2025 | 16·20
GIJÓN | JUNIO
9º CONGRESO FORESTAL ESPAÑOL

9CFE-1513

Actas del Noveno Congreso Forestal Español
Edita: **Sociedad Española de Ciencias Forestales. 2025**.
ISBN: **978-84-941695-7-1**

Organiza

Detección de árboles individuales mediante datos LiDAR en la Casa De Campo de Madrid (España)

PÉREZ HERNANDEZ H. (1), OLIVAR RUIZ J. (2)(3)(4), MARTÍN ALCÓN, S. (2), MARTÍN MOLINA D. (1), BRAVO NUÑEZ A. (2)(3)(5) Y TOMÉ MORAN J.L. (2).

(1) Escuela Técnica Superior de Ingenierías Agrarias de Palencia. Universidad de Valladolid (ETSIAA-UVa). Av. de Madrid, 57, 34004 Palencia

(2) Agresta S. Coop. C/Duque de Fernán Núñez 2, 1 º, 28012, Madrid, Spain

(3) Instituto Universitario de Investigación en Gestión Forestal Sostenible (iuFOR) Universidad de Valladolid-INIA. Avda, Madrid 44. 34004 Palencia.
(4) Departamento de Producción Vegetal y Recursos Forestales. Universidad de Valladolid. Avda, Madrid 44. 34004 Palencia.
(5) Departamento de Ciencias Agroforestales. Universidad de Valladolid. Avda, Madrid 44. 34004 Palencia.

Resumen

La tercera cobertura nacional LíDAR PNOA en desarrollo actualmente con una densidad de 5 pulsos/m² abre la posibilidad a analizar el uso de estos datos para inventarios de árbol individual. Sin embargo, hay pocos proyectos operativos que hayan trabajado con esta tecnología. El objeto de este estudio es analizar su potencial en un caso real en la Casa de Campo de Madrid. Para ello se han levantado en campo 99 parcelas circulares de 11,4 metros de radio con presencia de distintas especies en las que se han medido la altura y rumbo de cada árbol. Trabajando sobre los datos LiDAR capturados por un vuelo específico de densidad equivalente, se ha procedido a buscar los ápices de los pies con el filtro de máximos locales del paquete “lidR” sobre la nube de puntos. La presente comunicación resume las mejores parametrizaciones del algoritmo en función de la formación, la especie y la fracción de cabida cubierta, indicando las ventajas y limitaciones de la metodología para la individualización de pies. Sus resultados reflejan su potencial para posicionar los ápices como primer paso en la delineación de sus copas y mejorar la estimación de la densidad con LiDAR en un futuro.

Palabras clave

Lidar, árbol individual, inventario lidar.

1. Introducción

La gestión forestal ha aumentado su importancia debido al contexto actual de cambio climático y la creciente presión que ejerce sobre los montes y ecosistemas. Para ello los gestores han de tener a su disposición herramientas que les permitan tomar decisiones con una cierta seguridad., En este sentido el presente trabajo se ocupa de una variable difícil de calcular o estimar actualmente como es el número de arboles de un determinado monte ya que podría ser en el futuro un dato a tener en cuenta para planificar acciones de conservación o explotación de la masa.

Tradicionalmente, el número de árboles de una masa se calcula a partir de los

datos de un inventario, es decir, extrapolaciones mediante el conteo de árboles en una superficie de muestreo suficiente en parcelas sistemáticas del monte siendo una opción económicamente costosa, lenta y orientada a obtener un error de muestreo objetivo.

Desde principios del siglo XXI comienzan a aparecer metodologías para trabajar estimar variables dasométricas a partir de datos LiDAR por méetodos de masa (Næsset, E., 2002), sin embargo, el número de pies ha resultado una variable especialmente retadora dando los peores ajustes de entre las principales variables de masa (Fernandez-landa et al, 2017).

La propuesta que se realiza en este texto es analizar trabajar con una aproximación alternativa de estimación del número de pues utilizando métodos de árbol individual, aprovechando el potencial que supone la mayor densidad (5 puntos/m^2) de la tercera cobertura nacional LiDAR PNOA (Hyyppä & Inkinen, 1999).

Para estimar de forma fácil y económica el número de arboles existentes en una determinada masa se ha utilizado un filtro de máximos locales del paquete de R (R Core Team., 2024) “lidR” (Roussel et al., 2020) que busca puntos máximos (ápices de árboles) en un modelo digital de alturas verticales (MDAV) en un caso real como el de la Casa de Campo de Madrid con unos resultados prometedores alcanzando a estimar una mayor cantidad de arboles (469.773). También se trató de determinar el potencial de esta metodología para utilizarlo en la identificación de arboles individuales con resultados esperanzadores, aunque todavía lejanos.

Para finalizar se analizó el potencial uso de métodos basados en imágenes, pero estos demostraron que aún no han alcanzado una precisión suficiente como para ser tenidos en cuenta, aunque su uso en un futuro no se descarta debido a que su principal problema es que necesitan muchos datos de entrenamiento para mejorar sus predicciones.

2. Objetivos

El objetivo principal de esta investigación es dotar de herramientas de decisión a los gestores forestales mediante la estimación del número de árboles presentes en un área determinada aprovechando los datos generados por la tercera cobertura nacional LiDAR PNOA.

Para la consecución de este objetivo se han realizado 99 parcelas de 4 especies/grupos distintos (pino puro, encina pura, arizonica pura y mixto) en los que se utilizará un filtro de máximos locales de la biblioteca de Rstudio “lidR” como estimador del número de árboles presentes en cada parcela. A continuación, se comprobará cómo se comporta y cuál es la mejor configuración del filtro para cada una de ellas. Teniendo en cuenta que con el algoritmo se pretende encontrar el punto más alto de la copa de los árboles, es decir su ápice.

Uno de los objetivos secundarios es la identificación de árboles individuales mediante la correlación de los puntos predichos con el verdadero árbol. Ppara ello se utilizaron 55 parcelas en las que se tomó la altura a todos los individuos para que, mediante el uso del rumbo, distancia al centro, declinación magnética y la posición corregida del centro de la parcela se pueda relacionar el punto predicho con el árbol real de manera visual.

3. Metodología 3.1 Zona de estudio

El área de estudio se encuentra en la Casa de Campo de Madrid que pertenece a la ciudad de Madrid (España), concretamente al distrito de Moncloa-Aravaca al oeste de la ciudad. Esta finca, cuenta aproximadamente con 1722 hectáreas convirtiéndose en el mayor parque público del municipio. Es considerado el "pulmón" de la ciudad albergando actividades deportivas, culturales y recreativas. La propiedad como tal se constituye en 1562 cuando Felipe II adquiere la finca para anexionarla a los terrenos del Palacio Real para actividades de recreo y caza principalmente. En 1931 fue cedida al ayuntamiento de Madrid y abierta al público tras la proclamación de la Segunda República Española y finalmente en 1985 fue catalogado como Monte de Utilidad Pública.

Figura 1. Situación de la Casa de Campo de Madrid respecto a España y la ciudad de Madrid.

La Casa de Campo consta de numerosos caminos y una orografía suave y accesible que facilita el estudio. Las especies dominantes del terreno son pino piñonero (*Pinus pinea)*, arizónica (*Cupressus arizonica*) y encina *(Quercus ilex*) con zonas de monte bajo y monte alto además de que está empezando la sucesión vegetal sustituyendo a los anteriores. En menor medida se pueden encontrar árboles como fresnos, olmos y especies de ribera cerca de los arroyos que recorren la finca antes de desembocar en el río Manzanares.

La zona de estudio tiene una extensión de 1.420,49 hectáreas y está compuesta por

86 Cantones. Se excluyeron las zonas de aparcamiento, el zoo y el parque de atracciones. Se ha calculado que aproximadamente hay 572,51 hectáreas ocupadas por pinos (fundamentalmente piñonero), 37,09 hectáreas ocupadas por arizónica, 372,26 hectáreas ocupadas por encina, 50,21 hectáreas ocupadas por fresnos (*fraxinus*) y 388,42 hectáreas en las que no hay una especie dominante y se consideran masas mixtas. Es importante resaltar que la zona de estudio fue duramente castigada por la tormenta Filomena en enero de 2021 cuando se perdieron numerosos individuos y afectó gravemente a las copas de los pinos además de curvar sus fustes en algunos casos.

Figura 2. Detalle de la zona de estudio con sus 86 cantones correspondientes.

3.2 Diseño experimental y muestreo

El muestreo fue realizado en agosto de 2024 aprovechando la realización de un inventario para la ordenación del monte. El inventario consta de 99 parcelas circulares (31 parcelas de pino, 6 parcelas de arizónica, 31 de mixto y 31 de encina) con un radio de 11,4 metros seleccionadas mediante un diseño estratificado y dirigido con cuatro grandes grupos diferenciados, cantones de pino puro, cantones de encina pura, cantones de arizónica pura y cantones mixtos (para que un cantón sea considerado puro el porcentaje de ocupación de la especie principal ha de superar o igualar el 70%). En estas parcelas se tomaron los datos de todos los árboles como especie, diámetro (en caso de no llegar al mínimo inventariable se contó el individuo y se apuntó como “regeneración”), distancia al centro de la parcela (fuste), y rumbo. En cada parcela como mínimo se midió la altura de 5 ejemplares y en caso de ser encina se apuntó si formaba parte de una “mata” (conjunto de brotes y rebrotes que se originan del sistema radicular de una encina común).

Figura 3. Parcela de pino de la casa de campo.

Además, de cara a futuros estudios se obtuvieron datos de altura media y fracción de cabida cubierta del cantón al que pertenecen las distintas parcelas, así como la altura de todos los arboles de 55 de esas 99 parcelas que previsiblemente se podrían usar para probar diferentes configuraciones del método dependiendo de la altura media de la masa o su fracción de cabida cubierta o para identificar arboles individualmente relacionando posición real con la predicha mediante la altura.

3.3 Tratamiento de los datos

En primer lugar, se decidió establecer un criterio para considerar un árbol individual. En el caso concreto de las encinas, aquellas varas que forman parte de una mata fueron contabilizadas como un solo individuo, debido a que el método utilizado para contar individuos localiza el punto mas alto de una copa por lo que no es capaz de separar grupos de encina que comparten espacio y copa.

Los datos LiDAR utilizados para el presente trabajo provienen de un vuelo realizado específicamente para la casa de campo por la UTE PARQUES MADRID LOTE 6 con motivo de los trabajos de revisión de la ordenación del monte, con una configuración equivalente a la de la tercera cobertura LiDAR (densidad media nominal de 5 pulsos/m^2).

En un primer paso se normalizo la nube de puntos LIDAR generando un modelo digital de alturas de la vegetación (MDAV) de 1 metro de tamaño de píxel utilizando desarrollos de software propios de Agresta S. Coop. y trabajando sobre el paquete “LidR”. A partir del MDAV trabajando con el citado paquete se utilizó un de filtro de máximos locales que realiza una búsqueda de máximos locales en una “ventana” circular de radio seleccionado en el MDAV para generar una capa de puntos en formato “shape”. Para ello se prepararon diferentes configuraciones del filtro para ver cual se ajustaba mejor a cada especie. Las elegidas fueron: Ventana

circular de 2 pixeles (metros), Ventana circular de 3 pixeles (metros), Ventana circular de 4 pixeles (metros), Ventana circular de 5 pixeles (metros), Ventana circular de 6 pixeles (metros), Ventana circular de 7 pixeles (metros), Ventana circular de tamaño variable en función de la altura (cambia el tamaño de la ventana en función de la altura del punto que está analizando).

Por último, para contabilizar los errores de manera precisa se geolocalizaron los centros de cada parcela con un GPS submétrico Trimble GEO7x y se realizó un buffer circular de 11,4 metros alrededor de cada uno de manera que mediante un script de R fuéramos capaces de saber cuantos puntos de cada configuración se encontraban dentro de cada parcela.

Los resultados generados por el código deberán tomarse como predicciones, ya que para considerarlos reales tendría que comprobarse que cada punto generado por el código coincide con un árbol en la realidad, y además poder dar una estimación de la cantidad de falsos positivos (arboles contados por el programa) hay por metro cuadrado, ya que es probable que una copa muy grande sea segmentada debido a que la ventana de búsqueda sea más pequeña que la copa y también se genera lo contrario cuando los árboles sean de un tamaño pequeño ya que la ventana de búsqueda tenderá a encontrar otra copa de otro árbol y lo tomará como máximo local.

En la figura 4 se puede observar un ejemplo en el que se representa una circunferencia de 11,4m de radio sombreada de color amarillo que señala los límites de la parcela, en azul oscuro los árboles predichos, en rojo los árboles reales (se localizó su fuste) y en azul claro el centro de la parcela sobre la ortofoto de la zona.

Figura 4. Representación de una parcela de la Casa de Campo de Madrid.

Como complemento se intentó comparar esta forma de predicción con otros dos

métodos basados en imágenes para comprobar sus ventajas e inconvenientes, para ello se programó en el lenguaje Python (Van Rossum, G., & Drake Jr, F. L.; 1995) y se utilizó Anaconda (*Anaconda Software Distribution*.; 2020) principalmente por su función como administrador de entornos virtuales.

El primero fue la biblioteca "Detectree2" (Ball, J.G.C., et al.; 2023), que cuenta con tres modelos entrenados "randresize", "Cambridge" (diseñado para arbolado urbano) y "paracou" (diseñado para selvas). Esta biblioteca necesita una imagen de tipo "tif" con un tamaño de píxel de unos 10cm y genera un archivo tipo "shape" de polígonos que son los arboles identificados. Los parámetros de entrada más importantes son el grado de solapamiento aceptable para las copas de los árboles (dependiendo de la masa puedes elegir que los polígonos que estén cerca se eliminen si la masa a estudiar tiene una separación suficiente entre copas como para que no se toquen por ejemplo), tamaño de "tile" en pixeles (divide la imagen inicial en pequeños parches) y el solapamiento de estos (cuanto mayor sea el solapamiento de parches mejor será la precisión aunque incrementa el tiempo de procesamiento). Como resultado se crea un archivo "shape" con polígonos en el que cada uno tendrá información como el área y la probabilidad de que ese polígono sea realmente un árbol.

El segundo fue el paquete "Deepforest" (Weinstein, B.G.; 2019), cuyo funcionamiento es similar al anterior. Necesita imágenes con un tamaño de píxel de unos 10cm, aunque esta biblioteca puede trabajar además con archivos de tipo "jpg" por lo que no hace falta georreferenciar la imagen para trabajar. Puede generar el resultado en una ventana emergente o guardarlo en un archivo tipo "shape".

Las pruebas de imagen se aplicaron sobre una foto realizada con Dron en un bosque de Ampudia (Palencia). Sin embargo, los resultados fueron poco alentadores por lo que finalmente se desechó la idea de aplicarlos en Madrid donde la resolución de la ortofoto disponible era menor.

3.4 Análisis estadístico

Finalmente, se comprobó qué configuraciones del método son mas acertadas para predecir el número total de árboles, realizando el cálculo de errores por parcela de cada configuración (número de árboles reales menos número de árboles predichos) para posteriormente realizar su histograma, media de errores por parcela y especie.

Error=Valor real-Prediccion

El histograma de los errores reveló que con la configuración ws3 estos toman una forma compatible con una normal. Por lo que se procede a asumir que los errores siguen una distribución normal, lo cual es compatible con el Teorema del Límite Central (TLC), que establece que la suma de variables aleatorias independientes

con varianza finita tiende hacia una distribución normal, independientemente de la distribución subyacente, permitiendo aplicar métodos estadísticos basados en distribuciones normales.

El numero total de parcelas ($N_{parcelas}$) no corresponde al numero de parcelas muestreadas, sino a una extrapolación basada en la relación entre el área total del estudio (A_{total}) y el área de cada parcela ($A_{parcela}$).

$$Nparcelas=A_{total}/A_{parcela}$$

Este cambio se ha realizado para escalar las estimaciones obtenidas en las parcelas muestreadas al área completa del estudio, ya que en principio las parcelas son representativas de la masa.

Para evaluar el posible sesgo sistemático de las predicciones se calculó la media de los errores (e). Si el valor medio del error es distinto de 0 esto indica un sesgo promedio que como consecuencia significa que las estimaciones serán mayores o menores que el valor real. Este sesgo se corrige mediante el producto de la media de los errores por el valor de $N_{parcelas}$.

$$Ajuste = e*N_{parcelas}$$

La predicción final será la suma de la estimación resultante del filtro de máximos locales mas el ajuste anteriormente mencionado.

$$Predicción = Estimación + ajuste$$

En cuanto a los intervalos de confianza, se ha asumido que la varianza de los errores en una parcela es representativa $(o_{errores})^2$. De manera que se calcula la desviación estándar global acumulada para extrapolar la varianza de las parcelas al área total.

$$SDglobal = ((o_{errores})^2 * N_{parcelas})^{\wedge 1/2}$$

Se eligió que los intervalos de confianza fueran del 95% para la predicción final. Por lo que el valor crítico de la distribución normal (z) toma el valor de 1,96 y se procede a calcular los intervalos de confianza como:

$$IC = Predicción +- z * SDglobal$$

Finalmente, para compensar todos los individuos del inventario que no han sido utilizados en el calculo se propone generar un coeficiente mediante el cociente de árboles totales entre árboles individuales.

Predicción final= (Árboles totales) / (Árboles individuales)

4. Resultados 4.1 Resultados del método basado en datos LiDAR con árbol individual

La mejor opción para la estimación del número total de árboles viene dada por la configuración con ventana circular de 3 pixeles (metros) o ws3, ya que tiene la menor media de errores por parcela. En la figura 5 se puede observar el histograma de los errores de las 99 parcelas que toman la forma de una distribución normal, por lo que aplicando el teorema del límite central en la que la suma de variables independientes y distribuidas de manera idénticas tiende a una distribución normal se puede asumir que los errores están aproximadamente normalmente distribuidos para los siguientes cálculos como la predicción final y los limites de confianza superior e inferior al 95% (LCI/LCS),. dDentro de los cuales se espera que se encuentre el número real de árboles.

Hay que tener en cuenta que los resultados podrían mejorar sustancialmente en montes sin daños tan grandes por tormenta y si las encinas se presentan en forma de monte alto o adehesadas ya que en las parcelas de monte alto el programa no tuvo apenas errores en la predicción.

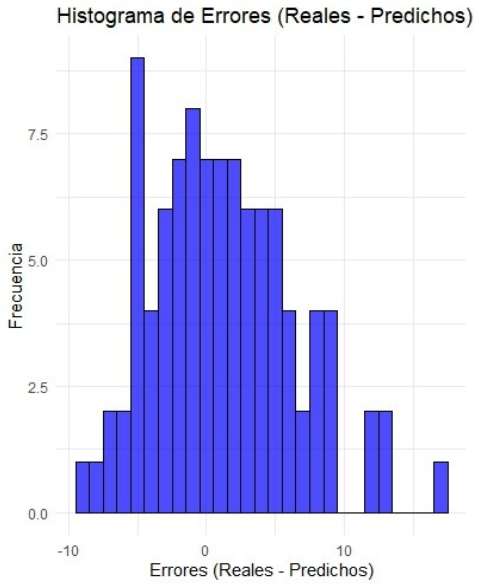

Figura 5. Histograma de los errores de la configuración ws3 en las 99 parcelas realizadas en la casa de campo.

En la tabla 1 se pueden observar algunos datos estadísticos relevantes como media de errores por parcela y especie, varianza de los errores y cálculo de su desviación estándar.

Tabla 1. Predicción final para la Casa de Campo de Madrid utilizando la configuración ws3.

Configuración	Área (ha)	Media de árboles por parcela (árboles)	Media del error por parcela (árboles)	Desviación estándar de la predicción total (árboles)	LCI 95% (árboles)	Predicción total (árboles)	LCS 95% (árboles)
ws3	1.420,49	10,28	1,24	968,32	302.517	304.415	306.312

Los resultados son prometedores, aunque habría que tener en cuenta que esos 306.312 árboles serían individuales conforme al criterio establecido, es decir no se contemplan las “matas” de encina con múltiples chirpiales. Para solucionar este problema se propone añadir un coeficiente al resultado final que será calculado mediante el cociente de arboles individuales entre arboles totales observados en las 99 parcelas resultando en 1,54 que como se puede observar en la tabla 2 aumenta considerablemente el número de árboles predichos.

Tabla 2. Predicción final ajustada para la Casa de Campo de Madrid utilizando la configuración ws3.

Configuración	Área (ha)	Coeficiente ajuste	LCI 95% (árboles)	Predicción (árboles)	LCS 95% (árboles)
ws3	1.420,49	1,54	466.844	469.773	472.700

Posteriormente, se ha realizado el mismo cálculo, pero estimando los individuos de cada especie por separado tabla 3. En todas las especies estudiadas la mejor configuración fue ws3.

Tabla 3. Predicción final para la Casa de Campo de Madrid separada por especie dominante utilizando la configuración ws3.

Clasificación	Área (ha)	Media árboles por parcela (árboles)	Media del error por parcela (árboles)	Desviación estándar global (árboles)	LCI 95% (árboles)	Predicción (árboles)	LCS 95% (árboles)
Pino puro	572,51	10,52	0,48	515,14	115.636	116.646	117.656
Arizónica puro	37,09	6,50	0	46,7	5.296	5.388	5.480
Encina puro	372,26	9,58	1,35	591,47	76.413	77.572	78.731
Fraxinus puro	50,21	9,58	1,35	217,23	12.452	12.878	13.304
mixto	388,42	11,50	2,17	521,86	90.012	91.035	92.057

En la tabla 4 se presenta la predicción final por especies y total ajustada mediante el uso de coeficientes de ajuste calculados como el cociente entre arboles totales y

arboles individuales.

Tabla 4. Predicción final para la Casa de Campo de Madrid separada por especie y total ajustada utilizando la configuración ws3.

Clasificación	Coeficiente ajuste	LCI 95% ajustado (árboles)	Predicción ajustada (árboles)	LCS 95% ajustado (árboles)
Pino puro	1,08	124907	125997	127088
Arizónica puro	1	5296	5.388	5480
Encina puro	2,39	182927	185703	188478
Fraxinus puro	2,39	29810	30829	31848
Mixto	1,33	119766	121127	122488
Total	-	465611	469044	472478

Se puede apreciar que existe un coeficiente de ajuste para pinos, esto es debido a que en varias parcelas se está produciendo la sucesión vegetal y existen pequeñas matas de encina de unos 2 metros de altura.

En un intento de comparar qué pasaría si se utilizaran los arboles totales en lugar de los individuales se realizó la predicción de los árboles del área total utilizando en este caso la configuración ws2 que fue la que mejor se comportó durante las pruebas con un resultado final de 478.356 árboles. En la figura 6 se presenta el histograma de los errores al utilizar la configuración ws2 para predecir el numero de arboles de las 99 parcelas.

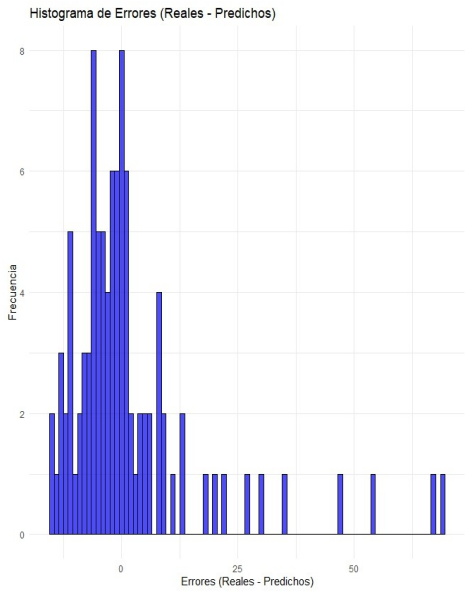

Figura 6. Histograma de los errores en las parcelas de la Casa de Campo de Madrid utilizando árboles totales con la configuración ws2.

4.2 Resultados de los métodos basados en imágenes

Los métodos basados en imágenes arrojaron resultados que rondan en el mejor de los casos el 50% de efectividad y necesitan fotos con un tamaño de píxel cercano a 10 cm para funcionar por lo que su uso tiene un alto coste económico inicial debido a la compra de una cámara con la resolución requerida y un dron en el que instalarla. Se sondeó la posibilidad de "entrenar" alguna de las dos bibliotecas, pero resulta un trabajo demasiado tedioso para los resultados que aportan, debido a que se han de introducir las copas en formato "shape" para entrenar el modelo, por lo que las copas se tienen que delinear a mano haciendo que este trabajo fuera descartado. En la figura 7 se presentan los resultados al utilizar "detectree2" y en la figura 8 se presentan los resultados obtenidos al utilizar "deepforest".

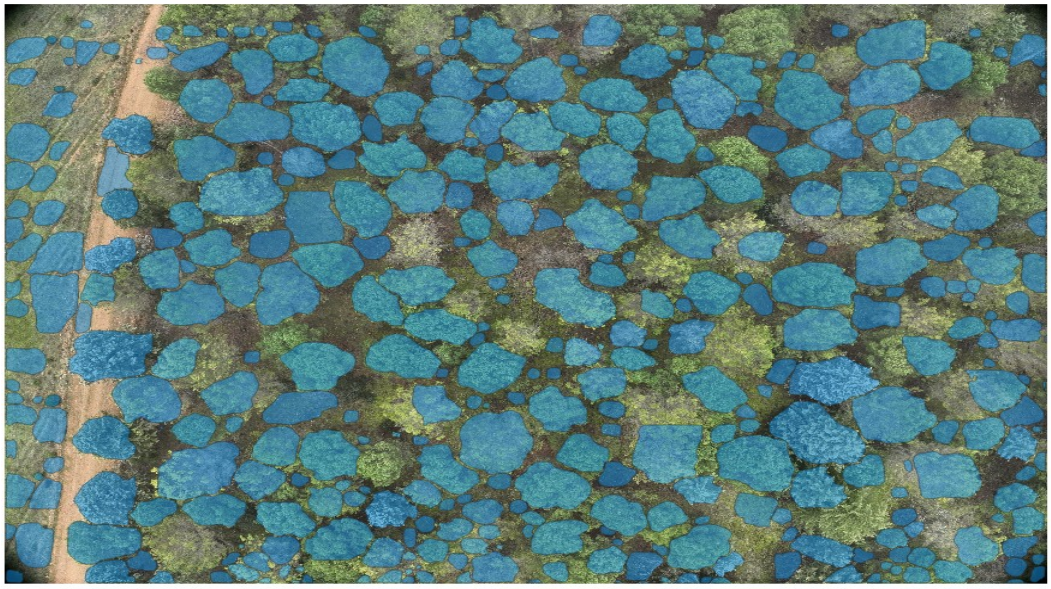

Figura 7. Resultados de detectree2 cada árbol encontrado se representa como un polígono azul.

Figura 8. Resultados de deepforest en el que los árboles encontrados por el programa están dentro de cuadrados rojos.

Los malos resultados obtenidos unido al hecho de la falta de disponibilidad de datos de imagen de muy alta resolución para la Casa de Campo, motivaron abandonar la idea de sacar resultados a partir de la imagen. Sin embargo, pese a los resultados, esta tecnología está avanzando mucho los últimos años y no se

descarta su uso en un futuro, siendo necesario en dicho caso trabajar con un mayor número de datos de entrenamiento para afinar las predicciones.

5. Discusión

Los resultados derivados del estudio sugieren que la predicción del número de árboles presentes en una zona determinada mediante el uso de datos LiDAR de la tercera cobertura nacional tiene sentido y puede llegar a dar una buena estimación como para ser considerada una herramienta valida a futuro de cara a la gestión de nuestros montes. Aparentemente la irregularidad estructural de las masas forestales de la Casa de Campo tras los daños sufridos por Filomena está influyendo negativamente en los resultados obtenidos, . Ccoherentemente a lo observado por otros autores (Valbuena 2013 y Latella 2021).

Sería interesante realizar nuevas parcelas para comprobar la hipótesis de que si aumentamos el numero de parcelas por especie el histograma de los errores se distribuiría de forma normal. Además, al tener datos de fracción de cabida cubierta y altura media de los cantones se podría comprobar si existe alguna configuración del filtro de máximos locales que se adecue mejor a esa especie o dentro de la misma especie a diferentes alturas y/o fracción de cabida cubierta.

El método utilizado mostró mejores resultados en coníferas que en frondosas principalmente debido a la existencia de zonas con encina en monte bajo con cantidades altas de matas que comparten una misma copa. Las zonas de monte alto mostraron una media menor de errores, aunque es cierto que las parcelas de monte alto tenían encinas adehesadas con copas muy grandes y separadas entre sí lo que mejora su detección.

En el caso de las coníferas, se observaron diferencias entre pino y arizónica, aunque no se pudo ofrecer un resultado claro debido a que solo se realizaron 6 parcelas de arizónica. Las diferencias pueden deberse a que generalmente el pino tenía mayor densidad por parcela lo que complica la detección de árbol individual debido a la presencia de individuos dominados a lo que hay que sumar la irregularidad estructural de las masas y la curvatura de los fustes que produjo Filomena en 2021.

Se comprobó la predicción que ofrecería el algoritmo si se utilizan los arboles totales del inventario de campo con resultados similares (478.356 árboles) a los de la tabla 3 (469.773 árboles) y tabla 5 (469.044 árboles) en este caso se estimarían con la configuración ws2. Lo interesante fue que el histograma de los errores parece indicar que posiblemente el número real de árboles sea mayor del estimado debido a que hay parcelas en las que se infraestiman muchos individuos (figura 8). Esto es debido a que el algoritmo no es capaz de localizar individuos del estrato inferior ya que se toma como punto de partida un MDAV en el que cada píxel guarda el valor máximo de la altura que ocupa. Esto se suma a la existencia de matas de encina con múltiples fustes que convergen en una misma copa haciendo poco probable su localización. En parcelas de pinos este problema fue anecdótico y se produjo en un numero pequeño de parcelas que o bien tenían pequeñas encinas

de hasta 2 metros brotando como parte de la sucesión vegetal previsible para la zona o en zonas muy afectadas por Filomena en las que se curvaron tanto los fustes que ha generado que algunos individuos tengan la copa debajo de la del vecino.

Durante la realización del estudio fueron contemplados métodos basados en imágenes para comparar resultados, pero generalmente llegaron al 50% de acierto. Además, son económicamente menos atractivos de aplicar ya que requieren fotos con un tamaño de píxel de 10 cm, son más difíciles de programar y de entrenar.

De cara al posicionamiento de los arboles y su identificación se podría utilizar redes neuronales convolucionales o tecnologías similares ya que en 55 parcelas de las 99 se tomaron todos los datos de alturas y se geolocalizaron los fustes de cada árbol para después crear capas de puntos en formato “shape” para ser comparados visualmente en un GIS y los resultados fueron prometedores, lo que nos acercaría a la identificación de arboles individuales y mas tarde a la delimitación de sus copas. La propuesta podría ser utilizar algoritmos que tengan en cuenta la cercanía entre ambos puntos y la similitud entre sus alturas. Los posibles problemas a tener en cuenta serían que el filtro de máximos locales señala el punto más alto del ápice de las copas y en campo se han medido los fustes por lo que se pueden generar diferencias notables en los árboles que tengan el centro de la copa dentro de una parcela de muestreo, pero no su fuste o viceversa.

6. Conclusiones

La utilización de los datos LiDAR con densidades mayores de 2puntos/m^2 como los esperados en la tercera cobertura PNOA mediante una aproximación de árbol individual puede ser una herramienta útil para estimar la densidad en masas forestales.

El método mejora su eficacia cuando la masa no tiene cobertura completa (Cantero et al, 2017) y tiene una altura uniforme ya que será incapaz de localizar el estrato inferior en masas arbóreas estratificadas,. Llo que provoca que en el caso concreto de la Casa de Campo de Madrid el número real de arboles probablemente sea mayor al estimado.

Sería necesaria la realización de mas inventarios para poder representar mejor a cada especie y si fuera posible, tomar datos dentro de una misma especie en masas con fracción de cabida cubierta y alturas distintas. Un ejemplo claro según los resultados sería la encina ya que a pesar de tener pocas parcelas de monte alto se comportó de manera sustancialmente distinta a las parcelas de monte bajo.

Los métodos basados en imágenes demostraron potencial de uso en un futuro, aunque tienen una barrera de entrada económica moderada, así como de conocimientos de programación y necesitan muchos más datos de entrenamiento para poder mejorar sus predicciones actuales.

7. Agradecimientos

Quisiéramos agradecer en primer lugar a David Martín Molina por su dedicación durante la realización de las parcelas que conforman el inventario. A la UTE en especial a José María López y Patricia Martín de la UTE Parques Madrid Lote 6. Responsables de la gestión de la casa de campo por la ayuda y el acompañamiento durante las tareas de campo y por último al ayuntamiento de Madrid.

8. Bibliografía

ANACONDA SOFTWARE DISTRIBUTION.; 2020. Anaconda Documentation. Anaconda Inc.

BALL, J.G.C.; HICKMAN, S.H.M.; JACKSON, T.D.; KOAY, X.J.; HIRST, J.; JAY, W.; ARCHER, M.; AUBRY-KIENTZ, M.; VINCENT, G.; COOMES, D.A.; 2023. Accurate delineation of individual tree crowns in tropical forests from aerial RGB imagery using Mask R-CNN. Remote Sens Ecol Conserv. 9(5):641-655.

CANTERO FAUQUIER, FJ.; TOMÉ MORÁN, JL.; BRAVO FERNÁNDEZ, JA.; FERNÁNDEZ-LANDA, A.; Herramientas de localización de árboles individuales con el módulo de procesado de QGIS a partir de información LiDAR y ortofotografía aérea. 7CFE01-137. Plasencia.

FERNANDEZ-LANDA, A.; TOMÉ, J.L.; SANDOVAL, V.; VALLEJO, R.; 2017. Integrando datos LiDAR, información satelital y parcelas del Inventario Forestal Nacional español en la predicción de variables de inventario. 7º CFE. Plasencia.

HYYPPÄ, J.; INKINEN, M.; 1999. Detecting and estimating attributes for single trees using laser scanner. The Photogrammetric Journal of Finland, 16, pp 27-42.

LATELLA, M.; SOLA, F.; CAMPOREALE, C. A.; 2021. Density-Based Algorithm for the Detection of Individual Trees from LiDAR Data. Remote Sens, 13, 322.

NÆSSET, E.; 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. Remote Sens. Environ. 80, 88–99.

R CORE TEAM.; 2024. R: A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna, Austria.

ROUSSEL, J-R.; AUTY, D.; COOPS, N.; TOMPALSKI, P.; GOODBODY, T.R.H.; MEADOR A.S.; BOURDON J-F.; BOISSIEU, F.; ACHIM, A.; 2020. lidR: An R package for Analysis of Airborne Laser Scanning (ALS) data. Remote Sensing of Environment, Volume 251, 112061, ISSN 0034-4257.

VALBUENA, M. A.; 2013. Determinación de variables forestales de masa y de árboles individuales mediante delineación de copas a partir de datos LiDAR Aerotransportado. Aplicación a las masas de Pinus Sylvestris L. en Álava. Tesis doctoral. Universidad de La Rioja. Escuela Técnica Superior de Ingeniería Industrial.

VAN ROSSUM, G.; & DRAKE JR, F. L.; 1995. Python reference manual. Centrum voor Wiskunde en Informatica Amsterdam.

WEINSTEIN, B.G.; MARCONI, S.; BOHLMAN, S.; ZARE, A.; WHITE, E.P.; 2019. Individual Tree-Crown Detection in RGB Imagery Using Semi-Supervised Deep Learning Neural Networks. Remote Sensing; 11, 1309.