 3 cm. La nube fusionada resultante tenía algo más de 6 millones de puntos (1570 puntos/m²).

Las propiedades biométricas de todos los árboles de pino carrasco situados en el área de trabajo ampliada fueron medidas en la nube de puntos fusionada mediante el visor 3D del software Fusion/LDV. Así se obtuvo la altura, posición y área proyectada de corona de hasta 90 árboles dominantes (pino carrasco) (Fernando J. Aguilar et al., 2019).



3.3 METODOLOGÍA

Para poder ejecutar los algoritmos planteados y evaluar su capacidad de detección de los árboles presentes en la parcela experimental se adoptarán dos métodos principales: i) el uso de la nube de puntos RPAS-DAP original y ii) el empleo del Modelo de Altura de Dosel (CHM).

Los métodos testados basados en la segmentación de las nubes de puntos son el desarrollado por Li et al. (2012) y el basado en un conocido algoritmo de agrupación no supervisada de datos (*clustering*) denominado *Mean Shift Clustering (MSC)*. Este último método, adaptado a su aplicación para la extracción de árboles en nubes de puntos de masas forestales, ya ha sido empleado por algunos autores (Ferraz et al., 2012, 2016). En cuanto a los algoritmos basados en la obtención previa del CHM, se han testados los algoritmos Dalponte & Coomes (2016) y Silva et al. (2016), junto con los algoritmos implementados en el software Fusion (McGaughey, 2018), y un diagrama de flujo codificado en Matlab que hace uso de la herramienta *Digital Forestry Toolbox (DFT)* (Parkan, 2018).

A modo general, se fijaron parámetros que coinciden en algunos de los algoritmos para tener una base concreta y justa a la hora de la comparación de métodos. Algunos de estos factores fueron el factor de suavizado (*Smoothing*) del CHM, que se fijó en tres (3), debido a que esta variable es el promedio recomendado en el manual y la más adecuada para este tipo de proyecto (Silva et al., 2016), y la altura mínima para el análisis de árboles individuales, o comúnmente denominada *Threshold*, que se fijó en cuatro y siete metros. Ambos umbrales de análisis fueron empleados como frontera entre la capa inferior del bosque o sotobosque (*understory*), conformado por encinas y arbustos, y la capa superior (árboles dominantes) compuesta por ejemplares desarrollados de pino carrasco. Se analizaron ambas variables en todos los algoritmos para así poder examinar su influencia en los resultados. Evaluar con un umbral por debajo de cuatro metros provocaría que la vegetación del sotobosque interfiera con los resultados del estudio (Liu et al., 2021). Téngase en cuenta que este tipo de vegetación de bajo porte es difícil de modelar (Wang, 2020).

El motivo por el cual se ensayarán los algoritmos modificando los parámetros de funcionamiento implicados se debe a que, además de encontrar el método más preciso para la parcela experimental, también se pretende estudiar el rango idóneo y la sensibilidad de los resultados a la variación de dichos parámetros (Vega et al., 2014).



3.3.1 Algoritmo implementado en el software Fusion/LDV

Para el método implementado en el software Fusion/LDV, la obtención de información se basa principalmente en la obtención de máximos locales (*CanopyMaxima*), a partir de un *Canopy Height Model* (CHM), elaborado de manera inicial, en tres pasos:

- 1- Obtención del modelo digital de superficie de la vegetación (*CanopyModel*).
- 2- Obtención del CHM.
- 3- Obtención de los puntos *CanopyMaxima*.

Los parámetros de los algoritmos que implementa Fusion son el *Cellsize* (la medida que tendría de la cuadrícula en el rasterizado) y el *Threshold* de altura mínima de análisis, explicado anteriormente, que para este tipo de proyecto se fijó en alturas mínimas de cuatro y siete metros. También es necesario fijar el suavizado (*Smoothing*) para la eliminación del “ruido” o aquellos elementos que distorsionan y evitan identificar con claridad los máximos locales reales (ápices de árboles) del CHM (McGaughey, 2018).

Para poder desarrollar el CHM en este software es necesario insertar en el código un parámetro denominado *Ground*. El *Ground*, por su nombre en inglés, es lo que sería el terreno (Digital Terrain Model; DTM), fundamental como referencia para la determinación de la altura de cada punto y la aplicación de los umbrales de exclusión por altura mínima (McGaughey, 2018). El algoritmo de *CanopyMaxima* se encarga de encontrar e identificar aquellos árboles que se encuentren por encima de la variable umbral (cuatro y siete metros) desde el archivo del CHM. Este algoritmo emplea un método de búsqueda de máximos locales basado en una ventana de tamaño variable en función de la altura del árbol objetivo (Popescu & Wynne, 2004). En concreto, el tamaño de la ventana por defecto viene expresado como una función polinómica que depende de la altura h (medida sobre el CHM) del punto considerado y que responde a la siguiente expresión: $2.51503 + 0.00901 h^2$. Aunque esta expresión que configura la ventana adaptativa puede ser cambiada por el usuario, en este estudio se empleó la configuración por defecto. Finalmente, se exportaron todos los datos referentes a los árboles extraídos en formato csv y en forma de listado para luego ser procesados y analizar la efectividad del algoritmo implementado en Fusion en relación con el resto de los algoritmos testados.



3.3.2 Digital Forestry Toolbox (DFT)

DFT es un conjunto de códigos Matlab diseñada por Matthew Parkan con el motivo de obtener características e informaciones de los bosques mediante sensores remotos (Parkan, 2018). Trabaja directamente con el CHM y realiza la segmentación de árboles individuales sobre una imagen raster (CHM) utilizando el algoritmo de *watershed segmentation* (Kwak et al., 2007). Este último extrae automáticamente las coronas de los árboles a partir de los datos del CHM. Los pasos de ejecución son similares a los descritos en la sección 3.3.1. No obstante, a la hora de la detección de árboles se incluye la segmentación “*watershed*” aplicada sobre el CHM. El suavizado se lleva a cabo mediante una función gaussiana de suavizado que sirve como un filtro tipo *low-pass*.

3.3.3 Algoritmo Mean Shift 2D y 3D

Mean Shift (MS) es un algoritmo de clasificación para encontrar grupos homogéneos en espacios de características. Fue propuesto inicialmente en 1975 por Fukunaga (Fukunaga, 1990). El agrupamiento (*clustering*) Mean Shift es un algoritmo basado en ventanas deslizantes que intenta encontrar áreas densas de puntos de datos. En cada iteración, la ventana deslizante se desplaza hacia regiones de mayor densidad haciendo coincidir el centroide de cada clúster con la media de los puntos dentro de la ventana. La mayor ventaja que presenta este algoritmo es que no es necesario el conocimiento a priori del número de clases.

En este trabajo se ha utilizado la versión del algoritmo implementada en la librería de Python scikit-learn 0.24.2, ensayando la búsqueda de clústeres sobre un espacio 2D (proyección de los puntos 3D sobre el plano $Z = 0$) (MS2D) y directamente en el espacio 3D de la nube de puntos original (MS3D). Aproximaciones similares han sido llevadas a cabo para la segmentación de árboles por autores como Ferraz et al. (2012) y Ferraz et al. (2016), aunque hay que subrayar que los algoritmos MS2D y MS3D testados en este estudio son una réplica de los algoritmos presentados en los dos trabajos citados, sino que simplemente utilizan como núcleo o motor de agrupamiento el mismo algoritmo general MS.

Lo que más destaca de estos algoritmos es que su funcionamiento solo depende de un solo parámetro, el *Bandwidth* o ancho de banda. El *Bandwidth* se refiere a lo que sería el tamaño de aquellos puntos de masa (o *kernel*, en inglés), que constituyen el clúster, ya sea en 2D o 3D (Ferraz et al., 2016). Cabe resaltar que esta variable no es universal, por lo que su valor óptimo



puede variar en función de las áreas forestales y tipos de bosque bajo estudio. En efecto, un mayor tamaño de los árboles objetivo implica un mayor tamaño del Bandwidth (Ferraz et al., 2012). Este parámetro puede afectar enormemente a los resultados obtenidos.

Tanto el MS2D como MS3D se examinaron con las alturas mínimas de análisis de cuatro y siete metros. Conviene indicar que son algoritmos que trabajan directamente con la nube de puntos original, en lugar de estar basados en el CHM, por lo que la ejecución de los mismos se elabora en cinco pasos:

- 1- Lectura de los puntos 3D de la nube de puntos ingresada.
- 2- Aplicación del algoritmo Mean Shift añadiendo el bandwidth seleccionado.
- 3- Extracción de la altura máxima de los árboles y eliminación de aquellos que se encuentren por debajo de la altura mínima colocada.
- 4- Determinación de lo que se llama el *Convex Hull* (la forma que arroja el área de trabajo con los parámetros ingresados) y la extracción del diámetro de la corona de cada uno.
- 5- Exportación de los resultados en csv (listado de árboles detectados y sus medidas: altura y diámetro de corona).

Este algoritmo puede adaptarse a zonas con vegetación irregular (Ferraz et al., 2016). A partir de los árboles segmentados es posible profundizar en el estudio y lograr obtener informaciones importantes de la vegetación extraída, tales como la altura de los árboles, el tamaño de la corona y la densidad, que en futuro puedan servir para mapear la distribución espacial de biomasa en la zona de interés.

3.3.4 Algoritmo de Li et al. (2012)

El algoritmo de Li et al. (2012) segmenta los árboles individuales a partir de la nube de puntos. Para ello selecciona el punto con mayor cota con respecto al terreno y emplea una separación por distancias horizontales entre puntos y reglas de decisión que permite ir añadiendo, o excluyendo, cada punto al árbol o clúster en formación. Es decir, este algoritmo trabaja con las distancias horizontales entre árboles, ya que el espacio que hay entre los ápices de las copas (la parte más alta del árbol) es mucho mayor que la separación existente entre la parte más baja de los mismos (forma cónica de la copa) (Li et al., 2012). El algoritmo contabiliza los árboles de acuerdo con la segmentación obtenida a partir de los puntos superiores del árbol hasta llegar al



punto de cota mínima. Recordar que se ha fijado una cota mínima de análisis tomada en valores de cuatro y siete metros.

La manera en la que el código contabiliza la cantidad de árboles es que, si la distancia entre los puntos más altos es menor que el *threshold* ingresado (distancia horizontal), contabiliza el punto como perteneciente al árbol en formación. Con esto podemos corroborar que el *threshold* es un parámetro muy importante para la eficiencia de este algoritmo, ya que podría provocar resultados de árboles sobre-segmentados (error de comisión) o muchos árboles podrían no ser considerados (error de omisión). Li especifica que el valor inicial de este parámetro resulta ser muy similar al radio medio de corona de los árboles presentes en la zona de trabajo (Li et al., 2012). No obstante, es difícil estimar el valor correcto de distancia mínima, ya que puede variar dependiendo del tamaño de los árboles y su morfología (bifurcaciones). Para este algoritmo, la altura mínima de análisis (*threshold*) es una variable sensible, debido a que Li et al. (2012) plantea que en las zonas forestales cuyos árboles están situados a mayor distancia entre unos y otros la altura mínima de análisis debe ser mayor que aquellas zonas donde los árboles se encuentren plantados más cerca unos con otros. Por lo que seleccionar una altura mínima de análisis errónea podría causar que el algoritmo no contabilice todos los árboles presentes, provocando lo que sería una “segmentación pobre”, al seleccionar una variable elevada, o una segmentación excesiva, al ingresar una altura mínima de análisis reducida (Li et al., 2012).

Una de las ventajas de este algoritmo es que trabaja con todos los puntos de la nube, sin dejar ningún punto sin clasificar, por lo que en caso de que el algoritmo detecte una rama u follaje que corresponda a uno de los árboles, automáticamente lo cuenta como parte del árbol que se está segmentando o lo incluye en el que encuentre más cercano. Para la correcta segmentación de árboles, el algoritmo funciona variando tres parámetros: i) el parámetro R, que hace referencia a la regla de espacio mínimo que hay entre dos árboles (comúnmente el radio medio de corona), ii) la altura mínima de análisis, y iii) el Speed-up, que correspondería al radio máximo de la corona. Este último parámetro se suele seleccionar atendiendo a que su valor sea superior al radio máximo de corona presente en la zona de interés. En resumen, se eliminan del análisis todos los puntos de la nube cuya distancia horizontal al punto inicial del clúster (ápice del árbol) supera el valor de speed-up empleado. De esta forma se acelera la velocidad del algoritmo.

También añadir que la forma de trabajo del mismo es por medio de un bucle, es decir, no deja de trabajar hasta que encuentre y clasifique todos los puntos según las configuraciones (Li et al., 2012). Este algoritmo se ejecutó mediante la adaptación del código R presente en el paquete lidR (Roussel et al., 2020). Cabe destacar que los autores hicieron un ensayo para examinar su



algoritmo analizando una parcela con una medida parecida a la zona de este estudio, 50 x 50 m, y los resultados obtenidos por su parte fueron muy precisos.

3.3.5 Algoritmo de Dalponte & Coomes (2016)

El algoritmo de Dalponte & Coomes (2016) se basa en la segmentación de árboles individuales tomando como base la imagen rasterizada del Modelo de Altura del Dosel (*CHM*). Este algoritmo, por su forma de operar, puede tener cierto parecido con la metodología de Fusion, detallada en la sección 3.3.2. El algoritmo localiza aquellos puntos máximos locales del CHM mediante un tamaño de ventana especificado por el usuario. Estos puntos se consideran puntos semilla, representando ápices de árboles. A partir de estos puntos semilla, se toman los píxeles más cercanos del CHM y los añade al árbol si esos píxeles se encuentran por debajo del valor umbral que el usuario determinó como el porcentaje de altura máxima. En el caso de que un píxel sea mayor que el valor umbral, lo excluye del árbol objetivo. Este procedimiento es repetido hasta completar la clasificación de todos los puntos de manera iterativa. Una vez clasificado todos los puntos, el programa procede a determinar las alturas resultantes de la vegetación agrupada y representa el *convex-hull* (envolvente convexa de los píxeles de cada árbol) de la segmentación final (Dalponte & Coomes, 2016).

Este método también ha sido adaptado del código R original que forma parte del paquete lidR (Roussel et al., 2020). Para obtener resultados óptimos con este algoritmo, se debe trabajar con los siguientes tres parámetros: i) el diámetro de la corona máxima (predeterminado en 10 por los autores y denominado como *Max Crown Factor*), ii) el porcentaje de la diferencia de altura (valores entre 0 y 1), denominado *Threshold Seed*, iii) y la altura mínima de análisis (*Threshold*). Recalcar también que estos valores, a pesar de que los autores proponen ciertos valores predeterminados, no podrían resultar eficientes en todas las zonas y con todo tipo de vegetación, por lo que el usuario es el encargado de acomodar los parámetros según sea requerido.

3.3.6 Algoritmo de Silva et al. (2016)

Este algoritmo también es de los que se ejecutan sobre el Modelo de Altura de Dosel (*CHM*) para la segmentación de árboles individuales. Se ejecuta en el lenguaje R (Rstudio) a partir del paquete LidR (Roussel et al., 2020). A nivel práctico, los parámetros que el usuario debe ir ajustando en esta metodología son el diámetro de la corona (*Max. Crown*), la exclusión (*Exclusion*) y la altura mínima de análisis (*Threshold*). El primero debe estar entre 0 y 1 con relación a la altura del árbol. El segundo, que de igual manera debe tomar valores entre 0 y 1,



elimina los píxeles que se encuentren por debajo del producto entre el valor del parámetro y la altura del árbol. Finalmente, el tercer parámetro simplemente excluye aquellos píxeles con una cota inferior a la mínima de análisis.

El algoritmo procesa de manera similar al resto de los métodos descritos anteriormente que trabajan con el CHM. Lo diferente resulta en la manera en la que localiza e individualiza los árboles. Una vez ejecutado el programa, el código detecta cada árbol de manera individual, determinando los polígonos convexos de las coronas de los árboles localizados. Como resultado final obtenemos los perímetros de cada uno de los árboles presentes, junto al área que posee cada corona (Silva et al., 2016).

3.3.7 Comparación Entre Métodos

Para la comparación entre métodos y selección de los parámetros que más se ajustan a una mayor precisión y sensibilidad y menor error de cada método y selección del algoritmo más preciso per se, se analizan todos los resultados obtenidos mediante un código en el que arroja como resultado lo que se llama Evaluación de Precisión (*Accuracy Assesment*) en el desarrollador Matlab (*The MathWork Inc.*). El *Accuracy Assesment* propicia los resultados en términos de porcentajes de manera general, en cuanto a la contabilización de todos los árboles, o de manera más precisa, análisis de errores tanto en la altura de estos como en su corona.

Con el *Accuracy Assesment* desarrollado en Matlab se pretende comparar los resultados de lo que sería el *Groundtruth* con los resultados obtenidos de los algoritmos analizados. El *Groundtruth*, en inglés, se refiere al valor de referencia real de la variable de interés en el área de estudio. Para los resultados finales procesados por el programa, obtendremos un listado con los diversos errores y su porcentaje, la precisión de la información obtenida, la sensibilidad y el F-score que tienen los resultados ingresados para cada uno de los algoritmos y los parámetros experimentados. Se tomaron en cuenta todos los factores a la hora de seleccionar el método que mejor se aplicaba al proyecto. No obstante, los que se observaron detenidamente y que tuvieron más influencia a la hora de la selección fueron los siguientes: i) la Sensibilidad (*Recall*) indica el porcentaje de árboles que fueron clasificados como tales por el algoritmo, y se relaciona con el error de omisión (1-recall); ii) la Precisión (*Precision*), indica el nivel de corrección de los árboles detectados por el algoritmo, y se relaciona con el error de comisión (1-precision); iii) el *F-score*, que mide la exactitud global del algoritmo integrando a las dos métricas anteriores mediante la media armónica de los errores de omisión y comisión.



En el artículo de Liu et al. (2021) se especifican las fórmulas para la obtención de estos tres indicadores a partir del conteo de los árboles correctamente segmentados (con respecto al *groundtruth*), o Verdadero Positivo (*True Positive*; *TP*), los árboles erróneamente contabilizados por el algoritmo (Falso Positivo o *False Positive*; *FP*), y los árboles que el algoritmo no ha sido capaz de identificar (Falso Negativo o *False Negative*; *FN*).

$$\text{Recall}(r) = \frac{TP}{TP + FN}; \text{ Precision}(p) = \frac{TP}{TP + FP}; \text{ Fscore} = 2 \frac{r \cdot p}{r + p} \quad 1)$$

Igualmente se han empleado estadísticas basadas en la diferencia de valores (residuos calculados como valor estimado menos valor observado) de parámetros estimados (e.g. altura del árbol) como la media y mediana (errores sistemáticos), la raíz del error medio cuadrático (RMSE) (error aleatorio) y el valor relativo del RMSE ($100 * \text{RMSE} / \text{valor medio de la variable observada}$). También se ha determinado el coeficiente de determinación (R^2 de los valores observados y estimados por el algoritmo para el caso de la altura del árbol (H) y el diámetro de corona (CD; *Crown Diameter*).

3.4 RESULTADOS

En primer lugar, es importante señalar que en una fase preliminar se compararon los resultados obtenidos con los umbrales de altura mínima de cuatro y siete metros, determinándose que no había una gran diferencia en la precisión final (*Accuracy Assesment*). Por esta razón se estableció presentar los resultados obtenidos con la altura umbral de siete metros, excluyendo por tanto la detección de pequeñas encinas y sotobosque en general.

Hay que añadir, que los parámetros en común que poseen los algoritmos basados en el CHM, como son suavizado y tamaños de ventana, se mantuvieron fijos para comprobar realmente el funcionamiento de cada algoritmo. En este sentido, la ventana de suavizado se mantuvo en 3x3 píxeles, tal y como se comentó en la sección 3.3.1, mientras que el tamaño de ventana (*Window Size*; *WS*) se fijó en cinco 5x5.



3.4.1 Algoritmo implementado en el software Fusion/LDV

En el caso del software Fusion, se examinó la variación de parámetros como el *Cellsize* (resolución del CHM) y el *Threshold*. Los *Cellsize* utilizados variaron entre 0.25 m y 2.00 m, con saltos de 0.25 m y la altura mínima de 7 metros. En la Fig. 2 se puede comprobar que los valores de las métricas *Recall* y *F-score* se van reduciendo conforme va disminuyendo la resolución del CHM de entrada (*Cellsize*). En efecto, conforme disminuye la resolución del CHM observamos un aumento del error de omisión, es decir, se incrementa significativamente el número de árboles no detectados por el algoritmo. Obviamente este efecto tiende a disminuir el valor del F-score. En definitiva, una pérdida de resolución del CHM en el que se basa el algoritmo produce una notable pérdida de capacidad de detección de árboles por la disminución del número de máximos locales detectados (ápices de árboles). En cierto modo, se podía decir que el algoritmo se vuelve más conservador.

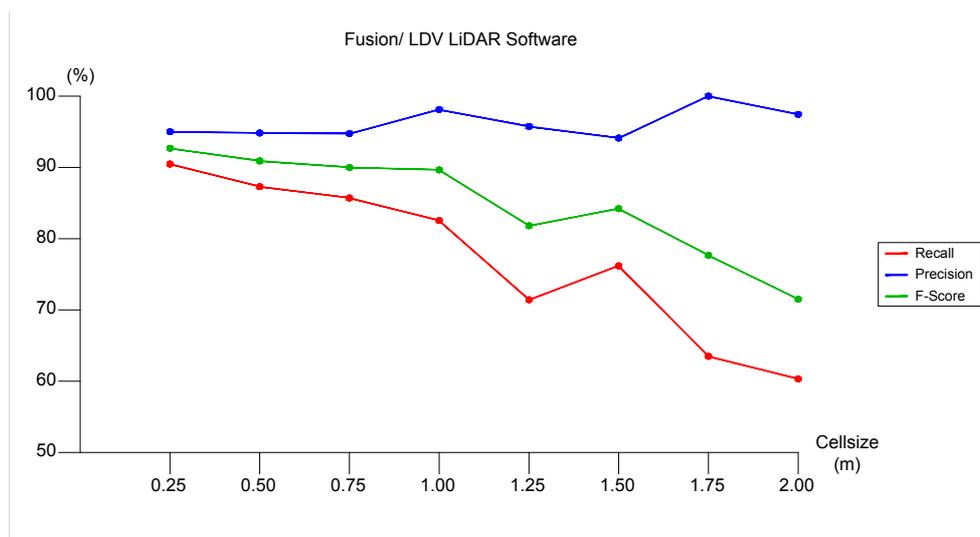


Figura 2. Resultados obtenidos con el algoritmo implementado en el software de Fusion/LDV con altura mínima de 7m y Cellsize entre 0.25 – 2.00 m.

Por otra parte, en la Tabla 1 se presentan los resultados de la estimación de la altura de cada árbol, observándose unos errores sistemáticos muy pequeños, sobre todo en el caso de la mediana de los residuos, con valores inferiores a 1 cm en todos los casos. En el caso de los errores aleatorios, el RMSE ofrece valores inferiores a 30 cm, lo que supone un RMSE relativo inferior al 2.4%. Estos resultados se confirman al analizar los resultados del coeficiente de determinación R^2 , con valores superiores a 0.94, lo que significa un muy buen ajuste entre los datos estimados y observados.



En la Tabla 2 se presentan los resultados de la estimación del diámetro de corona. En este caso los resultados no son tan buenos como los encontrados en la estimación de la altura del árbol, con errores sistemáticos muy variables que tanto implican una sobreestimación (valores positivos) como una subestimación del diámetro de corona. Los errores aleatorios son también elevados, con valores de RMSE que oscilan entre 0.8 y 2 m aproximadamente, lo que supone un error relativo excesivo de hasta el 43%. Los valores negativos de R^2 confirman que no existe relación entre los diámetros de corona estimados y observados.

	Altura (H)					
	Cellsize (m)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R^2
FUSION	0.25	-0.069	-0.006	0.275	2.348	0.942
	0.50	-0.052	-0.002	2.441	2.084	0.955
	0.75	-0.053	-0.004	0.246	2.101	0.954
	1.00	-0.048	-0.003	0.246	2.083	0.952
	1.25	-0.015	-0.002	0.041	0.340	0.999
	1.50	-0.024	-0.002	0.072	0.607	0.996
	1.75	-0.015	-0.001	0.047	0.394	0.998
	2.00	0.000	-0.001	0.078	0.642	0.995

Tablas 1. Errores sistemáticos y aleatorios de la variable estimada "altura del árbol" obtenidos a partir del software Fusion/LDV. Los valores de referencia serían los obtenidos con el Cellsize en 0.25m (el valor que ofreció mejores resultados de F-score).

	Diámetro de la Corona (CD)					
	Cellsize (m)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R^2
FUSION	0.25	-1.860	-1.739	2.083	43.449	-3.339
	0.50	-0.620	-0.559	1.123	23.225	-0.296
	0.75	0.078	0.169	0.874	18.127	0.221
	1.00	0.345	0.148	1.144	23.271	-0.466
	1.25	0.883	0.910	1.188	23.668	-0.710
	1.50	1.089	0.941	1.467	29.344	-1.665
	1.75	1.242	1.158	1.492	28.705	-2.207
	2.00	1.673	1.573	2.002	38.436	-4.560

Tabla 2. Errores sistemáticos y aleatorios de la variable estimada "diámetro de corona" obtenidos a partir del software Fusion/LDV. Los valores de referencia serían los obtenidos con el Cellsize en 0.25m (el valor que ofreció mejores resultados de F-score).



3.4.2 Digital Forest Toolbox (DFT)

A través del conjunto de códigos Matlab, pertenecientes a la librería Digital Forest Toolbox se testearon variaciones de los parámetros del *Cellsize* (resolución del CHM), la función gaussiana del suavizado del CHM y la altura mínima analizada (7 metros). Los *Cellsize* se examinaron con los mismos datos planteados en el apartado 3.4.1 (entre 0.25 m – 2.00 m). Para la función gaussiana del suavizado del CHM se probaron factores de suavizado (desviación estándar) de 0.5, 0.8, 1.5 y 2.0, siempre trabajando sobre ventanas móviles de 3x3 píxeles. En las figuras 3, 4, 5 y 6 se puede observar que el código se comporta similar al software Fusion/LDV en cuanto al parámetro de la resolución del CHM. En efecto, a medida que se va reduciendo la resolución (*Cellsize*), el error de omisión aumenta notablemente, independientemente del aumento del suavizado gaussiano. Por ende, el F-score y el error de comisión van disminuyendo, logrando así que el nivel de corrección de los árboles detectados vaya aumentando a menor resolución del CHM. Si bien es cierto que también se puede observar que a mayor factor de suavizado (filtro gaussiano), menor debe ser la resolución del CHM para que la relación entre el porcentaje de árboles detectados y el nivel de corrección de los árboles sea proporcional.

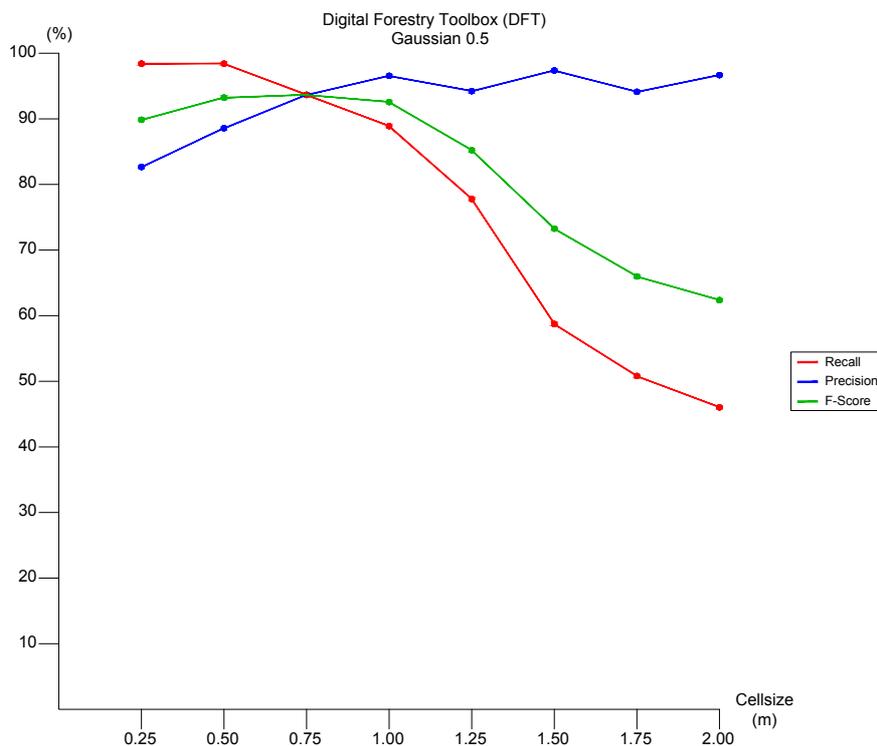


Figura 3. Resultados obtenidos en el conjunto de códigos Matlab (Digital Forestry Toolbox) con altura mínima en 7m, *Cellsize* entre 0.25 – 2.00 m y función gaussiana con factor de suavizado de 0.50.



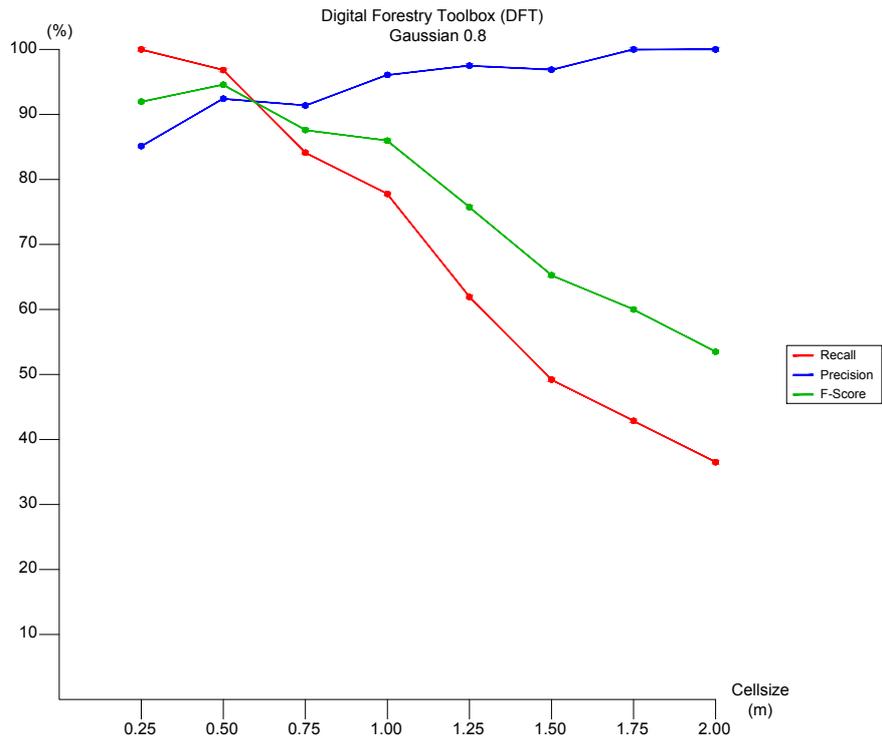


Figura 4. Resultados obtenidos en el conjunto de códigos Matlab (Digital Forestry Toolbox) con altura mínima en 7m, Cellsize entre 0.25 – 2.00 m y función gaussiana con factor de suavizado de 0.80.

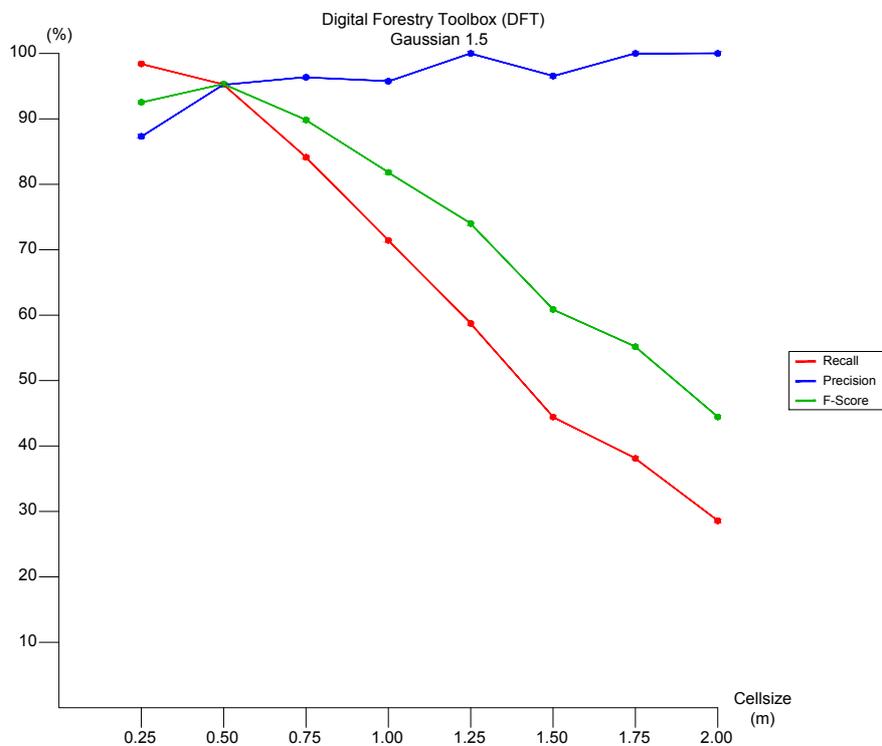


Figura 5. Resultados obtenidos en el conjunto de códigos Matlab (Digital Forestry Toolbox) con altura mínima en 7m, Cellsize entre 0.25 – 2.00 m y función gaussiana con factor de suavizado de 1.50.



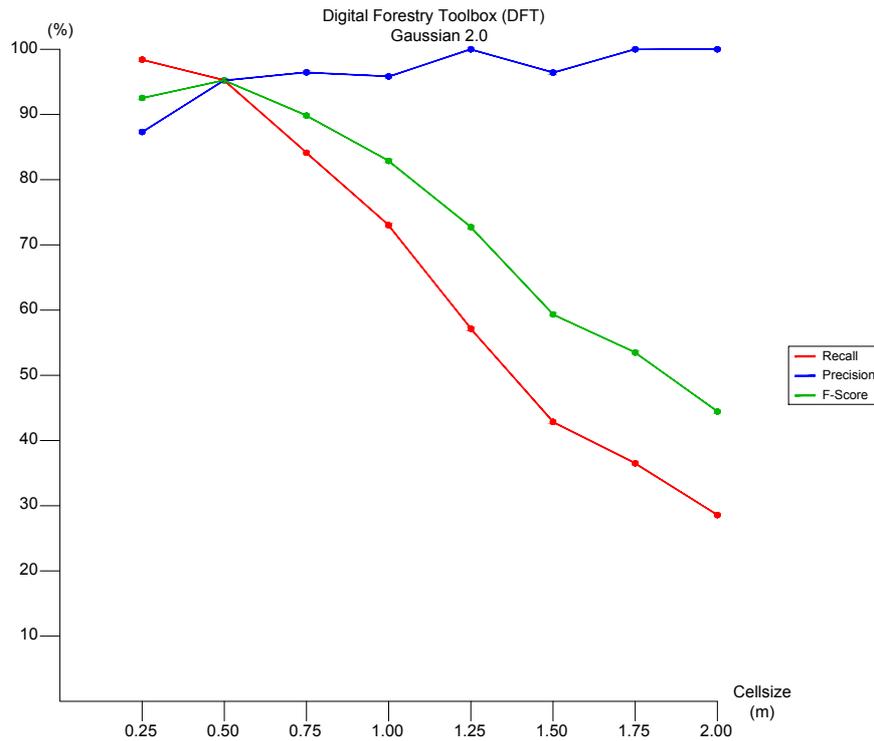


Figura 6. Resultados obtenidos en el conjunto de códigos Matlab (Digital Forestry Toolbox) con altura mínima en 7m, Cellsize entre 0.25 – 2.00 m y función gaussiana con factor de suavizado de 2.00.

En la Tabla 3 se pueden observar los resultados de la estimación de la altura del árbol. En efecto, para todas las variables presentadas en los diversos parámetros resultaron ser errores sistemáticos muy pequeños, no sobrepasando los 5 cm para el promedio y la mediana de los residuos. De igual forma, los errores aleatorios son inferiores a los 47 cm y el RMSE relativo se limita al 4.02%, por lo que el coeficiente de determinación mínimo resultó estar en 0.87.

En la Tabla 4 se presentan los resultados de la estimación del diámetro de corona. Comparando estos resultados con los de la altura del árbol en la Tabla 3, estos presentan una sobreestimación en los errores sistemáticos de hasta 3.80 y 3.60 metros para el error promedio y mediano, respectivamente. Así como también un error aleatorio desde los 0.99 m hasta los 4.65 m, afectando directamente el RMSE relativo de hasta un 85%, por lo que la relación entre los datos estimados y observados es nula debido a los valores negativos presentados.



		Altura (H)					
DIGITAL FORESTRY TOOLBOX (DFT)	Gaussian #	Cellsize (m)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²
		0.5	0.25	-0.170	-0.029	0.466	4.024
0.50			-0.092	-0.028	0.283	2.445	0.950
0.75			-0.086	-0.019	0.294	2.539	0.947
1.00			-0.070	-0.018	0.276	2.360	0.941
1.25			-0.013	-0.013	0.108	0.911	0.991
1.50			0.024	0.005	0.126	1.053	0.988
1.75			0.017	0.022	0.097	0.793	0.992
2.00			-0.039	0.018	0.268	2.202	0.943
0.8		0.25	-0.138	-0.030	0.354	3.061	0.921
		0.50	-0.081	-0.019	0.273	2.349	0.950
		0.75	-0.077	-0.019	0.313	2.663	0.927
		1.00	0.001	-0.002	0.121	1.020	0.989
		1.25	0.028	0.038	0.132	1.106	0.987
		1.50	-0.018	0.014	0.266	2.182	0.939
		1.75	0.055	0.044	0.105	0.859	0.992
		2.00	0.037	0.044	0.104	0.846	0.992
1.5		0.25	-0.138	-0.027	0.357	3.088	0.920
		0.50	-0.080	-0.018	0.278	2.395	0.947
		0.75	-0.059	-0.017	0.300	2.557	0.934
		1.00	0.027	0.029	0.108	0.904	0.991
		1.25	0.044	0.045	0.118	0.986	0.990
		1.50	-0.032	0.021	0.298	2.431	0.924
		1.75	0.054	0.047	0.103	0.833	0.990
		2.00	0.052	0.044	0.101	0.808	0.990
2.0		0.25	0.138	-0.027	0.357	3.088	0.920
		0.50	-0.082	-0.019	0.278	2.396	0.947
		0.75	-0.059	-0.017	0.300	2.557	0.934
		1.00	0.021	0.024	0.113	0.956	0.991
	1.25	0.051	0.046	0.124	1.036	0.990	
	1.50	-0.032	0.044	0.304	2.478	0.924	
	1.75	0.049	0.045	0.097	0.780	0.992	
	2.00	0.047	0.044	0.102	0.818	0.989	

Tabla 3. Errores sistemáticos y aleatorios de la variable estimada “altura de árbol” obtenidos a partir del conjunto de códigos Matlab (DFT). Los valores de referencia serían los obtenidos con el Cellsize de 0.50m y función gaussiana con factor de suavizado de 2.0 m.

		Diámetro de la Corona (CD)					
DIGITAL FORESTRY TOOLBOX (DFT)	Gaussian #	Cellsize (m)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²
		0.5	0.25	-0.182	-0.058	1.099	23.154
0.50			0.031	0.111	0.993	20.933	0.155
0.75			0.323	0.187	1.109	23.581	-0.143
1.00			0.480	0.404	1.151	23.905	-0.331
1.25			0.745	0.435	1.325	27.177	-0.991
1.50			1.540	1.384	2.177	43.069	-5.294
1.75			1.864	1.730	2.762	53.156	-9.864
2.00			2.363	2.081	3.238	61.547	-13.169
0.8		0.25	-0.141	-0.053	1.007	21.306	0.131
		0.50	0.142	0.182	0.997	20.932	0.151
		0.75	0.539	0.409	1.208	25.048	-0.419
		1.00	0.744	0.650	1.413	28.632	-1.709
		1.25	1.367	1.050	2.097	41.760	-4.791
		1.50	2.098	1.648	3.076	60.251	-12.779
		1.75	2.446	1.891	3.816	74.287	-19.138
		2.00	3.046	3.262	3.951	72.778	-31.896
1.5		0.25	-0.091	-0.040	0.967	20.378	0.199
		0.50	0.219	0.217	1.098	23.282	-0.124
		0.75	0.567	0.464	1.245	26.070	-0.604
		1.00	0.963	0.758	1.651	33.009	-2.659
		1.25	1.555	1.245	2.328	46.337	-5.826
		1.50	2.418	2.113	3.418	67.056	-15.974
		1.75	3.002	2.589	4.129	79.499	-21.157
		2.00	3.736	3.151	4.648	85.158	-44.346
2.0		0.25	-0.094	-0.045	0.974	20.526	0.187
		0.50	0.220	0.217	1.090	23.099	-0.106
		0.75	0.563	0.464	1.247	26.120	-0.610
		1.00	0.926	0.649	1.650	33.270	-2.414
	1.25	1.552	1.227	2.551	50.363	-6.783	
	1.50	2.425	2.131	3.407	66.341	-16.265	
	1.75	3.157	2.708	4.351	83.338	-22.725	
	2.00	3.786	3.582	4.639	85.005	-44.184	

Tabla 4. Errores sistemáticos y aleatorios de la variable estimada “diámetro de corona” obtenidos a partir del conjunto de códigos Matlab (DFT). Los valores de referencia serían los obtenidos con el Cellsize de 0.50m y función gaussiana con factor de suavizado de 2.0 m.



3.4.3 Algoritmo Mean Shift 2D y 3D

El algoritmo Mean Shift (tanto 2D como 3D) solo presenta un parámetro de ajuste, el denominado ancho de banda (*Bandwidth*). Los bandwidths testados oscilaron entre 0.50 m y 6.00 m con saltos de 0.50 m. En las Figs. 6 y 7 se puede observar que el MS2D no pudo detectar árboles con un ancho de banda menor de los 1.50 m. Para el MS3D la detección de árboles menor a un ancho de banda de 1 m tampoco fue posible. No obstante, para ambos casos se puede comprobar que el error de omisión va aumentando y el error de comisión va disminuyendo conforme va creciendo el Bandwidth. Acorde se va reduciendo el porcentaje de árboles detectados, el F-score tiende a tener la misma conducta. Sin embargo, para el MS3D, el nivel de corrección de los árboles detectados es mínimo a un menor tamaño del kernel, pero va aumentando según lo hace el ancho de banda hasta llegar a un tamaño medio de bandwidth y vuelve a descender. Se puede comprobar que, para la parcela experimental en estudio, los resultados de este algoritmo no son lo suficientemente viables, tanto en 2D como 3D, por lo que pierde su credibilidad para zonas forestales con características similares.

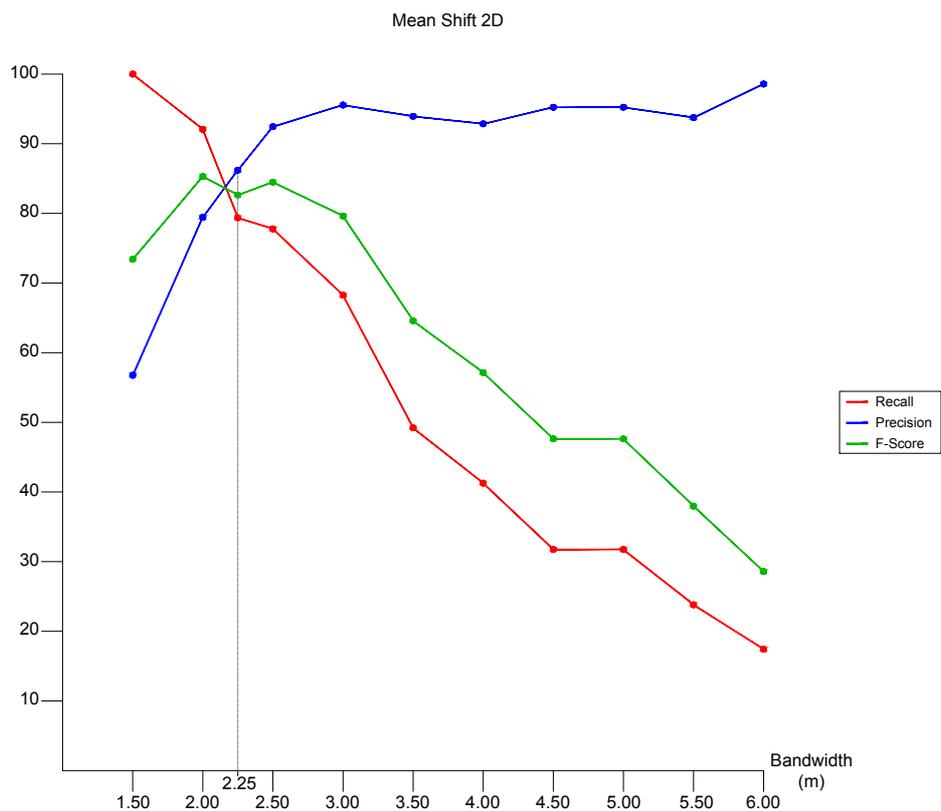


Figura 7. Resultados obtenidos con el algoritmo Mean Shift 2D con altura mínima de 7 m y Bandwidth entre 1.50 m – 6.00 m.



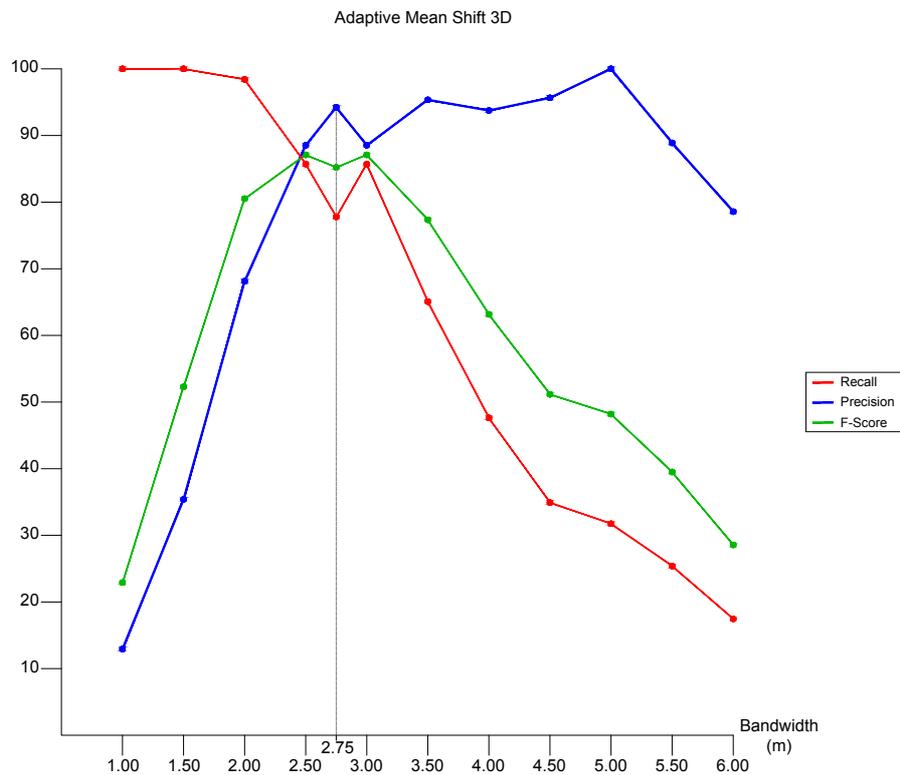


Figura 8. Resultados obtenidos con el algoritmo Mean Shift 3D con altura mínima de 7 m y Bandwidth entre 1.00 m – 6.00 m.

En cuanto a las Tablas 5 y 6, se presentan los resultados MS2D y MS3D de la estimación de la altura de cada árbol y del diámetro de corona, respectivamente. Para la estimación de la altura de cada árbol, se pueden observar que, para los errores sistemáticos, el error promedio no sobrepasa los 70 cm en 3D y los valores del error mediano son inferiores a 1 cm. Para el error aleatorio en ambos casos, conforme aumenta el ancho de banda también lo hace este error, llegando a un máximo de 1 m, también influyendo en el RMSE relativo con un valor de hasta un 9%. No obstante, el coeficiente de determinación (R^2) presenta unos valores superiores a 0.62, sin tomar en cuenta los anchos de banda en 5.50 m y 6.00 m, el cual se pueden verificar que los resultados son inferiores de 0.27 y hasta un valor negativo, no siendo esto un buen ajuste. Por lo que se puede determinar que estos resultados no son los más precisos a la hora de comprobar los ajustes entre los datos estimados y los observados.

En el caso del diámetro de corona los resultados tampoco ofrecen mucha credibilidad, ya que los errores sistemáticos, tanto para el promedio como para el error mediano son inferiores a los 70 cm y a 1 cm. En cuanto al error relativo, se sitúa entre los 14 cm hasta 1.12 m., por lo que el RMSE relativo mínimo es de un 0.50% hasta un 9%, afectando así el coeficiente de



determinación de resultados mayormente negativos. Confirmando así, que no existe relación entre los diámetros de corona estimados y observados.

		Altura (H)					
		Bandwidth (m)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²
MEAN SHIFT 2D		1.50	-0.012	0.002	0.405	3.504	0.896
		2.00	-0.019	0.005	0.325	2.770	0.914
		2.25	-0.006	0.006	0.217	1.844	0.962
		2.50	0.047	0.007	0.144	1.218	0.983
		3.00	0.141	0.008	0.460	3.486	0.815
		3.50	0.189	0.010	0.527	4.367	0.795
		4.00	0.141	0.007	0.507	4.130	0.796
		4.50	0.024	0.006	0.064	0.507	0.995
		5.00	0.407	0.009	0.819	6.694	0.617
		5.50	0.590	0.009	0.993	8.029	0.038
	6.00	0.558	0.009	1.008	8.068	0.273	
MEAN SHIFT 3D		1.00	-0.158	0.002	0.541	4.675	0.816
		1.50	0.015	0.007	0.317	2.743	0.937
		2.00	0.025	0.007	0.440	3.798	0.880
		2.50	0.032	0.007	0.347	2.949	0.912
		2.75	0.041	0.007	0.156	1.314	0.981
		3.00	0.032	0.007	0.347	2.949	0.912
		3.50	0.123	0.009	0.383	3.201	0.877
		4.00	0.370	0.009	0.749	6.237	0.511
		4.50	0.138	0.008	0.390	3.144	0.840
		5.00	0.439	0.008	0.860	7.057	0.615
	5.50	0.263	0.008	0.547	4.358	0.721	
	6.00	0.702	0.014	1.117	9.048	-0.219	

Tabla 5. Errores sistemáticos y aleatorios de la variable estimada “altura de árbol” obtenidos a partir del algoritmo MS2D y MS3D. Los valores de referencia serían los obtenidos con el Bandwidth en 2.50 m del MS3D (el valor que ofreció mejores resultados del F-score).

		Diámetro de la Corona (CD)					
		Bandwidth (m)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²
MEAN SHIFT 2D		1.50	-0.666	-0.610	1.258	26.617	-0.356
		2.00	-0.320	-0.322	1.044	21.727	-0.034
		2.25	-0.210	-0.342	0.927	18.830	0.008
		2.50	-0.116	-0.239	0.965	19.507	-0.130
		3.00	0.276	0.055	1.057	20.818	-0.315
		3.50	0.382	0.379	1.117	21.288	-0.184
		4.00	0.516	0.612	1.230	22.374	-0.797
		4.50	0.760	0.866	1.361	24.144	-1.537
		5.00	1.139	0.875	1.815	33.807	-1.532
		5.50	1.891	1.247	2.355	45.548	-3.299
	6.00	1.954	1.237	2.507	46.851	-2.536	
MEAN SHIFT 3D		1.00	-1.782	-1.793	2.126	44.964	-2.871
		1.50	-0.914	-0.903	1.543	32.649	-1.041
		2.00	-0.272	-0.275	1.323	27.869	-0.501
		2.50	-0.053	0.068	1.142	23.309	-0.206
		2.75	0.058	0.047	1.093	22.092	-0.305
		3.00	-0.053	0.068	1.142	23.309	-0.206
		3.50	0.219	0.298	1.169	22.651	0.461
		4.00	0.568	0.552	1.236	23.023	0.927
		4.50	0.779	0.906	1.340	24.301	-2.291
		5.00	1.197	1.027	1.846	34.648	-1.478
	5.50	1.414	0.994	1.872	34.565	-2.101	
	6.00	2.113	2.210	2.562	49.142	-3.202	

Tabla 6. Errores sistemáticos y aleatorios de la variable estimada “altura de árbol” obtenidos a partir del algoritmo MS2D y MS3D. Los valores de referencia serían los obtenidos con el Bandwidth en 2.50 m del MS3D (el valor que ofreció mejores resultados del F-score).



3.4.4 Algoritmo de Li et al. (2012)

En el caso del algoritmo de Li et al. (2012), se testaron con las modificaciones en los parámetros del espacio mínimo entre árboles (R), el radio máximo de la corona (Speed-Up) y la altura mínima de análisis. El parámetro R se trabajó con números enteros entre 1 y 5 m, y el Speed-Up entre 5 y 10 m, ya que entre 10 y 15 m el algoritmo no presentaba diferencias entre los resultados arrojados. En las Figs. 9 y 10 se puede observar que el error de omisión y de comisión son relativamente bajos, y, por ende, el F-score se mantiene paralelo con los mismos. No obstante, se puede verificar que, a mayor tamaño de espacio mínimo, el error de omisión aumenta, al igual que el F-score. Sin embargo, el error de comisión disminuye. También es posible observar que a mayor radio máximo de corona los datos resultan tener una notable capacidad de detección y de corrección relativamente altas y más compactas, en comparación con el Speed-Up menor. Nótese como los valores de evaluación de precisión (p, r y F-score) resultan muy estables para valores de R de hasta 3 m, lo que resulta muy atractivo para la aplicación del algoritmo en este tipo de parcela analizada con el tipo de bosque Mediterráneo.

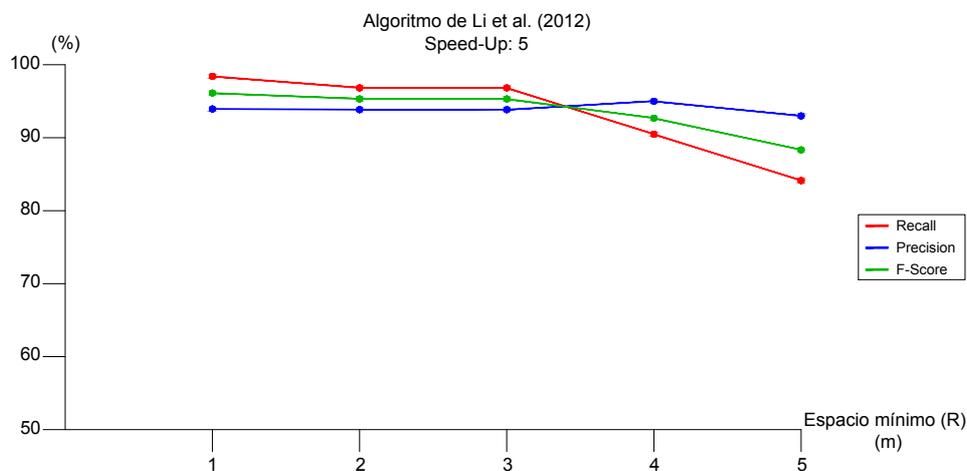


Figura 9. Resultados obtenidos con el algoritmo de Li et al. (2012) con altura mínima de 7m, espacio mínimo entre 1.00 – 5.00 m y Speed-Up entre 5 y 10 m.



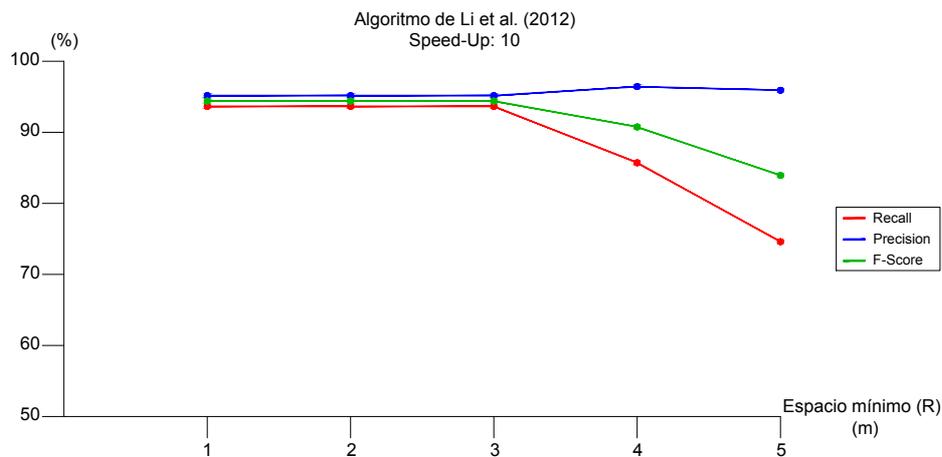


Figura 10. Resultados obtenidos con el algoritmo de Li et al. (2012) con altura mínima de 7m, espacio mínimo entre 1.00 – 5.00 m y Speed-Up entre 5 y 10 m.

Por otra parte, en la Tabla 7 se presentan los resultados de la estimación de la altura de cada árbol, donde se puede observar que los errores sistemáticos son inferiores a 0.5 cm en todos los casos, tanto para el error mediano como para el error promedio. De igual forma, el error aleatorio máximo resultó estar entre 9 y 60 cm aproximadamente con un porcentaje de RMSE relativo de máximo de un 5.36%. El coeficiente de determinación entre los datos estimados y los observados resultó dar valores superiores a 0.70, lo que apunta a que el ajuste de los datos estimados por el algoritmo a los datos observados es bueno.

En cuanto al diámetro de corona, en la Tabla 8, los resultados no son tan efectivos como los de la estimación de la altura, ya que los errores sistemáticos varían, presentando un error promedio máximo de 3.17 m, un error mediano de 2.82 m y un mínimo de 80 cm para ambos. Los errores aleatorios son mayores que los presentados en la Tabla 7, oscilando entre 1.75 y 4.42 m, afectando así el RMSE relativo de hasta un 87%, por lo que la relación entre el ajuste de los datos estimados y observados es prácticamente nula, ya que todos los valores resultan ser negativos.



		Altura (H)					
	Speed-Up (m)	R (m)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²
LI ET AL. (2012)	5	1	-0.104	0.005	0.378	3.262	0.911
		2	-0.126	0.004	0.458	3.934	0.858
		3	-0.126	0.004	0.458	3.934	0.858
		4	-0.115	0.005	0.565	4.844	0.758
		5	-0.163	0.005	0.629	5.360	0.688
	10	1	-0.087	0.005	0.389	3.337	0.898
		2	-0.087	0.005	0.389	3.337	0.898
		3	-0.087	0.005	0.389	3.337	0.898
		4	-0.006	0.005	0.100	0.855	0.992
		5	0.000	0.005	0.092	0.778	0.993

Tabla 7. Errores sistemáticos y aleatorios de la variable estimada "altura de árbol" obtenidos del algoritmo de Li et al. (2012) en el software libre RStudio. Los valores de referencia serían los obtenidos con el espacio mínimo entre árboles (R) en 1.00 m y radio máximo de corona (Speed-Up) en 5 m.

		Diámetro de la Corona (CD)					
	Speed-Up (m)	R (m)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²
LI ET AL. (2012)	5	1	0.809	0.712	1.751	36.937	-1.609
		2	0.844	0.829	1.811	38.064	-1.784
		3	0.862	0.829	1.805	37.946	-1.766
		4	1.001	0.930	2.059	42.876	-3.316
		5	1.221	1.611	2.370	48.218	-5.492
	10	1	1.988	1.194	3.439	71.524	-9.482
		2	2.306	1.744	3.734	77.649	-11.354
		3	2.333	1.744	3.763	78.248	-11.545
		4	2.549	1.604	3.911	80.130	-15.855
		5	3.168	2.822	4.419	87.253	-25.070

Tabla 8. Errores sistemáticos y aleatorios de la variable estimada "altura de árbol" obtenidos del algoritmo de Li et al. (2012) en el software libre RStudio. Los valores de referencia serían los obtenidos con el espacio mínimo entre árboles (R) en 1.00 m y radio máximo de corona (Speed-Up) en 5 m.



3.4.5 Algoritmo de Dalponte & Coomes (2016)

Para el algoritmo de Dalponte & Coomes (2016), en la sección 3.3.5, se especificó que este algoritmo trabaja bajo las modificaciones de tres parámetros principales que resultan ser: i) el diámetro de la corona máxima, ii) el porcentaje de la diferencia de altura (*Threshold Seed*) y iii) la altura mínima. Para el diámetro de la corona máxima se trabajaron con píxeles entre 5 y 30, con saltos de 5 píxeles. Para el porcentaje de la diferencia de la altura se utilizaron los valores intermedios entre 0 y 1 (0 - 100%) con saltos de 0.10. En las Figs.11-19 se puede comprobar que tanto los valores del Recall, Precision y F-Score se mantienen paralelos para los diversos *Threshold Seed*, por lo que se podría decir que este parámetro no afecta directamente a los resultados de la parcela analizada. Es importante destacar como los cambios de píxeles del diámetro de la corona máxima provocan que el error de omisión aumente y el error de comisión disminuya, por lo que el F-score tiende también a disminuir un poco. También se puede observar que cuando se alcanza un cierto valor de máximo de corona, los valores de las métricas se mantienen igual. En este sentido, los resultados ofrecidos por el algoritmo resultan poco sensibles a la variación del máximo diámetro de corona.

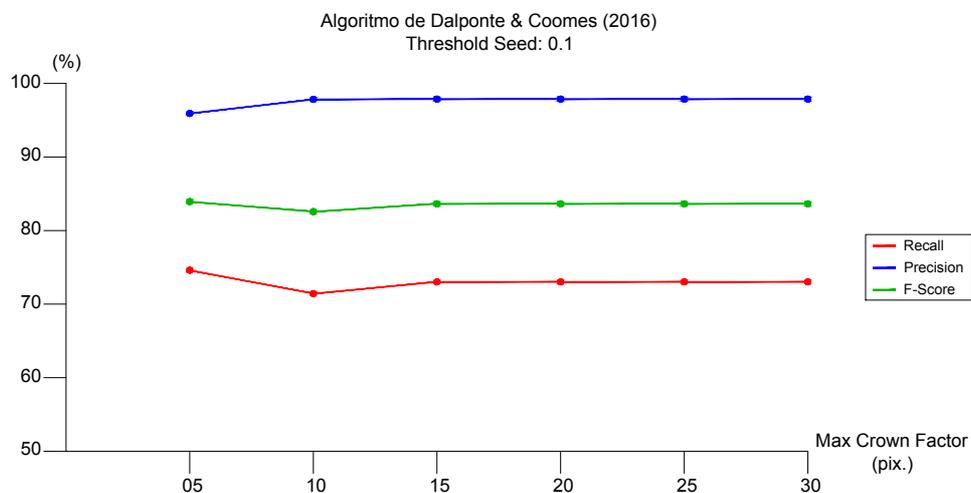


Figura 11. Resultados obtenidos con el algoritmo de Dalponte & Coomes (2016) con altura mínima de 7m, Factor de la Corona Máxima entre 5 – 30 píxeles y el porcentaje de la diferencia de la altura en 10%.



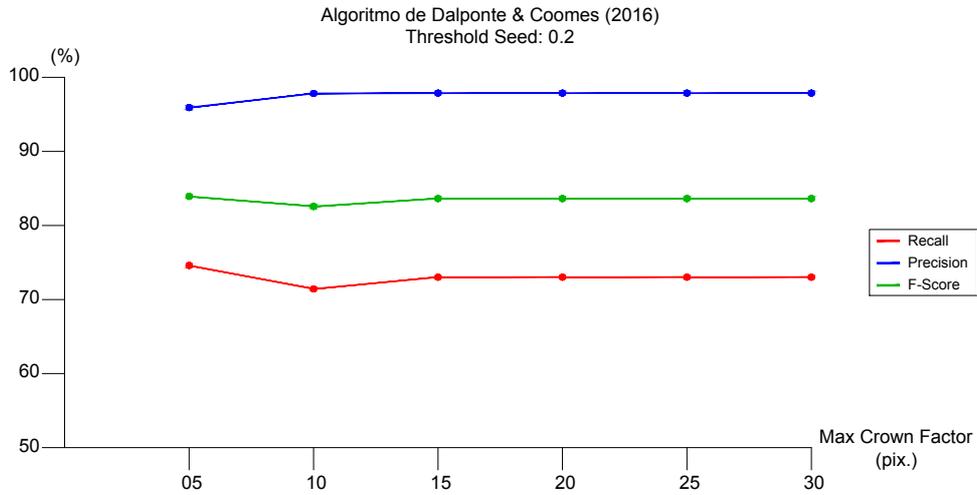


Figura 12. Resultados obtenidos con el algoritmo de Dalponte & Coomes (2016) con altura mínima de 7m, Factor de la Corona Máximo entre 5 – 30 píxeles y el porcentaje de la diferencia de la altura en 20%.

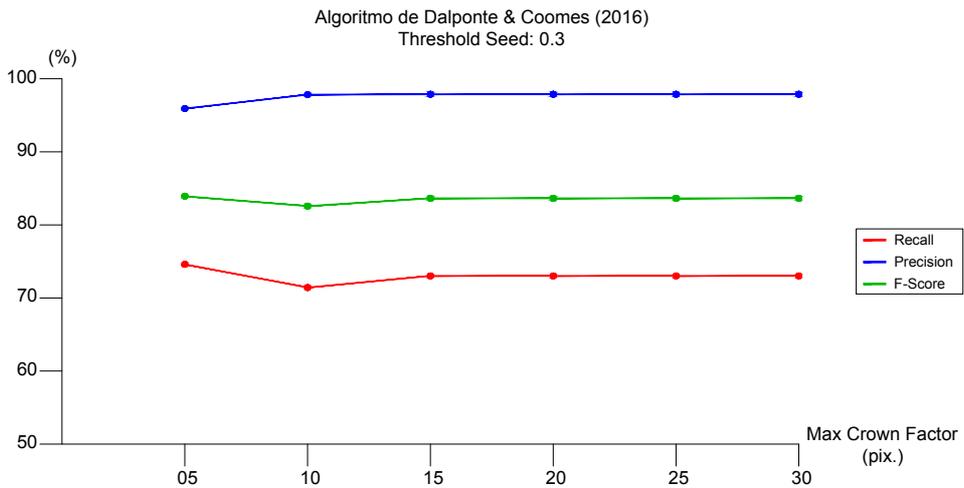


Figura 13. Resultados obtenidos con el algoritmo de Dalponte & Coomes (2016) con altura mínima de 7m, Factor de la Corona Máximo entre 5 – 30 píxeles y el porcentaje de la diferencia de la altura en 30%.



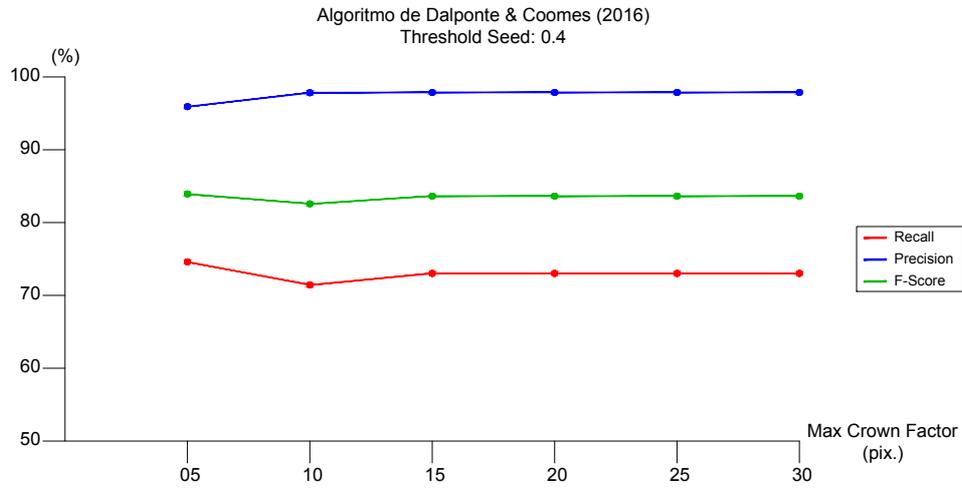


Figura 14. Resultados obtenidos con el algoritmo de Dalponte & Coomes (2016) con altura mínima de 7m, Factor de la Corona Máximo entre 5 – 30 píxeles y el porcentaje de la diferencia de la altura en 40%.

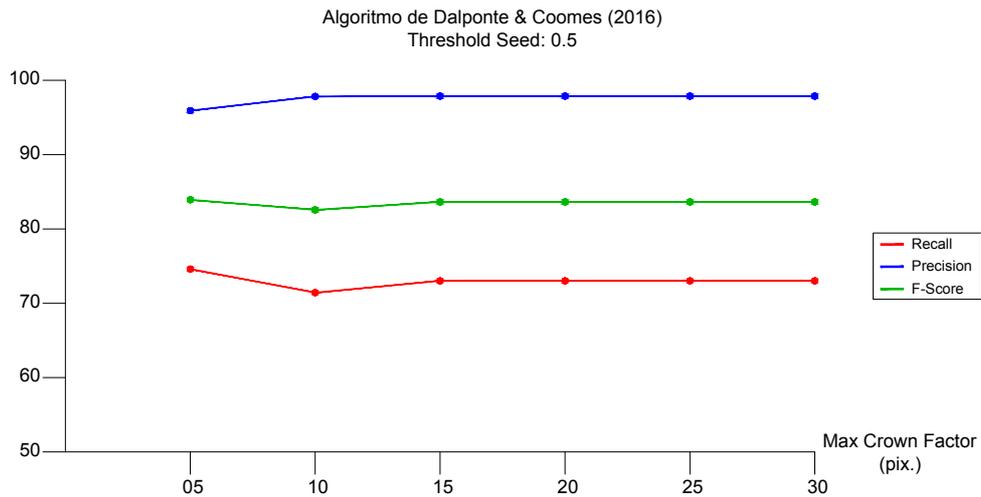


Figura 15. Resultados obtenidos con el algoritmo de Dalponte & Coomes (2016) con altura mínima de 7m, Factor de la Corona Máximo entre 5 – 30 píxeles y el porcentaje de la diferencia de la altura en 50%.



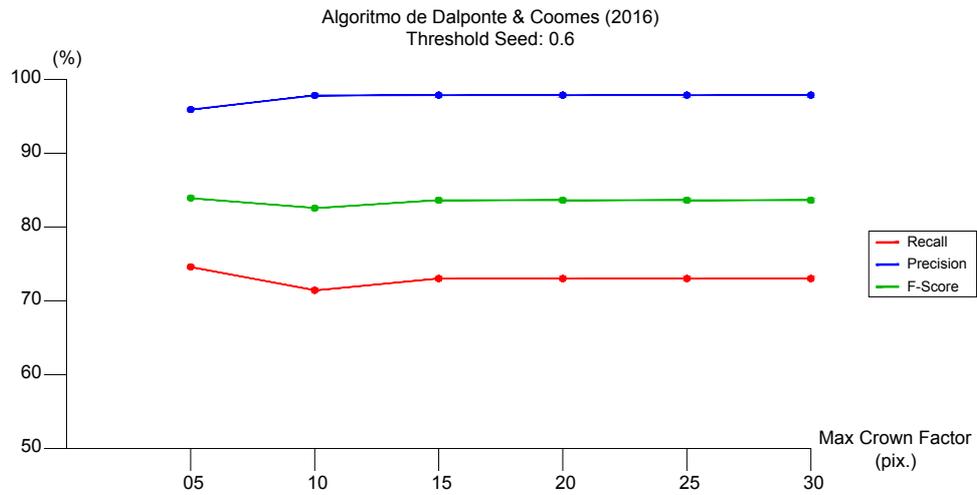


Figura 16. Resultados obtenidos con el algoritmo de Dalponte & Coomes (2016) con altura mínima de 7m, Factor de la Corona Máximo entre 5 – 30 píxeles y el porcentaje de la diferencia de la altura en 60%.

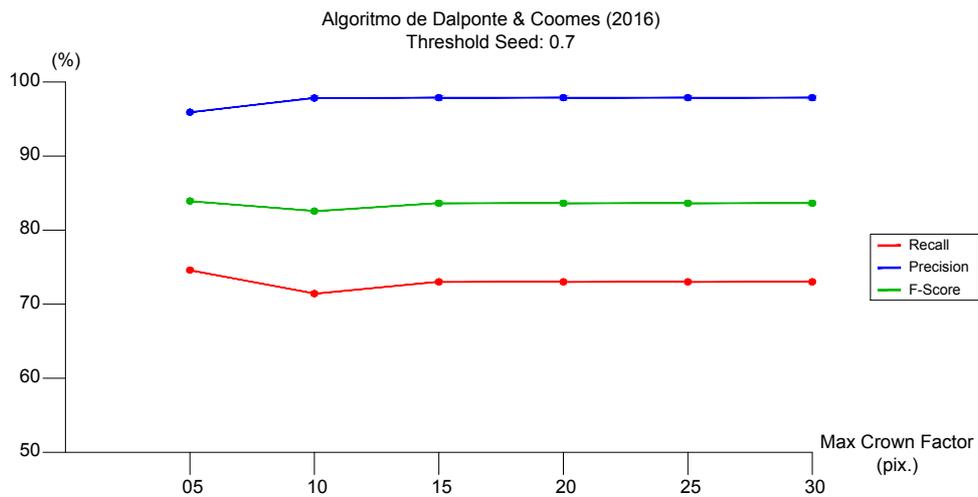


Figura 17. Resultados obtenidos con el algoritmo de Dalponte & Coomes (2016) con altura mínima de 7m, Factor de la Corona Máximo entre 5 – 30 píxeles y el porcentaje de la diferencia de la altura en 70%.



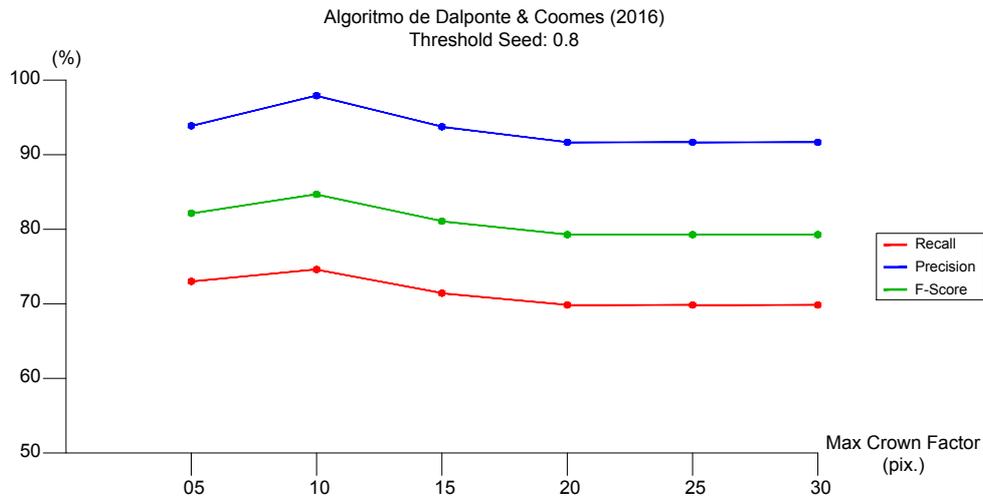


Figura 18. Resultados obtenidos con el algoritmo de Dalponte & Coomes (2016) con altura mínima de 7m, Factor de la Corona Máximo entre 5 – 30 píxeles y el porcentaje de la diferencia de la altura en 80%.

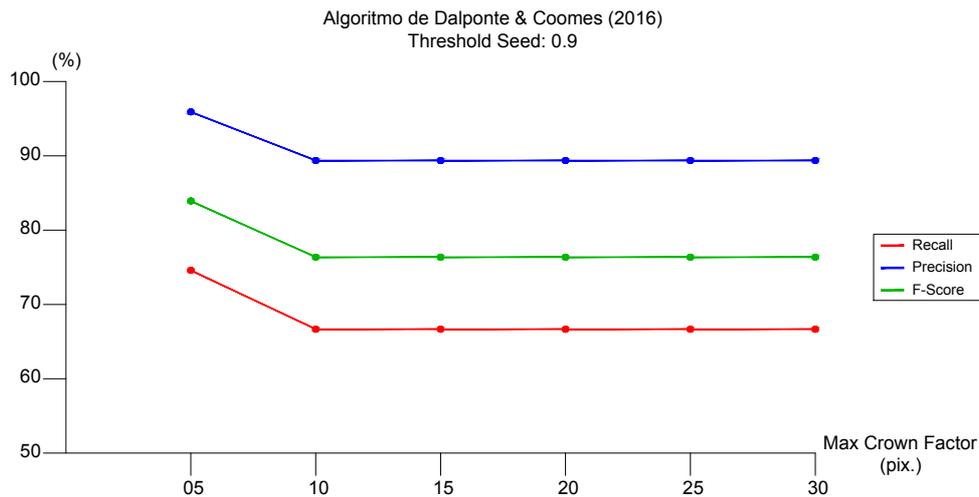


Figura 19. Resultados obtenidos con el algoritmo de Dalponte & Coomes (2016) con altura mínima de 7m, Factor de la Corona Máximo entre 5 – 30 píxeles y el porcentaje de la diferencia de la altura en 90%.

En la Tabla 9 se presentan los resultados de la estimación de la altura de cada árbol. Se pueden observar que los errores sistemáticos, tanto para el error promedio como para el error mediano es de valores inferiores a 1 cm. En cuanto al error aleatorio, el máximo presentado es de 55 cm, lo que produce un error RMSE relativo máximo de 4.66%. El coeficiente de determinación es superior a 0.99, por lo que se puede deducir que los datos estimados y los datos observados concuerdan.



Ya en la Tabla 10 se presentan los resultados de la estimación del diámetro de corona, cuyos resultados varían significativamente. Para los errores sistemáticos se pueden observar datos sobreestimados y subestimados, valores negativos y positivos, respectivamente, que pueden ir desde 1 m positivo, hasta 1 m negativo. En cuanto a los errores aleatorios, estos pueden llegar a estar en 2.20 m aproximadamente, el cual afecta directamente el porcentaje del RMSE relativo, llevándolo a un máximo de 44.50%. Esto último produce que los resultados del coeficiente de determinación sean únicamente valores negativos, confirmando así que la relación entre los diámetros de corona estimados y los observados no existe.

	Thr. Seed (%)	CMF (pix)	Altura (H)				
			Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²
DALPONTE & COOMES (2016)	0.1	5	0.000	0.005	0.092	0.778	0.993
		10	-0.005	0.005	0.103	0.875	0.992
		15	-0.008	0.005	0.105	0.891	0.991
		20	-0.008	0.005	0.105	0.891	0.991
		25	-0.008	0.005	0.105	0.891	0.991
		30	-0.008	0.005	0.105	0.891	0.991
	0.2	5	0.000	0.005	0.092	0.778	0.993
		10	-0.005	0.005	0.103	0.875	0.992
		15	-0.008	0.005	0.105	0.891	0.991
		20	-0.008	0.005	0.105	0.891	0.991
		25	-0.008	0.005	0.105	0.891	0.991
		30	-0.008	0.005	0.105	0.891	0.991
	0.3	5	0.000	0.005	0.092	0.778	0.993
		10	-0.005	0.005	0.103	0.875	0.992
		15	-0.008	0.005	0.105	0.891	0.991
		20	-0.008	0.005	0.105	0.891	0.991
		25	-0.008	0.005	0.105	0.891	0.991
		30	-0.008	0.005	0.105	0.891	0.991
	0.4	5	0.000	0.005	0.092	0.778	0.993
		10	-0.005	0.005	0.103	0.875	0.992
		15	-0.008	0.005	0.105	0.891	0.991
		20	-0.008	0.005	0.105	0.891	0.991
		25	-0.008	0.005	0.105	0.891	0.991
		30	-0.008	0.005	0.105	0.891	0.991
	0.5	5	0.000	0.005	0.092	0.778	0.993
		10	-0.005	0.005	0.103	0.875	0.992
		15	-0.008	0.005	0.105	0.891	0.991
		20	-0.008	0.005	0.105	0.891	0.991
		25	-0.008	0.005	0.105	0.891	0.991
		30	-0.008	0.005	0.105	0.891	0.991
	0.6	5	0.000	0.005	0.092	0.778	0.993
		10	-0.005	0.005	0.103	0.875	0.992
		15	-0.008	0.005	0.105	0.891	0.991
		20	-0.008	0.005	0.105	0.891	0.991
		25	-0.008	0.005	0.105	0.891	0.991
		30	-0.008	0.005	0.105	0.891	0.991
	0.7	5	0.000	0.005	0.092	0.778	0.993
		10	-0.005	0.005	0.103	0.875	0.992
		15	-0.008	0.005	0.105	0.891	0.991
		20	-0.008	0.005	0.105	0.891	0.991
		25	-0.008	0.005	0.105	0.891	0.991
		30	-0.008	0.005	0.105	0.891	0.991
	0.8	5	0.000	0.005	0.093	0.785	0.993
		10	-0.009	0.005	0.105	0.889	0.991
		15	-0.001	0.005	0.091	0.768	0.993
		20	-0.044	0.005	0.299	2.507	0.927
		25	-0.044	0.005	0.299	2.507	0.927
		30	-0.044	0.005	0.299	2.507	0.927
0.9	5	-0.009	0.005	0.112	0.941	0.990	
	10	-0.176	0.005	0.565	4.710	0.731	
	15	-0.173	0.005	0.559	4.660	0.737	
	20	-0.173	0.005	0.559	4.660	0.737	
	25	-0.173	0.005	0.559	4.660	0.737	
	30	-0.173	0.005	0.559	4.660	0.737	

Tabla 9. Errores sistemáticos y aleatorios de la variable estimada altura de árbol obtenidos a partir del algoritmo Dalponte & Coomes (2016). Los valores de referencia serían los obtenidos con el Crown Max. Factor en 10 píxeles y un Threshold Seed de 80% (el valor que ofreció mejores resultados de F-Score).



	Thr. Seed (%)	CMF (pix)	Diámetro de la Corona (CD)				
			Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²
DALPONTE & COOMES (2016)	0.1	5	-0.416	-0.503	0.953	18.822	-0.213
		10	0.995	1.040	1.543	30.598	-1.973
		15	1.031	1.064	1.550	30.706	-2.061
		20	1.031	1.064	1.550	30.706	-2.061
		25	1.031	1.064	1.550	30.706	-2.061
		30	1.031	1.064	1.550	30.706	-2.061
	0.2	5	-0.416	-0.503	0.953	18.822	-0.213
		10	0.995	1.040	1.543	30.598	-1.973
		15	1.031	1.064	1.550	30.706	-2.061
		20	1.031	1.064	1.550	30.706	-2.061
		25	1.031	1.064	1.550	30.706	-2.061
		30	1.031	1.064	1.550	30.706	-2.061
	0.3	5	-0.416	-0.503	0.953	18.822	-0.213
		10	0.995	1.040	1.543	30.598	-1.973
		15	1.031	1.064	1.550	30.706	-2.061
		20	1.031	1.064	1.550	30.706	-2.061
		25	1.031	1.064	1.550	30.706	-2.061
		30	1.031	1.064	1.550	30.706	-2.061
	0.4	5	-0.416	-0.503	0.953	18.822	-0.213
		10	0.995	1.040	1.543	30.598	-1.973
		15	1.031	1.064	1.550	30.706	-2.061
		20	1.031	1.064	1.550	30.706	-2.061
		25	1.031	1.064	1.550	30.706	-2.061
		30	1.031	1.064	1.550	30.706	-2.061
	0.5	5	-0.416	-0.503	0.953	18.822	-0.213
		10	0.995	1.040	1.543	30.598	-1.973
		15	1.031	1.064	1.550	30.706	-2.061
		20	1.031	1.064	1.550	30.706	-2.061
		25	1.031	1.064	1.550	30.706	-2.061
		30	1.031	1.064	1.550	30.706	-2.061
	0.6	5	-0.418	-0.503	0.956	18.879	-0.221
		10	1.003	1.089	1.536	30.457	-1.946
		15	1.036	1.021	1.550	30.703	-2.061
		20	1.036	1.021	1.550	30.703	-2.061
		25	1.036	1.021	1.550	30.703	-2.061
		30	1.036	1.021	1.550	30.703	-2.061
	0.7	5	-0.440	-0.535	0.970	19.144	-0.255
		10	0.868	0.733	1.469	29.124	-1.693
		15	0.960	0.729	1.605	31.791	-2.281
		20	0.960	0.729	1.605	31.791	-2.281
		25	0.960	0.729	1.605	31.791	-2.281
		30	0.960	0.729	1.605	31.791	-2.281
	0.8	5	-0.693	-0.847	1.101	21.654	-0.629
		10	0.227	-0.251	1.426	28.295	-1.629
		15	0.328	-0.310	1.802	35.574	-3.121
		20	0.375	-0.281	1.859	36.525	-3.409
		25	0.390	-0.281	1.892	37.176	-3.567
		30	0.390	-0.281	1.892	37.176	-3.567
	0.9	5	-1.491	-1.646	1.797	35.474	-3.337
		10	-0.921	-1.421	1.918	38.106	-3.143
		15	-0.708	-1.417	2.200	43.720	-4.455
		20	-0.687	-1.417	2.241	44.524	-4.657
		25	-0.687	-1.417	2.241	44.524	-4.657
		30	-0.687	-1.417	2.241	44.524	-4.657

Tabla 10. Errores sistemáticos y aleatorios de la variable estimada altura de árbol obtenidos a partir del algoritmo Dalponte & Coomes (2016). Los valores de referencia serían los obtenidos con el Crown Max. Factor en 10 píxeles y un Threshold Seed de 80% (el valor que ofreció mejores resultados de F-Score).



3.4.6 Algoritmo de Silva et al. (2016)

En el caso del algoritmo de Silva et al. (2016), se testaron parámetros tales como el valor máximo del diámetro, o *Max Crown Factor*, con valores entre 0 y 1 con saltos de 10 décimas (al ser representado en porcentaje), la exclusión (*Exclusion*), valorado de igual forma que el anterior, y la altura mínima. En las Figs. 20-28 se puede comprobar que los resultados de este algoritmo se comportan de manera similar a los ofrecidos por el algoritmo de Dalponte & Coomes (2016), ya que el porcentaje de árboles correctamente detectados es de un 74%, con un nivel de corrección en la identificación de árboles de casi un 95%, por lo que el F-score resulta estar entre ambos porcentajes. En general, el error de omisión se disminuye ligeramente a medida que el porcentaje de tamaño del factor máximo de la corona aumenta, aunque la estabilidad del error de omisión frente a la variación de este factor es muy elevada. Un comportamiento similar sigue la métrica de precisión, donde se aprecia como el error de comisión disminuye a la misma vez que el *recall* aumenta. Lo que se puede determinar es que, luego de ingresar cierto porcentaje del factor de la corona máxima, la detección de árboles y el nivel de corrección de los mismos no sufren cambios algunos y se mantienen homogéneos. Tampoco se observa una incidencia notable en relación con la variación del parámetro de exclusión.

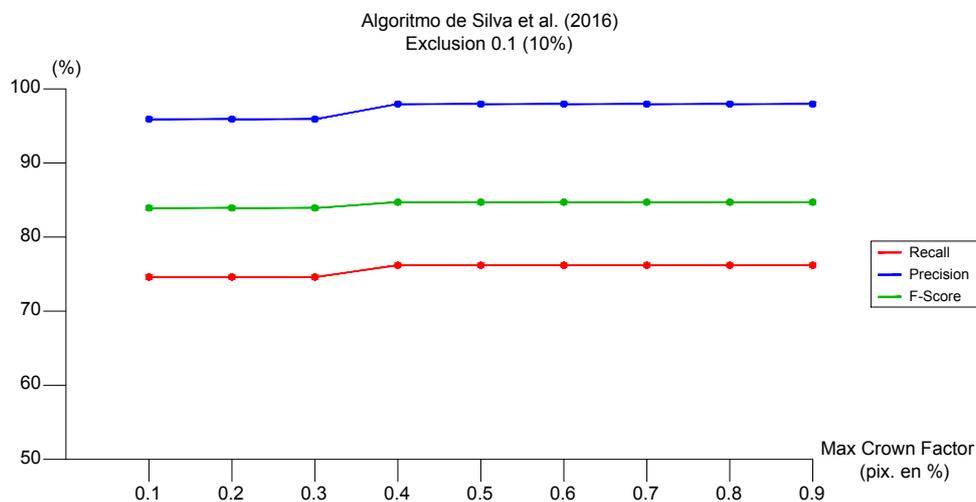


Figura 20. Resultados obtenidos con el algoritmo de Silva et al. (2016) con altura mínima de 7m, Factor de la Corona Máxima de un 10% del tamaño de los píxeles y el porcentaje de la exclusión en 10%.



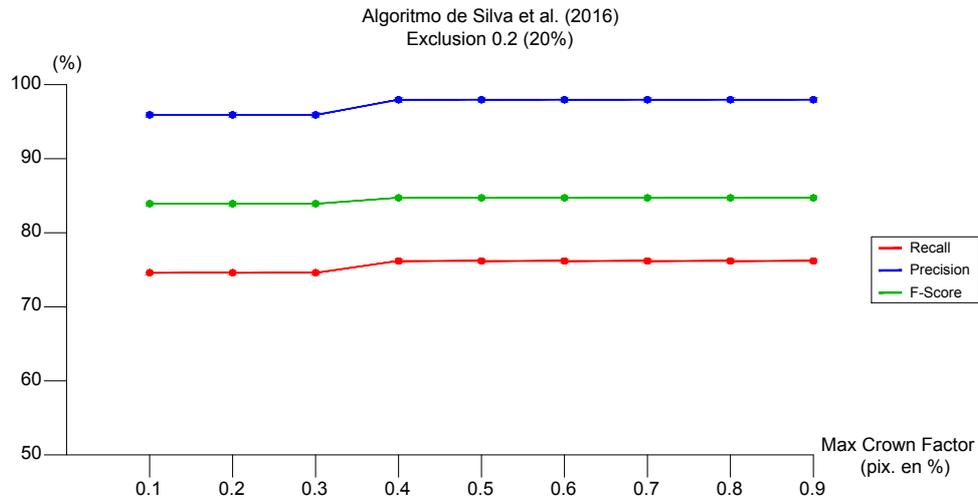


Figura 21. Resultados obtenidos con el algoritmo de Silva et al. (2016) con altura mínima de 7m, Factor de la Corona Máxima de un 20% del tamaño de los píxeles y el porcentaje de la exclusión en 20%.

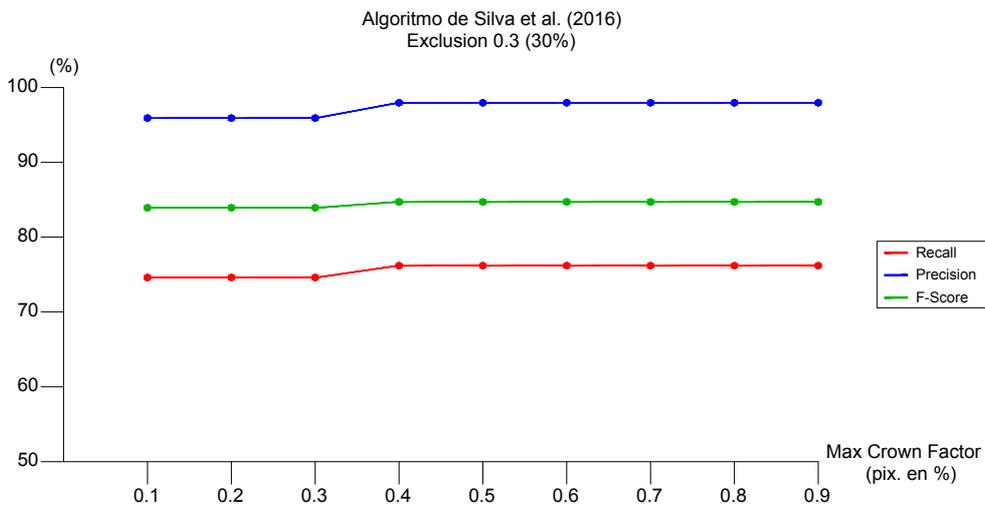


Figura 22. Resultados obtenidos con el algoritmo de Silva et al. (2016) con altura mínima de 7m, Factor de la Corona Máxima de un 30% del tamaño de los píxeles y el porcentaje de la exclusión en 30%.



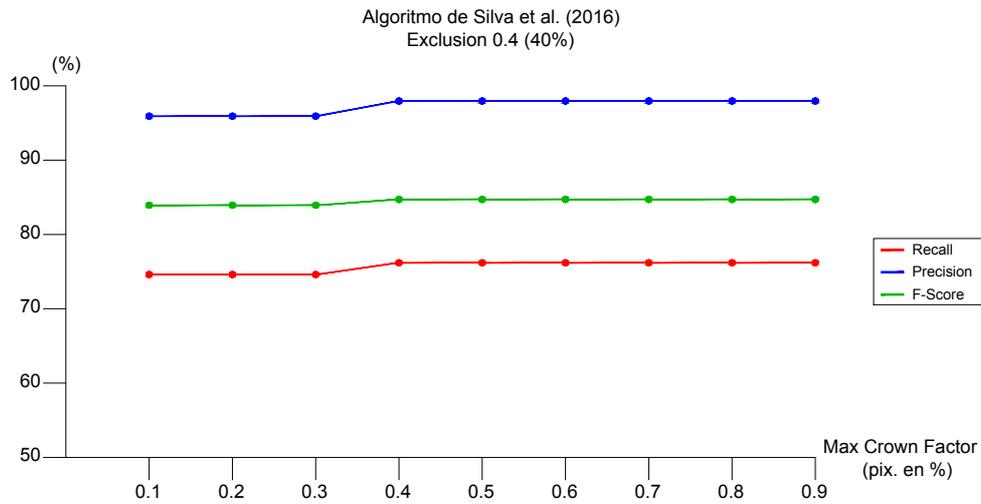


Figura 23. Resultados obtenidos con el algoritmo de Silva et al. (2016) con altura mínima de 7m, Factor de la Corona Máxima de un 40% del tamaño de los píxeles y el porcentaje de la exclusión en 40%.

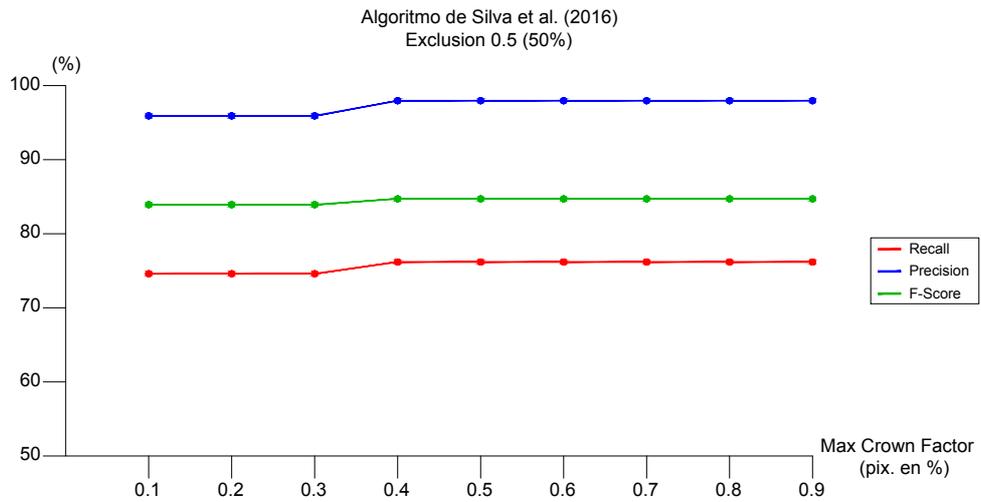


Figura 24. Resultados obtenidos con el algoritmo de Silva et al. (2016) con altura mínima de 7m, Factor de la Corona Máxima de un 50% del tamaño de los píxeles y el porcentaje de la exclusión en 50%.



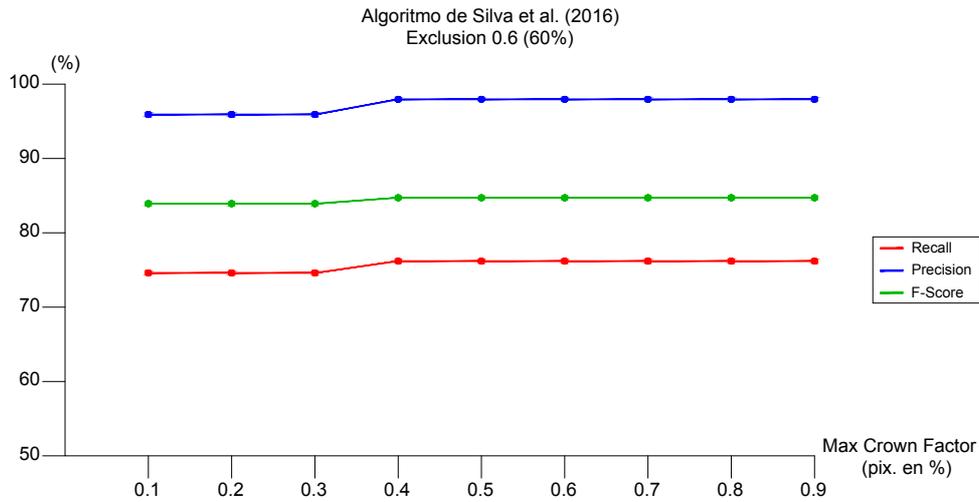


Figura 25. Resultados obtenidos con el algoritmo de Silva et al. (2016) con altura mínima de 7m, Factor de la Corona Máxima de un 60% del tamaño de los píxeles y el porcentaje de la exclusión en 60%.

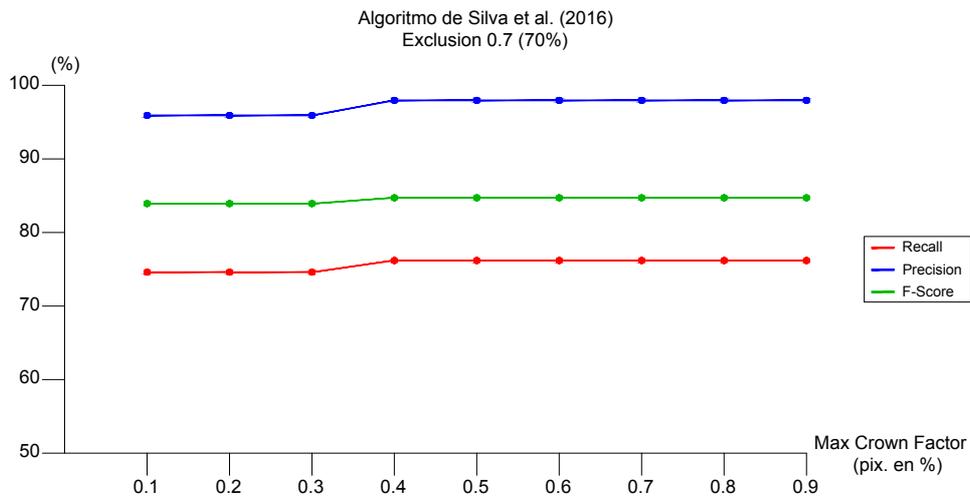


Figura 26. Resultados obtenidos con el algoritmo de Silva et al. (2016) con altura mínima de 7m, Factor de la Corona Máxima de un 70% del tamaño de los píxeles y el porcentaje de la exclusión en 70%.



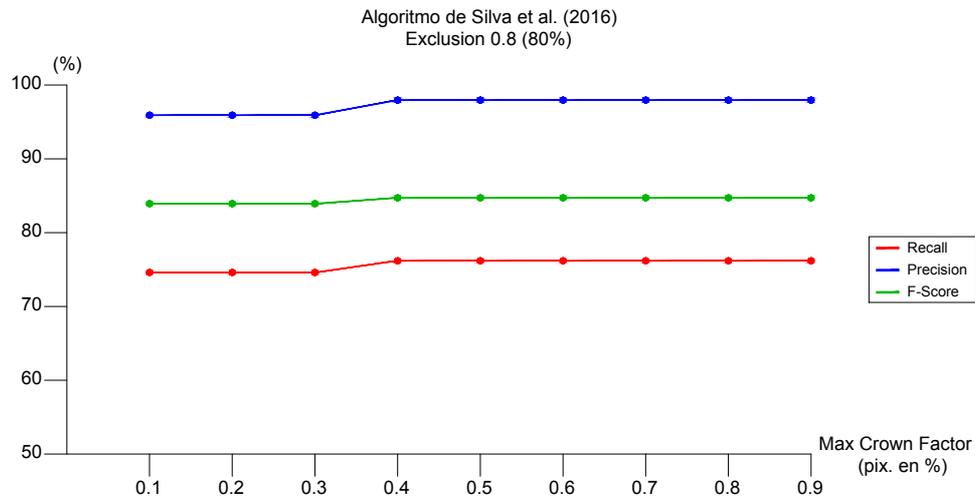


Figura 27. Resultados obtenidos con el algoritmo de Silva et al. (2016) con altura mínima de 7m, Factor de la Corona Máxima de un 80% del tamaño de los píxeles y el porcentaje de la exclusión en 80%.

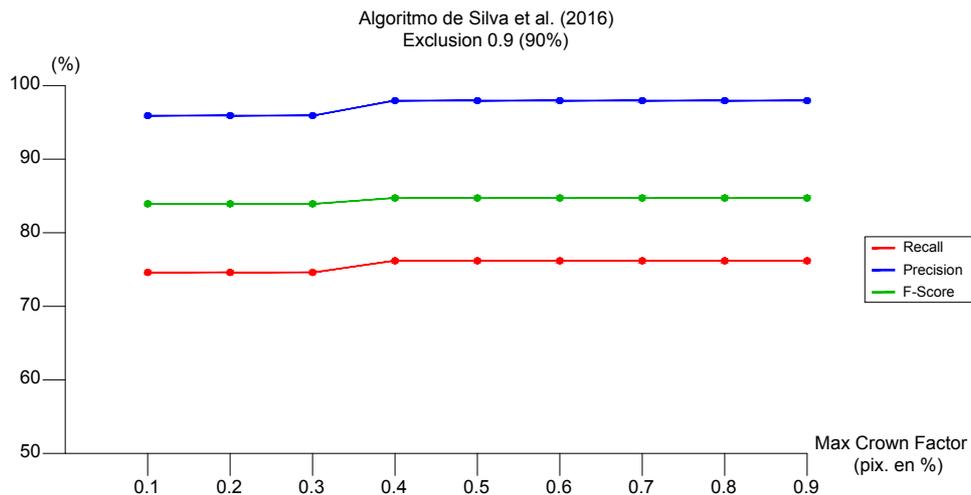


Figura 28. Resultados obtenidos con el algoritmo de Silva et al. (2016) con altura mínima de 7m, Factor de la Corona Máxima de un 90% del tamaño de los píxeles y el porcentaje de la exclusión en 90%.

En la Tabla 11 se presentan los resultados de la estimación de la altura de cada árbol, observándose errores sistemáticos muy inferiores a 1 cm (en valor absoluto) para el caso de los errores medio y mediano. En cuanto al error aleatorio, RMSE, los valores son inferiores a 10 cm, por lo que el RMSE relativo no supera el 0.85%, siendo estos buenos resultados notables en cuanto al coeficiente de determinación, el cual se mantiene en 0.99. Esto confirma que el ajuste entre los datos estimados y los observados son efectivos para este algoritmo, al menos para los



árboles que el algoritmo es capaz de detectar. Es necesario subrayar que estos resultados vienen dados por el bajo error de comisión del algoritmo, aunque hay un número importante de árboles que no son detectados (en torno al 26%).

La Tabla 12 muestra los resultados de la estimación del diámetro de la corona. En este caso los resultados no son adecuados como los que se observan en la estimación de la altura del árbol. Esto se debe a que los errores sistemáticos son elevados y muy variables con alternancia de valores positivos y negativos para el caso del error promedio y mediano. Los errores aleatorios son también excesivos, oscilando entre los 99 cm y los casi 3 m, resultando un RMSE relativo entre 19-59%. La relación entre los diámetros de corona estimados y observados es nula, con valores del R^2 negativos.

	Exclusión (%)	CMF (% pix.)	Altura (H)				
			Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R^2
SILVA ET AL. (2016)	0.1	0.10	0.000	0.005	0.092	0.778	0.993
		0.20	0.000	0.005	0.092	0.778	0.993
		0.30	-0.001	0.005	0.093	0.781	0.993
		0.40	-0.006	0.005	0.100	0.846	0.992
		0.50	-0.006	0.005	0.100	0.846	0.992
		0.60	-0.006	0.005	0.100	0.846	0.992
		0.70	-0.006	0.005	0.100	0.846	0.992
		0.80	-0.006	0.005	0.100	0.846	0.992
		0.90	-0.006	0.005	0.100	0.846	0.992
	0.2	0.10	0.000	0.005	0.092	0.778	0.993
		0.20	0.000	0.005	0.092	0.778	0.993
		0.30	-0.001	0.005	0.093	0.781	0.993
		0.40	-0.006	0.005	0.100	0.846	0.992
		0.50	-0.006	0.005	0.100	0.846	0.992
		0.60	-0.006	0.005	0.100	0.846	0.992
		0.70	-0.006	0.005	0.100	0.846	0.992
		0.80	-0.006	0.005	0.100	0.846	0.992
		0.90	-0.006	0.005	0.100	0.846	0.992
	0.3	0.10	0.000	0.005	0.092	0.778	0.993
		0.20	0.000	0.005	0.092	0.778	0.993
		0.30	-0.001	0.005	0.093	0.781	0.993
		0.40	-0.006	0.005	0.100	0.846	0.992
		0.50	-0.006	0.005	0.100	0.846	0.992
		0.60	-0.006	0.005	0.100	0.846	0.992
		0.70	-0.006	0.005	0.100	0.846	0.992
		0.80	-0.006	0.005	0.100	0.846	0.992
		0.90	-0.006	0.005	0.100	0.846	0.992
	0.4	0.10	0.000	0.005	0.092	0.778	0.993
		0.20	0.000	0.005	0.092	0.778	0.993
		0.30	-0.001	0.005	0.093	0.781	0.993
		0.40	-0.006	0.005	0.100	0.846	0.992
		0.50	-0.006	0.005	0.100	0.846	0.992
		0.60	-0.006	0.005	0.100	0.846	0.992
		0.70	-0.006	0.005	0.100	0.846	0.992
		0.80	-0.006	0.005	0.100	0.846	0.992
		0.90	-0.006	0.005	0.100	0.846	0.992
	0.5	0.10	0.000	0.005	0.092	0.778	0.993
		0.20	0.000	0.005	0.092	0.778	0.993
		0.30	-0.001	0.005	0.093	0.781	0.993
		0.40	-0.006	0.005	0.100	0.846	0.992
		0.50	-0.006	0.005	0.100	0.846	0.992
		0.60	-0.006	0.005	0.100	0.846	0.992
		0.70	-0.006	0.005	0.100	0.846	0.992
		0.80	-0.006	0.005	0.100	0.846	0.992
		0.90	-0.006	0.005	0.100	0.846	0.992



		Altura (H)					
Exclusión (%)	CMF (% pix.)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²	
SILVA ET AL. (2016)	0.6	0.10	0.000	0.005	0.092	0.778	0.993
		0.20	0.000	0.005	0.092	0.778	0.993
		0.30	-0.001	0.005	0.093	0.781	0.993
		0.40	-0.006	0.005	0.100	0.846	0.992
		0.50	-0.006	0.005	0.100	0.846	0.992
		0.60	-0.006	0.005	0.100	0.846	0.992
		0.70	-0.006	0.005	0.100	0.846	0.992
		0.80	-0.006	0.005	0.100	0.846	0.992
		0.90	-0.006	0.005	0.100	0.846	0.992
	0.7	0.10	0.000	0.005	0.092	0.778	0.993
		0.20	0.000	0.005	0.092	0.778	0.993
		0.30	-0.001	0.005	0.093	0.781	0.993
		0.40	-0.006	0.005	0.100	0.846	0.992
		0.50	-0.006	0.005	0.100	0.846	0.992
		0.60	-0.006	0.005	0.100	0.846	0.992
		0.70	-0.006	0.005	0.100	0.846	0.992
		0.80	-0.006	0.005	0.100	0.846	0.992
		0.90	-0.006	0.005	0.100	0.846	0.992
	0.8	0.10	0.000	0.005	0.092	0.778	0.993
		0.20	0.000	0.005	0.092	0.778	0.993
		0.30	-0.001	0.005	0.093	0.781	0.993
		0.40	-0.006	0.005	0.100	0.846	0.992
		0.50	-0.006	0.005	0.100	0.846	0.992
		0.60	-0.006	0.005	0.100	0.846	0.992
		0.70	-0.006	0.005	0.100	0.846	0.992
		0.80	-0.006	0.005	0.100	0.846	0.992
		0.90	-0.006	0.005	0.100	0.846	0.992
	0.9	0.10	0.000	0.005	0.092	0.778	0.993
		0.20	0.000	0.005	0.092	0.778	0.993
		0.30	-0.001	0.005	0.093	0.781	0.993
		0.40	-0.006	0.005	0.100	0.846	0.992
		0.50	-0.006	0.005	0.100	0.846	0.992
		0.60	-0.006	0.005	0.100	0.846	0.992
		0.70	-0.006	0.005	0.100	0.846	0.992
		0.80	-0.006	0.005	0.100	0.846	0.992
		0.90	-0.006	0.005	0.100	0.846	0.992

Tabla 11. Errores sistemáticos y aleatorios de la variable estimada "altura de árbol" obtenidos a partir del algoritmo Silva et al. (2016). Los valores de referencia serían los obtenidos con el Factor de Corona Máximo en un 40% con una exclusión en un 50% (el valor que ofreció mejores resultados de F-Score).

		Diámetro de la Corona (CD)					
Exclusión (%)	CMF (% pix.)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)	R ²	
SILVA ET AL. (2016)	0.1	0.10	-2.724	-2.737	2.841	56.087	-9.772
		0.20	-0.575	-0.619	0.994	19.632	-0.320
		0.30	0.645	0.519	1.195	23.723	-0.711
		0.40	1.076	1.000	1.550	30.920	-1.851
		0.50	1.250	1.126	1.720	34.321	-2.512
		0.60	1.269	1.126	1.743	34.772	-2.605
		0.70	1.329	1.175	1.787	35.646	-2.789
		0.80	1.350	1.175	1.812	36.159	-2.899
		0.90	1.357	1.175	1.823	36.380	-2.947
	0.2	0.10	-2.724	-2.737	2.841	56.087	-9.772
		0.20	-0.585	-0.619	1.007	19.874	-0.353
		0.30	-0.578	0.519	1.174	23.321	-0.654
		0.40	0.959	0.937	1.503	29.995	-1.683
		0.50	1.090	1.090	1.630	32.523	-2.154
		0.60	1.104	1.090	1.649	32.903	-2.228
		0.70	1.126	1.090	1.655	33.014	-2.250
		0.80	1.157	1.126	1.683	33.575	-2.361
		0.90	1.171	1.126	1.705	34.027	-2.453
	0.3	0.10	-2.724	-2.737	2.841	56.087	-9.772
		0.20	-0.588	-0.619	1.009	19.922	-0.359
		0.30	0.549	0.519	1.162	23.070	-0.619
		0.40	0.924	0.937	1.479	29.500	-1.595
		0.50	1.059	1.082	1.611	32.143	-2.081
		0.60	1.074	1.082	1.631	32.531	-2.156
		0.70	1.075	1.082	1.632	32.566	-2.162
		0.80	1.075	1.082	1.632	32.566	-2.162
		0.90	1.075	1.082	1.632	32.566	-2.162



		Diámetro de la Corona (CD)					
		Exclusión (%)	CMF (% pix.)	Mean Error (m)	Median Error (m)	RMSE (m)	Relative RMSE (%)
SILVA ET AL. (2016)	0.4	0.10	-2.724	-2.737	2.841	56.087	-9.772
		0.20	-0.590	-0.619	1.010	19.940	-0.362
		0.30	0.536	0.519	1.155	22.940	-0.600
		0.40	0.908	0.928	1.470	29.326	-1.564
		0.50	1.025	1.061	1.579	31.504	-1.959
		0.60	1.040	1.061	1.599	31.902	-2.305
		0.70	1.041	1.061	1.601	31.936	-2.041
		0.80	1.041	1.061	1.601	31.936	-2.041
		0.90	1.041	1.061	1.601	31.936	-2.041
	0.5	0.10	-2.724	-2.737	2.841	56.087	-9.772
		0.20	-0.597	-0.619	1.011	19.968	-0.365
		0.30	0.491	0.436	1.119	22.216	-0.501
		0.40	0.858	0.867	1.423	28.384	-1.402
		0.50	0.960	1.032	1.527	30.460	-1.767
		0.60	0.976	1.032	1.547	30.868	-1.841
		0.70	0.977	1.032	1.549	30.902	-1.847
		0.80	0.977	1.032	1.549	30.902	-1.847
		0.90	0.977	1.032	1.549	30.902	-1.847
	0.6	0.10	-2.724	-2.737	2.841	56.087	-9.772
		0.20	-0.627	-0.642	1.033	20.396	-0.425
		0.30	0.389	0.257	1.067	21.180	-0.364
		0.40	0.749	0.704	1.342	26.772	-1.137
		0.50	0.824	0.876	1.419	28.310	-1.390
		0.60	0.835	0.880	1.431	28.555	-1.431
		0.70	0.836	0.880	1.433	28.590	-1.437
		0.80	0.836	0.880	1.433	28.590	-1.437
		0.90	0.836	0.880	1.433	28.590	-1.437
	0.7	0.10	-2.724	-2.737	2.841	56.087	-9.772
		0.20	-0.779	-0.777	1.154	22.779	-0.777
		0.30	0.037	-0.056	1.057	20.992	-0.340
		0.40	0.338	0.331	1.222	24.388	-0.774
		0.50	0.382	0.350	1.262	25.171	-0.889
		0.60	0.393	0.350	1.269	25.325	-0.912
		0.70	0.393	0.350	1.270	25.341	-0.915
		0.80	0.393	0.350	1.270	25.341	-0.915
		0.90	0.393	0.350	1.270	25.341	-0.915
	0.8	0.10	-2.736	-2.737	2.854	56.362	-9.878
		0.20	-1.162	-1.218	1.465	28.928	-1.866
		0.30	-0.650	-0.827	1.322	26.248	-1.905
		0.40	-0.414	0.714	1.314	26.211	-1.049
		0.50	-0.359	0.714	1.325	26.435	-1.084
		0.60	-0.350	0.714	1.325	26.443	-1.085
		0.70	-0.350	0.714	1.325	26.443	-1.085
		0.80	-0.350	0.714	1.325	26.443	-1.085
		0.90	-0.350	0.714	1.325	26.443	-1.085
	0.9	0.10	-2.892	-2.881	3.002	59.280	-11.034
		0.20	-2.160	-2.318	2.356	46.526	-6.413
		0.30	-1.910	-2.269	2.243	44.550	-5.035
		0.40	-1.805	-2.037	2.204	43.973	-4.766
		0.50	-1.779	-2.037	2.213	44.156	-4.814
		0.60	-1.778	-2.037	2.214	44.164	-4.816
		0.70	-1.778	-2.037	2.214	44.164	-4.816
		0.80	-1.778	-2.037	2.214	44.164	-4.816
		0.90	-1.778	-2.037	2.214	44.164	-4.816

Tabla 12. Errores sistemáticos y aleatorios de la variable estimada "diámetro de corona" a partir del algoritmo Silva et al. (2016). Los valores de referencia serían los obtenidos con el Factor de Corona Máximo en un 40% con una exclusión en un 50% (el valor que ofreció mejores resultados de F-Score).



3.5 DISCUSIÓN

Los resultados cuantitativos ofrecidos por las métricas de Sensibilidad (*Recall*), Precisión (*Precision*) y F-score han permitido demostrar que un algoritmo que utiliza la nube de puntos original es más preciso que aquel que utiliza productos derivados como el CHM, tal y como ya ha sido apuntado por otros autores (Paris et al., 2016). Esto se debe a que aquellos algoritmos basados en el CHM están expuestos a que los resultados presenten errores originados en la propia construcción del CHM. Por ejemplo, en la calidad geométrica del propio CHM, la selección de parámetros tales como el *smoothing* (Vega et al., 2014), o en la definición del tamaño de ventana variable en función de la altura del CHM para la búsqueda adaptativa de máximos locales sobre el ráster interpolado (Li et al., 2012).

Por otra parte, los algoritmos basados en Modelo de Altura Dosel no son efectivos a la hora de detectar aquellos árboles (*understory*) que se encuentran debajo de los árboles dominantes y que no se visualizan a simple vista (Dalponte & Coomes, 2016).

3.5.1 Algoritmo implementado en el software Fusion/LDV

Los pasos de este algoritmo son ejecutados linealmente, y aunque el manejo es fácil para el usuario, es necesario tener la referencia del manual del software este para poder llegar a obtener los resultados deseados en cada paso. En la sección 3.4.1 se puede comprobar que a medida que la resolución del CHM (*Cellsize*) se va reduciendo, los resultados, en cuanto a la detección de árboles empeoran notablemente, aunque al mismo tiempo también disminuye el error de comisión. Esta tendencia hace que disminuya el F-score conforme aumenta el *Cellsize*. También se puede determinar que el tamaño del suavizado (ventana de 3x3 píxeles) es el acertado para la efectividad de este tipo de proyectos, como sucede con el presente algoritmo y el resto de los trabajados en el presente proyecto. En general, los resultados ofrecidos por el flujo de trabajo proporcionado por el software Fusion no pueden considerarse óptimos en el caso de la parcela de estudio analizada.

3.5.2 Digital Forestry Toolbox (DFT)

Esta librería de códigos Matlab demostró como es más apropiado trabajar con CHM de alta resolución (*Cellsize* menores) y un factor suavizado gaussiano elevado. En las figuras de la sección 3.4.3 se pueden observar que los comportamientos de los errores de omisión, comisión,



y por ende el F-score, son similares a los resultados obtenidos por el algoritmo implementado en el software Fusion/LDV.

3.5.3 Algoritmo Mean Shift 2D y 3D

Como este algoritmo trabaja directamente con la variación de un solo parámetro (*Bandwidth*) esta variable es la responsable de que el algoritmo detecte mayor cantidad de árboles presentes con un nivel de corrección de los mismos alta, es decir, que no ocurra una sobre-segmentación. Para la parcela experimental los resultados obtenidos en 2D y 3D demuestran que, a mayor tamaño del ancho de banda, el error de omisión se vuelve mayor y el error de comisión menor. Como el *Recall* va disminuyendo, el F-score también actúa de igual forma, por lo que los resultados obtenidos no resultan adecuados para la morfología de este tipo de bosque mediterráneo, con pino carrasco como árbol dominante. No obstante, Ferraz especifica que un *bandwidth* menor, aunque aplicable para aquellas zonas donde se trabaje con sotobosque (*understory vegetation*), podría llegar a segmentar los puntos de los árboles que sean muy altos (sobre-segmentar), por lo que recomienda no disminuir demasiado el valor asignado al parámetro de *bandwidth* (Ferraz et al., 2012). Este método, a pesar de que no fuese el óptimo para este tipo de investigación, es eficiente a la hora de trabajar con áreas boscosas de las cuales las diversas capas de vegetación se encuentran visiblemente separadas (Vega et al., 2014).

3.5.4 Algoritmo de Li et al. (2012)

Dentro de los algoritmos testados, el de Li et al. (2012) ha sido el que ofreció los mejores resultados. Este algoritmo ha tenido una relación eficiente entre la detección de árboles presentes y el nivel de corrección en detección de dichos árboles, por lo que el F-score resultó elevado en todos los casos. Los resultados obtenidos confirman que los errores de omisión y comisión son relativamente bajos en comparación con el resto de los algoritmos examinados, siendo un algoritmo que se mantiene estable hasta valores del parámetro de espaciamiento mínimo (*R*) superiores a 3m. A partir de este valor, el error de omisión aumenta y el error de comisión disminuye. También resaltar que, a mayor radio máximo de la corona (parámetro *speed-up*), más rápido trabaja el algoritmo, más preciso se torna y más compactos son los resultados. No obstante, a pesar de ser el más efectivo para el presente proyecto, debe ser analizado en bosques de capas densas y/o diversas capas (Vega et al., 2014) para comprobar si realmente es el adecuado para todo tipo de vegetación.



3.5.5 Algoritmo de Dalponte & Coomes (2016)

Los resultados de este algoritmo no fueron los mejores de los ofrecidos por el conjunto de algoritmos testados en la parcela experimental estudiada. Esto se debe a que todos sus resultados son homogéneos y constantes luego de aumentar el valor del parámetro factor máximo de corona. Para todas las variaciones del parámetro *Threshold Seed* (puntos semilla), el porcentaje de la detección de árboles presentes se mantuvo menor de un 75%, con un bajo error de comisión en todos los casos, significando que el algoritmo es muy estable ante la variación de sus parámetros internos. Aunque, a pesar de que los resultados del estudio no son óptimos, esto no quiere decir que este algoritmo no sea eficiente en otro tipo de arquitecturas de bosques. El estudio elaborado por los autores para comprobar la eficiencia del algoritmo se basó en la identificación de especies y estimación de la densidad del carbón fijado en bosques de coníferas principalmente, aunque con presencia de abedul y álamo, en los Alpes Italianos. En este tipo de bosque, el algoritmo arrojó buenos resultados en cuanto a la precisión, por lo que se puede determinar que el algoritmo de Dalponte & Coomes (2016) podría ser eficiente para estudios con características parecidas a las testeadas por los autores.

3.5.6 Algoritmo de Silva et al. (2016)

Los resultados de este algoritmo, igual que el de Dalponte & Coomes (2016), son similares en todas las variaciones del parámetro de *Exclusion*. Sin embargo, la diferencia entre ambos algoritmos es que, a mayor tamaño de factor de la corona máxima, disminuyen ligeramente los errores de comisión y omisión. El porcentaje de detección de los árboles presentes se mantiene en un 75% aproximadamente para todos los casos y, por ende, el F-score se mantiene en un intervalo intermedio entre la sensibilidad y la precisión. Cabe destacar que Silva et al. (2016) indican que la precisión de la segmentación de árboles podría variar para los diferentes árboles debido a la forma orgánica de sus coronas y la densidad de la capa forestal (Silva et al., 2016).



4. CONCLUSIONES

Para la parcela experimental estudiada, el algoritmo de Li et al. (2012) fue el que mejores resultados obtuvo con relación a los valores de las métricas recall, precision y F-score. Adicionalmente, los resultados ofrecidos fueron estables ante la variación de sus parámetros internos (dentro de un rango razonable).

El algoritmo implementado en Fusion/LDV y el basado en la librería de Matlab DFT mostraron mejores resultados cuanto mayor fue la resolución del CHM en el que se basan, disminuyendo claramente los errores de comisión y omisión. Esto indica que el parámetro *Cellsize* resulta crucial en ambos métodos. En cuanto al algoritmo Mean Shift (2D y 3D), el parámetro primordial del ancho de banda (*Bandwidth*) es el esencial para una correcta detección de los árboles presentes y un elevado nivel de precisión en la detección de los mismos. No obstante, para la parcela experimental, a pesar de testear con diversas variables, no resultó ser el más efectivo, ya sea por el tipo de bosque o tipo de árboles presentes.

Los resultados ofrecidos por los algoritmos de Dalponte & Coomes (2016) y Silva et al. (2016) fueron similares. Los errores de omisión resultaron ser altos y los de comisión bajos en ambos casos. De esta forma, los dos algoritmos no demostraron ser los más efectivos para la segmentación de árboles en la parcela estudiada.

Con relación a los resultados de la estimación de la altura y el diámetro de la corona, la estimación de la altura de árbol fue adecuada en todos los casos, mientras que el diámetro de corona arrojó unos pobres resultados. En este sentido, los algoritmos ensayados no permitieron obtener un diámetro de corona preciso, por lo que se debería testar otras aproximaciones y/o algoritmos, por ejemplo, la metodología de segmentación basada en objetos (*Object Based Image Analysis*; OBIA), para intentar determinar de forma automática este importante parámetro relacionado con la biomasa del árbol.

Coincidiendo con lo indicado por Li et al. (2012), el modelo de altura del dosel (CHM) no permite visualizar la imagen en tres dimensiones de los árboles, por lo que los algoritmos que trabajan con este modelo ráster tienden a incurrir en errores en cuanto a la precisión y contabilización de árboles (Li et al., 2012).



En cuanto a la obtención de las métricas de evaluación de la precisión (*Accuracy Assesment*), esta herramienta, desarrollada en Matlab, resultó fundamental para la determinación de los errores de omisión y comisión, junto con el cálculo del parámetro F-score. Igualmente fue la herramienta encargada de la determinación de los errores sistemáticos y aleatorios en la estimación de variables dendrométricas altura y diámetro de corona.

A pesar de que el algoritmo de Li et al. (2012) arrojara los mejores resultados, pensamos que los resultados presentados en este trabajo son preliminares, y solo deben tomarse como una primera aproximación al problema. En efecto, aún debe ser estudiado en otras parcelas de bosque Mediterráneo (con diferente densidad y altura de árboles, cobertura vegetal, presencia de sotobosque, etc) para validar los resultados obtenidos en este estudio. De igual forma, y con relación al resto de los algoritmos ensayados, es conveniente indicar que los resultados obtenidos podrían variar ostensiblemente en función de la arquitectura de la parcela de referencia y el tipo de ecosistema forestal, por lo que no se recomienda descartar ninguna de las opciones planteadas en futuros estudios.



5. AGRADECIMIENTOS

En primer lugar, agradecerle a mi familia y a Luis Eduardo, quienes siempre me apoyan en todos mis proyectos. Así como también agradecerle a mi asesor, Fernando J. Aguilar, por la confianza en el proyecto y el seguimiento efectuado y a Abderrahim Nemmaoui por incentivar me a seguir adelante y luchar por mis sueños.



6. REFERENCIAS

- Aguilar, F. J., Aguilar, M. A., Blanco, J. L., Nemmaoui, A., & Lorca, A. M. G. (2016). Analysis and validation of grid DEM generation based on Gaussian markov random field. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 41(June), 277–284. <https://doi.org/10.5194/isprsarchives-XLI-B2-277-2016>
- Aguilar, Fernando J., Nemmaoui, A., Aguilar, M. A., & Peñalver, A. (2019). Fusion of terrestrial laser scanning and RPAS image-based point clouds in Mediterranean forest inventories. *Dyna (Spain)*, 94(3), 131–136. <https://doi.org/10.6036/8882>
- Almeida, D. R. A., Stark, S. C., Shao, G., Schietti, J., Nelson, B. W., Silva, C. A., Gorgens, E. B., Valbuena, R., Papa, D. de A., & Brancalion, P. H. S. (2019). Optimizing the remote detection of tropical rainforest structure with airborne lidar: Leaf area profile sensitivity to pulse density and spatial sampling. *Remote Sensing*, 11(1). <https://doi.org/10.3390/rs11010092>
- Dalponte, M., & Coomes, D. A. (2016). Tree-centric mapping of forest carbon density from airborne laser scanning and hyperspectral data. *Methods in Ecology and Evolution*, 7(10), 1236–1245. <https://doi.org/10.1111/2041-210X.12575>
- Felicísimo, A. M. (1994). Parametric statistical method for error detection in digital elevation models. *ISPRS Journal of Photogrammetry and Remote Sensing*, 49(4), 29–33. [https://doi.org/10.1016/0924-2716\(94\)90044-2](https://doi.org/10.1016/0924-2716(94)90044-2)
- Ferraz, A., Bretar, F., Jacquemoud, S., Gonçalves, G., Pereira, L., Tomé, M., & Soares, P. (2012). 3-D mapping of a multi-layered Mediterranean forest using ALS data. *Remote Sensing of Environment*, 121, 210–223. <https://doi.org/10.1016/j.rse.2012.01.020>
- Ferraz, A., Saatchi, S., Mallet, C., & Meyer, V. (2016). Lidar detection of individual tree size in tropical forests. *Remote Sensing of Environment*, 183(September), 318–333. <https://doi.org/10.1016/j.rse.2016.05.028>



- Fukunaga, K. (1990). *Introduction to Statistical Pattern Recognition - 2nd Edition*. Academic Press. <https://www.elsevier.com/books/introduction-to-statistical-pattern-recognition/fukunaga/978-0-08-047865-4>
- Gómez, C., Alejandro, P., Hermosilla, T., Montes, F., Pascual, C., Ruiz, L. Á., Álvarez-Taboada, F., Tanase, M. A., & Valbuena, R. (2019). Remote sensing for the Spanish forests in the 21st century: A review of advances, needs, and opportunities. *Forest Systems*, 28(1). <https://doi.org/10.5424/fs/2019281-14221>
- Hirata, Y., Furuya, N., Saito, H., Pak, C., Leng, C., Sokh, H., Ma, V., Kajisa, T., Ota, T., & Mizoue, N. (2018). Object-based mapping of aboveground biomass in tropical forests using LiDAR and very-high-spatial-resolution satellite data. *Remote Sensing*, 10(3). <https://doi.org/10.3390/rs10030438>
- Kershaw, J. A., Ducey, M. J., Beers, T. W., & Husch, B. (2016). *Forest Mensuration: Edition 5*. John Wiley & Sons. <https://sites.google.com/site/26sept20menjipar5/hwar89RKnS20yewunr6857>
- Li, W., Guo, Q., Jakubowski, M. K., & Kelly, M. (2012). A new method for segmenting individual trees from the lidar point cloud. *Photogrammetric Engineering and Remote Sensing*, 78(1), 75–84. <https://doi.org/10.14358/PERS.78.1.75>
- Maas, H. G., Bienert, A., Scheller, S., & Keane, E. (2008). Automatic forest inventory parameter determination from terrestrial laser scanner data. *International Journal of Remote Sensing*, 29(5), 1579–1593. <https://doi.org/10.1080/01431160701736406>
- McGaughey, R. J. (2018). *FUSION / LDV: Software for LIDAR Data Analysis and Visualization*. U.S. Department of Agriculture, Forest Service, Pacific Northwest Research Station, University of Washington, Seattle, WA, USA. August, 123. http://forsys.cfr.washington.edu/Software/FUSION/FUSION_manual.pdf
- Popescu, S. C., & Wynne, R. H. (2004). Seeing the trees in the forest: Using lidar and multispectral data fusion with local filtering and variable window size for estimating tree height. *Photogrammetric Engineering and Remote Sensing*, 70(5), 589–604. <https://doi.org/10.14358/PERS.70.5.589>



Roussel, J. R., Auty, D., Coops, N. C., Tompalski, P., Goodbody, T. R. H., Meador, A. S., Bourdon, J. F., de Boissieu, F., & Achim, A. (2020). lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, 251(February), 112061. <https://doi.org/10.1016/j.rse.2020.112061>

Vega, C., Hamrouni, A., El Mokhtari, A., Morel, M., Bock, J., Renaud, J. P., Bouvier, M., & Durrieue, S. (2014). PTrees: A point-based approach to forest tree extraction from lidar data. *International Journal of Applied Earth Observation and Geoinformation*, 33(1), 98–108. <https://doi.org/10.1016/j.jag.2014.05.001>

Wehr, A., & Lohr, U. (1999). Airborne laser scanning - An introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing*, 54(2–3), 68–82. [https://doi.org/10.1016/S0924-2716\(99\)00011-8](https://doi.org/10.1016/S0924-2716(99)00011-8)

White, J. C., Coops, N. C., Wulder, M. A., Vastaranta, M., Hilker, T., & Tompalski, P. (2016). Remote Sensing Technologies for Enhancing Forest Inventories: A Review. *Canadian Journal of Remote Sensing*, 42(5), 619–641. <https://doi.org/10.1080/07038992.2016.1207484>

