



---

**Universidad de Valladolid**  
**Campus de Palencia**

**ESCUELA TÉCNICA SUPERIOR  
DE INGENIERÍAS AGRARIAS**

**Máster en Ingeniería de Montes**

**ESTUDIO DE LA PRODUCTIVIDAD DE LAS  
MASAS DE REPOBLACIÓN DE PINO  
LARICIO (*Pinus nigra* Arn.) EN LA RIOJA A  
PARTIR DE TECNOLOGÍA LIDAR  
AEROTRANSPORTADA**

**Alumno: Roberto Calvo Sáenz**

Tutor: Dr. Felipe Bravo Oviedo

Director: Dr. Manuel Ángel Valbuena Rabadán

Julio de 2016





---

**Universidad de Valladolid**  
**Campus de Palencia**

**ESCUELA TÉCNICA SUPERIOR  
DE INGENIERÍAS AGRARIAS**

**Máster en Ingeniería de Montes**

**ESTUDIO DE LA PRODUCTIVIDAD DE LAS  
MASAS DE REPOBLACIÓN DE PINO  
LARICIO (*Pinus nigra* Arn.) EN LA RIOJA A  
PARTIR DE TECNOLOGÍA LIDAR  
AEROTRANSPORTADA**

**Alumno: Roberto Calvo Sáenz**

Tutor: Dr. Felipe Bravo Oviedo

Director: Dr. Manuel Ángel Valbuena Rabadán

Julio de 2016



## RESUMEN

Se ha realizado un estudio de la productividad potencial en madera de las masas de *Pinus nigra* Arn. procedentes de repoblación en la Comunidad Autónoma de La Rioja, a partir de información dasométrica del Inventario Forestal Nacional (IFN), información de edades de las masas e información LiDAR (acrónimo del inglés de *Laser Imaging Detection and Ranging*) aerotransportada del Plan Nacional de Ortofotografía Aérea (PNOA).

Para conocer las distintas productividades que presenta el pino laricio en La Rioja se ha analizado la información dasométrica tomada en el segundo, tercero y cuarto IFN en La Rioja, en los años 1988, 1999 y 2012 respectivamente. Con los pares de puntos de edad y altura dominante según la definición de Assmann ( $H_0$ ) se han elaborado los grupos de curvas de calidad de estación anamórficas, probando los modelos de crecimiento de Hossfeld I y Mitscherlich I, también conocido este último más frecuentemente como modelo de Richards-Chapman. Mediante procedimientos de ajuste lineal y no lineal se han ajustado las ecuaciones anteriores y se han establecido 5 Índices de Sitio (SI: 4, 8, 12, 16 y 20) que representan la altura dominante de Assmann (en metros) a la edad típica de 40 años.

A partir de la tecnología LiDAR se ha obtenido una estimación de la altura dominante de Assmann mediante la construcción de un modelo lineal  $y = a + b * x + \varepsilon$ , siendo "y" el valor a estimar, en este caso la altura dominante de Assmann ( $H_0$ ) medida en 2012 en el IFN 4, "a" el término independiente, "b" el término dependiente, "x" el valor de la métrica LiDAR del vuelo PNOA-LiDAR, siendo en este caso el valor del percentil 95 de la altura de la nube de puntos, y "ε" el término del error aleatorio del modelo.

Gracias al empleo de la tecnología LiDAR se ha elaborado un mapa de productividad potencial en madera para un total de 7.711,84 ha en formato vectorial para poder trabajarlo en Sistemas de Información Geográfica (SIG), de gran utilidad en la gestión forestal para el manejo de datos, en el cual se muestra en celdas cuadradas de 625 m<sup>2</sup> (25x25 m) el índice de sitio que corresponde a cada celda, en función de su valor de  $H_0$  y edad, de acuerdo a las clases establecidas a partir de las curvas de calidad de estación elaboradas en este mismo trabajo. En la información contenida en este vectorial se incluye también información importante de cara a la gestión como es la Fracción de Cobertura (FCC) de cada celda. La información obtenida servirá para orientar la gestión de este tipo de masas y las repoblaciones con la especie estudiada.

**Palabras clave:** IFN, LiDAR aéreo, calidad de estación, índice de sitio, *Pinus nigra*



# MEMORIA



## ÍNDICE:

|  |           |
|--|-----------|
| <b>1. ANTECEDENTES</b> .....   | <b>1</b>  |
| 1.1. PLANTEAMIENTO GENERAL .....   | 1         |
| 1.2. CURVAS DE CALIDAD DE ESTACIÓN .....   | 1         |
| 1.3. TECNOLOGÍA LIDAR .....  | 3         |
| <b>2. OBJETIVOS</b> .....  | <b>8</b>  |
| <b>3. MATERIAL Y MÉTODOS</b> .....   | <b>8</b>  |
| 3.1. ZONIFICACIÓN DEL ÁREA DE ESTUDIO .....  | 8         |
| 3.2. OBTENCIÓN DE DATOS.....   | 11        |
| 3.2.1. Información cartográfica y datos LIDAR .....                                | 11        |
| 3.2.2. Selección de las masas objeto de estudio.....                               | 13        |
| 3.2.3. Datos dendro y dasométricos de partida .....                                | 14        |
| 3.3. PROCESADO DE DATOS .....  | 16        |
| 3.3.1. Modelización de curvas de calidad de estación anamórficas.....              | 16        |
| 3.3.2. Procesado de la información LIDAR aérea.....                                | 20        |
| 3.3.3. Modelización de la información LIDAR .....                                  | 31        |
| 3.3.4. Incorporación de resultados al Sistema de Información Geográfica (SIG)..... | 33        |
| <b>4. RESULTADOS Y DISCUSIÓN</b> .....   | <b>34</b> |
| 4.1. RESULTADOS.....   | 34        |
| 4.1.1. Curvas de calidad de estación .....   | 34        |
| 4.1.2. Modelización de la información LIDAR aerotransportada .....                 | 38        |
| 4.1.3. Incorporación de resultados al Sistema de Información Geográfica (SIG)..... | 45        |
| 4.2. DISCUSIÓN .....   | 50        |
| <b>5. CONCLUSIONES</b> .....   | <b>53</b> |
| <b>6. BIBLIOGRAFÍA</b> .....   | <b>55</b> |

---

|                                    |            |
|------------------------------------|------------|
| <b>7. ANEJOS A LA MEMORIA.....</b> | <b>62</b>  |
| ANEJO 1.....                       | 63         |
| ANEJO 2.....                       | 66         |
| ANEJO 3.....                       | 68         |
| ANEJO 4.....                       | 83         |
| <b>AGRADECIMIENTOS.....</b>        | <b>108</b> |

## ÍNDICE DE TABLAS:

**Tabla 1.** Clasificación de la *American Society for Photogrammetry and Remote Sensing* (ASPRS) para las nubes de puntos LiDAR.

**Tabla 2.** Variables climáticas de las masas repobladas de *Pinus nigra* en La Rioja y variable ortométrica.

**Tabla 3.** Características del vuelo de captura de la información LiDAR del PNOA.

**Tabla 4.** Teselas, superficies y número de parcelas del Inventario Forestal Nacional (IFN) respecto a cada rango de edad estudiado.

**Tabla 5.** Valores de altura dominante de Assmann y edades a fecha del inventario para cada IFN estudiado.

**Tabla 6.** Modelos de crecimiento estudiados.

**Tabla 7.** Principales resultados del reporte de “*Catalog*” de Fusion® V3.50 para el archivo PNOA\_2010\_Lote5\_CYL-RIO\_550-4678\_ORT-CLA-COL.las.

**Tabla 8.** Algunos de los estadísticos de las nubes de puntos LiDAR arrojados por los algoritmos de procesamiento de Fusion® V3.50.

**Tabla 9.** Resultados del ajuste de las curvas de calidad de estación (valores de la ecuación de la curva guía).

**Tabla 10.** Ecuaciones de curva guía de Hossfeld I (mod.) ajustada para las repoblaciones de *Pinus nigra* Arn. en La Rioja y ecuaciones para cada índice de sitio (SI).

**Tabla 11.** Resultados de los modelos de predicción de altura dominante de Assmann a partir de datos LiDAR aéreos.

**Tabla 12.** Tests estadísticos realizados sobre el modelo (Model.4) y resultados.

**Tabla 13.** Resultados de la validación del modelo Model.4 y Model.1 para las 13 parcelas excluidas del ajuste.

**Tabla 14.** Representación de los índices de sitio para toda la superficie estudiada de *Pinus nigra* Arn. en La Rioja

## ÍNDICE DE FIGURAS:

**Figura 1.** Esquema general de un vuelo LiDAR.

**Figura 2.** Esquema de una masa forestal con haces de luz LiDAR y puntos de retorno.

**Figura 3.** Captura en FugroViewer™ V2.2 de una vista de una nube de puntos LiDAR del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja clasificada por colores de acuerdo con la clasificación de ASPRS (*American Society for Photogrammetry and Remote Sensing*).

**Figura 4.** Vista 3D en Fusion® V3.50 de nube de puntos LiDAR del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja coloreada con la información de las ortofotos en RGB.

**Figura 5.** Situación de la Comunidad Autónoma de La Rioja sobre el mapa de España.

**Figura 6.** Distribución en La Rioja de las masas objeto de estudio de pino laricio procedentes de repoblación.

**Figura 7.** Muestreo de la edad en campo con barrena Pressler y fase de conteo de anillos de crecimiento en gabinete.

**Figura 8.** Trayectoria de la altura dominante de Assmann respecto a la edad de las parcelas de *Pinus nigra* Arn. del IFN 2 IFN 3 e IFN 4.

**Figura 9.** Diagrama de flujo del proceso seguido para el procesado de la información LiDAR.

**Figura 10.** Salida gráfica del algoritmo “Catalog” de Fusion® V3.50 de los valores de densidad de retornos para tamaño de pixel de 1 m<sup>2</sup> para el archivo PNOA\_2010\_Lote5\_CYL-RIO\_550-4678\_ORT-CLA-COL.las.

**Figura 11.** Imagen de un mapa de intensidades de retornos LiDAR de una formación de *Pinus nigra* Arn. obtenida con el algoritmo “IntensityImage” de Fusion® V3.50 para una nube de puntos del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

**Figura 12.** Vista 3D en Fusion® V3.50 de puntos de suelo (*class: 2*) de una nube de puntos del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

**Figura 13.** Vista de Fusion® V3.50 de una parcela poblada por *Pinus nigra* Arn. La paleta de la izquierda muestra elevaciones ortométricas y la de la derecha valores normalizados respecto al nivel del suelo. Nube de puntos del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

**Figura 14.** Detalle 3D en Fusion® V3.50 de una formación de *Pinus nigra* Arn. en La Rioja con histograma de alturas a partir de 2 metros. Nube de puntos del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

**Figura 15.** Nube de puntos LiDAR, Modelo Digital del Terreno, y Modelo Digital de Vegetación. Datos LiDAR del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja .

**Figura 16.** Vista general en QGis® V2.8.1 del monte “Las Santanas” de Santa Engracia del Jubera. Vectorial tipo polígono con la tabla de atributos con la métrica LiDAR asociada a cada celda procesado con Fusion® V3.50. Datos del vuelo LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

**Figura 17.** Curvas de calidad de estación para las masas repobladas de *P. nigra* en La Rioja con edad típica de 40 años.

**Figura 18.** Gráficas de residuos, valores ajustados, gráfico cuantil-cuantil y de influencia de las observaciones del modelo Hossfeld I (mod.) lineal.

**Figura 19.** Curvas de calidad de estación con los límites entre calidades.

**Figura 20.** Diagramas de dispersión de la altura dominante de Assmann ( $H_0$ ) y las variables LiDAR *Elev.mean* y *Elev.P95*.

**Figura 21.** Diagrama de dispersión de  $H_0$  frente a *Elev.P95* con la recta ajustada (Model.4).

**Figura 22.** Gráfica de predichos y observados del modelo (Model.4).

**Figura 23.** Gráfico Q-Q para el modelo seleccionado (Model.4).

**Figura 24.** Gráficas de residuos, valores ajustados y de influencia de los residuos del modelo (Model.4).

**Figura 25.** Gráfico de predichos y observados para las 13 parcelas excluidas en el ajuste del modelo Model.4 empleadas para la validación del modelo.

**Figura 26.** Vista general en QGis® V2.8.1 del monte nº 12 “Valdeova y Almedaños” de Robres del Castillo clasificado por porcentajes de Fracción de Cabida Cubierta (FCC).

**Figura 27.** Vista general en QGis® V2.8.1 de un rodal de *Pinus nigra* del MUP nº 77 “Urquiara” de Santurdejo clasificado por alturas dominantes de Assmann calculadas a partir del modelo Model.4.

**Figura 28.** Vista general en QGis® V2.8.1 de un rodal de *Pinus nigra* en el paraje “San Juan de Agriones” de Santa Engracia del Jubera clasificado por alturas dominantes de Assmann calculadas a partir del modelo Model.4.

**Figura 29.** Vista general en QGis® V2.8.1 de los MUPs nº 233 “Hayedo y Abanto” de Ribafrecha y nº 209 “La Selva y Grimón” de Lagunilla del Jubera clasificado por edades a fecha de 2012 (año del IFN 4).

**Figura 30.** Vista general en QGis® V2.8.1 del monte “Las Santanas” de Santa Engracia del Jubera clasificado por calidad de estación con las clases definidas en este trabajo.

**Figura 31.** Vista general en QGis® V2.8.1 de los MUP nº 169 “La Santa” de Bezares y nº 218 “Santices y Cajjal” de Arenzana de Arriba clasificado por calidad de estación con las clases definidas en este trabajo.

## 1. ANTECEDENTES

### 1.1. PLANTEAMIENTO GENERAL

Desde las primeras investigaciones forestales en el siglo XVIII se ha intentado evaluar, clasificar, comprender y estimar la productividad, crecimiento y producción de un rodal forestal (ASSMAN, 1970 en PRETZSCH, 2009).

En los comienzos de la investigación forestal, para el estudio de la calidad de un rodal forestal, fue frecuente el empleo del volumen de madera en pie (PRESSLER, 1877 en PRETZSCH, 2009). No obstante, dada la alta correlación entre la edad de un rodal, su altura y su productividad total en madera (EICHHORN, 1902 en PRETZSCH, 2009) es posible una alternativa al uso del volumen en pie para estudiar la productividad, mediante el empleo de la altura, estando además menos influenciada que el volumen por las cortas que se llevan a cabo en las masas (PRETZSCH, 2009). La Ley de Eichhorn establece que hay una relación directa entre la producción de madera de un rodal y su altura (ASSMANN, 1970 en MADRIGAL, 1999; PARÉ y BOUCHON, 1987 en MADRIGAL, 1999; ORTEGA Y MONTERO, 1988).

En dasometría, se pueden definir distintos tipos de altura de la masa (altura media, altura dominante de Assmann, altura media de Lorey, ...), siendo frecuente el empleo de la altura dominante de Assmann, definida como la altura promedio de los 100 pies·ha<sup>-1</sup> de mayor diámetro, y de la edad, para el estudio de la productividad potencial en madera de una estación (ASSMANN, 1970 en PRETZSCH, 2009; ORTEGA, 1989; BENGOA, 1999; BRAVO & MONTERO, 2001). Debido a que la altura dominante está menos influenciada por las cortas que se aplican en las masas que la altura media, es más recomendable el empleo de la primera para estudiar la productividad (ASSMANN, 1970 en PRETZSCH, 2009; BENGOA, 1999).

### 1.2. CURVAS DE CALIDAD DE ESTACIÓN

El empleo de curvas de calidad de estación para evaluar la productividad de una estación forestal mono-específica y regular es una de las técnicas comúnmente usada en la ciencia forestal. Un juego de curvas es una familia de patrones de desarrollo de la altura de la masa (generalmente  $H_0$ ) frente a la edad, siendo el método de referencia más usado el Índice de Sitio (SI), que se define como la altura dominante del rodal a una edad especificada o edad típica (BRAVO et al., 2012). El Índice de Sitio, tiene una larga historia de desarrollo y empleo para el estudio de la productividad forestal (WEISKITTEL et al., 2011).

La altura dominante de Assmann, representada comúnmente como  $H_0$  o  $H_{100}$ , es un parámetro de importancia en crecimiento forestal y modelos de producción (OLIVER &

LARSON, 1996; BRAVO & MONTERO, 2001), siendo además un elemento básico en la ecología forestal y el manejo de ecosistemas (BARNES et al., 1997) y uno de los tres parámetros, junto con la densidad y el área basimétrica, fundamentales desde el punto de vista dasométrico para caracterizar de forma más sintética una masa forestal (BENGOA, 1999).

Para el estudio de la calidad de estación pueden emplearse factores ecológicos asociados con la estación o variables medidas de forma directa sobre los árboles, siendo habitual el empleo del patrón de crecimiento en altura dominante (ADAME et al., 2007), como ya se ha indicado. El uso de la altura dominante para el estudio de la calidad de estación es ampliamente empleado en masas monoespecíficas, monoestratificadas y coetáneas, estando su uso más discutido en masas mixtas en sentido amplio (PRETZSCH, 2009).

En muchas especies maderables, el crecimiento en altura de los pies dominantes (100 pies más gruesos  $\cdot \text{ha}^{-1}$ ) se asume que se mantiene sin cambios en un amplio intervalo de valores de densidad de la masa. Esta suposición permite el empleo de la altura dominante, a una edad de referencia especificada (edad típica), como índice de calidad de sitio (MEREDIEU et al., 2003).

Es vital conocer la capacidad productiva de un rodal dado para seleccionar la mejor estrategia de manejo o gestión (KOTZE & VONK, 1997; MONSERUD & HUANG, 2003), de forma que esta se adecue a las características y potencialidades productivas de cada caso. La necesidad de conocer la productividad de las masas se hace importante, por ejemplo, a la hora de definir la vocación de una masa, dejando las masas de buena calidad como productoras de madera y las de mala calidad como productoras de hongos, dado que en la mayor parte de las formaciones arboladas de peor calidad el valor de los hongos puede superar el valor maderable (ÁLVAREZ et al., 2001).

Los métodos tradicionales más usados para la elaboración de las curvas de calidad de estación emplean procedimientos de ajuste de ecuaciones, pudiéndose ver muchos de ellos como tres casos especiales de métodos generales de desarrollo de ecuaciones (CLUTTER et al, 1983 en BRAVO et al, 2012): el Método de la Curva Guía, Métodos de Predicción de Parámetros y Métodos de Ecuaciones Diferenciales.

En este trabajo se pretende estudiar la productividad de las masas repobladas de *Pinus nigra* Arn. en La Rioja y para ello se van a elaborar unas curvas de calidad de estación para la especie en la región mediante el empleo de las parcelas del segundo, tercer y cuarto Inventario Forestal Nacional (IFN), inventariadas en 1988, 1999 y 2012 respectivamente.

El pino laricio (*Pinus nigra* Arn.) es una especie que no se encuentra de forma natural en La Rioja siendo la totalidad de sus masas procedentes de repoblación. Ha sido frecuente el empleo de *Pinus nigra* en estaciones con escaso suelo y elevado déficit hídrico, siendo la

variedad más empleada la austriaca (*Pinus nigra* var. *austriaca*) (FERNÁNDEZ-ALDANA, 2015).

Según datos del IFN 4 (MAGRAMA, 2013), el pino laricio ocupa en La Rioja un total de 9.428,37 ha, superficie que crece actualmente de forma tímida gracias a las políticas de reforestación de tierras agrarias de la Política Agraria Común (PAC).

Actualmente es posible encontrar variedad de curvas de calidad de estación para distintas especies y distintas áreas geográficas, tanto para masas naturales (PITA, 1964; GARCÍA ABEJÓN, 1981, ALONSO y MADRIGAL, 2007) como para masas repobladas (RÍO et al., 2006; MADRIGAL et al., 2007).

Existen actualmente distintos trabajos de curvas de calidad de estación para *Pinus nigra* en distintas partes de España (GÓMEZ-LORANCA, 1996; PALAHÍ & GRAU, 2003; MARTÍN-BENITO et al., 2008; RÍO et al. 2006) y un juego de curvas específico para repoblaciones de *P. nigra* para la Comunidad de Castilla y León (RÍO et al., 2006).

### 1.3. TECNOLOGÍA LIDAR

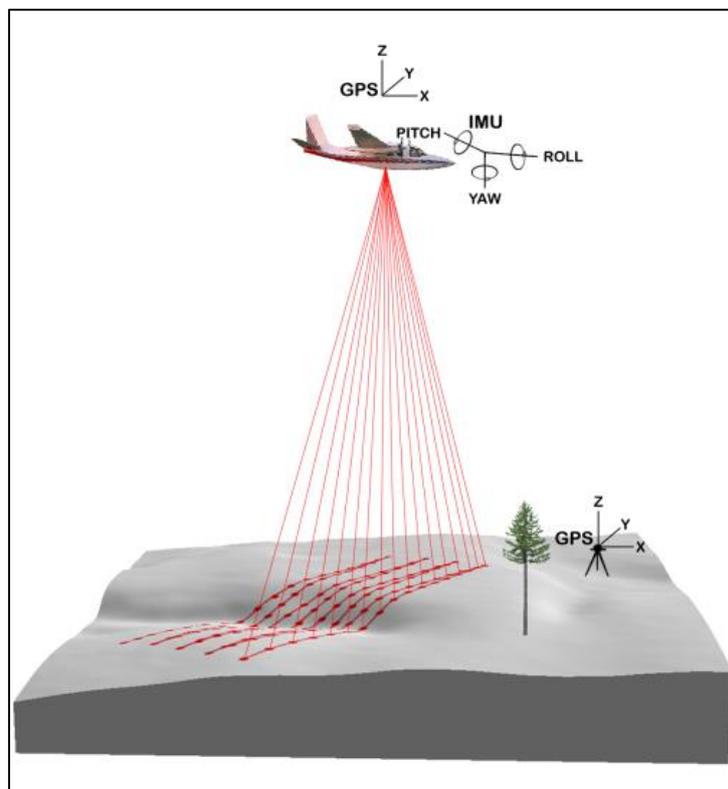
Gracias al avance y empleo de nuevas tecnologías se facilita la gestión de grandes superficies y permite abaratar costes en gran medida, favoreciendo en parte el no abandono de la planificación forestal gracias a esos menores costes y facilidades, que las nuevas tecnologías de gestión forestal aportan (FERNÁNDEZ-LANDA et al., 2013).

La tecnología LiDAR (*Ligth Detection and Ranging Systems* o *Laser Imaging Detection and Ranging*) emplea luz láser para medir distancias, siendo una tecnología que se emplea en multitud de casos, tiene aplicaciones para el estudio la topografía (KRABILL et al., 1984; SCHREIER et al., 1985; BUFTON et al, 1991; RITCHIE, 1995), las características de la vegetación forestal, como por ejemplo la biomasa forestal, la fracción de cabida cubierta y otras variables daso y dendrométricas (NELSON et al., 1984, 1988a,b; TESFAMICHAEL et al., 2010; VALBUENA, 2014), el volumen de madera gruesa comercializable,... (MACLEAN & KRABILL, 1986) e incluso se ha usado para estimaciones de los niveles de aerosoles en la atmósfera (MCGAUGHEY, 2015).

Actualmente encontramos distintas modalidades LiDAR, LiDAR terrestre y LiDAR aéreo, y es posible encontrar trabajos con aplicación en el campo forestal empleando LiDAR terrestre (WATT & DONOQUUE, 2005; UZQUIANO et al., 2014) y LiDAR aerotransportado (MAGNUSSEN & BOUDEWYN, 1998; ALONSO, 2011; TOMÉ-MORAN et al., 2013; VALBUENA, 2014). Los sistemas LiDAR aéreos han demostrado en numerosos estudios las buenas relaciones entre la métrica LiDAR y distintas variables de interés forestal como pueden ser las alturas de masa, el área basimétrica, el índice de área foliar,... (MAGNUSSEN & BOUDEWYN, 1998; MAGNUSSEN et al., 1999; NAESSET, 2004; ANDERSEN et al., 2005;

KOCH, 2010; KAARTINEN et al., 2012; VALBUENA, 2014), aunque la información obtenida mediante técnicas aéreas se limita a una vista vertical del bosque (UZQUIANO et al., 2014).

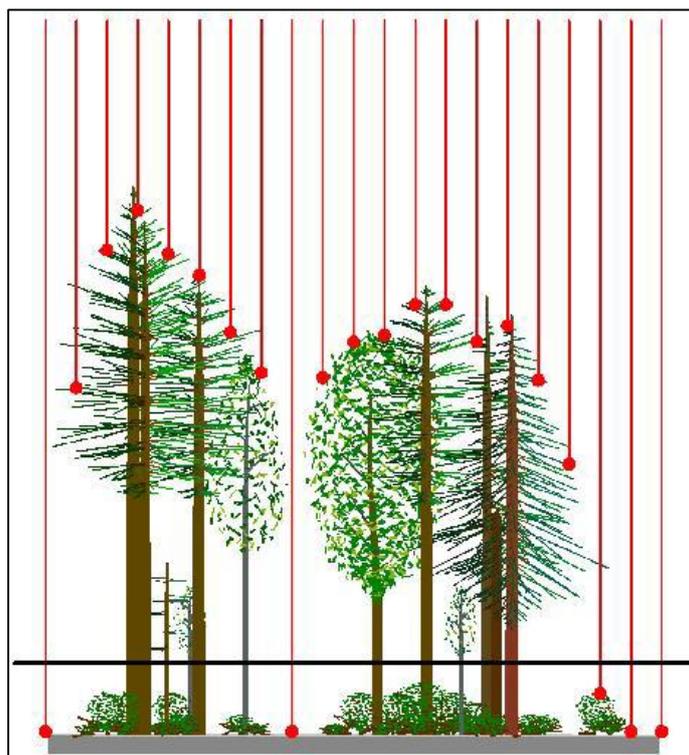
Ambos sistemas tienen la misma base, la diferencia es la forma de toma de información, siendo desde medios aerotransportados en el caso del LiDAR aéreo, y desde medios terrestres el LiDAR terrestre. Mediante el empleo de un haz láser se barre una zona de la que se quiere tener información (Figura 1). El vuelo y trayectoria del aeroplano, a la hora de tomar la información, se registra a través de sistemas GPS (*Geographical Positioning System*) y mediante Sistemas Inerciales (IMU), lo cual permite que se le asigne a cada punto de la nube una tripleta de coordenadas, de acuerdo a la localización del sensor LiDAR en cada momento de la toma de datos. Hay que destacar que es necesaria la presencia de estaciones GPS en tierra que sirvan de referencia al aeroplano (Figura 1).



**Figura 1.** Esquema general de un vuelo LiDAR. Tomado de MCGAUGHEY (2015).

La información que capturan los sistemas LiDAR, es una información tridimensional, y el resultado es una nube de puntos, en la cual, cada punto de la nube contiene información latitudinal, longitudinal y ortométrica, es decir, cada punto posee coordenada X, Y y Z. Normalmente esta información se refiere a coordenadas absolutas, aunque es posible también trabajar con esta información referida a coordenadas relativas.

La base de la medición con LiDAR consiste en que cuando el haz de luz choca con una superficie sólida, este rebota, provocando una serie de retornos, que son detectados por el sensor, detectando la distancia a la que se ha producido el retorno y asignándole unas coordenadas, de acuerdo con la posición GPS del aeroplano o de la posición del escáner LiDAR. Unos retornos del haz LiDAR se producirán en la primera línea de copas y tendremos otros que serán capaces de llegar al suelo a través de las copas, de esta forma se obtienen distintos retornos a distintos niveles verticales en la masa forestal, lo que va a permitir estudiar la estructura vertical de la vegetación con bastante precisión (Figura 2).



**Figura 2.** Esquema de una masa forestal con haces de luz LiDAR y puntos de retorno. Tomado de MCGAUGHEY (2015).

Los sensores láser aerotransportados permiten analizar los bosques en un formato 3D a lo largo de extensas áreas, además, a diferencia de los métodos de teledetección monoscópicos ópticos que dan información horizontal sobre el bosque, los sistemas LiDAR modernos proporcionan información georreferenciada de la estructura vertical de las masas forestales (POPESCU et al., 2002).

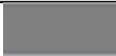
Hay una serie de ventajas claras del inventario LiDAR aéreo frente al inventario clásico, claro está, dependiendo de la variable forestal a medir, encontrando los mejores resultados del LiDAR aéreo para variables verticales como la altura dominante, altura media, .... pudiéndose llegar incluso, si la densidad de puntos de la nube LiDAR lo permite, a identificar pies individuales (VALBUENA, 2014). Otra ventaja de la información LiDAR de cara a la gestión forestal es que es información georreferenciada por lo que es posible, después del

correspondiente tratamiento, tratarla como una base de datos espacial (VALBUENA, 2014) e incorporar dicha información a un SIG (Sistema de Información Geográfica). Los SIG juegan un importante papel como integradores de gran variedad de datos y grandes volúmenes de información, propios de la gestión de un complejo campo como son los recursos renovables (SÁNCHEZ et al., 1999).

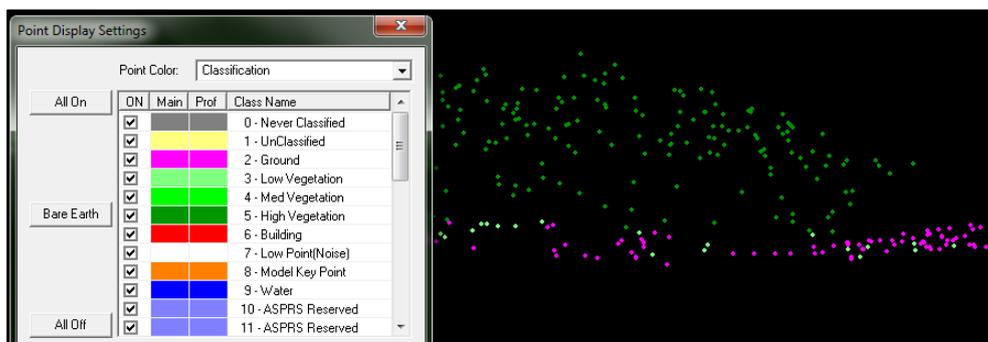
El empleo de la tecnología LiDAR para la gestión de masas forestales a gran escala permite reducir los costes de inventario en gran medida. A modo de ejemplo se puede dar un valor aproximado de en torno a 6 €/ha (FERNÁNDEZ et al., 2013).

Para poder proceder con el procesado de la información LiDAR, esta debe estar clasificada. Esto quiere decir, a cada punto de la nube LiDAR se le asigna una clase numérica, que tiene asociado un color (Tabla 1). La clasificación establece a qué nivel vertical u objeto pertenece el punto. Esta clasificación ha sido establecida por la *American Society for Photogrammetry and Remote Sensing* (ASPRS) (<https://www.asprs.org/>) y es la clasificación que encontramos en las nubes de puntos del LiDAR del PNOA, que son las que se emplean en este trabajo.

**Tabla 1.** Clasificación de la *American Society for Photogrammetry and Remote Sensing* (ASPRS) para las nubes de puntos LiDAR.

| Clase numérica | Clase de color  | Clase                           |
|----------------|---|---------------------------------|
| 0              |  | Creado, nunca clasificado       |
| 1              |  | Sin asignar                     |
| 2              |  | Suelo                           |
| 3              |  | Vegetación baja                 |
| 4              |  | Vegetación media                |
| 5              |  | Vegetación Alta                 |
| 6              |  | Edificio                        |
| 7              |  | Punto bajo (ruido)              |
| 8              |  | Clave de modelo                 |
| 9              |  | Agua                            |
| 10 - 11        |  | Reservado para definición ASPRS |
| 12             |  | Puntos de solape                |
| 13 - 60        |  | Reservado para definición ASPRS |

El hecho de que a cada punto se le asigne una clase de las establecidas por la ASPRS facilita el procesado, y, además, facilita la visualización en los distintos softwares disponibles (Figura 3).



**Figura 3.** Captura en FugroViewerTM® V2.2 de una vista de una nube de puntos LiDAR del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja clasificada por colores de acuerdo con la clasificación de ASPRS (*American Society for Photogrammetry and Remote Sensing*).

En la Figura 3, que se corresponde con un corte de la nube de puntos LiDAR del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) en una parcela de *Pinus nigra* Arn. en La Rioja, se aprecian claramente los puntos de suelo en morado (*class: 2*) y los puntos de vegetación en verde (*class: 3, 4 y 5*). Junto con la toma de la información LiDAR aérea, se toman fotografías aéreas, de modo que a cada punto LiDAR se le puede asignar el valor RGB (*Red, Green, Blue*) del punto de la fotografía que coincide con sus coordenadas X-Y, pudiéndose así visualizar la nube de puntos LiDAR en 3D y con los colores RGB reales de la ortofoto (VALBUENA, 2014) (Figura 4).



**Figura 4.** Vista 3D en Fusion® V3.50 de nube de puntos LiDAR del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja coloreada con la información de las ortofotos en RGB.

## 2. OBJETIVOS

El objetivo final de este trabajo es elaborar un grupo de curvas de calidad de estación y un mapa en formato vectorial donde figuran las distintas calidades de estación, elaborado a partir de tecnología LiDAR aerotransportada de forma que, se disponga de una información básica para la gestión de las masas repobladas de *Pinus nigra* Arn. en La Rioja y que sirva de orientación de cara a las repoblaciones con la especie estudiada.

El objetivo principal de este trabajo se alcanzará mediante los siguientes objetivos parciales:

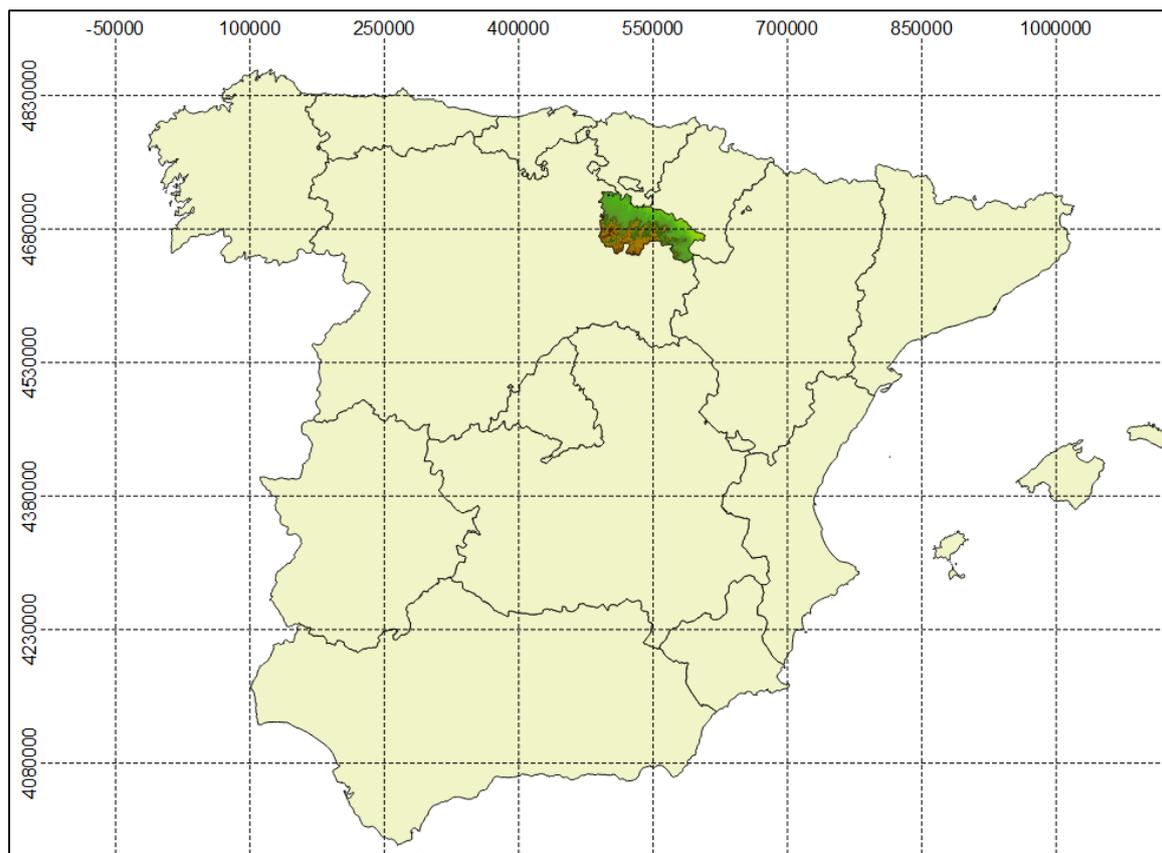
- El desarrollo una familia de curvas de calidad de estación aplicables a las masas repobladas de *Pinus nigra* Arn. en La Rioja.
- La obtención de un modelo válido para estimar la altura dominante de Assmann a partir de datos LiDAR aéreos para las masas repobladas de *Pinus nigra* Arn. repobladas en La Rioja.
- La elaboración de un mapa de calidades de estación en formato vectorial a partir de la información LiDAR disponible y de la información dasométrica del Cuarto Inventario Forestal Nacional (IFN 4).

Mediante este trabajo además se explorará la posibilidad de emplear la base de datos del Inventario Forestal Nacional para elaborar curvas de calidad de estación y modelos de predicción de variables dasométricas (altura dominante de Assmann en este caso concreto) a partir de información LiDAR aerotransportada.

## 3. MATERIAL Y MÉTODOS

### 3.1. ZONIFICACIÓN DEL ÁREA DE ESTUDIO

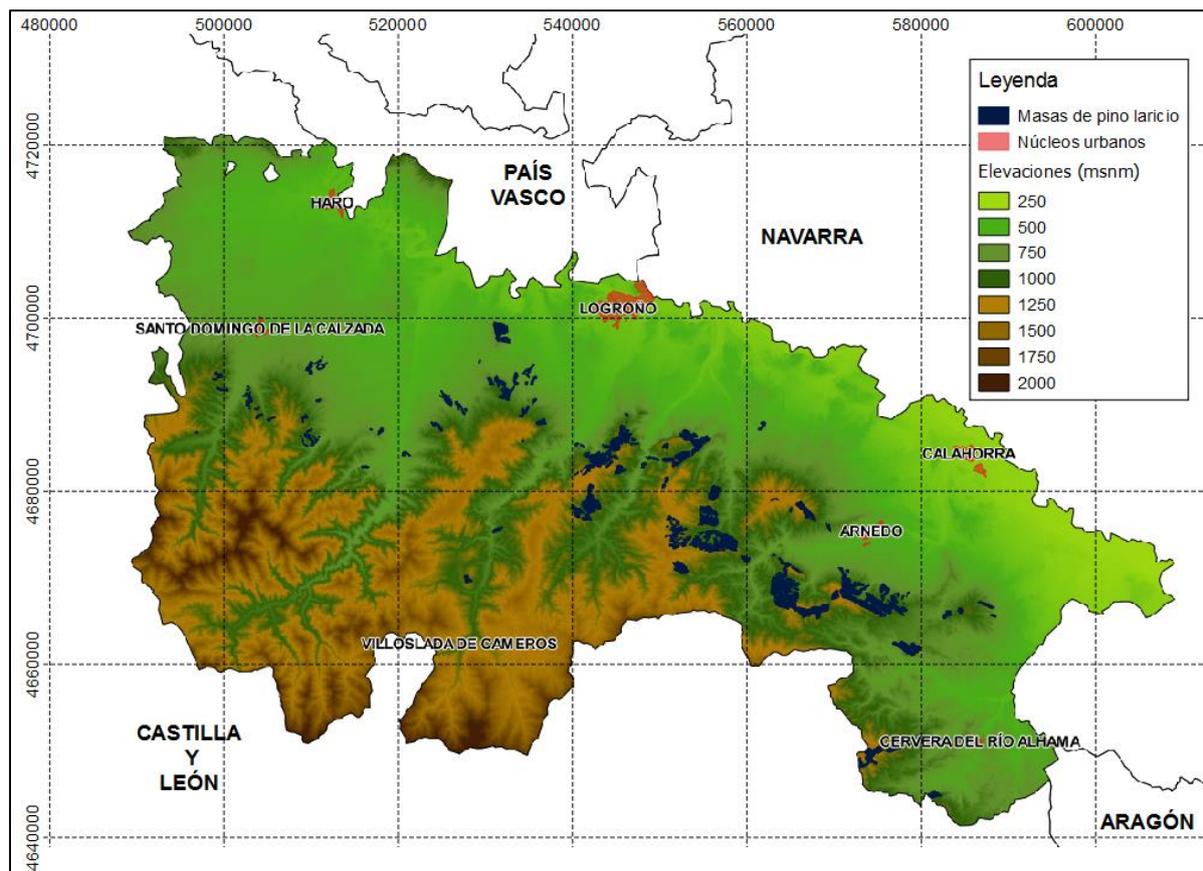
Este trabajo busca estudiar la productividad de las formaciones de *Pinus nigra* Arn. procedentes de repoblación que están localizadas en la Comunidad Autónoma de La Rioja, situada en el tercio norte de la península ibérica (Figura 5).



**Figura 5.** Situación de la Comunidad Autónoma de La Rioja sobre el mapa de España. Coordenadas respecto a EPSG: 25830.

Del total de 9.428,37 ha que ocupa el pino laricio en La Rioja, según datos del IFN 4 (MAGRAMA, 2013), se analizan en este estudio un total de 7.711,84 ha, que se corresponden con las formaciones en las cuales encontramos a *P. nigra* como especie principal (Figura 6).

Se excluyen de este estudio las formaciones que se localizan en los Montes Obarenes, en el límite septentrional de la región, que linda a la Comunidad Autónoma Vasca y a la provincia de Burgos, en Castilla y León, en las proximidades del municipio de Haro y sus alrededores.



**Figura 6.** Distribución en La Rioja de las masas objeto de estudio de pino laricio procedentes de repoblación. Coordenadas respecto a EPSG: 25830.

Las coordenadas extremas de la zona de estudio respecto al sistema de referencia ETRS89 UTM30N son:

X mínima: 496.600,2 m

X máxima: 584.908,2 m

Y mínima: 4.644.470,5 m

Y máxima: 4.699.617,1 m

Los pinares de pino laricio que se estudian en este caso se encuentran distribuidos en el territorio de forma dispersa, ocupando un amplio rango altitudinal, de temperaturas medias y de precipitaciones (Tabla 2).

**Tabla 2.** Variables climáticas de las masas repobladas de *Pinus nigra* en La Rioja y variable ortométrica. Fuente de las variables climáticas: Gobierno de La Rioja.

| Variables     | Altitud (msnm) | Precipitación (mm) | Temperatura (°C) |
|---------------|----------------|--------------------|------------------|
| <b>Máxima</b> | 1500           | 800                | 13,0             |
| <b>Media</b>  | 985            | 600                | 10,5             |
| <b>Moda</b>   | 1200           | 500                | 10,0             |
| <b>Mínima</b> | 470            | 400                | 8,0              |

Como podemos ver (Tabla 2) la mayor parte de las masas repobladas de *Pinus nigra* Arn. se encuentran entorno a una altitud de 1200 metros sobre el nivel del mar. El régimen de precipitaciones anuales más frecuente es en torno a 500 mm y las temperaturas en torno a 10 °C.

De acuerdo con la clasificación de RIVAS-MARTÍNEZ (1987), el pino laricio en La Rioja se encuentra en la región corológica mediterránea, en dos pisos bioclimáticos diferenciados, siendo estos el piso mesomediterráneo y el supramediterráneo. Es en el piso supramediterráneo donde encontramos la mayor parte de las formaciones que se están estudiando. Las masas de *Pinus nigra* en La Rioja se encuentran en regiones propias de masas de frondosas (*Fagus sylvatica*, *Quercus pyrenaica*, *Quercus faginea* y *Quercus ilex*).

## 3.2. OBTENCIÓN DE DATOS

### 3.2.1. Información cartográfica y datos LiDAR

La información cartográfica y la información LiDAR empleada en este trabajo, que ha sido descargada de varios servidores web, son compatibles con la Licencia Creative Commons Atribución 4.0 (CC-BY 4.0) de acuerdo con lo expuesto en la Orden FOM/2807/2015, de 18 de diciembre de 2015, por la que se aprueba la política de difusión pública de la información geográfica generada por la Dirección General del Instituto Geográfico Nacional.

Se parte de la información presentada en el Mapa Forestal de la Rioja (MFLR) en formato vectorial y extensión “.shp”, que ha sido descargada del servidor de cartografía de La Rioja (IDERioja) (<http://www.iderioja.larioja.org/>) junto con otra información cartográfica también en extensión “.shp”, como son los límites de los términos municipales de la C.C.A.A. de La Rioja y los Montes de Utilidad Pública (MUP).

La otra fuente cartográfica empleada es el Instituto Geográfico Nacional (IGN) (<http://www.ign.es/>), desde cuyo servidor se ha obtenido información de fotogramas aéreos, correspondientes a los realizados dentro del Plan Nacional de Ortofotografía Aérea (PNOA) en La Rioja en el año 2014 y en el año 2009, con una resolución de 25 cm/pixel en ambos

casos. Las hojas cartográficas del Mapa Topográfico Nacional (MTN) 1:50.000 que incluyen la zona de estudio son: 0202, 0203, 0204, 0240, 0241, 0242, 0243, 0280, 0281 y 0319.

También pertenece al PNOA la información LiDAR empleada, y que ha sido descargada del servidor del IGN (<http://www.ign.es/>) en extensión “.laz” y con un tamaño por archivo de 2 x 2 km de superficie. El año de toma de la información LiDAR es el año 2010 y se corresponde con el vuelo para las comunidades de Castilla y León y de La Rioja (lote 5).

La información LiDAR empleada tiene una densidad media de 0,5 puntos/m<sup>2</sup>, siendo algo mayor en las zonas de solape de las pasadas del aeroplano. Los archivos LiDAR descargados del servidor del IGN se encuentran clasificados según los estándares de la ASPRS (*American Society for Photogrammetry and Remote Sensing*) y están además coloreados mediante RGB a partir de las ortofotos del propio PNOA, que se toman a la par del LiDAR. Las características principales del vuelo LiDAR se muestran a continuación (Tabla 3).

**Tabla 3.** Características del vuelo de captura de la información LiDAR del PNOA. Fuente: IGN (<http://www.ign.es/>).

| <b>Sensor LiDAR y equipos auxiliares</b>              |   |
|---|---|
| Tipo de sensor  | Sensor LiDAR  |
| Campo de visión transversal (FOV)                     | < 50° efectivos                                       |
| Frecuencia de escaneado                               | > 45 kHz para:<br>FOV = 50° y alcance < 3.000 m       |
| Densidad promedio. Resolución espacial                | 0,5 puntos/m <sup>2</sup>                             |
| Resolución radiométrica de intensidades múltiples     | Rango dinámico ≥ 8 bits                               |
| Múltiples retornos                                    | ≥ 4 retornos/pulso con discriminación en altura ≥ 4 m |
| GPS   | Doble frecuencia > 2 Hz                               |
| Sistema inercial (IMU/INS)                            | Frecuencia de registro de datos ≥ 200 Hz              |
| <b>Vuelo y cobertura de puntos LiDAR</b>              |   |
| Dirección de las pasadas                              | Este – oeste (siguiendo paralelos)                    |
| Recubrimiento transversal de las pasadas              | ≥ 15  |
| Deriva  | < 0,1 °/hora  |
| Desviación de la trayectoria del avión                | < 15 m sobre la planificada                           |
| Desviación vertical sensor LiDAR                      | < 5 °   |
| Precisión global horizontal nadiral tras el procesado | RMSE X, Y < 30 cm<br>RMSE Z < 20 cm                   |
| Precisión general altimétrica: error medio cuadrático | RMSE Z < 0,20 m                                       |
| Precisión general altimétrica: error máximo           | ≤ 40 m en el 95 % de los casos                        |
| Dsicrepancia altimétrica entre pasadas                | ≤ 0,40 m  |
| <b>Toma de datos GPS en vuelo</b>                     |   |
| Distancia entre receptores                            | < 40 km   |
| Precisión posterior al procesado                      | RMSE ≤ 10 cm (X, Y, Z)                                |

Se ha trabajado en todo momento sobre el sistema de referencia ETRS89, con código de la *European Petroleum Survey Group* (EPSG) nº 25830 (para ETRS89 UTM 30N), puesto que es el sistema oficial en territorio español de acuerdo con el Real Decreto 1071/2007, de 27 de julio, por el que se regula el sistema geodésico de referencia oficial en España.

Para trabajar con la información cartográfica se ha empleado en todo momento el software QGIS® V2.8.1 que tiene licencia GPL (*General Public License*) y puede ser descargado de <http://www.qgis.org/es/site/>.

### 3.2.2. Selección de las masas objeto de estudio

Las masas forestales procedentes de repoblación pobladas por *P. nigra* se han seleccionado en primer lugar del Mapa Forestal de La Rioja (MFLR), que como se ha comentado en el apartado 3.2.1. Información cartográfica y datos LiDAR, se ha descargado del servidor de Infraestructuras Espaciales de La Rioja (<http://www.iderioja.larioja.org/>) en formato vectorial con extensión “.shp”.

Sobre la información presentada en el Mapa Forestal de La Rioja se ha realizado un proceso de depuración de teselas, en el cual se han eliminado todas aquellas en las que *P. nigra* estaba ausente o presentaba una ocupación inferior al 50 %, así como todas las teselas que no tenían suficiente entidad, habiéndose seleccionado como superficie mínima de las teselas para el estudio 1 ha. No obstante, en algunos casos concretos, se han mantenido polígonos menores a la hectárea debido principalmente a su localización y existencia de datos necesarios para abordar el estudio. Hay que destacar además que se han incorporado algunas formaciones pobladas por *P. nigra* de acuerdo con lo presentado por CALVO-SÁENZ (2014).

Con ayuda de las ortofotos de los años 2009 y 2014 se han depurado y re-digitalizado algunas teselas del MFLR. La época de captura del fotograma aéreo del año 2014 se corresponde con el periodo de crecimiento vegetativo, y el vuelo del 2009 con el periodo de parada vegetativa, por lo que se ha podido diferenciar con bastante seguridad las masas de frondosas de las de coníferas, en las zonas en las que su diferenciación era dudosa, a partir de la visualización de los distintos fotogramas mencionados.

Tras eliminar también las formaciones de las que no se tenía información de las edades y todas las masas de la zona de los Montes Obarenes, la superficie total del estudio abarca 7.718,91 ha, suponiendo esto casi el 82 % de la superficie que ocupa la especie en la región.

### 3.2.3. Datos dendro y dasométricos de partida

Para abordar el estudio de la productividad, a través de la calidad de estación, se necesita tener la información de las edades de las distintas formaciones. El grueso de la información de las edades de las masas repobladas de *P. nigra* ha sido proporcionada por la Dirección General del Medio Natural del Gobierno de La Rioja, y proviene de Proyectos de Ordenación, Planes Selvícolas y Planes de Aprovechamientos y de información cartográfica específica en formato vectorial.

De una pequeña porción de las formaciones objeto de estudio, que eran necesarias para abordar este trabajo, no se tenía información previa de las edades por lo que ha sido necesario diseñar un muestreo dirigido sobre estas formaciones para tomar muestras mediante una barrena Pressler (Figura 7).

Posteriormente a la toma de muestras en campo se ha calculado la edad de las masas mediante el conteo de anillos de crecimiento en gabinete (Figura 7) tras lijar levemente las muestras para poder diferenciar mejor los distintos anillos de crecimiento. Para el conteo se escanearon los canutillos con una resolución de 1500 ppp. Las muestras se tomaron a una altura de 20 cm por lo que al número de anillos contados en la muestra se le han sumado 2 años, 1 año por cada 10 cm altura sobre el suelo (MADRIGAL et al., 1992).



**Figura 7.** Muestreo de la edad en campo con barrena Pressler (izda.) y fase de conteo de anillos de crecimiento en gabinete (dcha.).

La repoblación más madura que se incluye en este estudio comenzó a plantarse en el año 1944 y la más joven es del año 2000. El rango de edades que se va a estudiar en este trabajo es de 20 a 70 años. Los rangos de edades más representados a nivel de superficie son las clases 40-50 y 50-60 años con 2.230,43 ha y 3.602 ha respectivamente, encontrándose sin embargo poca superficie de las clases de edad de 60-70 años y de 20-30 años (Tabla 4).

**Tabla 4.** Teselas, superficies y número de parcelas del Inventario Forestal Nacional (IFN) respecto a cada rango de edad estudiado. Sup.: Superficie; ha: hectáreas.

| Rango edad   | Superficie      |            | nº teselas | Sup. Máxima tesela | Sup. Media tesela | Sup (mínima tesela (ha)) | Nº parcelas IFN |
|--------------|-----------------|------------|------------|--------------------|-------------------|--------------------------|-----------------|
|              | ha              | %          |            | ha                 | ha                | ha                       |                 |
| 20 - 30      | 579,69          | 7,52       | 11         | 217,3              | 52,70             | 1,22                     | 10              |
| 30 - 40      | 807,32          | 10,47      | 49         | 82,46              | 16,47             | 1,64                     | 7               |
| 40 - 50      | 2.230,43        | 28,92      | 149        | 158,84             | 14,96             | 0,23                     | 45              |
| 50 - 60      | 3.602,00        | 46,71      | 193        | 153,03             | 18,66             | 0,31                     | 101             |
| 60 - 70      | 492,50          | 6,39       | 26         | 86,42              | 18,94             | 1,02                     | 15              |
| <b>Total</b> | <b>7.711,84</b> | <b>100</b> | <b>428</b> |                    |                   |                          | <b>178</b>      |

La información de la altura dominante ( $H_0$ ), variable dasométrica que va a emplearse para el estudio de la productividad, junto con la edad, procede de la base de datos del Inventario Forestal Nacional (IFN). En este estudio se analizan las parcelas puras de *Pinus nigra* medidas en el segundo, tercero y cuarto Inventario Forestal Nacional (IFN 2, IFN 3 e IFN 4 respectivamente). Las parcelas del IFN empleadas en este trabajo se muestran en el Anejo 1.

El valor de altura dominante (Tabla 5) para cada una de las parcelas seleccionadas se ha calculado en el IDE (Entorno de Desarrollo Integrado) de R RStudio® V0.99.896 mediante una rutina que se adjunta en el Anejo 3. R es un entorno de software libre (licencia GPL (*General Public License*)) para computación y salidas gráficas (<https://www.r-project.org/>). RStudio® puede descargarse de <https://www.rstudio.com/>. Para la elaboración del código en R se ha consultado también ROBINSON (2015).

Se han analizado en total 178 parcelas del IFN (Tabla 4 y Tabla 5). Al estudiar tres IFN seguidos se tienen 3 mediciones por cada parcela en un lapso de tiempo de 10 años (entre cada inventario). Hay que destacar, no obstante, que no se tienen 3 mediciones de todas las parcelas dado que existen parcelas de nueva creación, que no se midieron en inventarios anteriores (Anejo 1).

También encontramos casos en los cuales no se midió la misma parcela en los inventarios consecutivos por distintos motivos (cambio de uso de la masa, no localización del rejón

metálico que marca el centro de la parcela, ...), las cuales han sido excluidas del estudio. Se ha trabajado con un total de 178 mediciones, 43 correspondientes al IFN 2, 59 del IFN 3 y 76 del IFN 4 (Tabla 5).

**Tabla 5.** Valores de altura dominante de Assmann y edades a fecha del inventario para cada IFN estudiado.

| Inventario                 | IFN 2 (año 1988)   |             | IFN 3 (año 1999)   |             | IFN 4 (año 2012)   |             |
|----------------------------|--------------------|-------------|--------------------|-------------|--------------------|-------------|
|                            | H <sub>0</sub> (m) | Edad (años) | H <sub>0</sub> (m) | Edad (años) | H <sub>0</sub> (m) | Edad (años) |
| <b>Máximo</b>              | 9,78               | 38,0        | 17,65              | 49,0        | 21,97              | 62,0        |
| <b>Media</b>               | 5,84               | 23,2        | 7,95               | 33,8        | 10,53              | 45,3        |
| <b>Moda</b>                | 3,50               | 23,0        | 5,50               | 34,0        | 10,24              | 47,0        |
| <b>Mínimo</b>              | 3,00               | 11,5        | 3,80               | 20,0        | 5,84               | 17,0        |
| <b>Desviación estándar</b> | 1,63               | 7,0         | 2,39               | 7,3         | 2,78               | 9,4         |
| <b>Total parcelas</b>      | 43                 |             | 59                 |             | 76                 |             |

### 3.3. PROCESADO DE DATOS

#### 3.3.1. Modelización de curvas de calidad de estación anamórficas

El ajuste de las curvas de calidad de estación se ha realizado con el IDE RStudio® V0.99.896, al igual que los cálculos de la altura dominante. Se adjuntan las rutinas de código empleadas en el Anejo 3. Para la preparación y manejo de dichos códigos se ha empleado también el programa Notepad++® V6.7.5 (licencia GPL (*General Public License*)) que puede descargarse de <https://notepad-plus-plus.org/>. Las rutinas que se han empleado para los ajustes han sido modificadas a partir de las presentadas en BRAVO et al. (2015) y se adjuntan en el Anejo 3.

La metodología escogida para la elaboración de las curvas de calidad de estación ha sido en este caso el Método de la Curva Guía, debido principalmente al tiempo limitado del que se disponía para realizar el estudio y por su sencillez, obteniéndose unas curvas de tipo anamórfico, en las que la distancia entre las curvas se mantiene proporcional.

En este trabajo se ha seleccionado como edad típica 40 años, debido a que es una edad intermedia en el total de nuestra serie de datos y coincide además con la edad a mitad del turno para la especie, de acuerdo con lo presentado por RÍO et al. (2006), que recomienda una edad de 60-80 años en las mejores calidades y de 80-90 años en las peores, para repoblaciones de *Pinus nigra* Arn. en Castilla y León.

Para ajustar las curvas de calidad de estación para las masas de *P. nigra* procedente de repoblación en La Rioja se han probado los modelos de producción de Hossfeld I (mod.) y de Mitscherlich I (Tabla 6), tomados de KIVISTE et al. (2002). Se han seleccionado estos modelos puesto que cumplen con la premisa de que, pasan por el origen, tienen un punto de inflexión y tienen una asíntota horizontal, de acuerdo con el crecimiento natural que presentan

una especie forestal o una masa a lo largo de su vida, que se ajusta a una curva de tipo sigmoideal (KIVISTE et al., 2002).

**Tabla 6.** Modelos de crecimiento estudiados (Tomados de KIVISTE et al. (2002)) \* Clasificación de SHVETS Y ZEIDE (1996): PD: decrecimiento potencial; ED: decrecimiento exponencial.

| ID     | Nombre modelo   | Expresión matemática del modelo                    | Número de parámetros | Ámbito de definición                        | Grupo* |
|--------|---|--|----------------------|---|--------|
| Mod. 1 | Hossfeld I (mod.)                                       | $y = \frac{t^2}{(a + b \cdot t)^2}$ $a > 0$        | 2                    | $\forall t \geq 0$<br>$t \neq -\frac{a}{b}$ | PD     |
| Mod. 2 | Mitscherlich I (1919)<br>(Richards-Chapman (1959-1961)) | $y = a \cdot (1 - e^{-b \cdot t})^c$ $a, b, c > 0$ | 3                    | $\forall t \geq 0$                          | ED     |

En el modelo de producción de Hossfeld I (modificado) (Tabla 6) "y" representa la altura dominante ( $H_0$ ) en metros,  $t$  es la edad en años y "a" y "b" son los parámetros que hay que ajustar, siendo "a" el parámetro que afecta a la edad a la que se alcanza el punto de inflexión, siendo mayor esta edad para mayores valores de "a", y "b" afecta a la asíntota horizontal y a la edad que se alcanza el punto de inflexión, de modo que el aumento de "b" supone una disminución de ambos. Este modelo pertenece al grupo de modelos de decrecimiento potencial, de acuerdo con la clasificación de SHVETS y ZEIDE (1996).

En el modelo conocido habitualmente como Richards-Chapman (1959-1961), o modelo de Mitscherlich I (1919) (Tabla 6) "y" representa la altura dominante ( $H_0$ ) en metros, "t" es la edad en años y "a", "b" y "c" son los coeficientes que hay que ajustar, donde "a" coincide con la asíntota horizontal del modelo, de forma que con el aumento del parámetro "a" aumenta el valor de dicha asíntota. El parámetro "b" afecta a la edad a la que se alcanza el punto de inflexión, de modo que al aumentar "b", disminuye dicha edad. El parámetro "c" afecta al igual que el coeficiente "b" a la edad a la que se alcanza el punto de inflexión del modelo, de modo que aumentos del valor de "c" provocan aumentos en dicha edad. Este modelo pertenece al grupo de modelos de decrecimiento exponencial, de acuerdo con la clasificación de SHVETS y ZEIDE (1996).

Se exponen por separado, el procedimiento seguido para el ajuste de los modelos de producción presentados, buscándose en primer lugar, una linealización de los modelos del tipo  $y = (a + b \cdot t) + \varepsilon$  donde "y" es la variable de respuesta, "a" el término independiente, que indica la ordenada al origen, o lo que es lo mismo, el valor que toma la variable de respuesta para un valor de la variable regresora igual a 0, "b" el coeficiente que acompaña a la variable independiente o regresora "t", y que indica la pendiente de la recta. Siendo "ε" el término del error aleatorio del modelo.

### - Mod.1: Hossfeld I (mod.):

En primer lugar, se ha linealizado la función de Hossfeld I (mod.) definiendo como variable dependiente " $1/\sqrt{y}$ " y como variable independiente " $1/t$ ".

$$y = \frac{t^2}{(a + b \cdot t)^2} \quad \rightarrow \text{linealización} \rightarrow \quad \frac{1}{\sqrt{y}} = b + a \cdot \frac{1}{t}$$

Con los valores obtenidos en el ajuste lineal de la ecuación de Hossfeld I (mod.), realizado mediante el procedimiento "lm" de R, que nos definen la ecuación de la curva guía, se ha buscado la familia de curvas de calidad de estación, para una edad típica de 40 años y un total de 5 índices de sitio (SI 4, SI 8, SI 12, SI 16 y SI 20), los cuales indican la altura dominante, en metros, a la edad típica.

Para hallar las ecuaciones de las distintas curvas, a partir de la curva guía, manteniendo el parámetro "a" constante y para "t" igual a 40 años, y dando los distintos valores de SI definidos previamente, se obtienen distintos valores del parámetro "b", dando lugar a la primera familia de curvas.

A continuación, se ha realizado el proceso de regresión no lineal ("nlm") de R, que emplea el algoritmo de Gauss-Newton y el proceso "nlsLM" del paquete "minpack.lm" que emplea el algoritmo de Levenberg-Marquardt. Como valores semilla para el ajuste no lineal se han establecido los valores de los parámetros ajustados en el modelo lineal.

De forma análoga al caso del ajuste lineal, las distintas curvas de calidad se han obtenido a partir de la ecuación de la curva guía manteniendo "a" constante y para "t" igual a 40 años, dando los distintos valores de SI, se calculan los correspondientes valores del parámetro "b", obteniéndose así la segunda familia de curvas del modelo de producción de Hossfeld I (mod.).

### - Mod.2: Mitscherlich I (1919) / (Richards-Chapman (1959-1961)):

Siguiendo lo presentado por BRAVO et al. (2015) se ha realizado un ajuste lineal del modelo de Mitscherlich I, para lo que se ha definido como variable independiente " $\ln(e^{-b \cdot t})$ " y como variable dependiente " $\ln(y)$ ".

$$y = a \cdot (1 - e^{-b \cdot t})^c \quad \rightarrow \text{linealización} \rightarrow \quad \ln(y) = \ln(a) + c \cdot \ln(e^{-b \cdot t})$$

Para obtener los valores de los parámetros "a" y "c", debido a que el coeficiente "b" está incluido en la variable independiente, se realizan distintos ajustes de la ecuación linealizada de Mitscherlich I para distintos valores de "b", conforme a lo presentado por

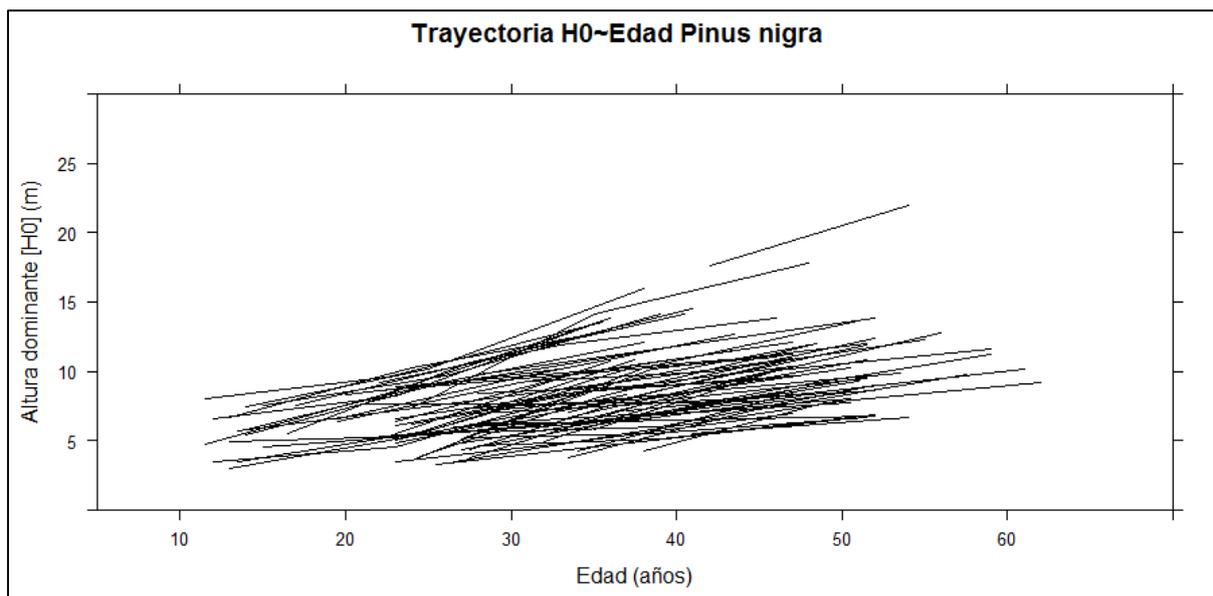
BRAVO et al. (2015) y partiendo de valores de otros estudios (FEKEDULEGN et al., 1999; BRAVO et al., 2001; RÍO et al., 2006; BRAVO et al., 2015). Una vez fijado un valor de " $b$ " adecuado se obtienen los valores de " $a$ " y " $c$ " mediante regresión lineal con el procedimiento " $lm$ " de R.

Tras obtener los coeficientes " $a$ " y " $c$ " de la curva guía, se busca la familia de curvas. De igual modo a lo descrito para el caso de la función de Hossfeld I (mod.), manteniendo constante el parámetro " $c$ " y el parámetro " $b$ ", y para " $t$ " igual a 40 años, dando los distintos valores de SI (SI 4, SI 8, SI 12, SI 6 y SI 20) vamos obteniendo los valores del parámetro " $a$ " y de esta forma la primera familia de curvas de calidad de estación de Richards-Chapman.

Con los valores de los coeficientes obtenidos en el ajuste lineal como valores semilla, se ha realizado el proceso " $nlm$ " de R, que emplea el algoritmo de Gauss-Newton y el proceso " $nlsLM$ " del paquete " $minpack.lm$ " de R, que emplea el algoritmo de Levenberg-Marquardt. También se probó el procedimiento " $nlm$ " y " $nlsLM$ " de R dando como valores semilla los parámetros de otros estudios (FEKEDULEGN et al., 1999; BRAVO et al., 2001; RÍO et al., 2006; BRAVO et al., 2015).

De forma análoga para lo descrito en el Mod.1 de Hossfeld I (mod.) y de igual modo que en el caso del modelo lineal, dando valores al parámetro " $a$ " para la edad de referencia " $t$ " igual a 40 años, manteniendo " $c$ " y " $b$ " constantes y fijando para la variable dependiente los distintos índices de sitio se obtienen los distintos valores de " $a$ " y de esta forma el segundo grupo de curvas de calidad de estación del modelo de Mitscherlich I.

A la hora de seleccionar el modelo más adecuado para nuestra serie de datos de  $H_0$  y edades se ha comparado error de estimación de los parámetros, el error residual estándar de cada modelo (RSE) y el coeficiente de determinación ( $R^2$ ), así como la representación de las curvas sobre la dispersión de los pares de datos de  $H_0$ -Edad (Figura 8). Gráficamente se han visualizado además los residuos de cada modelo. Las salidas de R, tanto gráficas como numéricas se muestran en el Anejo 4.



**Figura 8.** Trayectoria de la altura dominante de Assmann respecto a la edad de las parcelas de *Pinus nigra* Arn. del IFN 2 IFN 3 e IFN 4.

Se ha obtenido también de forma analítica el límite entre las clases de calidad de estación definidas (SI 4, SI 8, SI 12, SI 6 y SI 20) para el grupo de curvas de calidad elegido, de forma que se pueda asignar el valor del índice de sitio a cada celda del archivo vectorial que se busca obtener en este trabajo, en función del valor de la edad y la altura dominante que presente cada una.

### 3.3.2. Procesado de la información LiDAR aérea

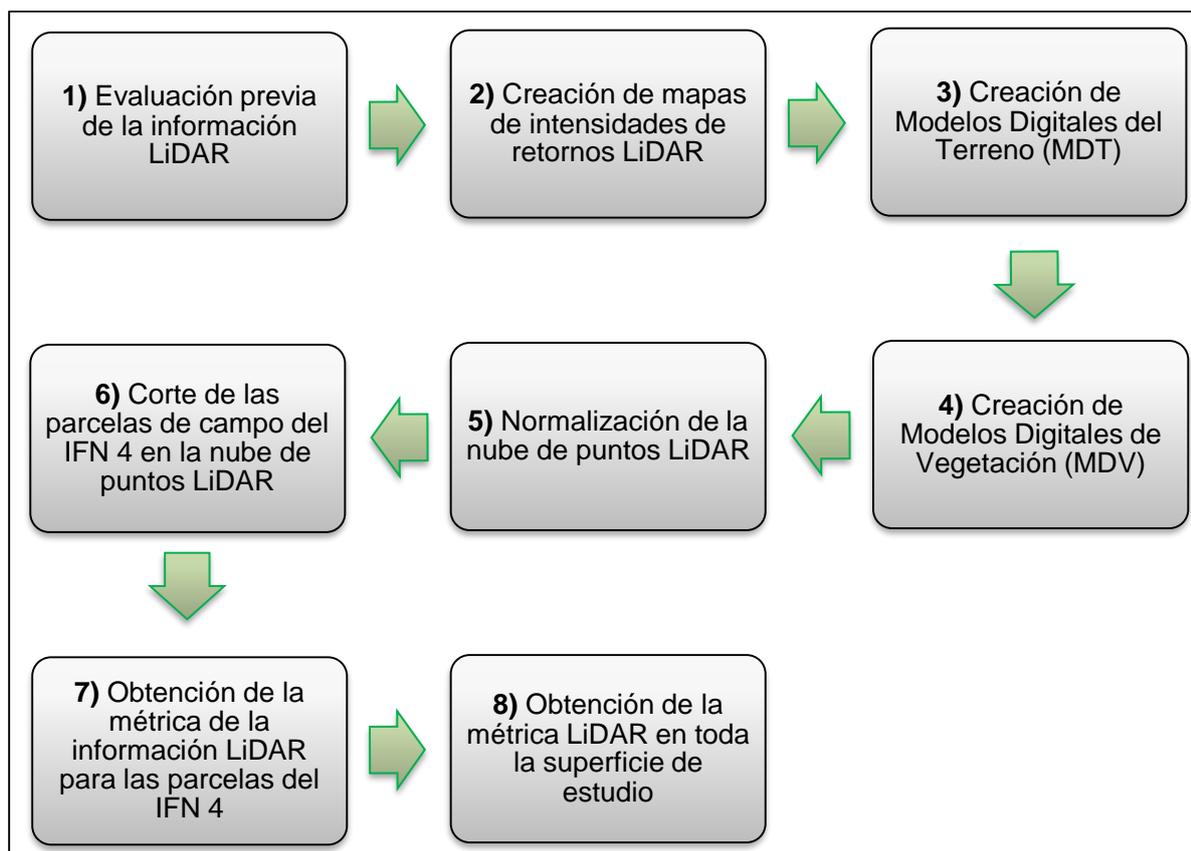
Para trabajar con datos LiDAR se ha empleado en primer lugar el programa LASTask ToolsADB® V1.1.2, programado por D. Alejandro de Blas y que se ha descargado del servidor del IGN (<http://www.ign.es/>), para descomprimir los archivos descargados en extensión “.laz” a “.las”. También se ha empleado el visor FugroViewerTM® V2.2 (<http://www.fugroviewer.com/default.asp>), que permite visualizar datos LiDAR brutos. FugroViewerTM® tiene una licencia temporal para lo que es necesario suscribirse a la plataforma.

El procesado de la información LiDAR se ha realizado exclusivamente la herramienta Fusion® V3.50 (<http://forsys.cfr.washington.edu/fusion/fusionlatest.html>), basado en la librería OpenGL® (<https://www.opengl.org/>) y programado en C++, específica para trabajar datos LiDAR en aplicaciones forestales y desarrollada por Servicio Forestal del Departamento de Agricultura de los Estados Unidos (*Forest Service-United States Department of Agriculture (USDA)*). Fusion® incorpora funciones de la librería de datos LiDAR Lastools® (<https://rapidlasso.com/>) cuya fuente de código tiene licencia LGPL (*Lesser General Public License*).

Se ha empleado la GUI (*Graphical User Interface*) de Fusion® V3.50, para visualizar las nubes de puntos. No obstante, para el procesado de la información LiDAR se han corrido los algoritmos incluidos en Fusion® V3.50 sobre el Procesador de Comandos de Windows (CMD). Los comandos se han preparado con el programa Notepad++® V6.7.5 y mediante hojas de cálculo de Microsoft Excell® y estos se muestran en el.

Para el procesado de la información LiDAR se ha empleado el programa Fusion® V3.50 exclusivamente, aunque también se probaron inicialmente los algoritmos incluidos en LasTools® V160606. Finalmente se decidió emplear únicamente Fusion® V3.50 dado que está desarrollado para aplicaciones específicas en el campo forestal y además permite lanzar sus algoritmos de procesado sobre la consola de comandos de Windows (CMD), lo que hace más rápido y sencillo el procesado, especialmente en un trabajo como este, en el cual se han empleado un total 172 archivos LiDAR (".las").

Para el procesado de la información LiDAR se ha seguido un proceso consistente 8 partes fundamentales (Figura 9), que se detallan más adelante.



**Figura 9.** Diagrama de flujo del proceso seguido para el procesado de la información LiDAR.

## 1) Evaluación previa de la información LiDAR

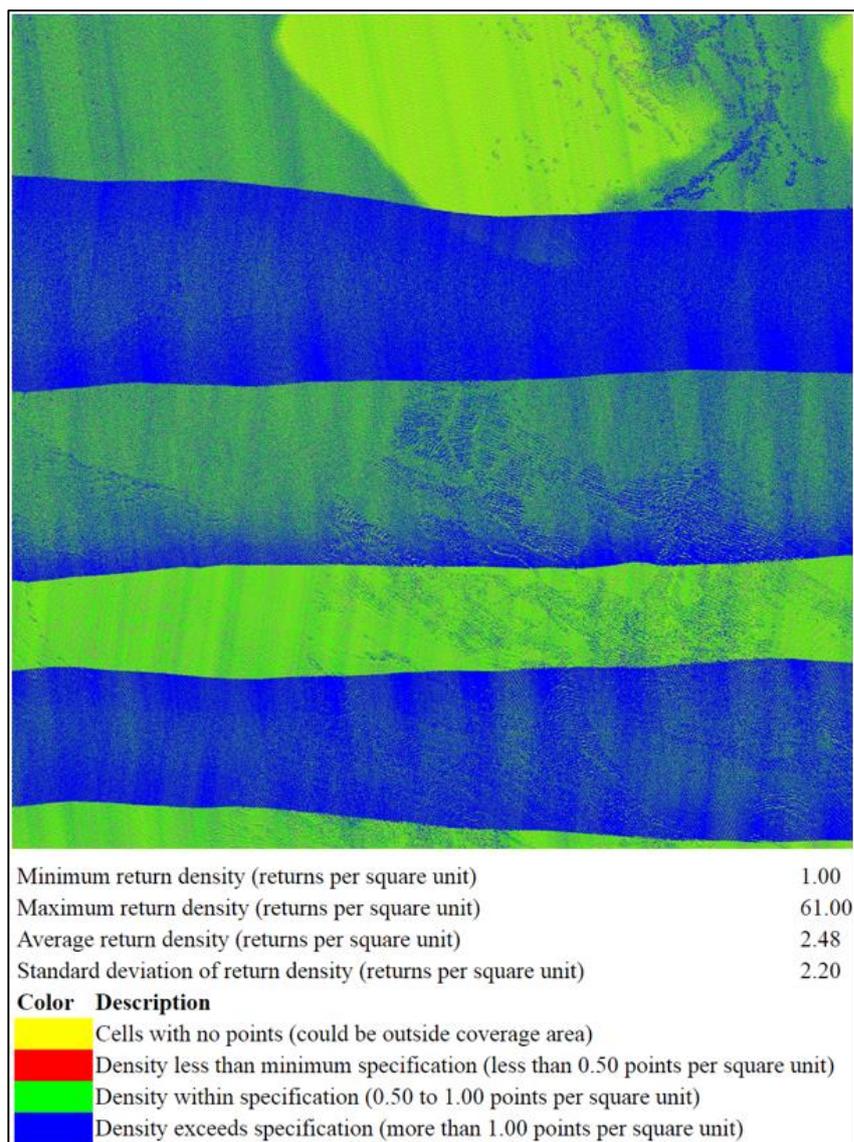
A partir del algoritmo “*Catalog*” de Fusion® V3.50 se ha realizado un análisis previo de la información LiDAR para ver sus características. A partir de dicho algoritmo se puede conocer la cobertura de los datos, la densidad de puntos y de retornos y los valores de intensidades. Este es el primer paso realizado, que permite conocer los datos antes de empezar con su procesado, sirviendo la información del reporte de “*Catalog*” como marco de referencia para el análisis. El comando que se ha ejecutado en la consola de comandos de Windows se muestra en el Anejo 2.

A modo de ejemplo se presenta la Tabla 7 y la Figura 10, que se corresponde con la información del archivo LiDAR PNOA\_2010\_Lote5\_CYL-RIO\_550-4678\_ORT-CLA-COL.las devuelta por el comando de “*Catalog*” de Fusion® V3.50.

**Tabla 7.** Principales resultados del reporte de “*Catalog*” de Fusion® V3.50 para el archivo PNOA\_2010\_Lote5\_CYL-RIO\_550-4678\_ORT-CLA-COL.las.

| Resumen de archivo |                   |              | Resumen por clasificación ASPRS |             |                      |
|--------------------|-------------------|--------------|---------------------------------|-------------|----------------------|
|                    |                   |              | Valor de clase ASPRS            | Nº retornos | Leyenda              |
| X (m)              | Máxima            | 551.999,99   | 1                               | 13.158      | Sin clasificar       |
|                    | Mínima            | 550.000,00   | 2                               | 1.764.988   | Suelo                |
| Y (m)              | Máxima            | 4.677.999,99 | 3                               | 1.200.096   | Vegetación baja      |
|                    | Mínima            | 4.676.000,00 | 5                               | 699.714     | Vegetación alta      |
| Z (m)              | Máxima            | 1.377,53     | 6                               | 536         | Edificios            |
|                    | Mínima            | 1.073,15     | 7                               | 81          | Puntos bajos (ruido) |
| Nº retornos        | 1 <sup>os</sup>   | 7.757.961    | 12                              | 4.495.603   | Puntos de solape     |
|                    | 2 <sup>os</sup>   | 401.563      | Resto clases                    | 0           |                      |
|                    | 3 <sup>os</sup>   | 14.480       | TOTAL                           | 8.174.176   |                      |
|                    | 4 <sup>os</sup>   | 172          |                                 |             |                      |
|                    | 5 <sup>os</sup> + | 0            |                                 |             |                      |
|                    | TOTAL             | 8.174.176    |                                 |             |                      |

De acuerdo a lo presentado en la Tabla 7, el archivo PNOA\_2010\_Lote5\_CYL-RIO\_550-4678\_ORT-CLA-COL.las, contiene un total de 8.174.176 retornos para un tamaño de 2.000 x 2.000 metros. La densidad de puntos, sin incluir los puntos de solape resulta de 0,91 puntos/m<sup>2</sup>. En todos los archivos LiDAR empleados se tienen como máximo 4 retornos, no observándose puntos correspondientes al 5º retorno en adelante.



**Figura 10.** Salida gráfica del algoritmo “*Catalog*” de Fusion® V3.50 de los valores de densidad de retornos para tamaño de pixel de 1 m<sup>2</sup> (*square unit* = 1 m<sup>2</sup>) para el archivo PNOA\_2010\_Lote5\_CYL-RIO\_550-4678\_ORO-CLA-COL.las.

Como podemos observar (Figura 10) la densidad de puntos se encuentra entre 0,5 y 1 retornos/m<sup>2</sup>, siendo máxima en las bandas de solape (densidad máxima de 61 puntos/m<sup>2</sup>). En ningún caso la densidad de puntos es menor de lo establecido en la Tabla 3, siendo la densidad promedio de 2,48 puntos/m<sup>2</sup>.

## 2) Creación de mapas de intensidades de retornos LiDAR

Con la herramienta Fusion® V3.50 se han realizado los mapas de intensidades de los retornos de la zona de estudio mediante la orden “*IntensityImage*”. Se ha empleado en este

caso un tamaño de pixel de 1x1 metro y el rango de frecuencias se ha fijado en base a las características de los archivos LiDAR, siendo el rango empleado para elaborar las imágenes de intensidades de 0 a 255. En el Anejo 2 se muestra el comando de “*IntensityImage*” empleado. Una aplicación práctica de los mapas de intensidades es que permiten diferenciar con claridad las copas de los árboles del suelo (Figura 11).

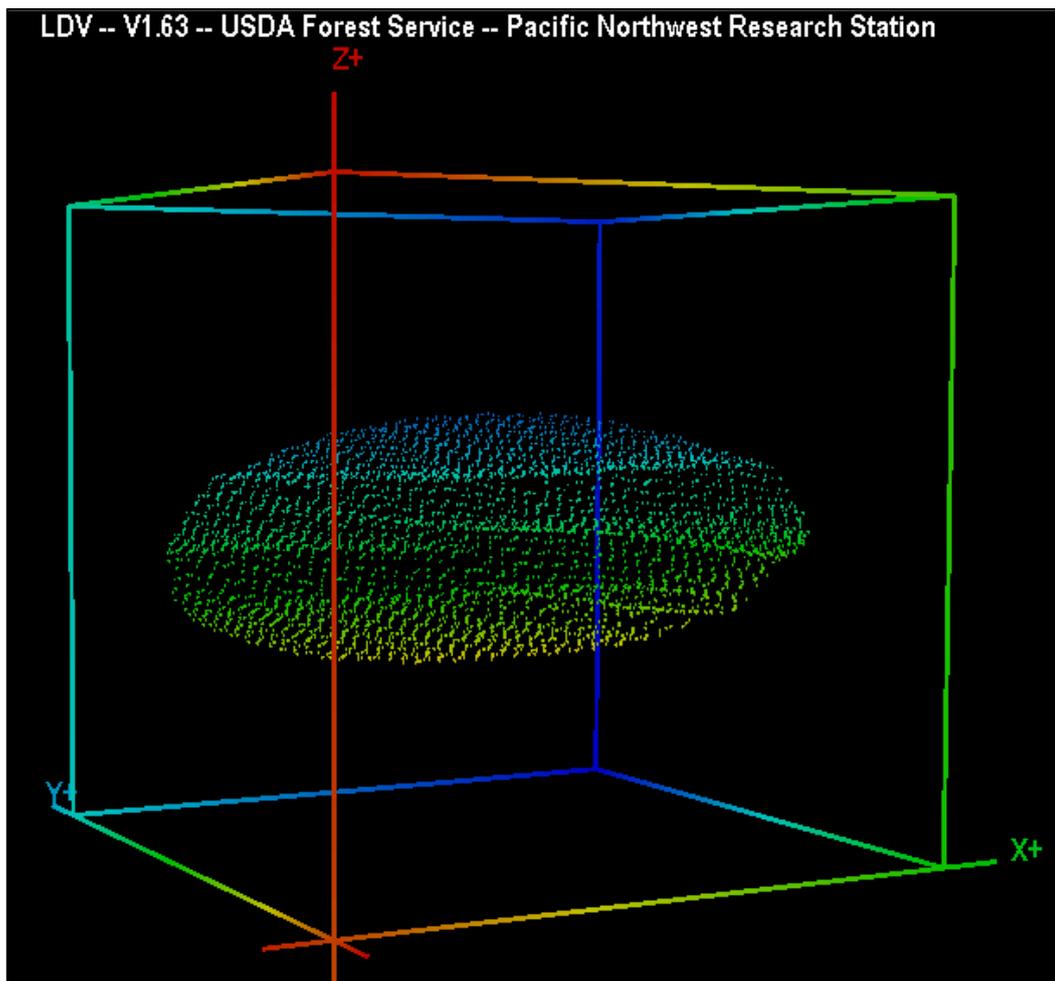


**Figura 11.** Imagen de un mapa de intensidades de retornos LiDAR de una formación de *Pinus nigra* Arn. obtenida con el algoritmo “*IntensityImage*” de Fusion® V3.50 para una nube de puntos del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

### 3) Creación de Modelos Digitales del Terreno (MDT)

Es la parte inicial del procesado LiDAR y de vital importancia dado que los MDT son usados en el proceso de normalización de la nube de puntos. Para elaborar los MDT se ha empleado el algoritmo “*GridSurfaceCreate*” de Fusion® V3.50 y se han realizado atendiendo a usar solo los puntos clasificados como suelo (*class: 2*, de acuerdo con la clasificación de ASPRS) (Figura 12).

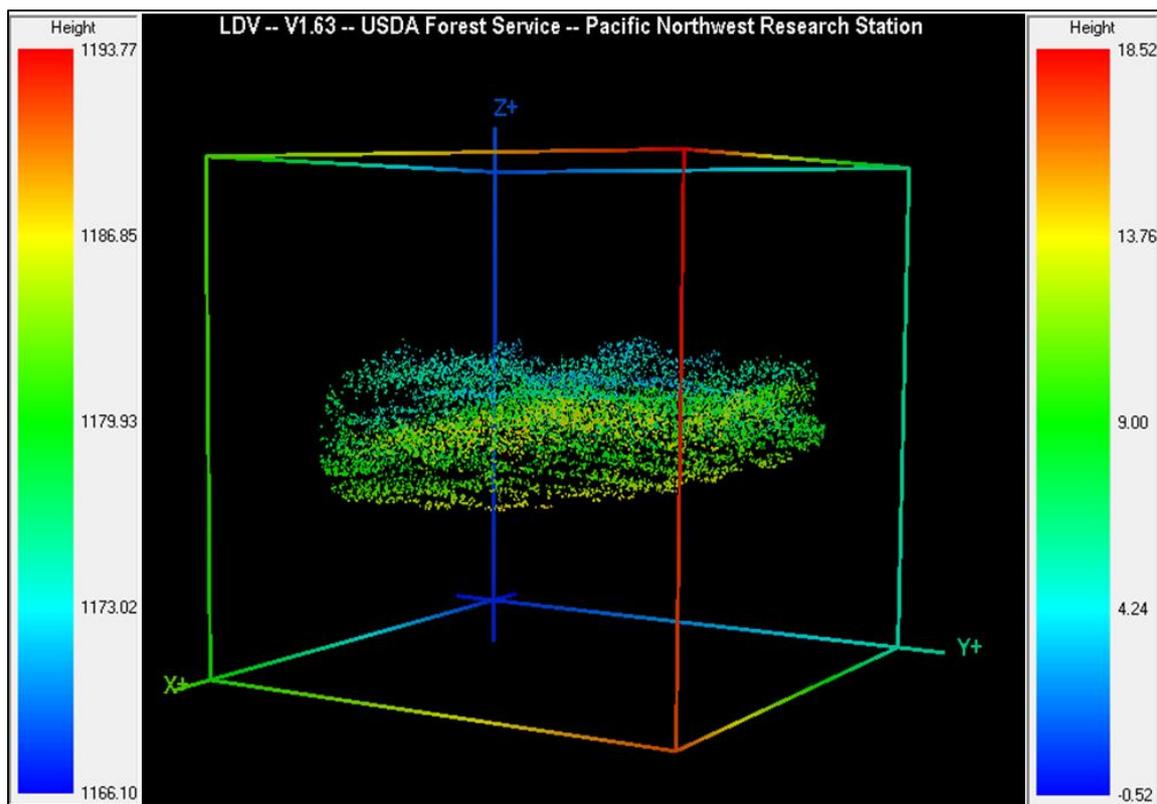
La salida del algoritmo “*GridSurfaceCreate*” tiene extensión “.dtm” y es necesario usar el algoritmo “*dtm2ascii*” para tener el MDT en la extensión “.ascii” de forma que se puede cargar en un SIG. El tamaño de pixel elegido para el MDT es de 2x2 metros, de esta forma, dado que la densidad de los archivos LiDAR empleados es, como poco, de 0,5 puntos/m<sup>2</sup>, se tienen al menos dos retornos LiDAR por cada pixel para elaborar el MDT. En el Anejo 2 se muestra la orden “*GridSurfaceCreate*” y “*dtm2ascii*” empleada para obtener los MDT en extensión “.ascii”. En la Figura 15 se observa un MDT obtenido a partir de una nube de puntos con Fusion® V3.50.



**Figura 12.** Vista 3D en Fusion® V3.50 de puntos de suelo (*class: 2*) de una nube de puntos del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

#### 4) Normalización de la nube de puntos LiDAR

La normalización de la nube de puntos es un proceso por el cual las elevaciones ortométricas de cada punto LiDAR pasan a ser referidas al nivel del suelo. Para ello es necesario el empleo de los MDT generados previamente a partir de las ordenes "GridSurfaceCreate" y "dtm2ascii". Los MDT obtenidos son ahora la cota 0 a la que se va a referir la información geográfica de los puntos LiDAR tras la normalización. La nube de puntos LiDAR normalizada (Figura 13) es la que nos va a dar la información para el cálculo de la información dasométrica de interés.



**Figura 13.** Vista de Fusion® V3.50 de una parcela poblada por *Pinus nigra* Arn. La paleta de la izquierda muestra elevaciones ortométricas y la de la derecha valores normalizados respecto al nivel del suelo. Nube de puntos del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

## 5) Creación de Modelos Digitales de Vegetación (MDV)

Para elaborar los MDV se ha empleado la orden “*Canopymodel*” de Fusion® V3.50 que emplea los primeros retornos LiDAR, es decir, los puntos con mayor elevación de la nube de puntos.

La salida de la orden “*Canopymodel*” tiene extensión “.dtm” y es necesario usar la orden “*dtm2ascii*” para tener el MDV en la extensión “.ascii” de forma que se puede cargar en un SIG. El tamaño de pixel elegido para el MDV es de 2x2 metros, al igual que para el MDT creado, de esta forma, se tienen al menos dos puntos LiDAR por cada pixel para elaborar el MDV. En el Anejo 2 se muestra la orden “*Canopymodel*” y “*dtm2ascii*” empleada para obtener los MDV en extensión “.ascii”. En la Figura 15 se observa un MDV obtenido a partir de una nube de puntos con Fusion® V3.50.

## 6) Corte de las parcelas de campo del IFN 4 en la nube de puntos LiDAR

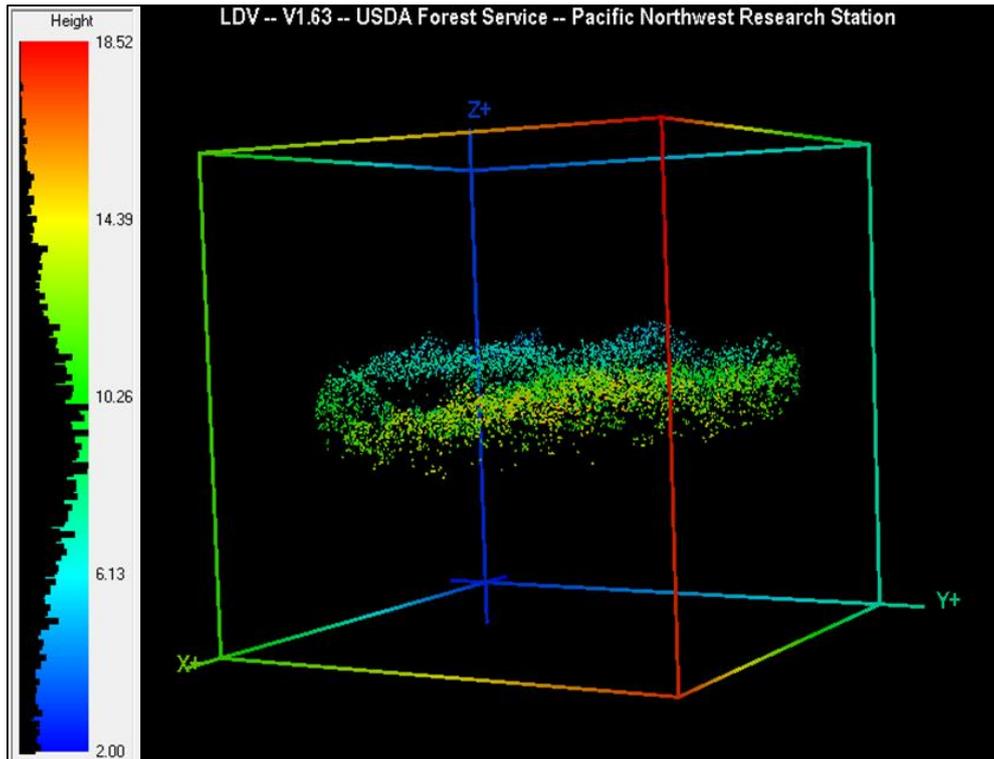
Para poder obtener valores de altura dominante ( $H_0$ ) a partir de la información LiDAR es necesario obtener un modelo válido que relacione la métrica del LiDAR con la variable dasométrica de interés. Se han empleado en este estudio los valores de altura dominante de un total de 66 parcelas medidas en el IFN 4 en el año 2012 (Anejo 1).

A través de la orden “*clipdata*” se ha cortado la información LiDAR correspondiente con las parcelas del IFN 4, que se han localizado a partir de sus coordenadas GPS referidas al sistema de referencia con EPSG: 25830. Los cortes de la nube de puntos LiDAR tienen las mismas características que las parcelas de campo, esto es referido al diámetro de la parcela circular (50 m). En el mismo proceso de corte con “*ClipData*” se realiza la normalización de la nube de puntos, indicando en cada caso el MDT correspondiente en extensión “.dtm”.

## 7) Obtención de la métrica de la información LiDAR para las parcelas del IFN 4

Sobre las nubes de puntos LiDAR correspondientes a las parcelas del IFN 4 se ha empleado la orden “*CloudMetrics*” de Fusion® V3.50 y se han obtenido los valores numéricos del LiDAR. Se ha establecido el límite inferior del procesado en 2 metros, mediante el empleo de los “*switches*” “*above:#*” y “*minht:#*”. El “*switch*” “*above*” se refiere a la altura sobre la que va a calcular la Fracción de Cobertura Cubierta (FCC) y “*minht*” indica la altura mínima de procesado, por lo que toda la métrica se corresponde con los puntos por encima de 2 metros. De esta forma nos aseguramos de dejar fuera los puntos correspondientes al matorral ( $h < 2$  m).

El hecho de eliminar los puntos LiDAR correspondientes a matorral, de cara al procesado y obtención de la métrica, permite obtener información detallada del arbolado, especialmente relativa a las alturas de la masa. En la Figura 14 se puede observar con detalle cómo se distribuyen las alturas, observándose que la mayor parte de los puntos se concentran en torno a los 8 – 10 metros de altura y que unos pocos alcanzan los 18 metros, esto nos puede dar una idea de la altura media y la altura dominante de la masa.



**Figura 14.** Detalle 3D en Fusion® V3.50 de una formación de *Pinus nigra* Arn. en La Rioja con histograma de alturas a partir de 2 metros. Nube de puntos del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

La métrica obtenida por el programa de Fusion® V3.50 es muy completa, incluyéndose los estadísticos principales de alturas de los retornos y de la intensidad de los pulsos. En nuestro caso, para elaborar el modelo de predicción de la altura dominante de Assmann en función de la métrica LiDAR, se han probado como variables independientes distintos estadísticos de elevaciones del LiDAR, como pueden ser “*Elev.mean*, *Elev.maximum*, *Elev.P95* y *Elev.P99*”, cuya descripción se añade en la Tabla 8, junto con otras variables de la métrica LiDAR arrojadas por Fusion® V3.50.

En la Tabla 8 se puede observar que el número total de retornos (*Total return count above*) y el porcentaje de los primeros retornos (*Porcentaje first returns*) se refieren a una altura de 2 metros, de acuerdo con lo especificado mediante los “*switches*” “*above:#*” y “*minht:#*” y explicado anteriormente.

**Tabla 8.** Algunos de los estadísticos de las nubes de puntos LiDAR arrojados por los algoritmos de procesado de Fusion® V3.50.

| Estadístico LiDAR de Fusion® V3.50        | Denominación                                   | Significado   |
|---|--|---|
| <b>Total return count</b>                 | Número total de retornos                       | Contabiliza el número total de retornos   |
| <b>Total return count above 2.0</b>       | Número total de retornos a los 2 metros        | Contabiliza el número total de retornos a una altura de 2 metros  |
| <b>Elev.minimum</b>                       | Elevación mínima                               | Elevación mínima de la nube de puntos   |
| <b>Elev.maximum</b>                       | Elevación máxima                               | Elevación máxima de la nube de puntos   |
| <b>Elev.mean</b>                          | Elevación media                                | Altura media de la nube de puntos   |
| <b>Elev.variance</b>                      | Varianza de elevación                          | Varianza de las alturas de los retornos   |
| <b>Elev.CV</b>                            | CV de la elevación                             | Coficiente de variación de las alturas de los retornos  |
| <b>Elev.kurtosis</b>                      | Coficiente de kurtosis de las elevaciones      | Valor del coeficiente de apuntamiento del conjunto de retornos  |
| <b>Elev.P95</b>                           | Altura del percentil 95                        | Valor de la altura que deja el 95 % de los retornos por debajo  |
| <b>Elev.P99</b>                           | Altura del percentil 99                        | Valor de la altura que deja el 99 % de los retornos por debajo  |
| <b>Percentage first returns above 2.0</b> | Porcentaje de primeros retornos a los 2 metros | Porcentaje del total de primeros retornos a una altura de dos metros. Se corresponde con el valor calculado de Fracción de Cobertura (FCC) a 2 metros de altura |

Otro importante grupo de estadísticos arrojados por Fusion® V3.50 se refieren a los valores de intensidades de los retornos, pero que en este caso no han sido empleados.

## 8) Obtención de la métrica de la información LiDAR en toda la superficie de estudio

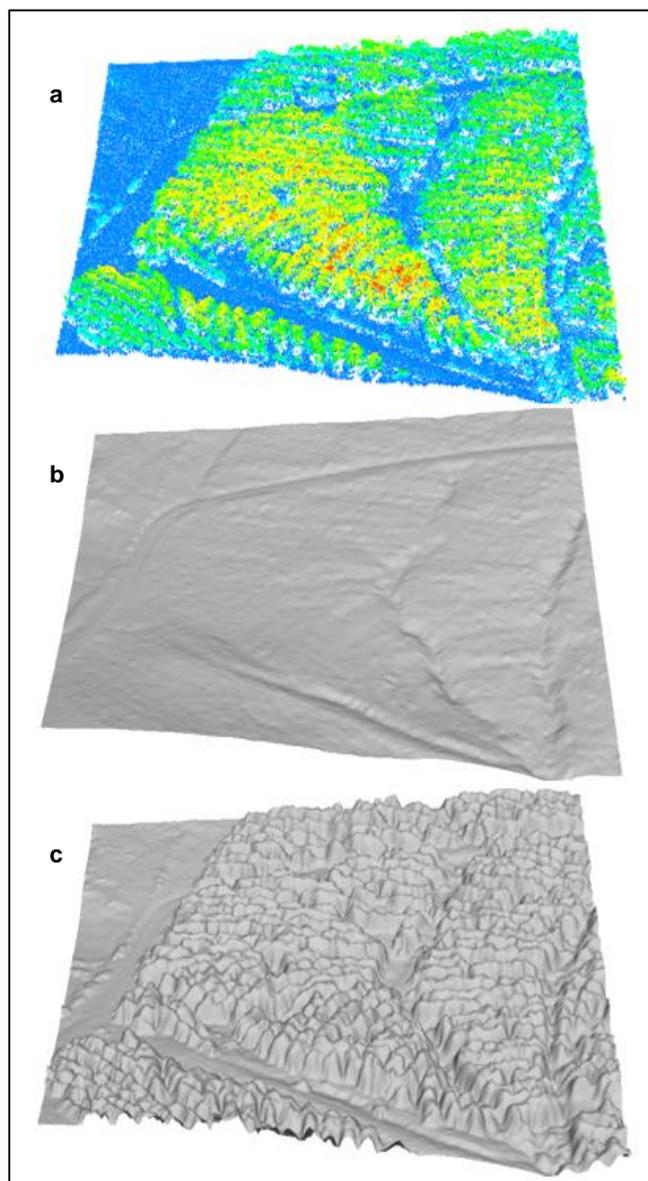
Para obtener los valores de la métrica del LiDAR para la totalidad de la superficie de estudio se ha empleado la orden “*GridMetrics*” de Fusion® V3.50, especificando un tamaño de celda de 25 metros.

Al igual que en el paso 5), descrito anteriormente, se ha establecido el límite inferior del procesado en 2 metros, mediante el empleo de los “*switches*” “*above:#*” y “*minht:#*”. Como ya se ha indicado, el “*switch*” “*above*” se refiere a la altura sobre la que va a calcular la Fracción de Cobertura (FCC) y “*minht*” indica la altura mínima de procesado, por lo que toda la métrica se corresponde con los puntos por encima de 2 metros.

Al establecer una altura mínima para el procesado de la información LiDAR se excluye la parte del sistema correspondiente al matorral, por lo que la información LiDAR analizada es referente solo a las copas del arbolado ( $h > 2$  m), lo que proporciona información muy valiosa de las copas (Figura 14). Al igual que para el caso 6) se ha especificado una altura mínima de procesado de 2 m (*minht:2*) y se ha calculado la FCC a partir de los retornos a 2 metros (*above:2*). De esta forma, al calcularse la métrica LiDAR de igual modo que para las parcelas

de campo, se pueden incorporar posteriormente los modelos obtenidos a nuestra información vectorial, ya que la métrica coincide respecto a la altura de procesamiento mínima.

En la Figura 15, se muestra, para una misma muestra de datos LiDAR, los modelos digitales de superficies que se pueden obtener, tanto el Modelo Digital del Terreno como el Modelo Digital de la Vegetación (MDT y MDV respectivamente).



**Figura 15.** Nube de puntos LiDAR (a) Modelo Digital del Terreno (b) y Modelo Digital de Vegetación (c). Datos LiDAR del vuelo del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

### 3.3.3. Modelización de la información LiDAR

A través de la información LiDAR se busca obtener una estimación de  $H_0$ , para ello es necesario elaborar un modelo matemático válido que permita relacionar ambas, la medida de  $H_0$  en campo (dato IFN 4) con la métrica LiDAR. Para ello se realiza un análisis a través de un modelo de regresión lineal simple  $y = (a + b \cdot x) + \varepsilon$  donde "y" es el valor convencional o variable dependiente, "a" el término independiente, "b" el término dependiente y "x" el valor de la métrica LiDAR, o término independiente y " $\varepsilon$ " el término del error aleatorio del modelo.

También se han probado modelos de regresión lineal múltiple  $y = (a + b \cdot x_1 + c \cdot x_2) + \varepsilon$  donde "y" es el valor convencional o variable dependiente, "a" el término independiente, "b" y "c" son los términos dependientes y " $x_1$ " y " $x_2$ " valores de la métrica LiDAR, o términos independientes y " $\varepsilon$ " el término del error aleatorio del modelo. Al ajustar modelos lineales múltiples se mejoran las predicciones futuras, que es lo que buscamos en este caso concreto. Además, el hecho de añadir una variable independiente más no complica la toma de datos para su empleo, dado que se obtienen con el mismo esfuerzo todas las variables de la métrica LiDAR en el procesado a través de los algoritmos "CloudMetrics" y "GridMetrics" de Fusion® V3.50.

Los modelos para predecir la altura dominante ( $H_0$ ) a partir de la métrica LiDAR se han elaborado al igual que las curvas de calidad de estación con el programa RStudio® V0.99.896 y se ha empleado también Notepad++® V6.7.5 para el manejo de las rutinas. El código para el ajuste de los modelos se presenta en el Anejo 3.

En este estudio únicamente se busca un modelo que relacione la variable dasométrica altura dominante ( $H_0$ ) medida en el IFN 4 con alguna variable del LiDAR.

Inicialmente se tienen 76 parcelas pobladas por *Pinus nigra* Arn. como especie principal y medidas en el IFN 4 (Anejo 1), que son las susceptibles de ser empleadas en el ajuste con la métrica LiDAR. Previamente se han comparado los valores de las alturas LiDAR con los valores de las alturas medidas en campo, observándose que en un total de 10 parcelas hay una diferencia significativa ( $> 2$  metros) entre la altura dominante medida en el IFN 4 y el LiDAR, lo que puede indicar una mala toma de las coordenadas de las parcelas de campo.

Para evitar problemas en el ajuste del modelo, las parcelas con grandes diferencias entre las alturas LiDAR y las alturas de campo (IFN 4), se han eliminado directamente, puesto que es muy importante que los datos estén correctamente georreferenciados (MAURO et al., 2013). Previamente a la selección de las 76 parcelas se habían eliminado las parcelas que de acuerdo con la información del IFN 4 no estaban bien posicionadas y que tampoco han sido incluidas para el ajuste de las curvas de calidad de estación.

Se tienen, por tanto, tras la conveniente depuración de parcelas, que no se consideran válidas para elaborar el modelo, 66 parcelas disponibles para elaborar los modelos de

predicción de altura dominante a partir del LiDAR ( $H_0 = \mathcal{F}(\text{métrica LiDAR})$ ). De estas 66 parcelas, se ha dejado el 20 % de las mismas sin incluir en el ajuste, para emplearlas en la validación del modelo. El 20 % de las parcelas resulta ser de 13,2 parcelas, habiéndose seleccionado 13 parcelas para la validación (Anejo 1). Para la selección aleatoria de las parcelas se ha empleado la utilidad “*sample*” de R.

A la hora seleccionar las variables de la métrica LiDAR que iban a formar parte de los modelos de predicción de la altura dominante se han analizado las correlaciones (Pearson, Spearman y correlaciones parciales) entre las variables a ajustar y se han elaborado matrices de dispersión de las distintas variables, para, de este modo, hacer una primera selección de las variables LiDAR que pueden ser variables independientes en nuestro modelo buscado.

Para la elección del mejor modelo de regresión  $H_0 = \mathcal{F}(\text{métrica LiDAR})$ , se han comparado los valores del Criterio de Información de Akaike (AIC) y el Criterio de Información Bayesiano (BIC) de los distintos modelos, siendo unos potentes métodos para determinar qué modelo se ajusta mejor a la serie de datos, pues indican la calidad relativa de los modelos estadísticos analizando la información que se pierde cuando se elige un modelo concreto (BURNHAM & ANDERSON, 2002). También se ha analizado el error residual estándar (RSE) de cada modelo y el coeficiente de bondad del ajuste ( $R^2$ ). El coeficiente de bondad  $R^2$  nos indica la proporción de los datos que puede explicar nuestro modelo y el RSE, el error residual que deja el modelo. Se han elegido estos estadígrafos dado que son los frecuentemente empleados en la elección de modelos de predicción de variables (BURNHAM & ANDERSON, 2002).

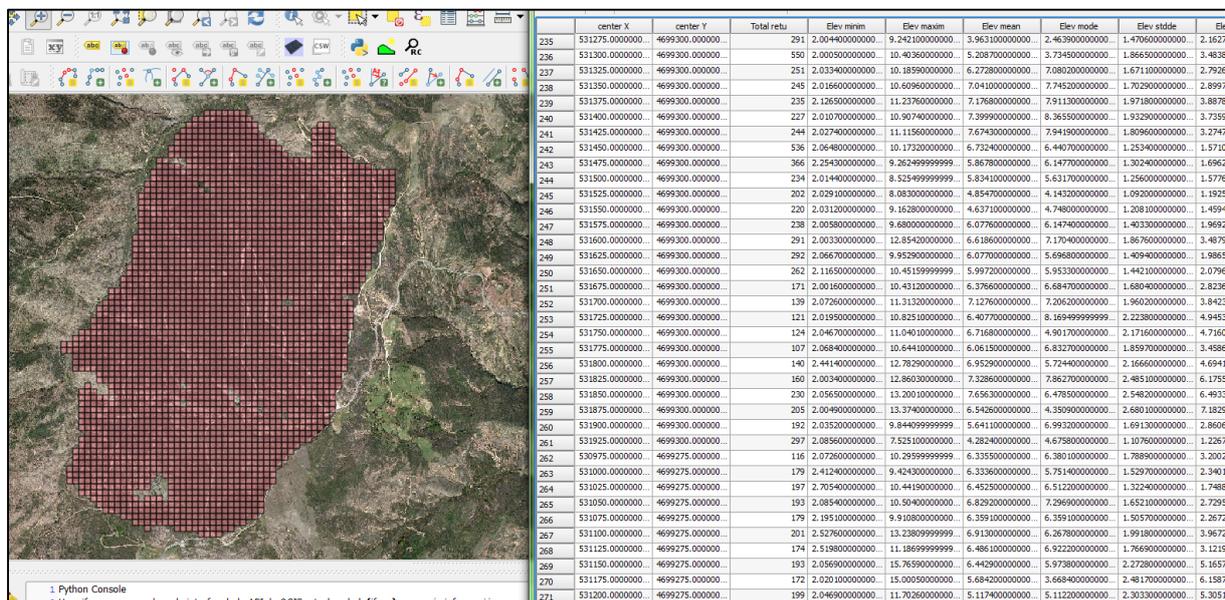
Se ha seleccionado el modelo que presenta mayor valor del coeficiente bondad del ajuste ( $R^2$ ), el menor valor de AIC, BIC y RSE. Se ha analizado además el test de homocedasticidad de Breusch-Pagan, el test de normalidad de los residuos de Kolmogórov-Smirnov y el test de valores atípicos de Bonferroni, buscando posibles valores atípicos que distorsionen el modelo.

Gráficamente se han analizado también los distintos modelos mediante la visualización de las dispersiones con las ecuaciones de ajuste. Se ha realizado también la representación de residuos frente a los valores ajustados, residuos estandarizados frente a los cuantiles teóricos, (residuos estandarizados)<sup>0,5</sup> frente a los valores ajustados y los residuos estandarizados frente a “*leverage*”.

La elección de los modelos, por tanto, ha sido tanto cualitativa (gráficos) como cuantitativa (resultados estadísticos numéricos). Los resultados de los ajustes de los modelos se muestran en el Anejo 4.

### 3.3.4. Incorporación de resultados al Sistema de Información Geográfica (SIG)

La información obtenida en el paso 8) Obtención de la métrica de la información LiDAR en toda la superficie de estudio, descrito en el punto 3.3.2. Procesado de la información LiDAR aérea, mediante el algoritmo “Gridmetrics” de Fusion® V3.50, se ha importado en extensión “.csv” a QGis® V2.8.1, cómo vectorial de tipo punto. A partir de este vectorial de puntos se obtiene un vectorial de tipo polígono mediante las herramientas de investigación de capas vectoriales denominada cuadrícula vectorial de QGis® V2.8.1. A este último es necesario incorporarle la información LiDAR, que se ha realizado con la herramienta para capas vectoriales incorporada en QGis® V2.8.1, de unión de atributos por localización. Como resultado se obtiene un mallado de 25 x 25 metros de lado (Figura 16) que contiene toda la información de la métrica LiDAR.



**Figura 16.** Vista general en QGis® V2.8.1 del monte “Las Santanas” de Santa Engracia del Jubera. Vectorial tipo polígono con la tabla de atributos con la métrica LiDAR asociada a cada celda procesado con Fusion® V3.50. Datos del vuelo LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA) del año 2010 en La Rioja.

Sobre el vectorial tipo polígono que tiene asociada la información LiDAR se aplica el modelo de predicción de la altura dominante de Assmann obtenido para tener, de esta forma, un valor estimado de altura dominante de Assmann en cada celda de nuestro archivo vectorial.

El paso siguiente es incorporar la información de edades al vectorial con el valor estimado de la altura dominante de Assmann, para así asignar a cada celda, en función del valor de  $H_0$  y de la edad, la clase correspondiente de calidad de estación, definida a partir de las curvas obtenidas en este trabajo.

## 4. RESULTADOS Y DISCUSIÓN

### 4.1. RESULTADOS

#### 4.1.1. Curvas de calidad de estación

Para los modelos de Hossfeld I (mod.) y Mitscherlich I se han obtenido mediante regresión lineal los valores de los parámetros de su forma lineal y mediante los algoritmos de Gauss-Newton y de Levenberg-Mardquardt para su forma no lineal, es decir, para la ecuación original del modelo.

Para el caso del modelo de Mitscherlich I, solo se ha obtenido resultado válido mediante ajuste lineal, no habiéndose llegado a una solución válida mediante regresión no lineal. En la Tabla 9 se muestran los valores de los coeficientes, así como los valores de  $R^2$  y RSE obtenidos.

Para el caso del modelo de Hossfeld I (mod.) mediante ajuste no lineal se ha llegado a la solución tras 4 iteraciones, tanto para el caso del algoritmo de Gauss-Newton como para Levenberg-Mardquardt. Para el modelo de Mitscherlich I mediante el algoritmo de Gauss-Newton no se obtiene ningún resultado y lo presentado se ha obtenido a partir del algoritmo de Levenberg-Mardquardt en el punto de llegar al máximo de iteraciones permitidas (400 en este caso). Aunque se maximicen las iteraciones y el número de llamadas a la función no se llega en ningún caso a un resultado válido.

**Tabla 9.** Resultados del ajuste de las curvas de calidad de estación (valores de la ecuación de la curva guía).

| Modelo         | Mod.1. Hossfeld I (mod.) lineal |            |         | Mod.1. Hossfeld I (mod.) no lineal |                        |         |
|----------------|---------------------------------|------------|---------|------------------------------------|------------------------|---------|
|                | Estimado                        | Std. Error | t-valor | Estimado                           | Std. Error             | t-valor |
| a              | 2,23261***                      | 0,27809    | 8,028   | 2,79780***                         | 0,40141                | 6,970   |
| b              | 0,28929***                      | 0,01021    | 28,344  | 0,25945***                         | 0,01133                | 22,890  |
| R <sup>2</sup> |                                 | 0,2474     |         |                                    | -                      |         |
| RSE            |                                 | 0,060      |         |                                    | 2,639                  |         |
| Modelo         | Mod.2. Mitscherlich I lineal    |            |         | Mod.2. Mitscherlich I no lineal    |                        |         |
|                | Estimado                        | Std. Error | t-valor | Estimado                           | Std. Error             | t-valor |
| a              | 12,97339***                     | 0.06259    | 40,947  | 3,286·10 <sup>2</sup>              | 2,47·10 <sup>5</sup>   | 0,001   |
| b              | 0,020                           | -          | -       | 2,505·10 <sup>-5</sup>             | 3,643·10 <sup>-2</sup> | 0,999   |
| c              | 0.67160***                      | 0.07758    | 8,657   | 5,194·10 <sup>-1</sup>             | 3,239·10 <sup>-1</sup> | 0,110   |
| R <sup>2</sup> |                                 | 0,2770     |         |                                    | -                      |         |
| RSE            |                                 | 0,314      |         |                                    | 2,622                  |         |

Niveles de significación: \*\*\* p < 0,001; \*\* p < 0,01

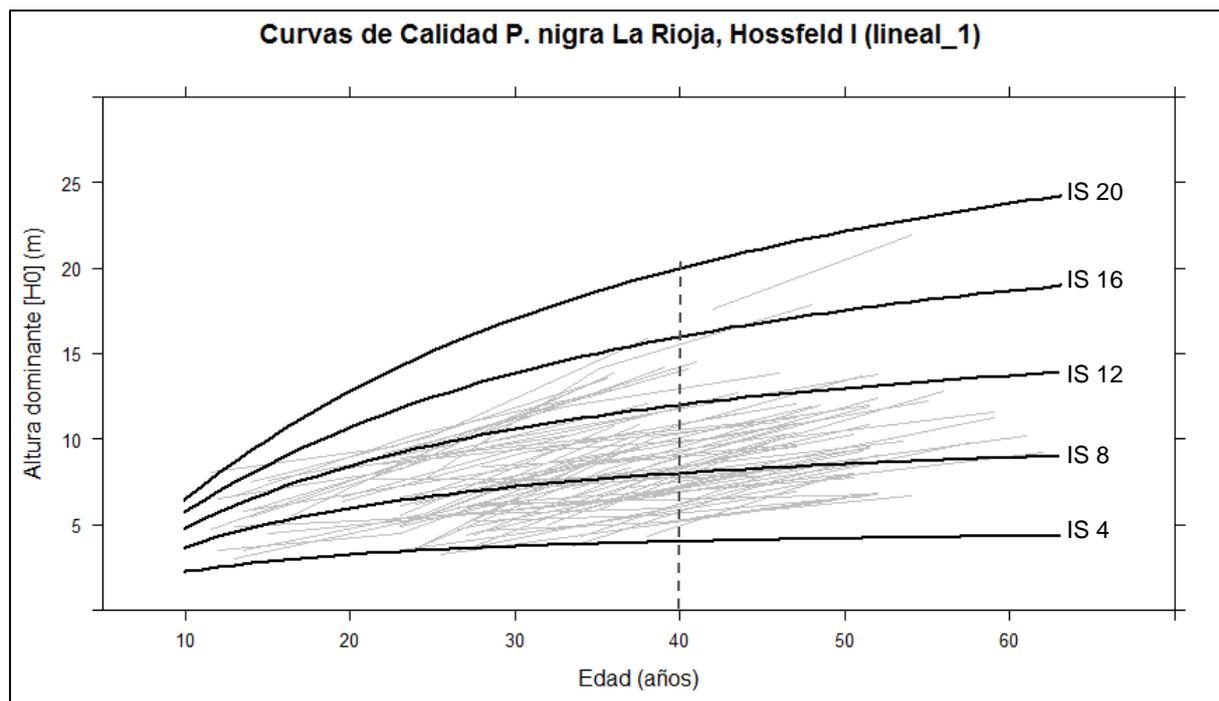
El mejor modelo para nuestra serie de datos se ajusta con Hossfeld I (mod.) de forma lineal, teniendo este el mínimo error residual estándar (RSE) y con todos los parámetros significativos. A pesar de no tener el mejor coeficiente  $R^2$  de bondad del ajuste, al visualizar el conjunto de las curvas de calidad de estación, se ha optado por esta ya que es la que mejor contiene a nuestra serie de datos de altura dominante de Assmann y edad (Figura 17).

En la Tabla 10 se muestra la ecuación de la curva guía obtenida en el ajuste lineal junto con las ecuaciones para los 5 Índices de Sitio, obtenidas manteniendo el parámetro “a” constante y dando valores a “b” para una edad típica “t” de 40 años y para las distintas clases de índice de sitio definidas, como ya se ha explicado anteriormente.

**Tabla 10.** Ecuaciones de curva guía de Hossfeld I (mod.) ajustada para las repoblaciones de *Pinus nigra* Arn. en La Rioja y ecuaciones para cada índice de sitio (SI).

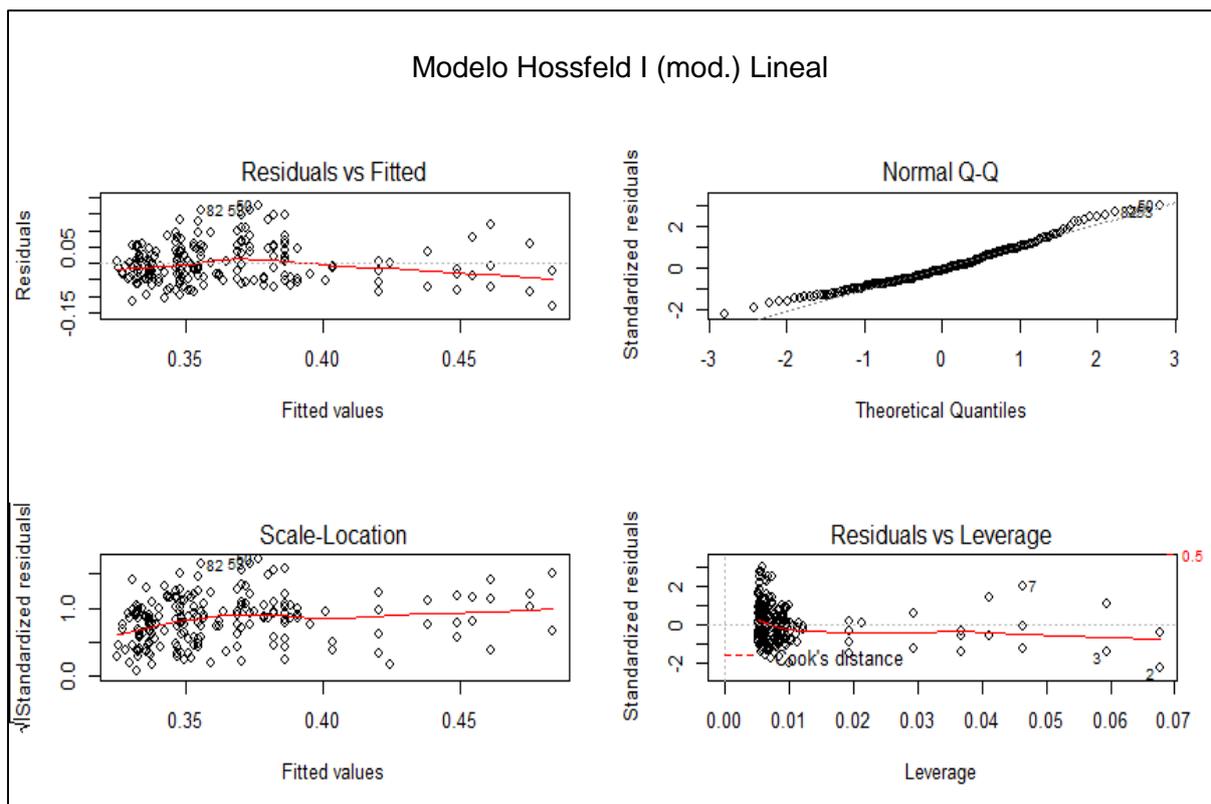
| Curva guía               |                        | Ecuación Hossfeld I (mod.)                        |
|--------------------------|------------------------|---|
|                          |                        | $H_0 = \frac{t^2}{(2,23261 + 0,28929 \cdot t)^2}$ |
| IS (m) [H <sub>0</sub> ] | Edad típica (años) [t] |   |
| 4                        | 40                     | $H_0 = \frac{t^2}{(2,23261 + 0,44418 \cdot t)^2}$ |
| 8                        | 40                     | $H_0 = \frac{t^2}{(2,23261 + 0,29774 \cdot t)^2}$ |
| 12                       | 40                     | $H_0 = \frac{t^2}{(2,23261 + 0,23261 \cdot t)^2}$ |
| 16                       | 40                     | $H_0 = \frac{t^2}{(2,23261 + 0,19418 \cdot t)^2}$ |
| 20                       | 40                     | $H_0 = \frac{t^2}{(2,23261 + 0,16779 \cdot t)^2}$ |

A continuación, se muestran las curvas de calidad de estación de Hossfeld I (mod.) para los 5 índices de Sitio predefinidos a 4, 8, 12, 16 y 20 metros para una edad típica de 40 años para las repoblaciones de *Pinus nigra* Arn. en La Rioja (Figura 17).



**Figura 17.** Curvas de calidad de estación para las masas repobladas de *P. nigra* en La Rioja con edad típica de 40 años.

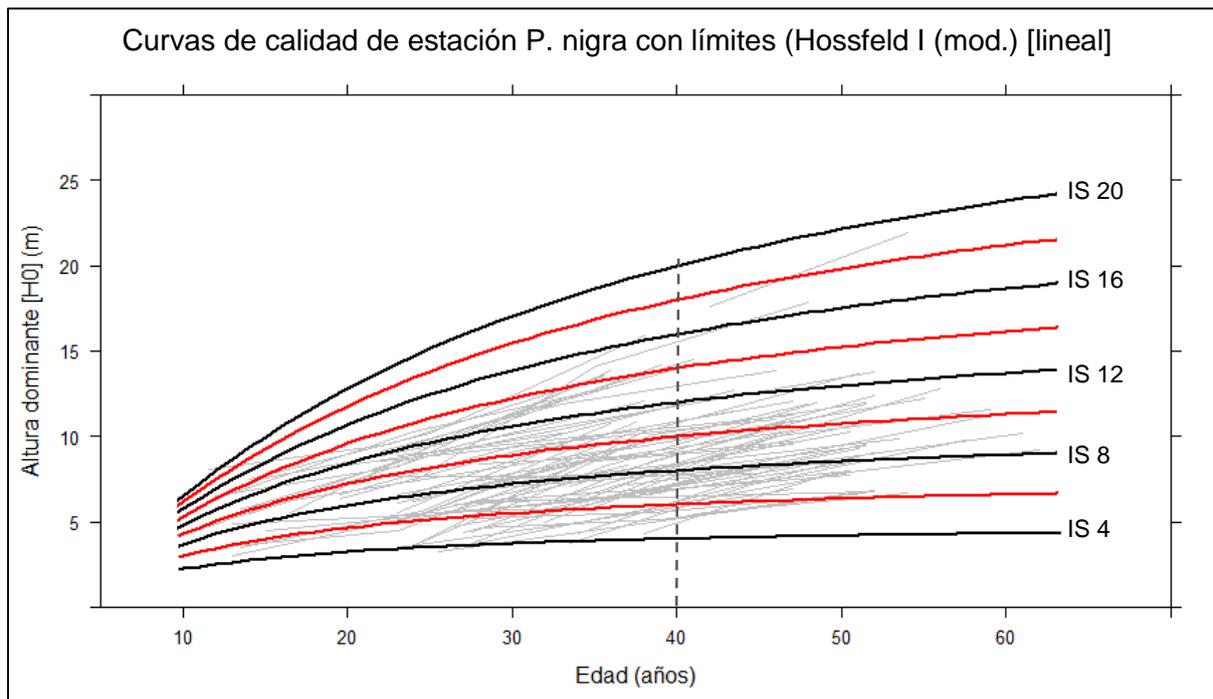
También se han analizado gráficamente los residuos del modelo y los valores ajustados, así como la influencia de los residuos (Leveraje) y el gráfico cuantil-cuantil (Figura 18) para el modelo seleccionado.



**Figura 18.** Gráficas de residuos, valores ajustados, gráfico cuantil-cuantil y de influencia de las observaciones del modelo Hossfeld I (mod.) lineal.

Como podemos observar (Figura 18) existe una cierta dependencia de los residuos del modelo ajustado. El gráfico Cuantil-Cuantil nos muestra un buen ajuste y al analizar la influencia de los residuos vemos que la mayoría se concentran en torno a valores bajos de "leverage", encontrando no obstante valores con cierta influencia. Con lo observado se puede concluir que el modelo elegido de Hossfeld I (mod.) ajustado mediante regresión lineal es adecuado para nuestra serie de datos de altura dominante de Assmann y edad.

Como ya se había introducido se han obtenido los límites entre las distintas calidades (Figura 19), de forma analítica (Anejo 3), para poder asignar un valor de índice de sitio a cada celda del archivo vectorial que se va a obtener en este trabajo.



**Figura 19.** Curvas de calidad de estación (negro) con los límites entre calidades (rojo).

Las curvas de calidad obtenidas no es recomendable emplearlas en masas más jóvenes de los 20 años, por la falta de correlación juvenil-adulto que los árboles suelen presentar (BRATOVICH et al., 1996) ni en masas mayores de 60 años, dado que no hay masas tan maduras incluidas en el estudio. El rango óptimo de aplicación de las curvas es por tanto de 20-60 años, por lo que se debe considerar con especial cuidado aplicarlas en otros rangos. En el Anejo 4 se adjuntan los resultados numéricos y gráficos de los distintos ajustes.

#### 4.1.2. Modelización de la información LiDAR aerotransportada

Tras el análisis de las correlaciones (Pearson, Spearman y corr. Parciales) y la visualización de las matrices de dispersión entre las distintas variables candidatas para entrar en el ajuste (Anejo 4), se han seleccionado las variables que mayor correlación presentan con la variable a predecir ( $H_0$ ) elaborándose 6 modelos de tipo lineal cuyos resultados se presentan en la Tabla 11.

**Tabla 11.** Resultados de los modelos de predicción de altura dominante de Assmann a partir de datos LiDAR aéreos.

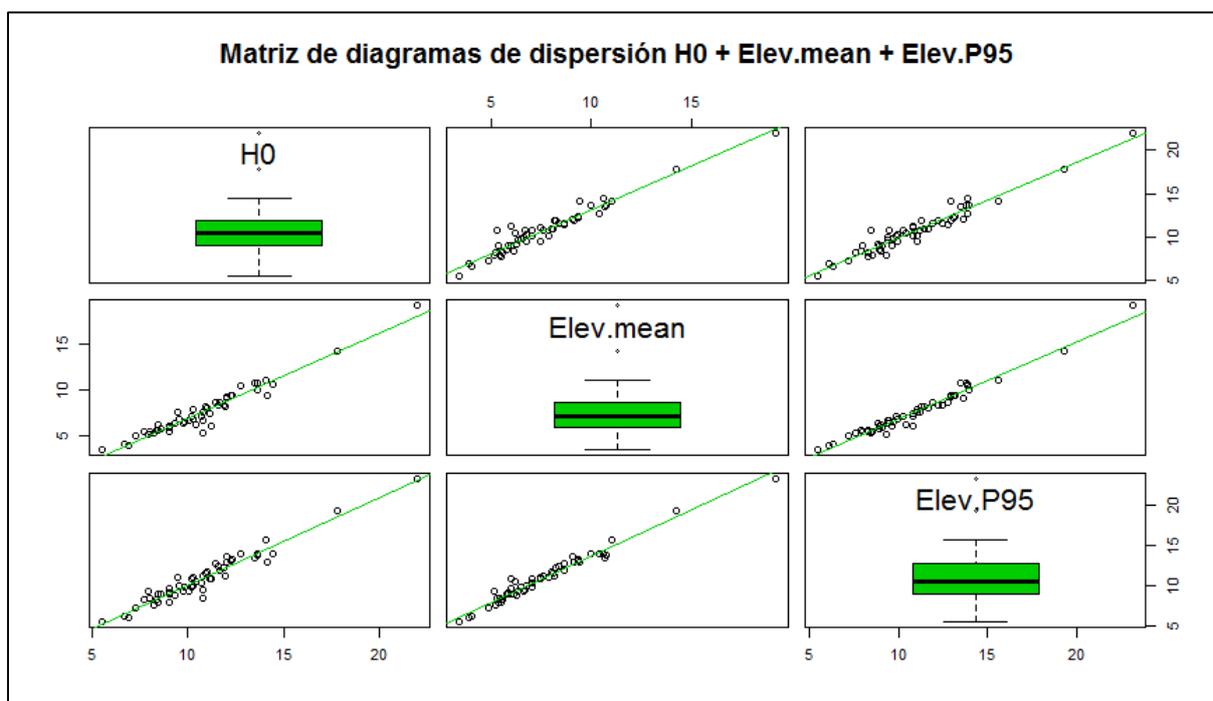
| Modelo         | Model.1 = $H_0 = a + b \cdot \text{Elev.mean}$    |            |         | Model.2 = $H_0 = a + b \cdot \text{Elev.mode}$                           |            |         |
|----------------|---|------------|---------|--|------------|---------|
|                | Estimado  | Std. Error | t-valor | Estimado   | Std. Error | t-valor |
| a              | 3,0595***   | 0,3941     | 10,40   | 4,11782***   | 11,19      | 11,19   |
| b              | 1,0149***   | 0,0368     | 27,58   | 0,82866***   | 19,26      | 19,26   |
| R <sup>2</sup> | 0,9309  |            |         | 0,8767   |            |         |
| RSE            | 0,7164  |            |         | 0,9706   |            |         |
| AIC            | 126,5355  |            |         | 151,2020   |            |         |
| BIC            | 132,4464  |            |         | 157,1128   |            |         |
| Modelo         | Model.3 = $H_0 = a + b \cdot \text{Elev.maximun}$ |            |         | Model.4 = $H_0 = a + b \cdot \text{Elev.P95}$                            |            |         |
|                | Estimado  | Std. Error | t-valor | Estimado   | Std. Error | t-valor |
| a              | 0,94785   | 0,67118    | 1,42    | 1,35528***   | 0,3620     | 3,74    |
| b              | 0,72698***  | 0,04839    | 15,03   | 0,86190***   | 0,0321     | 26,89   |
| R <sup>2</sup> | 0,8121  |            |         | 0,9328   |            |         |
| RSE            | 1,1980  |            |         | 0,6998   |            |         |
| AIC            | 173,5496  |            |         | 119,0209   |            |         |
| BIC            | 179,4605  |            |         | 124,9318   |            |         |
| Modelo         | Model.5 = $H_0 = a + b \cdot \text{Elev.P99}$     |            |         | Model.6 = $H_0 = a + b \cdot \text{Elev.P95} + c \cdot \text{Elev.mean}$ |            |         |
|                | Estimado  | Std. Error | t-valor | Estimado   | Std. Error | t-valor |
| a              | 0,83207*  | 0,47420    | 1,76    | 2,2150***  | 0,4480     | 4,94    |
| b              | 0,82703***  | 0,03834    | 21,57   | 0,3941*  | 0,1628     | 2,42    |
| c              | -   | -          | -       | 0,5594**   | 0,1914     | 2,92    |
| R <sup>2</sup> | 0,8993  |            |         | 0,9415   |            |         |
| RSE            | 0,8774  |            |         | 0,6687   |            |         |
| AIC            | 140,5076  |            |         | 112,6637   |            |         |
| BIC            | 146,4185  |            |         | 120,5449   |            |         |

Niveles de significación: \*\*\* p < 0,001; \*\* p < 0,01; \* p < 0, 05; \* p < 0,1

El modelo lineal múltiple (Model.6) presentado en la Tabla 11, se ha desechado debido a la alta colinealidad que tienen las variables de la métrica LiDAR entre sí (Figura 20), además los coeficientes que acompañan a las variables independientes del ajuste no son suficientemente significativas (Tabla 11). Se desecha el modelo a pesar de ser el modelo que mejor coeficiente de bondad de ajuste ( $R^2$ ) presenta, menor error residual estándar (RSE) y menores valores de del criterio de información de Arkaike (AIC) y del criterio de información Bayesiano (BIC).

Además, comparando el error estándar de estimación de los parámetros del modelo lineal múltiple (Model.6) con los modelos simples de las mismas variables (Model.1 y Model.4) se

observa que para el caso del modelo múltiple estos errores son mayores (Tabla 11), lo que hace que se descarte esta opción y se elijan los modelos simples frente al múltiple.



**Figura 20.** Diagramas de dispersión de la altura dominante de Assmann ( $H_0$ ) y las variables LIDAR *Elev.mean* y *Elev.P95*.

Finalmente se ha optado por elegir el modelo Model.4, que es el modelo con menor AIC, BIC, RSE y mejor  $R^2$ , de todos los modelos lineales simples estudiados, teniendo además el menor error de estimación de los parámetros y cuya expresión ajustada es:

$$H_0 = 1,35528 + 0,86190 \cdot Elev.P95$$

Donde " $H_0$ " es la altura dominante de Assmann y "*Elev.P95*" es la variable de la métrica LiDAR que se corresponde con la altura del percentil 95 de la nube de puntos LiDAR, es decir, que deja un 95 % de los puntos LiDAR por debajo de dicha altura.

Se ha representado gráficamente la ecuación del modelo ajustado (Model.4) sobre los pares de datos de altura dominante de Assmann, medida en el IFN 4, y la variable independiente (*Elev.P95*) y se observa que el ajuste es bastante bueno (Figura 21), encontrándose una buena correlación entre ambas variables.

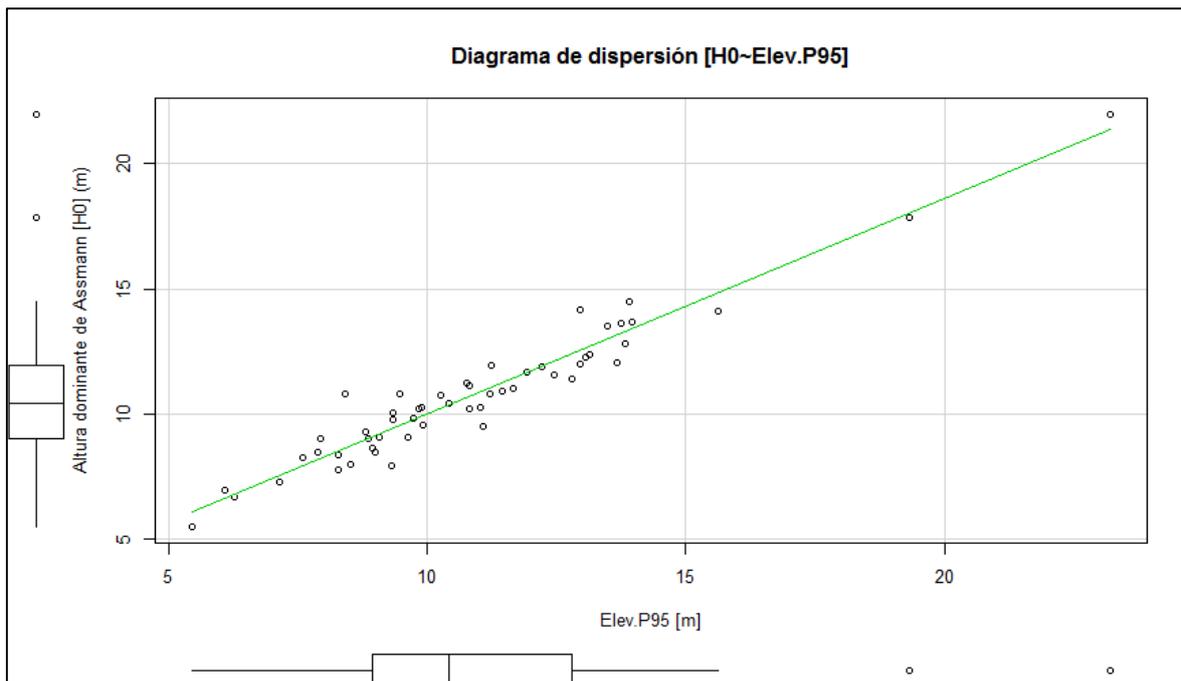


Figura 21. Diagrama de dispersión de  $H_0$  frente a  $Elev.P95$  con la recta ajustada (Model.4).

Se ha elaborado también la gráfica de valores predichos frente a los valores observados de altura dominante de Assmann, para las 53 parcelas del IFN 4 incluidas para el ajuste (Anejo 1), y se observa que el modelo arroja buenas predicciones (Figura 22) concentrándose dichos valores en torno a la diagonal.

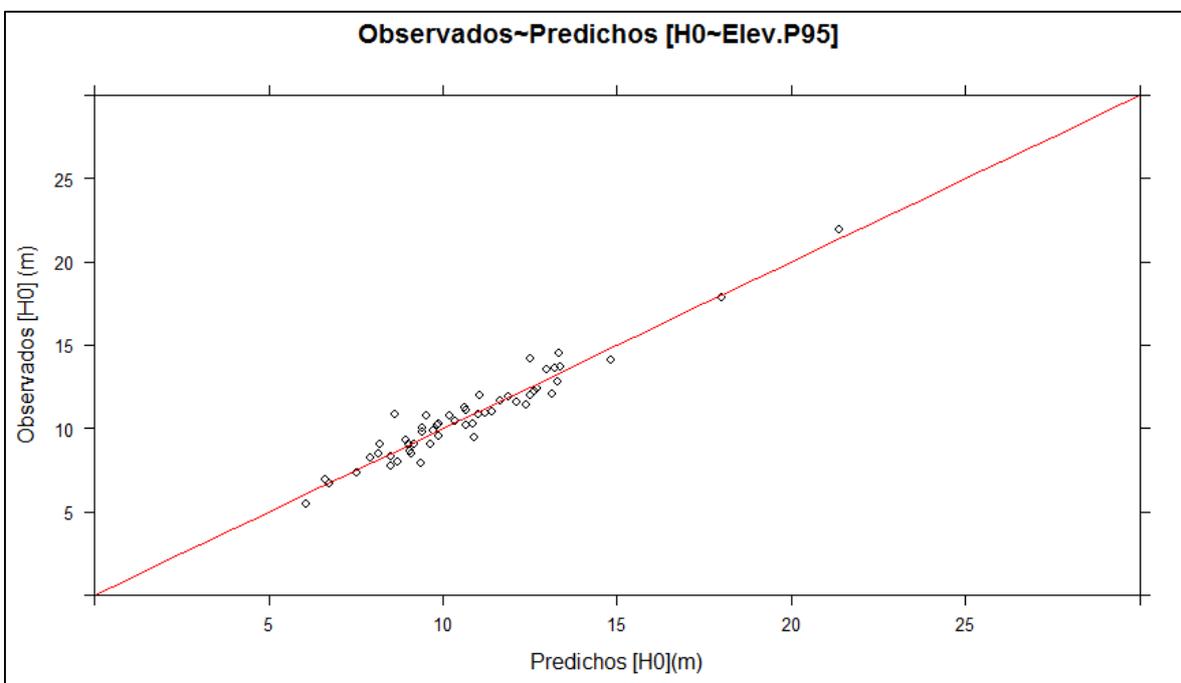


Figura 22. Gráfica de predichos y observados del modelo (Model.4).

También se ha elaborado un gráfico Quantil-Quantil con las líneas de confianza (Figura 23), así como las gráficas de los residuos del modelo y los valores ajustados, y un gráfico de la influencia (*Leverage*) de los residuos en el modelo, donde se observa que el modelo es de una calidad bastante aceptable (Figura 24).

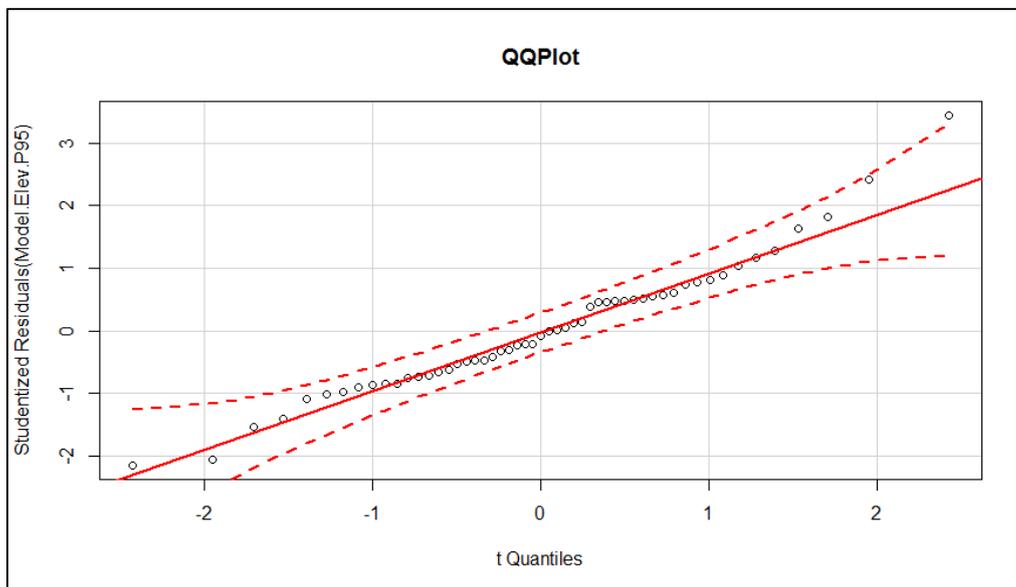


Figura 23. Gráfico Q-Q para el modelo seleccionado (Model.4).

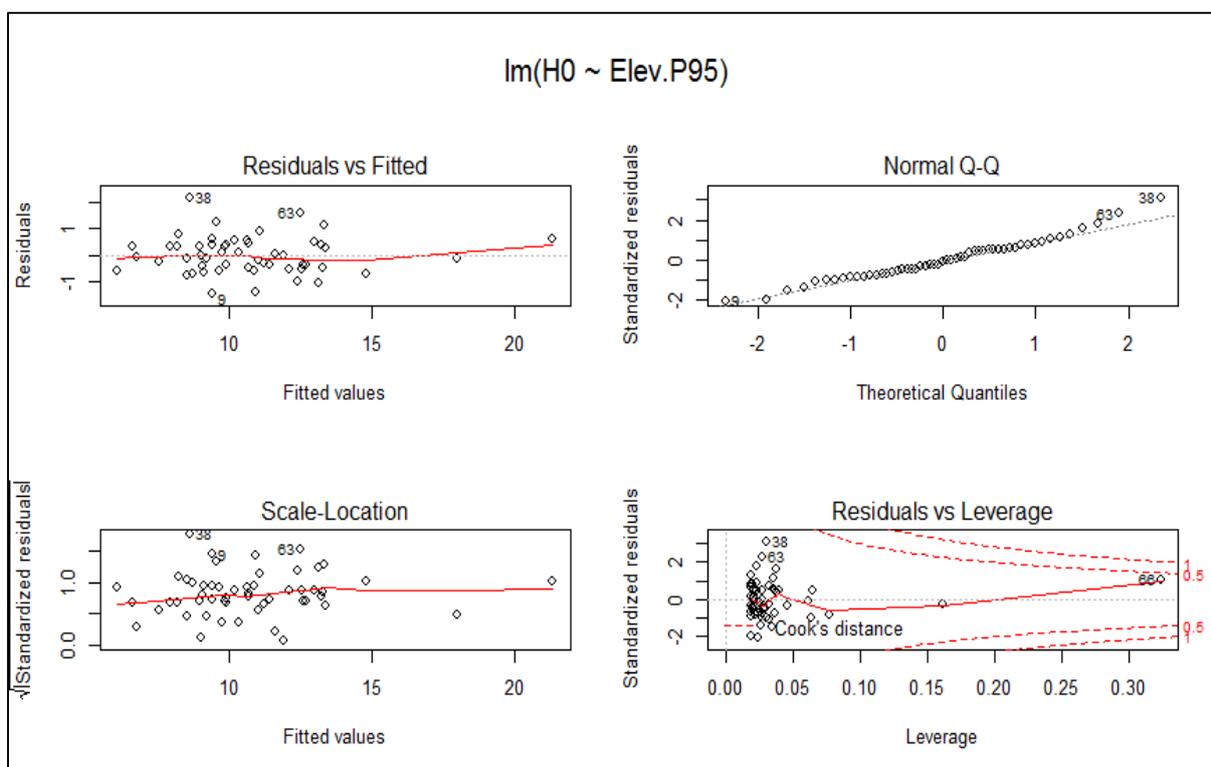


Figura 24. Gráficas de residuos, valores ajustados y de influencia de los residuos del modelo (Model.4).

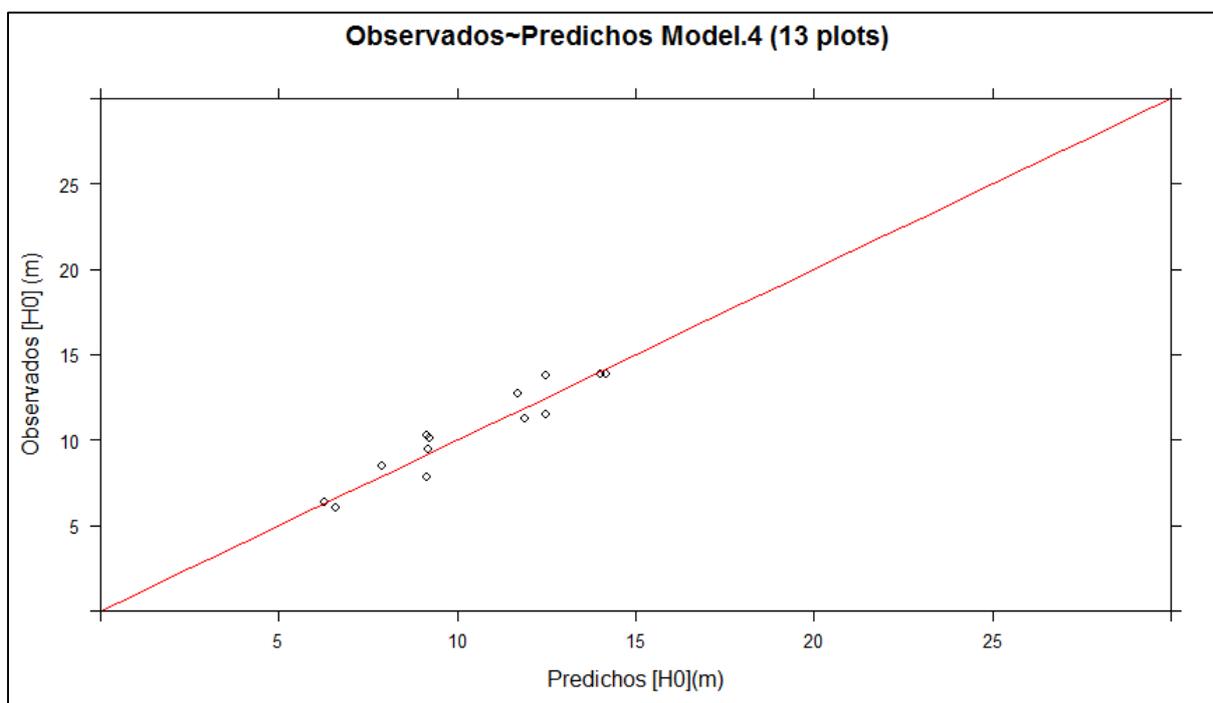
Sobre el modelo seleccionado para las predicciones de la altura dominante de Assmann (Model.4), que emplea como variable independiente el valor del percentil 95 de la nube de puntos LiDAR, se han realizado diferentes test para asegurar más aún su validez, cuyos resultados se muestran en la (Tabla 12).

**Tabla 12.** Tests estadísticos realizados sobre el modelo (Model.4) y resultados.

| Análisis                   | Test                        | p-valor       | Interpretación                                    |
|----------------------------|-----------------------------|---------------|---|
| Homocedasticidad           | Breusch-Pagan estudentizado | 0,9019 > 0,05 | Cumple (Homocedasticidad)                         |
| Normalidad de los residuos | Kolmogórov-Smirnov          | 0,9724 > 0,05 | Cumple (Residuos $\rightarrow \mathcal{N}(0,1)$ ) |
| Valores atípicos           | Bonferroni                  |               | Parcelas 1265 y 1214<br>No distorsionan el modelo |

Como puede observarse (Tabla 12) el modelo Model.4 que emplea el percentil 95 de la métrica LiDAR cumple las condiciones de varianza constante, normalidad de los residuos y no presenta valores que distorsionen el modelo.

El modelo seleccionado (Model.4.) se ha aplicado a 13 parcelas del IFN 4 que se excluyeron del ajuste y que se seleccionaron de manera aleatoria de las 66 totales, mediante la herramienta “*sample*” de R, para comparar la predicción de dicho modelo con los valores reales medidos en campo. Se ha representado gráficamente el valor predicho por el modelo frente al observado en la medición del IFN 4 (Figura 25).



**Figura 25.** Gráfico de predichos y observados para las 13 parcelas excluidas en el ajuste del modelo Model.4 empleadas para la validación del modelo.

Como podemos observar (Figura 25) los resultados arrojados por el modelo en comparación con los valores medidos en campo en el IFN 4 son bastante acertados, concentrándose en torno a la diagonal.

También se han comparado los resultados del modelo Model.1 y del Model.4, dado que el modelo Model.1 presentaba también buenos valores de AIC, BIC, RSE y R<sup>2</sup> (Tabla 11). En la Tabla 13 se muestran los resultados de predicción de los modelos Model.1 y Model.4 para las 13 parcelas excluidas del ajuste de manera aleatoria de las 66 totales.

**Tabla 13.** Resultados de la validación del modelo Model.4 y Model.1 para las 13 parcelas excluidas del ajuste. Error Model.1:  $|[(H_0 \text{ observada} - H_0 \text{ predicha Model.1}) / H_0 \text{ observada}]| \cdot 100$  (%); Error Model.4:  $|[(H_0 \text{ observada} - H_0 \text{ predicha Model.4}) / H_0 \text{ observada}]| \cdot 100$  (%).

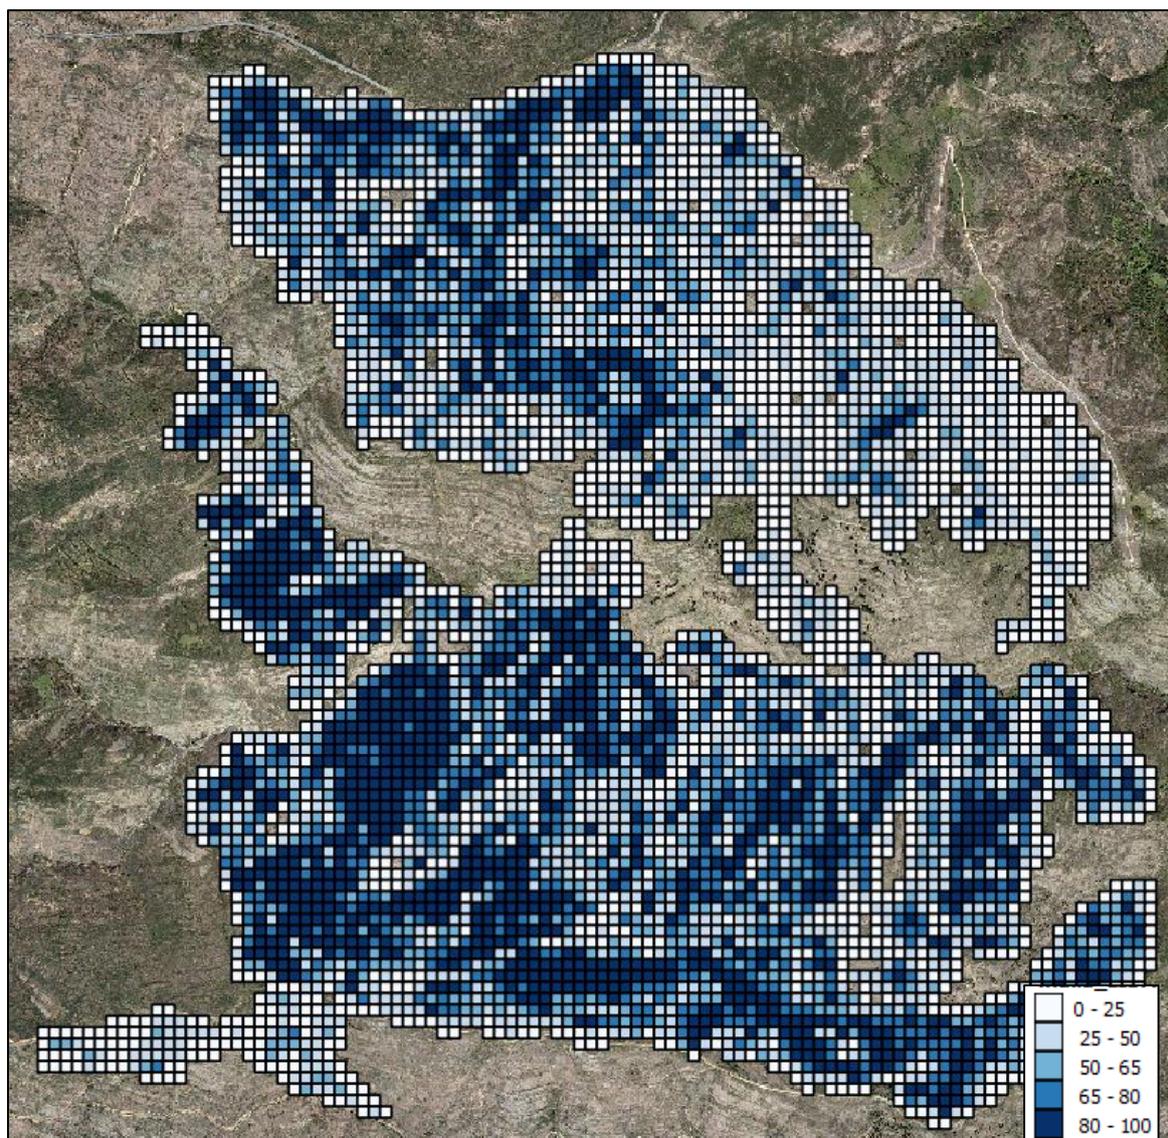
| Parcela IFN 4            | H <sub>0</sub> observada (m) | H <sub>0</sub> predicha Model.1 (m) | H <sub>0</sub> predicha Model.4 (m) | Error Model.1 | Error Model.4 |
|--------------------------|------------------------------|-------------------------------------|-------------------------------------|---------------|---------------|
| 49                       | 11,49                        | 12,24                               | 12,49                               | 6,57          | 8,71          |
| 57                       | 12,70                        | 10,92                               | 11,72                               | 14,01         | 7,75          |
| 705                      | 11,23                        | 11,22                               | 11,88                               | 0,06          | 5,78          |
| 713                      | 13,86                        | 14,80                               | 14,17                               | 6,78          | 2,25          |
| 716                      | 10,24                        | 9,39                                | 9,13                                | 8,33          | 10,84         |
| 755                      | 6,31                         | 6,72                                | 6,27                                | 6,55          | 0,68          |
| 778                      | 10,12                        | 9,12                                | 9,21                                | 9,83          | 8,99          |
| 790                      | 13,85                        | 12,64                               | 14,01                               | 8,76          | 1,14          |
| 797                      | 7,82                         | 9,35                                | 9,13                                | 19,61         | 16,73         |
| 1133                     | 13,81                        | 12,39                               | 12,48                               | 10,26         | 9,62          |
| 1178                     | 9,42                         | 9,00                                | 9,19                                | 4,46          | 2,44          |
| 1217                     | 8,46                         | 8,31                                | 7,90                                | 1,74          | 6,65          |
| 1252                     | 5,99                         | 7,48                                | 6,59                                | 24,83         | 9,94          |
| <b>Máximo</b>            |                              |                                     |                                     | <b>24,83</b>  | <b>16,73</b>  |
| <b>Media</b>             |                              |                                     |                                     | <b>9,37</b>   | <b>7,04</b>   |
| <b>Mínimo</b>            |                              |                                     |                                     | <b>0,06</b>   | <b>0,68</b>   |
| <b>Desviación típica</b> |                              |                                     |                                     | <b>6,83</b>   | <b>4,57</b>   |

Como puede observarse (Tabla 13) el modelo Model.4 arroja mejores predicciones que el modelo Model.1. Por ello se concluye que la elección del modelo ha sido la acertada.

#### 4.1.3. Incorporación de resultados al Sistema de Información Geográfica (SIG)

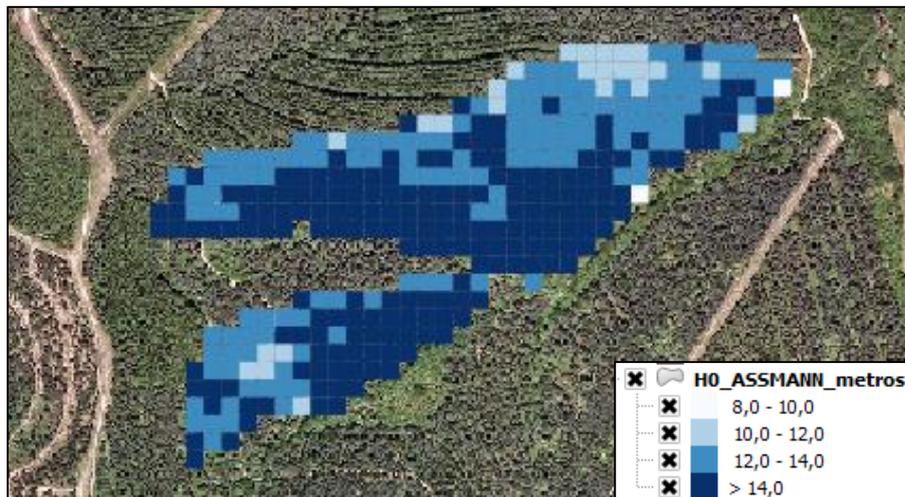
El archivo vectorial creado en este trabajo, incluye otra información que es de gran interés de cara a la gestión forestal, como es el valor de la Fracción de Cobertura (FCC) de cada celda, que se corresponde con el valor del porcentaje de primeros retornos a una altura de 2 metros (altura establecida en el procesado, ver punto 7) Obtención de la métrica de la información LiDAR para las parcelas del IFN 4 del apartado 3.3.2. Procesado de la información LiDAR aérea).

En la Figura 26 se muestra una captura en el SIG de la cuadrícula vectorial clasificada por Fracción de Cobertura (FCC) para un monte poblado de pino laricio en La Rioja.

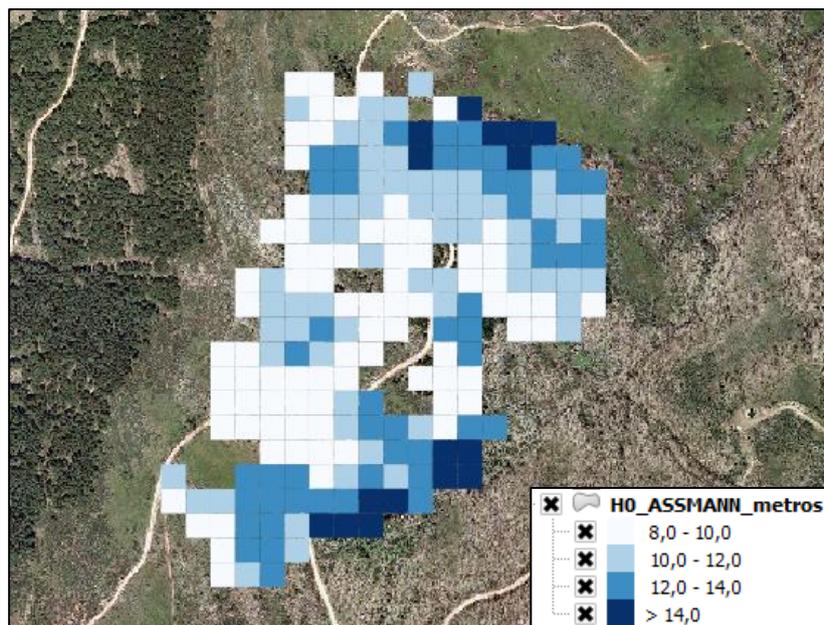


**Figura 26.** Vista general en QGis® V2.8.1 del monte nº 12 “Valdeova y Almedaños” de Robres del Castillo clasificado por porcentajes de Fracción de Cobertura (FCC).

El modelo de predicción de la altura dominante de Assmann a partir de la métrica LiDAR seleccionado, el modelo Model.4 ( $H_0 = 1,35528 + 0,86190 \cdot \text{Elev.P95}$ ) se ha incorporado a la tabla de atributos del archivo vectorial tipo polígono creado (Figura 27 y Figura 28), obteniendo de esta forma el valor de altura dominante predicha para cada celda del archivo vectorial.



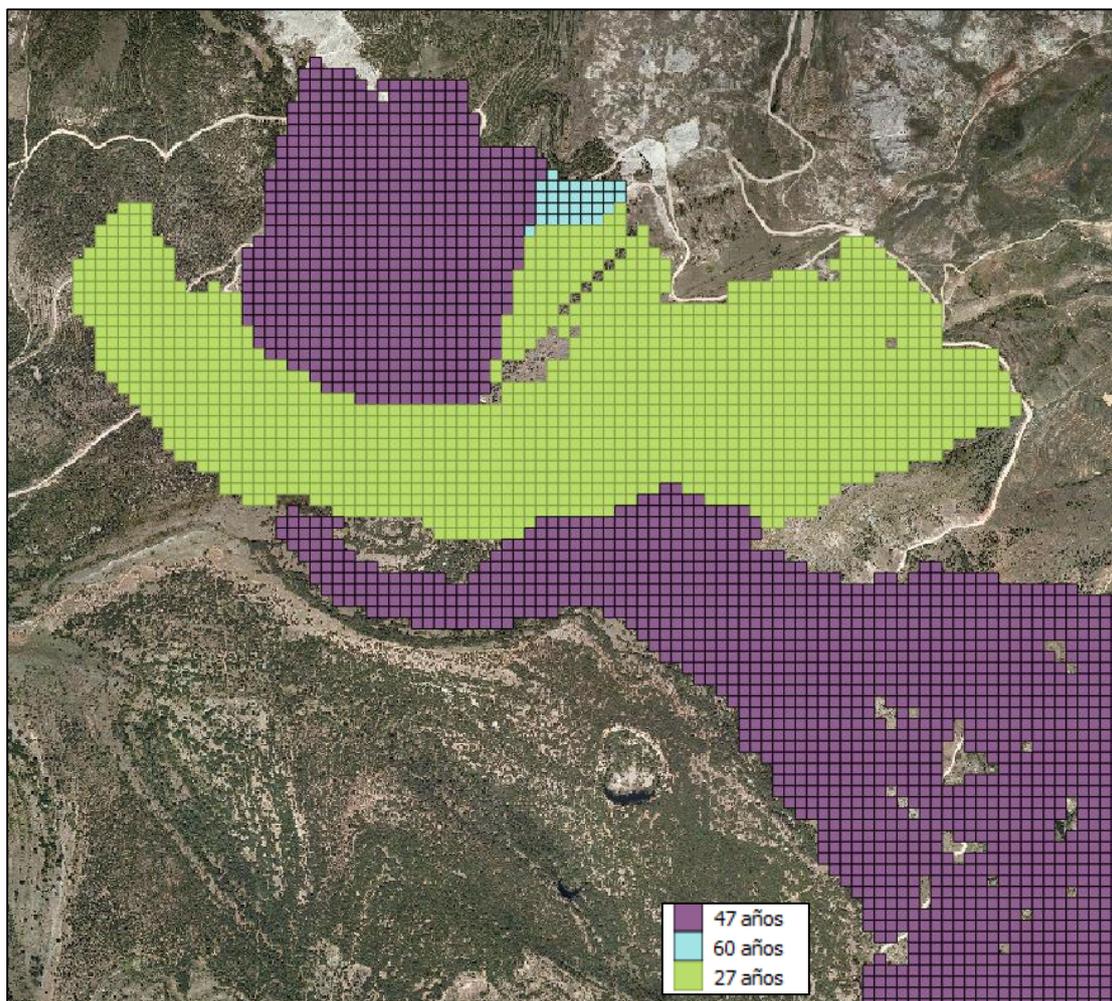
**Figura 27.** Vista general en QGIS® V2.8.1 de un rodal de *Pinus nigra* del MUP nº 77 “Urquiara” de Santurdejo clasificado por alturas dominantes de Assmann calculadas a partir del modelo Model.4.



**Figura 28.** Vista general en QGIS® V2.8.1 de un rodal de *Pinus nigra* en el paraje “San Juan de Agriones” de Santa Engracia del Jubera clasificado por alturas dominantes de Assmann calculadas a partir del modelo Model.4.

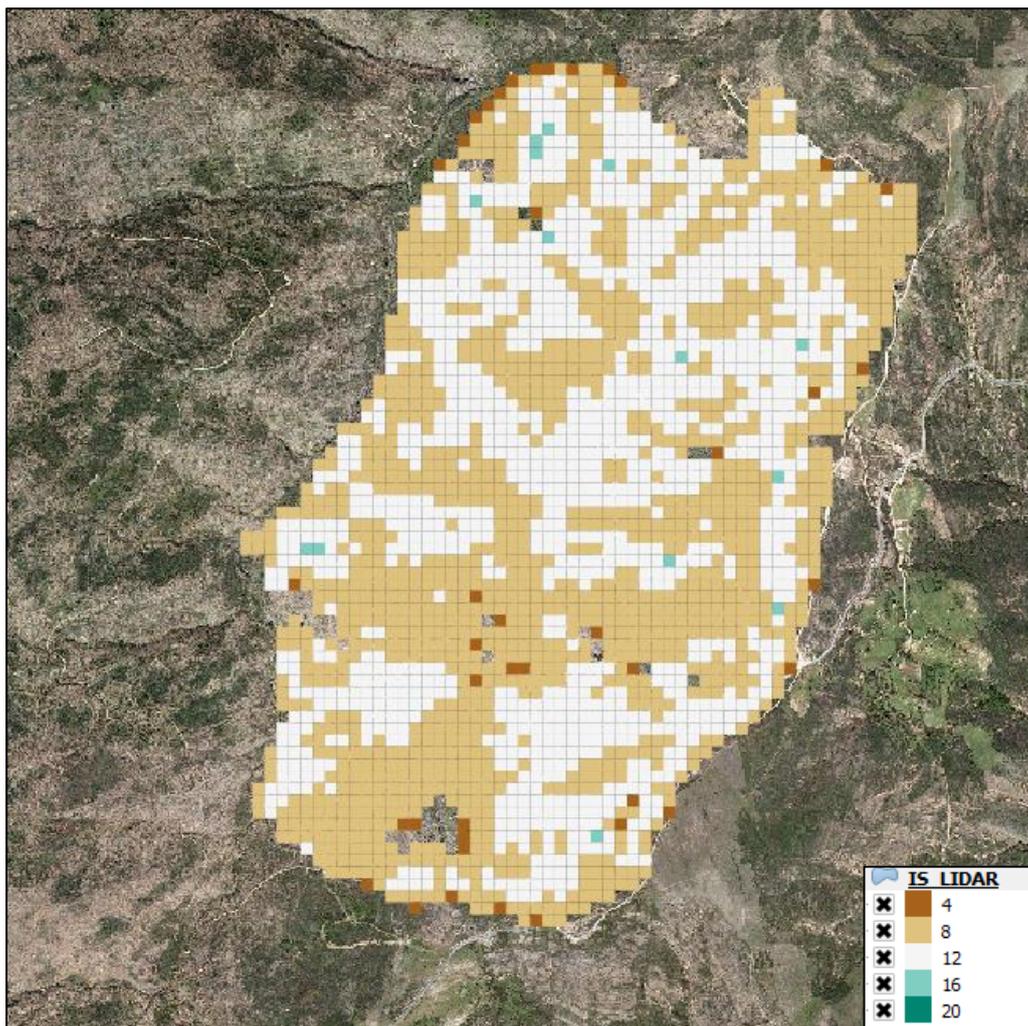
Con el valor de la edad de cada celda (Figura 29), el valor predicho de altura dominante de Assmann a partir del valor del percentil 95 del LiDAR y las ecuaciones analíticas de los límites entre las clases de índice de sitio establecidas, se ha asignado a

a cada celda el valor correspondiente de índice de sitio, obteniéndose así el mapa de calidades de estación (Figura 30 y Figura 31).



**Figura 29.** Vista general en QGis® V2.8.1 de los MUPs nº 233 “Hayedo y Abanto” de Ribafrecha y nº 209 “La Selva y Grimón” de Lagunilla del Jubera clasificado por edades a fecha de 2012 (año del IFN 4).

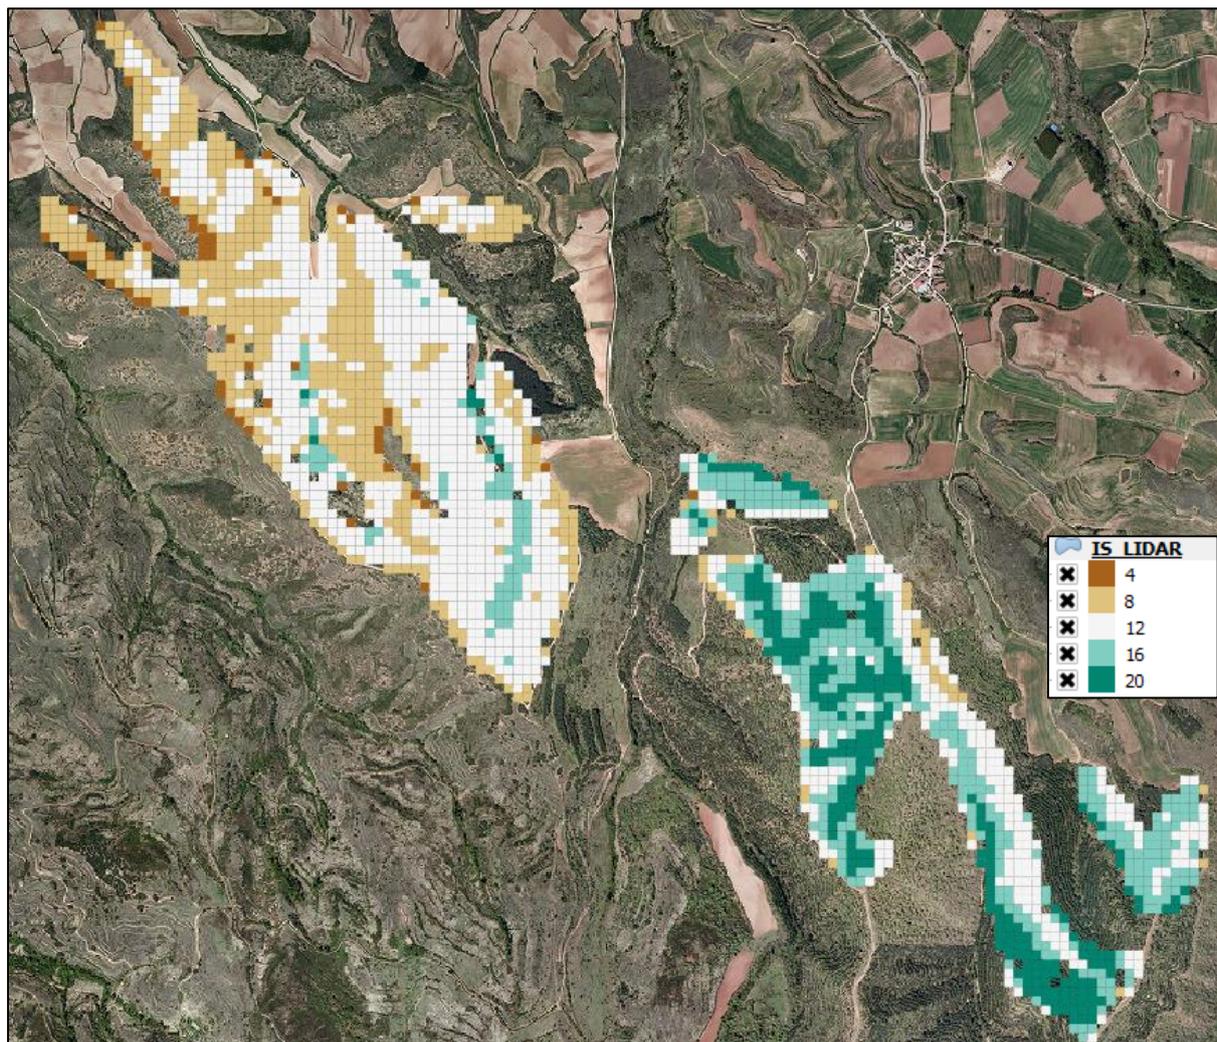
En las siguientes figuras (Figura 30 y Figura 31) se muestran dos capturas de tres montes poblados por *Pinus nigra*, con el mapa vectorial obtenido en este trabajo clasificado de acuerdo a las clases de calidad de estación definidas. Gracias a esto, se pueden comparar entre sí las distintas masas y tener una idea de su productividad, representada por los distintos índices de sitio, pudiendo así adecuar la gestión a sus características.



**Figura 30.** Vista general en QGis®V2.8.1 del monte “Las Santanas” de Santa Engracia del Jubera clasificado por calidad de estación con las clases definidas en este trabajo.

En el caso que se presenta (Figura 30) a modo de ejemplo para el monte “Las Santanas”, en el término municipal de Santa Engracia del Jubera, se observa que domina el índice de sitio 8, encontrándose en menor medida otros SI como son el 12 y en menor medida aún el 4 o el 16.

Comparando con otro caso, que se muestra en la Figura 31, se aprecia una mayor representación de los índices 16 y del 20, que no se encuentra en el caso del monte de “Las Santanas”.



**Figura 31.** Vista general en QGis® V2.8.1 de los MUP nº 169 “La Santa” de Bezares y nº 218 “Santices y Cajjal” de Arenzana de Arriba clasificado por calidad de estación con las clases definidas en este trabajo.

Respecto al total de la superficie de estudio, se ha elaborado una tabla (Tabla 14) que muestra la representación de los distintos índices de sitio a nivel de superficie.

**Tabla 14.** Representación de los índices de sitio para toda la superficie estudiada de *Pinus nigra* Arn. en La Rioja

| Índice de sitio (m a los 40 años) | Productividad | Número de celdas (625 m <sup>2</sup> ) | Superficie (ha) | Porcentaje de superficie (%) |
|-----------------------------------|---------------|--|-----------------|------------------------------|
| 4                                 | Muy baja      | 5.465                                  | 341,56          | 4,01                         |
| 8                                 | Baja          | 70.340                                 | 4.396,25        | 51,57                        |
| 12                                | Media         | 49.268                                 | 3.079,25        | 36,12                        |
| 16                                | Media-alta    | 9.591                                  | 599,44          | 7,03                         |
| 20                                | Alta          | 1.727                                  | 107,94          | 1,27                         |

Como puede observarse, el índice de sitio más representado en las masas de *Pinus nigra* Arn. repobladas en La Rioja (Tabla 14) es el índice de sitio de 8 metros a la edad típica de 40 años, encontrándose este en un total de 4.396,25 ha, lo que supone un 51,57 % de la superficie total estudiada.

Tras la clasificación del archivo vectorial obtenido por índices de sitio, se ha observado que el índice de 4 metros a la edad típica de 40 años se encuentra muy poco representado, a pesar de que a la hora de elaborar las curvas de calidad de estación fue necesario definirlo, siendo este valor de altura dominante de 4 metros a los 40 años de edad un valor muy bajo. La presencia de esta calidad de 4 metros a los 40 años de edad típica revela una mala elección de especie.

## 4.2. DISCUSIÓN

Se considera que los resultados obtenidos en este trabajo son suficientemente aceptables y válidos para ser empleados de cara a la gestión de las masas repobladas de *Pinus nigra* Arn. en La Rioja, habiéndose obtenido de manera satisfactoria una estimación de la altura dominante y del índice de sitio para un total de 7.711,84 ha de repoblaciones de *Pinus nigra* Arn. estudiadas en La Rioja.

En lo que se refiere a la metodología empleada para la elaboración de las curvas de calidad de estación, difiere de lo normalmente empleado en estudios similares, siendo más frecuente el empleo de análisis de troncos (BRAVO et al., 2007; LÓPEZ-SENESPLEDA y SÁNCHEZ-PALOMARES, 2007; RÍO et al., 2006; ÁLVAREZ et al., 2004) en vez de lo empleado en este caso, como son las mediciones sucesivas de los distintos Inventarios Forestales Nacionales (IFN 2, 3 y 4).

La morfología de las curvas obtenidas en este estudio, se ha comparado con las que presenta RÍO et al. (2006) para el mismo tipo de masas, masas repobladas de *Pinus nigra* Arn., pero en este caso para la C.C.A.A de Castilla y León. Las curvas obtenidas en este trabajo que se presenta muestran una evolución de la altura dominante de Assmann respecto a la edad mucho más tendida, respecto a lo presentado por RÍO et al. (2006), no estando presentes los índices de sitios inferiores definidos en este trabajo, pero sí los índices de sitio que muestran una mejor calidad.

En el trabajo de RÍO et al. (2006) se definen los índices de sitio de 12, 15, 18 y 20 metros a la edad típica de 50 años, frente a los SI de 4, 8, 12, 16 y 20 metros a la edad típica de 40 años definidos en este trabajo.

No se han definido los mismos índices de sitio que los propuestos por RÍO et al. (2006) dado que no representaban adecuadamente los datos de edad y altura dominante con los que se ha trabajado. Lo mismo ocurre con la edad típica, habiéndose seleccionado una edad típica

de 40 años debido a que es una edad intermedia en la serie de datos  $H_0$ -edad y además se corresponde con la edad a mitad del turno recomendado para la especie.

Por otro lado, para el caso estudiado por RÍO et al. (2006) para las masas de *Pinus nigra* Arn. de repoblación en Castilla y León, el modelo que mejor ajusta a los pares de datos de altura dominante y edad es el polimórfico de Richards frente al modelo seleccionado en este trabajo que ha sido el modelo anamórfico de Hossfeld I (mod.).

En el trabajo de CALVO-SÁENZ (2014), se estudia el índice de sitio de las masas de pino laricio en el Monte de Utilidad Pública nº 185 de la Comunidad Autónoma de La Rioja. En este trabajo se emplearon las curvas de calidad de estación propuestas por RÍO et al. (2006) y coinciden, respecto a este estudio con LiDAR, las zonas donde encontramos las mejores calidades y las peores en dicho MUP, no pudiéndose comparar los índices por estar definidos de forma distinta como ya se ha comentado.

Otro factor a analizar es el método de obtención empleado para las curvas, estando el método de la curva guía, que ha sido empleado en este caso, en desuso, frente a otros métodos como es el ADA (Aproximación de diferencias algebraicas) o el GADA (Aproximación de diferencias algebraicas generalizadas) (BRAVO et al., 2012) que vienen siendo más usados desde finales de la década de los 90 y en los años posteriores.

La elaboración de curvas de calidad de estación, para poder clasificar las formaciones forestales de cara a su manejo es, como ya se ha comentado al principio de este trabajo, uno de los principales objetivos de los investigadores forestales (WEISKITTEL et al., 2011), habiéndose obtenido en este trabajo una herramienta útil de gestión forestal, como es un mapa de calidades de estación, representadas a través de distintos índices de sitio.

La base de datos del Inventario Forestal Nacional (IFN), ha demostrado en numerosas ocasiones su gran utilidad, habiéndose empleado sus datos en multitud de estudios (BRAVO & MONTERO, 2001; BRAVO-OVIEDO et al., 2007; LÓPEZ-SENEPLEDA y SÁNCHEZ-PALOMARES, 2007; VALBUENA, 2014), como ha sido en este caso, que gracias a los datos del segundo, tercer y cuarto IFN se ha podido llevar a cabo este trabajo en el tiempo de que se disponía, habiendo sido imposible por el coste que supone el haber realizado un inventario, tanto para las curvas de calidad de estación como para la elaboración de los modelos  $H_0$ -LiDAR.

VALBUENA (2014) presenta un estudio de estimación de variables de masa y de árboles individuales a partir de información LiDAR aerotransportada del Plan Nacional de Ortofotografía aérea y de datos del Inventario Forestal Nacional para *Pinus sylvestris* en el País Vasco. En este caso se localizaron las parcelas en campo y se replantearon, recalculando sus coordenadas para obtener una comparación con el LiDAR más precisa, dado que las coordenadas en el IFN no se toman con suficiente precisión, cosa que se ha hecho patente en este trabajo al haber tenido que eliminar datos de parcelas del IFN 4 por no

encontrarse bien localizadas, lo que habría llevado a errores en la estimación de los modelos de predicción a partir del LiDAR, de acuerdo con lo expuesto por MAURO et al. (2013), siendo necesaria una correcta geolocalización de todos los datos.

La densidad de puntos de la que se partía en los datos LiDAR-PNOA empleados en este caso, difiere enormemente de la que disponía VALBUENA (2014), siendo de 0,5 puntos/m<sup>2</sup> en el caso que se ha analizado en este trabajo y de más de 2 puntos/m<sup>2</sup> en otro caso, lo que permitió llegar a aplicar métodos de árbol individual, delineando pies dominantes, frente al método de masa empleado en este trabajo.

El LiDAR aéreo ha demostrado en numerosas ocasiones su utilidad para el estudio de diversas variables de interés forestal (MAGNUSSEN & BOUDEWYN, 1998; MAGNUSSEN et al., 1999; NAESSET, 2004; ANDERSEN et al., 2005; KOCH, 2010; KAARTINEN et al., 2012; VALBUENA, 2014) con posibilidad de reducir los costes en grandes áreas de estudio (FERNÁNDEZ et al., 2013) y obteniéndose resultados de gran calidad, siempre que los modelos realizados para relacionar la métrica LiDAR y la variable o variables forestales de interés (MAURO et al., 2013).

La variable LiDAR que se ha empleado en este caso para estimar la altura dominante es el percentil 95 (Elev.P95) que explica los datos de altura dominante de Assmann del IFN 4 en un 93,28 %. A modo de ejemplo se pone el caso del estudio de ARIAS (2015) en el cuál se obtiene un modelo para estimar la altura dominante de masas de castaño a partir del percentil 99 del LiDAR, con un R<sup>2</sup> del 90,2 %. Se aprecia que el LiDAR arroja buenas predicciones de la altura dominante de la masa a partir de su métrica, por lo que este es una muy buena herramienta para el estudio y la caracterización de las masas forestales (KAARTINEN et al., 2012).

VALBUENA (2014) realiza una estimación de la altura dominante de las parcelas a partir del percentil 95 de la métrica LiDAR, con un coeficiente R<sup>2</sup> del 96,44 %, superior al R<sup>2</sup> que se ha obtenido en este caso siendo este del 93,28 %. El modelo obtenido para *Pinus sylvestris* es  $H_0 = 1,6534 + 0,9540 \cdot P95$ , siendo  $H_0$  la altura dominante de la parcela, y P95 el valor de la altura del percentil 95 del LiDAR, que es muy similar al obtenido en este estudio para *Pinus nigra* en La Rioja siendo este  $H_0 = 1,35528 + 0,86190 \cdot \text{Elev.P95}$ , siendo  $H_0$  la altura dominante y Elev.P95 el valor del percentil 95 de la nube de puntos LiDAR. La diferencia en los modelos presenta una mayor altura para las formaciones de silvestre en Álava que para las de laricio en La Rioja, para un mismo valor del percentil 95 del LiDAR.

Los Sistemas de Información Geográfica (SIG) son una magnífica herramienta con la que trabajar en el campo forestal, además de otros muchos, y gracias a ellos se puede gestionar la información geográfica (SÁNCHEZ et al., 1999; FERNÁNDEZ, 2015), como el mapa vectorial creado en este caso con la información LiDAR, el valor de altura dominante de Assmann, las edades y los valores de índices de sitio.

## 5. CONCLUSIONES

De los resultados obtenidos en este trabajo, tras la elaboración de las curvas de calidad de estación, del modelo de predicción de alturas dominantes de Assmann y del mapa de calidades de estación para las masas repobladas de pino laricio en La Rioja a partir de datos LiDAR aéreos, se extraen las siguientes conclusiones:

1. La base de datos del Inventario Forestal Nacional supone una importante fuente de datos para estudios ligados a la gestión forestal. Sin embargo, sería deseable un mejor posicionamiento de las parcelas, a ser posible con un Sistema de Posicionamiento Global (GPS) de precisión, dado que son parcelas que además se miden repetidas veces a lo largo de su vida útil. La información del IFN ha demostrado ser válida para elaborar curvas de calidad de estación con la aplicación que en este trabajo se le ha dado y suficientemente válida para la elaboración de modelos de predicción de la altura dominante a partir de datos LiDAR, sin olvidar los problemas derivados de la localización de las coordenadas de las parcelas que se han observado durante la elaboración de este trabajo.
2. El formato de toma de datos de campo del IFN, mediante parcelas de radio variable donde se miden los pies en uno u otro radio en función de su diámetro normal puede complicar la obtención de variables dasométricas de interés.
3. Es de gran importancia que los servicios de medio ambiente de las Comunidades Autónomas cuenten con información detallada de las formaciones forestales, como ha sido en este caso el dato de la edad de las repoblaciones.
4. Los datos LiDAR del PNOA suponen también una gran fuente de información de cara a estudios forestales y de cara a la gestión de los montes, pudiéndose mejorar en lo que a densidad de puntos se refiere, especialmente en zonas forestales.
5. Los programas de código abierto empleados en este trabajo han demostrado tener la capacidad suficiente para manejar la gran cantidad de información que arroja la tecnología LiDAR y se hace especialmente importante el poder contar con aplicaciones para el procesado de datos LiDAR específicas para el ámbito forestal, como es Fusion®.
6. El poder contar con información de detalle a nivel continuo de una gran superficie, como es el archivo vectorial obtenido con información de alturas dominantes de Assmann, edades y la clasificación por índices de sitio supone una gran herramienta para una gestión forestal sostenible.
7. Se hace necesario el seguir desarrollando estudios y trabajos con datos LiDAR en aplicaciones forestales, datos del IFN, ... que sirvan de ejemplo para otros venideros.
8. Se hace patente la necesidad de incorporar nociones básicas de programación y hacer más hincapié en el análisis estadístico avanzado en las titulaciones forestales, pues son muy necesarias para el manejo de grandes bases de datos y para el ajuste de modelos,

como pueden ser los modelos de calidad de estación o los modelos de predicción de variables dasométricas a partir del LiDAR.

## 6. BIBLIOGRAFÍA

- ADAME, P., CAÑELLAS, I., RÍO, M., MONTERO, G., (2007). Estudio del crecimiento en altura dominante de rebollares en Castilla y León. Cuad. Soc. Esp. Cienc. For. 21:19-24
- ÁLVAREZ, A., DÍAZ, L. y ORIA DE RUEDA, J. A. (2001). Valoración de la producción conjunta madera-setas. Aplicación al caso de la Carballeda (Zamora). Actas del III Congreso Forestal Español. Tomo 5, pp 775-780. Granada, 25-28 septiembre de 2001.
- ÁLVAREZ, J.G., BARRIO, M., DIÉGUEZ, U., ROJO, A. (2004) Metodología para la construcción de curvas de calidad de estación. Cuad. Soc. Esp. Cien. For. 18: 303-309
- ALONSO, R., MADRIGAL, G. (2007). Modelos de crecimiento e índices de Sitio para *Juniperus thurifera* en España. Cuadernos SECF 23, 99 - 106
- ANDERSERN, H.E., REUTEBUCH, S.E., MCGAUGHEY, R.J., (2005) Estimating forest canopy fuel parameters using LiDAR data. Remote Sensing of Environment 94: 441-449
- ARIAS, M., (2015) Modelización del monte bajo de castaño de Brañalonga (Tineo) mediante tecnología LiDAR. Escuela Politécnica de Mieres. Área de Ingeniería Agroforestal. Universidad de Oviedo.
- ASSMANN, E. (1970) The principles of forest yield study. Pergamon, Oxford, New York, en MADRIGAL, A., ÁLVAREZ, J.G., ROJO, A., RODRÍGUEZ, R., (1999). Tablas de producción para los montes españoles. Fundación Conde del Valle Salazar, Madrid.
- ASSMANN, E. (1970) The principles of forest yield study. Pergamon, Oxford, New York, en PRETZSCH, H. (2009) Forests Dynamics, Growth and Yield, From Measurement to Model. Springer. Germany
- BARNES, B.V., ZAK, D.R., DENTON, S.R., SPURR, S.H., (1997). Forest Ecology. John Wiley & Sons. Inc. New York.
- BENGOA, J.L., (1999). Estimación de la altura dominante de la masa a partir de la "altura dominante de parcela". Ventajas frente a la altura dominante de Assman. Invest. Agr.: Sist. Recur. For.: Fuera de Serie nº 1
- BRATOVICH, R., MARLATS, R.M., MIKELAITES, H., (1996). Relación juvenil-adulto de crecimientos en Alturas, diámetros y volúmenes de clones provenientes de cruzamientos controlados inter e intra-específicos de *Populus* sp. L.. Revista de la Facultad de Agronomía de La Plata, 101(1): 7-13

- BRAVO, F., MONTERO, G., (2001). Site index estimation in Scots pine (*Pinus sylvestris* L.) stands in the High Ebro Basin (northern Spain) using soil attributes. *Forestry*, Vol. 74, No. 4.
- BRAVO, F., ÁLVAREZ-GONZÁLEZ, J.G., RÍO, M., (Coords.) (2012) Growth and Yield Models in Spain: Historical Overview, Contemporary Examples and Perspectives. Instituto Universitario en Gestión Forestal Sostenible (Universidad de Valladolid-INIA) y Unidad de Gestión Forestal Sostenible (Universidad de Santiago de Compostela).
- BRAVO, F., HERRERO, C., BRAVO-NÚÑEZ, A., LARA, W., RIOFRÍO, J.G. (2015) Análisis de datos selvícolas con R. Universidad de Valladolid
- BUFTON, J.L., GARVIN, J.B., CAVANAUGH, J.F., RAMOS-IZQUIERDO, L., CLEM, T.D., KRABILL, W.B., (1991). Airborne LiDAR for profiling of surface topography. *Optical Engineering* 30 (1): 72-78
- BURNHAM, K., ANDERSON, D. (2002) Model selection and Multimodal Inference. Springer. New York
- CALVO-SÁENZ, R. (2014) Plan Dasocrático del MUP nº 185 'La Santa'. Término municipal de Munilla (La Rioja). Escuela Técnica Superior de Ingenierías Agrarias. Universidad de Valladolid
- CLUTTER, J.L., J.C. FORTSON, L.V. PIENAAR, G.H. BRISTER, AND R.L. BAILEY. (1983) Timber Management: A quantitative approach. John Wiley & Sons. Inc. New York.
- EICHHORN, F. (1902) Ertagstafeln für die Weißtanne. Verlag Julius Springer, Berlin en  
PRETZSCH, H. (2009) Forests Dynamics, Growth and Yield, From Measurement to Model. Springer. Germany
- FEKEDULEGN, D., MAC SIURTAÍN, M.P., COLBERT, J.J. (1999) Parameter Estimation of Nonlinear Growth Models in Forestry. *Silva Fennica* 33(4): 327-336
- FERNÁNDEZ-ALDANA, R. (2015) Mapa de los Bosques de La Rioja. Gobierno de La Rioja. Consejería de Agricultura, Ganadería y Medio Ambiente.
- FERNÁNDEZ, A., MARTÍNEZ, J.F., SOTO, M., SABÍN, P. (2013) Nuevos enfoques en la planificación forestal: Plan Selvícola de los pinares y hayedos de los montes de Utilidad Pública del Jubera-Alto-Cidacos (La Rioja). Ponencias del 6º Congreso Forestal Español, Vitoria. 6CFE01-475.
- FERNÁNDEZ, I., (2015). Aplicaciones SIG en Proyectos de Ordenación de Montes. Escuela Politécnica de Mieres. Área de Ingeniería Agroforestal. Universidad de Oviedo.

- GARCÍA ABEJÓN, J.L. (1981) Tablas de producción de densidad variable para *Pinus sylvestris* L. en el Sistema Ibérico. Comunicaciones INIA. Serie: Recursos Naturales, 10.
- GÓMEZ-LORANCA, J.A., (1996). *Pinus nigra* Arn. en el Sistema Ibérico: Tablas de crecimiento y producción. Monografías INIA, 93.
- KAARTINEN, H., HYYPPÄ, J., YU, X., VASTARANTA, M., HYYPPÄ, H., KUKKO, A., HOLOPAINEN, M., HEIPKE, C., HIRSCHMUGL, M., MORSDORF, F., NAESSET, E., PITKÄNEN, J., POPESCU, S., SOLBERG, S., WOLF, B.M., WU, J. (2012) An International Comparison of Individual Tree Detection and Extraction Using Airborne Laser Scanning. *Remote Sens.* 4(4): 950-974
- KIVISTE, A., ÁLVAREZ, J.G., ROJO, A., RUIZ, A.D., (2002). Funciones de crecimiento de aplicación en el ámbito forestal. Monografías INIA: Forestal 4. INIA, Madrid.
- KOCH, B. (2010) Status and future of laser scanning, synthetic aperture radar and hyperspectral remote sensing data for forest biomass assessment. *ISPRS Journal of Photogrammetry and Remote Sensing.* Vol 65
- KOTZE, H. and VONK, D. (1997) A Growth Simulator and Pruning Scheduler for *Pinus patula* in Mpulanga-North Providence, South Africa en AMARO, A. and TOMÉ, M. (Eds.) (1997) Empirical and Process Based Models for Forest Tree and Stand Growth Simulation. Salamandra, LDA. Lisboa.
- KRABILL, W.B., COLLINS, J.G., LINK, L.E., SWIFT, R.N., BUTLER, M.L. (1984). Airborne laser topographic mapping results. *Photogrammetric Engineering and Remote Sensing* 50 (6): 685-694.
- LÓPEZ-SENEPLEDA, E., SÁNCHEZ-PALOMARES, O. (2007). Modelo de calidad de estación y crecimiento en altura dominante para *Quercus faginea* Lam. en España. *Cuad. Soc. Esp. Cien. For.* 23: 199-205
- NAESSET, E., (2004) Practical large-scale forest stand inventory using a small-footprint airborne scanning laser. *Scandinavian Journal of Forest Research* 19(2): 164-179
- NELSON, R.F., KRABILL, W.B., MACLEAN, G.A., (1984). Determining forest canopy characteristics using airborne laser data. *Remote Sensing of Environment* 15: 201-212.
- NELSON, R.F., SWIFT, R., KRABILL, W., (1988a). Using airborne lasers to estimate forest canopy and stand characteristics. *Journal of Forestry* 86: 31-38
- NELSON, R.F., KRABILL, W., TONELLI, J., (1988b). Estimating forest biomass and volume using airborne laser data. *Remote Sensing of Environment* 24, 247-267.

- MACLEAN, G.A., KRABILL, W.B., (1986). Gross-merchantable timber volume estimation using an airborne LiDAR system. *Canadian Journal of Remote Sensing* 12 (1): 7-18.
- MADRIGAL, A., PUERTAS, F., MARTÍNEZ MILLÁN, F.J., (1992). Tablas de producción para *Fagus sylvatica* L. en Navarra. Serie Agraria, nº 3. Departamento de Agricultura, Ganadería y Montes. Gobierno de Navarra. Pamplona.
- MADRIGAL, A., ÁLVAREZ, J.G., ROJO, A., RODRÍGUEZ, R., (1999). Tablas de producción para los montes españoles. Fundación Conde del Valle Salazar, Madrid.
- MADRIGAL, A., ALONSO, R., CALAMA, R., MONTERO, G., MORO, J., (2007). Patrón de crecimiento en altura dominante en masas naturales y artificiales de *Pinus pinea* L.: Comparación a través de modelos dinámicos. Cuadernos SECF 23, 207-214.
- MAGNUSSEN, S., BOUDEWYN, P. (1998) Derivations of stand heights from airborne laser scanner data with canopy-based quantile estimators. *Can. J. For. Res.* 28: 1016 - 1031
- MAGNUSSEN, S., EGGERMONT, P., LARICCIA, V. (1999) Recovering tree heights from airborne laser scanner data. *For. Sci.* 45(3): 407-422
- MAGRAMA (2013) Cuarto Inventario Forestal Nacional: La Rioja (IFN 4). Ministerio de Agricultura Alimentación y Medio Ambiente. Madrid
- MAURO, F., VALENTÍN-GAMAZO, M., GARCÍA, A., VALBUENA, R., RODRÍGUEZ, R., DE BLAS, A. (2013). Influencia de los errores de posicionamiento GNSS en la estimación de variables dasométricas medias a partir de datos LiDAR. Ponencias del 6º Congreso Forestal Español, Vitoria. 6CFE01-485.
- MCGAUGHEY, R.J. (2015) FUSION/LDV: Software for LiDAR Data Analysis and Visualization. United States Department of Agriculture (USDA), Forest Service, Pacific Northwest Research Station, University of Washington, Seattle.
- MEREDIEU, C. PERRET, S. and DREYFUS, P. (2003). Modelling Dominant Height Growth: Effect of Stand Density en AMARO, A., REED, D. and SOARES, P. (Eds.) (2003). *Modelling Forests Systems*. CAB International.
- MONSERUD, R.A. and HUANG, S. (2003) Mapping Lodgepole Pine Site Index in Alberta en AMARO, A., REED, D. and SOARES, P. (Eds.) (2003). *Modelling Forests Systems*. CAB International.
- OLIVER, C.D., LARSON, B.C., (1996). *Forests Stand Dynamics*. John Wiley and Sons, New York.

- ORDEN FOM/2807/2015 , de 18 de diciembre de 2015, por la que se aprueba la política de difusión pública de la información geográfica generada por la Dirección General del Instituto Geográfico Nacional.
- ORTEGA, A., MONTERO, G. (1988). Evaluación de la calidad de estación de las estaciones forestales. Revisión bibliográfica. *Ecología* 2: 155-184
- PALAHÍ, M. & GRAU J.M. (2003). Preliminary site index model and individual-tree growth and mortality models for black pine (*Pinus nigra* Arn.) in Catalonia (Spain). *Invest. Agrar.; Sist. Recur. For.* 12: 137-148
- PITA, P.A. (1964) La calidad de estación en las masas de *Pinus sylvestris* L. en la Península Ibérica. *Anales IFIE* 9, 5 – 28.
- POESCU, S.C., WYNNE, R.H., NELSON, R.F. (2002) Estimating plot-level tree heights with LiDAR: local filtering with a canopy-height based variable window size. *Computers and Electronics in Agriculture.* 37: 71-95.
- PRESSLER, M. (1977) Forstliche Zuwachs-, Ertrags- und Bonitierungs- Tafeln mit Regeln und Beispielen. 2<sup>nd</sup> Ed. Selfpubl, Tharandt en PRETZSCH, H. (2009) *Forests Dynamics, Growth and Yield, From Measurement to Model.* Springer. Germany
- PRETZSCH, H. (2009) *Forests Dynamics, Growth and Yield, From Measurement to Model.* Springer. Germany
- REAL DECRETO 1071/2007, de 27 de julio de 2007, por el que se regula el sistema geodésico de referencia oficial en España.
- RÍO DEL, M., LÓPEZ, E., MONTERO, G. (2006) Manual de gestión para masas procedentes de repoblación de *Pinus pinaster* Ait., *Pinus sylvestris* L. y *Pinus nigra* Arn. en Castilla y León. Junta de Castilla y León, Consejería de Medio Ambiente
- RITCHIE, J.C., (1995). Airborne laser altimeter measurements of landscape topography. *Remote Sensing of Environment* 53: 91-96
- RIVAS-MARTÍNEZ, S. (1987) Memoria del mapa de series de vegetación de España. ICONA, Madrid.
- ROBINSON, A. (2015) IcebrakeR. Department of Mathematics and Statistics. University of Melbourne
- SÁNCHEZ, M.A., FERNÁNDEZ, A.A., ILLERA, P., (1999) Los sistemas de información geográfica en la gestión forestal. Teledetección. Avances y Aplicaciones. VIII Congreso Nacional de Teledetección. Albacete. pp. 96-99

SHVETS, V., ZEIDE, B., (1996). Investigating parameters of grown equations. Can. J. Res. 26, 1980-1990.

TESFAMICHAEL, S.G., VAN AARDT, J.A.N., AHMED, F. (2010) Estimating plot-level tree height and volumen of *Eucalyptus grandis* plantation using small-footprint, discrete return LiDAR data. Progress in Physical Geography 34(4) 515-540

TOMÉ, J.L., SANJUANBENITO, P., FERNÁNDEZ, A. (2013) Cartografía de Vegetación en la Comunidad de Madrid utilizando información LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA). Ponencias del 6º Congreso Forestal Español, Vitoria. 6CFE01-421.

UZQUIANO, S., MARTÍNEZ, J., SAN MARTÍN, R., BRAVO, F. (2014) Mediciones dendrométricas y dasométricas mediante técnicas LiDAR y fotogramétricas. Cuad. Soc. Esp. Cienc. For. 40: 193-202

VALBUENA, M.A. (2014) Determinación de variables forestales de masa y de árboles individuales mediante delineación de copas a partir de datos LiDAR Aerotransportados. Aplicación a las masas de *Pinus sylvestris* L. en Álava. Universidad de La Rioja, Servicio de Publicaciones.

WATT, P.J., DONOGHUE, D.N.M. (2005) Measuring Forest Structure with Terrestrial Laser Scanning. International Journal of Remote Sensing. Vol 26 nº 7

WEISKITTEL, A.R., HANN, D.W., KERSHAW-Jr., J.A. and VANCLAY, J.K. (2011) Forest Growth and Yield Modeling. Wiley-Blackwell. UK

**URL de interés consultadas:** (Consulta: dd/mm/año)

American Society of Photogrammetry and Remote Sensing: <https://www.asprs.org/>  
Ultima consulta: 08/07/2016

Infraestructura de Datos Espaciales de La Rioja: <http://www.iderioja.larioja.org/>  
Ultima consulta: 08/07/2016

Instituto Geográfico Nacional: <http://www.ign.es/>  
Ultima consulta: 08/07/2016

QGis®: <http://www.qgis.org/es/site/>  
Ultima consulta: 08/07/2016

Inventario Forestal Nacional: <http://www.magrama.gob.es/es/desarrollo-rural/temas/politica-forestal/inventario-cartografia/inventario-forestal-nacional/>

Ultima consulta: 08/07/2016

R®: <https://www.r-project.org/>

Ultima consulta: 08/07/2016

RStudio®: <https://www.rstudio.com/>

Ultima consulta: 08/07/2016

*General Public License y Lesser General Public License:*

<https://www.gnu.org/licenses/licenses.es.html>

Ultima consulta: 08/07/2016

Notepad++®: <https://notepad-plus-plus.org/>

Ultima consulta: 08/07/2016

FugroViewerTM®: <http://www.fugroviewer.com/default.asp>

Ultima consulta: 08/07/2016

Fusion®: <http://forsys.cfr.washington.edu/fusion/fusionlatest.html>

Ultima consulta: 08/07/2016

OpenGL®: <https://www.opengl.org/>

Ultima consulta: 08/07/2016

LasTools®: <https://rapidlasso.com>

Ultima consulta: 08/07/2016



# ANEJOS A LA MEMORIA



## **7. ANEJOS A LA MEMORIA**

### **ANEJO 1: Parcelas IFN**

- 1.1. Parcelas ajuste curvas de calidad de estación
- 1.2. Parcelas IFN 4 ajuste modelo  $H_0$ -LiDAR

### **ANEJO 2: Comandos de procesamiento de la información LiDAR (Fusion® V3.50)**

### **ANEJO 3: Códigos en lenguaje R**

- 3.1. Cálculo de la altura dominante de Assmann
- 3.2. Ajuste de las curvas de calidad de estación anamórficas
- 3.3. Elaboración del modelo altura dominante de Assmann~LiDAR

### **ANEJO 4: Salidas de R**

- 4.1. Histogramas de alturas dominantes de Assman de las parcelas IFN
- 4.2. Ajuste de curvas de calidad de estación anamórficas
- 4.3. Modelo altura dominante de Assmann~LiDAR



# ANEJO 1

## Parcelas IFN



## **PARCELAS AJUSTE CURVAS DE CALIDAD DE ESTACIÓN**

Parcelas del IFN empleadas para el ajuste de las curvas de calidad de estación para *Pinus nigra* Arn. de repoblación en La Rioja:

| Nº IFN | ID Parcela | Nº IFN | ID Parcela | Nº IFN | ID Parcela |
|--------|------------|--------|------------|--------|------------|
| 2      | 49         | 3      | 49         | 4      | 49         |
| 2      | 57         | 3      | 57         | 4      | 57         |
| -      | -          | 3      | 61         | 4      | 61         |
| -      | -          | 3      | 85         | 4      | 85         |
| -      | -          | 3      | 95         | 4      | 95         |
| -      | -          | 3      | 134        | 4      | 134        |
| -      | -          | 3      | 157        | 4      | 157        |
| -      | -          | 3      | 159        | 4      | 159        |
| -      | -          | 3      | 163        | 4      | 163        |
| -      | -          | 3      | 188        | 4      | 188        |
| 2      | 198        | 3      | 198        | 4      | 198        |
| 2      | 219        | 3      | 219        | 4      | 219        |
| -      | -          | -      | -          | 4      | 433        |
| -      | -          | 3      | 491        | 4      | 491        |
| 2      | 586        | 3      | 586        | 4      | 586        |
| 2      | 678        | 3      | 678        | 4      | 678        |
| 2      | 699        | -      | -          | 4      | 699        |
| 2      | 701        | 3      | 701        | 4      | 701        |
| 2      | 705        | -      | -          | 4      | 705        |
| 2      | 706        | 3      | 706        | 4      | 706        |
| 2      | 708        | 3      | 708        | 4      | 708        |
| 2      | 709        | 3      | 709        | 4      | 709        |
| 2      | 711        | 3      | 711        | 4      | 711        |
| 2      | 712        | 3      | 712        | 4      | 712        |
| 2      | 713        | 3      | 713        | 4      | 713        |
| 2      | 714        | 3      | 714        | 4      | 714        |
| 2      | 715        | 3      | 715        | 4      | 715        |
| -      | -          | -      | -          | 4      | 716        |
| 2      | 723        | 3      | 723        | 4      | 723        |
| -      | -          | -      | -          | 4      | 745        |
| -      | -          | -      | -          | 4      | 749        |
| -      | -          | -      | -          | 4      | 755        |
| -      | -          | -      | -          | 4      | 756        |
| 2      | 768        | 3      | 768        | 4      | 768        |
| -      | -          | 3      | 769        | 4      | 769        |
| 2      | 771        | 3      | 771        | 4      | 771        |
| 2      | 772        | 3      | 772        | 4      | 772        |
| 2      | 777        | -      | -          | 4      | 777        |

| Nº IFN | ID Parcela | Nº IFN | ID Parcela | Nº IFN | ID Parcela |
|--------|------------|--------|------------|--------|------------|
| -      | -          | 3      | 778        | 4      | 778        |
| 2      | 781        | 3      | 781        | 4      | 781        |
| 2      | 782        | 3      | 782        | 4      | 782        |
| -      | -          | 3      | 790        | 4      | 790        |
| -      | -          | 3      | 792        | 4      | 792        |
| -      | -          | 3      | 796        | 4      | 796        |
| -      | -          | 3      | 797        | 4      | 797        |
| 2      | 798        | 3      | 798        | 4      | 798        |
| 2      | 801        | 3      | 801        | 4      | 801        |
| 2      | 807        | 3      | 807        | 4      | 807        |
| 2      | 818        | 3      | 818        | 4      | 818        |
| 2      | 819        | 3      | 819        | 4      | 819        |
| 2      | 828        | 3      | 828        | 4      | 828        |
| 2      | 829        | -      | -          | 4      | 829        |
| 2      | 830        | -      | -          | 4      | 830        |
| 2      | 1133       | -      | -          | 4      | 1133       |
| 2      | 1134       | -      | -          | 4      | 1134       |
| 2      | 1135       | 3      | 1135       | 4      | 1135       |
| 2      | 1149       | 3      | 1149       | 4      | 1149       |
| 2      | 1150       | -      | -          | 4      | 1150       |
| 2      | 1176       | 3      | 1176       | 4      | 1176       |
| -      | -          | -      | -          | 4      | 1178       |
| 2      | 1183       | 3      | 1183       | 4      | 1183       |
| 2      | 1184       | 3      | 1184       | 4      | 1184       |
| 2      | 1195       | 3      | 1195       | 4      | 1195       |
| -      | -          | -      | -          | 4      | 1198       |
| 2      | 1199       | 3      | 1199       | 4      | 1199       |
| -      | -          | 3      | 1214       | 4      | 1214       |
| -      | -          | 3      | 1217       | 4      | 1217       |
| 2      | 1235       | 3      | 1235       | 4      | 1235       |
| -      | -          | 3      | 1236       | 4      | 1236       |
| -      | -          | 3      | 1257       | 4      | 1257       |
| -      | -          | 3      | 1259       | 4      | 1259       |
| -      | -          | 3      | 1260       | 4      | 1260       |
| -      | -          | 3      | 1265       | 4      | 1265       |
| -      | -          | 3      | 1266       | 4      | 1266       |
| -      | -          | 3      | 2162       | 4      | 2126       |
| -      | -          | -      | -          | 4      | 2162       |

## **PARCELAS IFN 4 MODELO H<sub>0</sub>~LiDAR**

Parcelas del IFN 4 empleadas para el ajuste de los modelos de predicción de altura dominante según la definición de Assmann indicando las 13 parcelas excluidas del ajuste y empleadas para la validación del modelo:

| <b>ID Parcela</b> | <b>Validación</b> | <b>ID Parcela</b> | <b>Validación</b> |
|-------------------|-------------------|-------------------|-------------------|
| 49                | x                 | 792               | -                 |
| 57                | x                 | 796               | -                 |
| 61                | -                 | 797               | x                 |
| 134               | -                 | 798               | -                 |
| 143               | -                 | 807               | -                 |
| 157               | -                 | 818               | -                 |
| 159               | -                 | 819               | -                 |
| 163               | -                 | 829               | -                 |
| 198               | -                 | 830               | -                 |
| 433               | -                 | 1133              | x                 |
| 491               | -                 | 1134              | -                 |
| 586               | -                 | 1135              | -                 |
| 699               | -                 | 1149              | -                 |
| 705               | x                 | 1176              | -                 |
| 706               | -                 | 1178              | x                 |
| 709               | -                 | 1182              | -                 |
| 712               | -                 | 1183              | -                 |
| 713               | x                 | 1184              | -                 |
| 714               | -                 | 1195              | -                 |
| 715               | -                 | 1199              | -                 |
| 716               | x                 | 1214              | -                 |
| 723               | -                 | 1217              | x                 |
| 745               | -                 | 1235              | -                 |
| 749               | -                 | 1236              | -                 |
| 755               | x                 | 1251              | -                 |
| 756               | -                 | 1252              | x                 |
| 768               | -                 | 1257              | -                 |
| 769               | -                 | 1259              | -                 |
| 771               | -                 | 1260              | -                 |
| 772               | -                 | 1265              | -                 |
| 778               | x                 | 1266              | -                 |
| 781               | -                 | 2126              | -                 |
| 790               | x                 | 2162              | -                 |



## **ANEJO 2**

### **Comandos de procesamiento de la información LiDAR (Fusion® V3.50)**



## **COMANDOS DE PROCESADO DE LA INFORMACIÓN LIDAR** **(Fusion® V3.50)**

Se muestran los comandos que se han corrido en la Consola de Comandos de Windows (MS-DOS) y que se han empleado para el procesado de las nubes de puntos obtenidas a partir del vuelo LiDAR. Solo se incluye un comando por cada proceso a modo de ejemplo.

Los puntos en los comandos (“.”) simbolizan espacios. “.dtm”, “.Las”, “.asc” y “.csv” son la extensión de los archivos.

### ➤ EVALUACIÓN PREVIA DE LA INFORMACIÓN LIDAR

**Catalog·/index·/drawtiles·/countreturns·/rawcounts·/intensity:1,0,255·/density:1,0.5,1·/firstdensity:1,0.5,1·Input\_File.Las·Output-File.csv**

### ➤ CREACIÓN DE MAPAS DE INTENSIDADES DEL PULSO LIDAR

**IntensityImage·/minint:0·/maxint:255·1·Output\_File.bmp·Input\_File.Las**

### ➤ CREACIÓN DE MODELOS DIGITALES DEL TERRENO (MDT)

- Obtención de MDT en extensión “.dtm”:

**GridSurfaceCreate·/class:2·Output\_File.dtm·2·M·M·1·0·0·0·Input\_File.Las**

- Conversión del MDT en extensión “.dtm” a “.asc”:

**dtm2ascii·Input\_File.dtm·Output\_File.asc**

### ➤ CREACIÓN DE MODELOS DIGITALES DE LA VEGETACIÓN (MDV)

- Obtención de MDV en extensión “.dtm”:

**Canopymodel·Output\_File.dtm·2·M·M·1·0·0·0·Input\_File.Las**

- Conversión del MDV en extensión “.dtm” a “.asc”:

**dtm2ascii·Input\_File.dtm·Output\_File.asc**

➤ CORTE DE LA NUBE DE PUNTOS CON LAS PARCELAS DEL IFN 4

**Clipdata·/shape:1·/dtm:InputMDT\_File.dtm·/height·Input\_File.Las·OutputPlot\_File.Las·MinX·MinY·MaxX·MaxY**

➤ OBTENCIÓN DE LA MÉTRICA LIDAR PARA LAS PARCELAS DE INVENTARIO

**CloudMetrics·/above:2·/minht:2·InputPlot\_File.Las·OutputStats\_File.csv**

➤ OBTENCIÓN DE LA MÉTRICA LIDAR PARA TODA LA SUPERFICIE DEL ESTUDIO

**Gridmetrics·/minht:2·InputMDT\_File.dtm·2·25·OutputStats\_File.csv·Input\_File.Las**

# ANEJO 3

## Códigos en lenguaje R



## CÁLCULO DE LA ALTURA DOMINANTE DE ASSMANN

### #####CALCULO DE INFORMACION DENDROMETRICA DE PARCELAS DEL IFN#####

```
#Se establece el directorio de trabajo
setwd('C:/datosR')

#Se crea un data.frame en R a partir de un archivo de origen .csv delimitado por
#";" ----X = 2 para IFN 2, X = 3 para IFN 3, X = 4 para IFN 4----
data_IFN <- read.delim('pies_ma_IFNX_LiDAR.csv', sep = ";", dec = ".",
                      header = TRUE)
str(data_IFN)#Vemos data_IFN

#Creamos en data_IFN una nueva columna llamada dap y que es el diametro promedio
#(cm):
data_IFN[,"dap"] <- with(data_IFN, (d1+d2)/20) #(cm)
str(data_IFN) #Vemos data_IFN

#Establecemos los grupos de las Clases diametricas (cm) y los grupos de los
#factores #de expansión:
#DIAMETROS
Vc <- c(42.5,22.5,12.5,7.5) #Vector con clases IFN diametro
#FACTORES DE EXPANSIÓN
Fc <- c(5.09, 14.15, 31.83, 127.32) #Vector con factores expansión IFN

#Creamos una nueva columna llamada n_ha y asignamos las clases de diámetro
#y los factores de expansión f(diametro), que se corresponden con el numero
#de pies por hectarea (característica IFN)
data_IFN[,"n_ha"] <- with(data_IFN,
  ifelse(dap >= vc[1], vc[1],
        ifelse(dap >= vc[2], fc[2],
              ifelse(dap >= vc[3], fc[3],
                    ifelse(dap >= vc[4], fc[4],
                          NA))))))
str(data_IFN)

#Creamos unas listas, hace un data.frame para cada parcela del estudio
lsdata_IFN <- split(data_IFN,as.factor(data_IFN$Parcela), drop = TRUE)

#Creamos f.assmann para el cálculo de H0
f.assmann <- function(x){
#x <- lsdata_IFN[[1]]## se hace solo para una de las listas. Con el doble [[1]]
#lee los datos de la lista 1
x <- x[with(x, order(dap, decreasing = TRUE)),] #Ordenamos dap de mayor a menor
#por diámetros
x[,"n_ha_sum"] <- with(x, cumsum(n_ha)) #Calcula pies/ha acumulados
```

```
x.1 <- subset(x, n_ha_sum <= 100) #Selecciona nada más los 100 pies/ha acumulados
#(siendo los más gruesos)
assmann<- mean(x$H.total) #Se calcula H0 como promedio de H.total (de los 100 más
#gruesos/ha)
return(assmann)}

#Obtenemos para cada parcela el valor de H0 y lo creamos en R (dataAssmann)
flassmann <- lapply(lsddata_IFN, function(x)f.assmann(x))
dataAssmann <- do.call(rbind,flassmann)

#Hacemos un histograma
hist(dataAssmann, main = "Alturas de Assmann IFNX", ylim = c(0,30),
      xlab = "Alturas de Assmann (m)", col = "grey")

head(dataAssmann,10)
```

## **AJUSTE DE LAS CURVAS DE CALIDAD DE ESTACIÓN ANAMÓRFICAS**

### **#####MODELO HOSSFELD I (Mod.)#####**

```
#Establecemos el directorio de trabajo
setwd('C:/datosR')

#Librerías necesarias:
library(lattice)
library(survival)
library(Formula)
library(ggplot2)
library(Hmisc)
library(Rcmdr) #Necesario para lmtest. Cerrar Rcmdr tras abrirse
library(lmtest)

#Leer el archivo y creamos dataframe
datos_calidad_estacion_LR<-read.delim('H0_EDAD_R_2_3_4.csv',sep=";",
                                       dec="." ,header=TRUE)

#Preparamos los datos:
  #1.Borramos datos con Edad = 0
  #2.Borramos los datos con H0 = 0
datos_calidad_estacion_LR <- subset(datos_calidad_estacion_LR, Edad !=0)
datos_calidad_estacion_LR <- subset(datos_calidad_estacion_LR, H0 !=0)

#se dibuja para los datos de las parcelas la trayectoria de H0~edad.
#Datos agrupados por parcela
xyplot(H0~Edad,data=datos_calidad_estacion_LR,groups=Parcela,type="l",
       col="black",main="Trayectoria H0~Edad Pinus nigra", ylab="Altura dominante
[H0] (m)", xlab="Edad (años)", xlim = c(0,70),
       ylim = c(0,30))

#Linealizamos el modelo de Hossfeld I (mod.),
#creamos la var. dependiente y la independiente
datos_calidad_estacion_LR[,"vardep1"]<-with(datos_calidad_estacion_LR,(1/H0^0.5))
datos_calidad_estacion_LR[,"varindep1"]<-with(datos_calidad_estacion_LR,(1/Edad))

#Hacemos un modelo lineal con Hossfeld I linealizado
Hossfeld.lineal_1 <- lm(datos_calidad_estacion_LR$vardep1 ~
                      (datos_calidad_estacion_LR$varindep1))
summary(Hossfeld.lineal_1)
```

```
#Hacemos el gráfico de la curva guía con los datos arrojados por el modelo
#Hossfeld.lineal_1 sobre los datos de las parcelas de campo
X<-c(1:80)
Y<-c(X^2/(2.23261 + 0.28929 * X)^2)
plot(X,Y,lwd=1, type="l", col = "red", lty=1, ljoin=10)
xyplot(H0~Edad,data=datos_calidad_estacion_LR,groups=Parcela,type="l",
       col="grey",
       main="P. nigra repoblación La Rioja/Hossfeld I b común (lineal_1)",
       ylab="Altura dominante [H0] (m)",
       ylim=c(0,30), xlim=c(0,80), xlab="Edad (años)",panel=function(x, y, ...){
         panel.xyplot(x, y, ...)
         panel.lines(X, Y, col=2, lwd=2)})

#Representamos el modelo con las bandas de confianza
qqPlot(Hossfeld.lineal_1, simulate=TRUE, id.method="y", id.n=2, main = 'QQPlot
       Hossfeld.lineal_1')

#Representamos:
# Residuos VS Ajustados
# Residuos Std VS Q
# Residuos Std^0.5 VS Ajustados
# Residuos Std VS Leverage
oldpar <- par(oma=c(0,0,3,0), mfrow=c(2,2))
plot(Hossfeld.lineal_1)
par(oldpar)

# Grupo de curvas Hossfeld.lineal_1
#Vamos calculando b para a constante e igual a 2.23261 y Edad=40 años para las 5
#clases de H0
X<-c(1:100)
Q<-c(X^2/(2.23261 + 0.44418 * X)^2)
K<-c(X^2/(2.23261 + 0.29774 * X)^2)
Z<-c(X^2/(2.23261 + 0.23286 * X)^2)
G<-c(X^2/(2.23261 + 0.19418 * X)^2)
H<-c(X^2/(2.23261 + 0.16779 * X)^2)

#hacemos ahora la gráfica de la familia de curvas sobre los datos de campo
plot(X,Q,lwd=1, type="l", col = "black", lty=2, ljoin=10)
xyplot(H0~Edad,data=datos_calidad_estacion_LR,groups=Parcela,type="l",
       col="grey",
       main="Curvas de Calidad P. nigra La Rioja, Hossfeld I (lineal_1)",
       ylab="Altura dominante [H0] (m)",xlab="Edad (años)",xlim=c(5,70),
       ylim = c(0,30),
       panel=function(x, y, ...){
         panel.xyplot(x, y, ...)
         panel.lines(X, Y, col=2, lwd=2)})
```

```

panel.lines(X, Q, col=1, lwd=2)
panel.lines(X, K, col=1, lwd=2)
panel.lines(X, Z, col=1, lwd=2)
panel.lines(X, G, col=1, lwd=2)
panel.lines(X, H, col=1, lwd=2))

#Hacemos un ajuste no lineal para lo que tenemos que definir el modelo Hossfeld I
#(mod.) original:
Hossfeld <- datos_calidad_estacion_LR$H0~(datos_calidad_estacion_LR$Edad^2)
/(a+b*datos_calidad_estacion_LR$Edad)^2

#ahora el ajuste no lineal (nls) dandole a los coeficientes los valores arrojados
#por el análisis lineal. Nls usa por defecto algoritmo Gauss-Newton
#Hossfeld.lineal_1<- a = 2.23261; b = 0.28929
nlmod.Hossfeld_1<-nls(Hossfeld, data=datos_calidad_estacion_LR,
start=list(a=2.23261, b=0.28929))
summary(nlmod.Hossfeld_1)
#Probamos con Levenberg-Marquardt
library(minpack.lm)
nlmod_marq_Hossfeld<-nlsLM(Hossfeld,data = datos_calidad_estacion_LR,
start = list(a=2.23261, b=0.28929))
summary(nlmod_marq_Hossfeld)

#Representamos:
# Residuos VS Ajustados
# Residuos Std VS Q
# Residuos Std^0.5 VS Ajustados
# Residuos Std VS Leverage
oldpar <- par(oma=c(0,0,3,0), mfrow=c(2,2))
plot(nlmod.Hossfeld_1)
par(oldpar)

#gráfico de la curva guía
X<-c(1:100)
Y<-c(X^2/(2.79780+0.25945*X)^2)
plot(X,Y,lwd=1, type="l", col = "red", lty=1, ljoin=10)
xyplot(H0~Edad,data=datos_calidad_estacion_LR,groups=Parcela,type="l",
col="grey",
main="Curvas de Calidad P. nigra La Rioja, Hossfeld I (no lineal)",
ylab="Altura dominante [H0] (m)",
ylim=c(0,30), xlim=c(0,80), xlab="Edad (años)",panel=function(x, y, ...){
panel.xyplot(x, y, ...)
panel.lines(X, Y, col=2, lwd=2)})

#Vamos calculando b para a constante e igual a 2.79780 y Edad=40 años para las 5
clases de H0

```

```

X<-c(1:100)
Q<-c(X^2/(2.79780 + 0.43006 * X)^2)
K<-c(X^2/(2.79780 + 0.28361 * X)^2)
Z<-c(X^2/(2.79780 + 0.21873 * X)^2)
G<-c(X^2/(2.79780 + 0.18006 * X)^2)
H<-c(X^2/(2.79780 + 0.15366 * X)^2)

#hacemos ahora la gráfica de la familia de curvas sobre los datos de campo
plot (X,Q,lwd=1, type="l", col = "black", lty=1, ljoin=10)
xyplot(H0~Edad,data=datos_calidad_estacion_LR,groups=Parcela,type="l",
col="grey",
main="Curvas de Calidad P. nigra La Rioja, Hossfeld I (no lineal)",
ylab="Altura dominante [H0] (m)",xlab="Edad (años)",xlim=c(5,70), ylim =
c(0,30),
panel=function(x, y, ...){
panel.xyplot(x, y, ...)
panel.lines(X, Q, col=1, lwd=2)
panel.lines(X, K, col=1, lwd=2)
panel.lines(X, Z, col=1, lwd=2)
panel.lines(X, G, col=1, lwd=2)
panel.lines(X, H, col=1, lwd=2)})

#####
#Limites entre clases # Grupo de curvas Hossfeld.lineal_1
X<-c(1:100)
Q<-c(X^2/(2.23261 + 0.44418 * X)^2)
K<-c(X^2/(2.23261 + 0.29774 * X)^2)
Z<-c(X^2/(2.23261 + 0.23286 * X)^2)
G<-c(X^2/(2.23261 + 0.19418 * X)^2)
H<-c(X^2/(2.23261 + 0.16779 * X)^2)
m<-c(X^2/(2.23261 + 0.35243 * X)^2)
q<-c(X^2/(2.23261 + 0.26041 * X)^2)
k<-c(X^2/(2.23261 + 0.21145 * X)^2)
z<-c(X^2/(2.23261 + 0.17989 * X)^2)

plot (X,Q,lwd=1, type="l", col = "black", lty=1, ljoin=10)
xyplot(H0~Edad,data=datos_calidad_estacion_LR,groups=Parcela,type="l",
col="grey",
main="Curvas de Calidad P. nigra La Rioja, Hossfeld I (lineal_1) [limites
clases]",
ylab="Altura dominante [H0] (m)",xlab="Edad (años)",xlim=c(5,70),
ylim = c(0,30),
panel=function(x, y, ...){
panel.xyplot(x, y, ...)
panel.lines(X, Q, col=1, lwd=2)
panel.lines(X, K, col=1, lwd=2)

```

```
panel.lines(X, Z, col=1, lwd=2)
panel.lines(X, G, col=1, lwd=2)
panel.lines(X, H, col=1, lwd=2)
panel.lines(X, m, col=2, lwd=2)
panel.lines(X, q, col=2, lwd=2)
panel.lines(X, k, col=2, lwd=2)
panel.lines(X, z, col=2, lwd=2))}
```

**#####MODELO MISTERLICH I (1919) // RICHARDS-CHAPMAN (1959-1961)#####**

```
#directorio de trabajo
setwd('C:/datosR')

#Librerias:
library(lattice)
library(survival)
library(Formula)
library(ggplot2)
library(Hmisc)
library(Rcmdr) #Necesario para lmtest. Cerrar Rcmdr
library(lmtest)

datos_calidad_estacion_LR<-read.delim("H0_EDAD_R_2_3_4.csv",sep=";",
                                     dec="." ,header=TRUE)

#Preparamos los datos:
  #1.borramos datos con edad=0 y con altura=0
datos_calidad_estacion_LR <- subset(datos_calidad_estacion_LR, Edad !=0)
datos_calidad_estacion_LR <- subset(datos_calidad_estacion_LR, H0 !=0)

str(datos_calidad_estacion_LR)

#se dibuja para los datos de las parcelas la trayectoria de H0~edad
xyplot(H0~Edad,data=datos_calidad_estacion_LR,groups=Parcela,type="l",
       col="black",
       main="Datos Pinus nigra repoblación La Rioja", ylab="Altura dominante [H0]
(m)", xlab="Edad (años)")

#Ajuste modelo Mitscherlich I lienalizado (BRAVO et al., 2015)
#Definimos la variable independiente y la variable independiente
datos_calidad_estacion_LR[, "vardep"]<-with(datos_calidad_estacion_LR,(log(H0)))

#Hacemos iteraciones con distintos valores de b buscando el que más se ajusta a
nuestros datos.
#Vamos dando valores a b hasta que se va estabilizando Adjusted R-squared
```

```

datos_calidad_estacion_LR[,"varindep1"]<-with(datos_calidad_estacion_LR,
                                                (log(1-exp(-0.005*Edad))))
datos_calidad_estacion_LR[,"varindep2"]<-with(datos_calidad_estacion_LR,
                                                (log(1-exp(-0.010*Edad))))
datos_calidad_estacion_LR[,"varindep3"]<-with(datos_calidad_estacion_LR,
                                                (log(1-exp(-0.015*Edad))))
datos_calidad_estacion_LR[,"varindep4"]<-with(datos_calidad_estacion_LR,
                                                (log(1-exp(-0.020*Edad))))

#Hacemos el ajuste lineal
Richards.lineal.1 <- lm(datos_calidad_estacion_LR$vardep ~
                       (datos_calidad_estacion_LR$varindep1))
summary(Richards.lineal.1)
Richards.lineal.2 <- lm(datos_calidad_estacion_LR$vardep ~
                       (datos_calidad_estacion_LR$varindep2))
summary(Richards.lineal.2)
Richards.lineal.3 <- lm(datos_calidad_estacion_LR$vardep ~
                       (datos_calidad_estacion_LR$varindep3))
summary(Richards.lineal.3)
Richards.lineal.4 <- lm(datos_calidad_estacion_LR$vardep ~
                       (datos_calidad_estacion_LR$varindep4))
summary(Richards.lineal.4)

#Hacemos el modelo para b = 0.020
datos_calidad_estacion_LR[,"vardep"]<-with(datos_calidad_estacion_LR,(log(H0)))
datos_calidad_estacion_LR[,"varindep"]<-with(datos_calidad_estacion_LR,
                                              (log(1-exp(-0.020*Edad))))

Richards.lineal<-lm(datos_calidad_estacion_LR$vardep~
                   (datos_calidad_estacion_LR$varindep))
summary(Richards.lineal)

#hacemos el gráfico de la curva guía con los valores sacados a partir del lm
#sobre los datos de campo
#Debemos deshacer el logaritmo (exp(Intercept))
X<-c(0:80)
Y<-c(exp(2.56290)*(1-(exp(-0.020*X)))^0.67160)
plot(X,Y,lwd=1, type='l',col='red', lty=1, ljoin=10)
xyplot(H0~Edad,data=datos_calidad_estacion_LR,groups=Parcela,type="l",
       col="grey",
       main="Curva guía Richards.lineal P. nigra La Rioja", ylab="Altura
dominante [H0] (m)", xlab="Edad (años)",
       panel=function(x, y, ...){
         panel.xyplot(x, y, ...)
         panel.lines(X, Y, col=2, lwd=2)})

```

```
#Hacemos la familia de curvas de calidad (una variable por cada IS).
#Se calcula a para los IS definidos, X = 40, siendo b = cte = 0.020 y
#c = cte = 0.67160
X<-c(0:80)
Q<-c(exp(1.78698)*(1-exp(-0.020*X))^0.67160) #IS: 4 m
K<-c(exp(2.48013)*(1-exp(-0.020*X))^0.67160) #IS: 8 m
Z<-c(exp(2.88560)*(1-exp(-0.020*X))^0.67160) #IS: 12 m
G<-c(exp(3.17328)*(1-exp(-0.020*X))^0.67160) #IS: 16 m
H<-c(exp(3.39642)*(1-exp(-0.020*X))^0.67160) #IS: 20 m

#Representamos la familia de curvas sobre los datos de campo
xyplot(H0~Edad,data=datos_calidad_estacion_LR,groups=Parcela,type="l",
       col="grey",
       main="Curvas de calidad de estación P. nigra La Rioja, Mitscherlich I
       (lineal)", ylim = c(0, 30), xlim = c(5,70),
       ylab="Altura dominante [H0] (m)",
       xlab="Edad (años)",
       panel=function(x, y, ...){
         panel.xyplot(x, y, ...)
         panel.lines(X, Q, col=1, lwd=2)
         panel.lines(X, K, col=1, lwd=2)
         panel.lines(X, Z, col=1, lwd=2)
         panel.lines(X, G, col=1, lwd=2)
         panel.lines(X, H, col=1, lwd=2)})

#Ajuste no lineal
#AJUSTE MEDIANTE nlm (NON LINEAR MODEL).
#Hacemos un ajuste no lineal para lo que tenemos que definir el objeto richards:
F_Richards<-datos_calidad_estacion_LR$H0~(a*((1-exp(-
                                     b*datos_calidad_estacion_LR$Edad))^c))

#ahora el ajuste no lineal (nls) dandole los valores semilla.
#Algoritmo de Gauss-Newton
#deshacemos el logaritmo en a--> a= exp(2.56290)
nlmod_Richards <- nls(F_Richards, data= datos_calidad_estacion_LR,
                    start=list(a=12.97339, b=0.02, c=0.67160))
summary(nlmod_Richards)

#Gauss-Newton no funciona.Probamos con Levenberg-Marquardt.
library(minpack.lm)
nlmod_marq_Richards<-nlsLM(F_Richards,data = datos_calidad_estacion_LR,
                          control = nls.lm.control(maxiter = 300,
                          maxfev = 500), start = list(a=12.97339, b=0.02,
                          c=0.67160))
summary(nlmod_marq_Richards)
```

#El algoritmo de Levenberg-Marquardt converge a un resultado (no válido)

## **ELABORACIÓN DEL MODELO ALTURA DOMINANTE DE ASSMANN~LiDAR**

**#####AJUSTE DE MODELOS ALTURA DOMINANTE - MÉTRICA LiDAR [H0~LiDAR]#####**

```
#Establecemos el directorio de trabajo
setwd("C:/datosR")

#Librerías necesarias
library(lattice)
library(survival)
library(Formula)
library(ggplot2)
library(Hmisc)
library(Rcmdr)
library(lmtest)
library(dgof)

#Leemos los datos y los importamos
datos_LiDAR_H0 <- read.table("C:/datosR/LiDAR_stat_66_plot.csv", header=TRUE,
sep=";",
                           na.strings="NA", dec=".", strip.white=TRUE)

#Selección aleatoria de 13 parcelas para la validación
sample(datos_LiDAR_H0$FileTitle, 13)

#Parcelas para la validación (13): Las excluimos para el ajuste
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="49_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="790_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="1252_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="705_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="778_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="1178_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="797_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="57_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="1217_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="716_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="1133_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="713_norm")
datos_LiDAR_H0<-subset(datos_LiDAR_H0, FileTitle !="755_norm")

# Estudio de correlaciones [PEARSON]/[SPEARMAN]/[PARCIALES]
rcorr.adjust(datos_LiDAR_H0[,c("H0", "Elev.maximum", "Elev.mean", "Elev.mode",
"Elev.P95", "Elev.P99")],
             type= "pearson", use= "complete")
```

```
rcorr.adjust(datos_LiDAR_H0[,c("H0", "Elev.maximum", "Elev.mean", "Elev.mode",
"Elev.P95", "Elev.P99")],
  type= "spearman", use= "complete")
partial.cor(datos_LiDAR_H0[,c("Elev.maximum", "Elev.mean", "Elev.mode",
"Elev.P95", "Elev.P99", "H0")],
  tests=TRUE, use= "complete")

#Matriz de diagramas de dispersión
scatterplotMatrix(~H0+Elev.mean+Elev.P95, reg.line=lm, smooth=FALSE,
  spread=FALSE, span=0.5, ellipse=FALSE, levels=c(.5, .9),
  id.n=0, diagonal = 'boxplot',
  data=datos_LiDAR_H0, main="Matriz de diagramas de dispersión H0
+ Elev.mean + Elev.P95")

#Matriz de diagramas de dispersión (con elipse)
scatterplotMatrix(~H0+Elev.mean+Elev.P95, reg.line=lm, smooth=FALSE,
  spread=TRUE, span= 0.5, ellipse= TRUE, levels=c(.5, .9),
  id.n=0, diagonal = 'boxplot',
  data=datos_LiDAR_H0, main="Matriz de diagramas de dispersión H0
+ Elev.mean + Elev.P95")

#Diagrama de dispersión [H0~Elev.P95]
scatterplot(H0~Elev.P95, reg.line=lm, smooth =FALSE, spread=FALSE,
  boxplots= 'xy', ellipse=FALSE,
  xlab= "Elev.P95 [m]", ylab= "Altura dominante de Assmann [H0] (m)",
  main= "Diagrama de dispersión [H0~Elev.P95]", data=datos_LiDAR_H0)

#Diagrama de dispersión [H0~Elev.mean]
scatterplot(H0~Elev.mean, reg.line=lm, smooth =FALSE, spread=FALSE,
  boxplots= 'xy', ellipse=FALSE,
  xlab= "Elev.mean [m]", ylab= "Altura dominante de Assmann [H0] (m)",
  main= "Diagrama de dispersión [H0~Elev.mean]", data=datos_LiDAR_H0)

#Hacemos un modelo lineal Para las distintas variables LiDAR
Model.1 <- lm(H0~Elev.mean, data=datos_LiDAR_H0)
Model.2 <- lm(H0~Elev.mode, data=datos_LiDAR_H0)
Model.3 <- lm(H0~Elev.maximum, data=datos_LiDAR_H0)
Model.4 <- lm(H0~Elev.P95, data=datos_LiDAR_H0)
Model.5 <- lm(H0~Elev.P99, data=datos_LiDAR_H0)
Model.6 <- lm(H0~Elev.P95+Elev.mean, data=datos_LiDAR_H0)

#Resultados de los modelos anteriores
summary(Model.1)
summary(Model.2)
summary(Model.3)
```

```
summary(Model.4)
summary(Model.5)
summary(Model.6)

#Obtenemos AIC () y BIC () de los distintos modelos
AIC(Model.1, Model.2, Model.3, Model.4, Model.5, Model.6)
BIC(Model.1, Model.2, Model.3, Model.4, Model.5, Model.6)

##El mejor resultado se obtiene con el modelo Model.4 (Elev.P95)
Model.Elev.P95<- lm(H0 ~ Elev.P95, data=datos_LiDAR_H0)
summary(Model.Elev.P95)

#Analizamos homocedasticidad de los residuos (Var=cte) [Test de BREUSCH-PAGAN]
bptest(H0 ~ Elev.P95, varformula = ~ fitted.values(Model.Elev.P95),
       studentize=TRUE, data=datos_LiDAR_H0)

#Añadimos al dataframe los ajustados y los residuos
datos_LiDAR_H0<- within(datos_LiDAR_H0, {
  fitted.Model.Elev.P95 <- fitted(Model.Elev.P95)
  residuals.Model.Elev.P95 <- residuals(Model.Elev.P95)
})

#Analizamos la normalidad de los residuos
#[Test de Kolmogorov-Smirnov]
x <- datos_LiDAR_H0$fitted.Model.Elev.P95
y <- datos_LiDAR_H0$H0
ks.test(x, y,
        alternative = c("two.sided"),
        exact = NULL)

#Buscamos valores atípicos en el modelo [Test de valores atípicos de BONFERRONI]
outlierTest(Model.Elev.P95)

#Representamos el modelo con las bandas de confianza
qqPlot(Model.Elev.P95, simulate=FALSE, id.method="y", id.n=0, main = "QQPlot")

#Representamos:
# Residuos VS Ajustados
# Residuos Std VS Q
# Residuos Std^0.5 VS Ajustados
# Residuos Std VS Leverage
oldpar <- par(oma=c(0,0,3,0), mfrow=c(2,2))
plot(Model.Elev.P95)
par(oldpar)

plot(datos_LiDAR_H0$fitted.Model.Elev.P95, datos_LiDAR_H0$H0)
```

```
X<-c(0:30)
Y<-c(X)

xyplot(H0~fitted.Model.Elev.P95,data=datos_LiDAR_H0,type="p", col="black",
      main="Observados~Predichos [H0~Elev.P95]", ylab="Observados [H0] (m)",
      ylim=c(0,30),
      xlim=c(0,30), xlab="Predichos [H0](m)", ellipse=TRUE, panel=function(x, y,
      ...){
      panel.xyplot(x, y, ...)
      panel.lines(X, Y, col=2, lwd=1)})
```

#### #####VALIDACION MODELO H0~METRICA LiDAR#####

```
#Establecemos el directorio de trabajo
setwd("C:/datosR")

#Librerías necesarias
library(lattice)
library(survival)
library(Formula)
library(ggplot2)
library(Hmisc)
library(Rcmdr)
library(lmtest)
library(dgof)

#Leemos los datos y los importamos
datos_LiDAR_H0_validacion <- Read.table("LiDAR_stat_13_plot_valida.csv",
      header=TRUE, sep=";",
      na.strings="NA", dec=".", strip.white=TRUE)

#Creamos una nueva columna llamada predichos e introducimos el modelo
datos_LiDAR_H0_validacion[,"predichos.Model.4"]<-with(datos_LiDAR_H0_validacion,
      (1.35528 + 0.86190 * datos_LiDAR_H0_validacion$Elev.P95))
str(datos_LiDAR_H0_validacion)

X<-c(0:30)
Y<-c(X)
xyplot(H0~predichos.Model.4,data=datos_LiDAR_H0_validacion,type="p", col="black",
      main="Observados~Predichos Model.4 (13 plots)",
      ylab="Observados [H0] (m)", ylim=c(0,30),
      xlim=c(0,30), xlab="Predichos [H0](m)", ellipse=TRUE,
      panel=function(x, y, ...){
      panel.xyplot(x, y, ...)
```

```
panel.lines(X, Y, col=2, lwd=1))

datos_LiDAR_H0_validacion[,"Err"]<-with(datos_LiDAR_H0_validacion,
    (abs((datos_LiDAR_H0_validacion$H0 -
    datos_LiDAR_H0_validacion$predichos.Model.4) /
    datos_LiDAR_H0_validacion$H0)*100))

#Creamos una nueva columna llamada predichos e introducimos el modelo
datos_LiDAR_H0_validacion[,"predichos.Model.1"]<-with(datos_LiDAR_H0_validacion,
    (3.0595 + 1.0149 * datos_LiDAR_H0_validacion$Elev.mean))
str(datos_LiDAR_H0_validacion)

X<-c(0:30)
Y<-c(X)
xyplot(H0~predichos.Model.1,data=datos_LiDAR_H0_validacion,type="p", col="black",
    main="Observados~Predichos Model.1 (13 plots)",
    ylab="Observados [H0] (m)", ylim=c(0,30),
    xlim=c(0,30), xlab="Predichos [H0](m)", ellipse=TRUE,
    panel=function(x, y, ...){
        panel.xyplot(x, y, ...)
        panel.lines(X, Y, col=2, lwd=1)})

datos_LiDAR_H0_validacion[,"Err_1"]<-with(datos_LiDAR_H0_validacion,
    (abs((datos_LiDAR_H0_validacion$H0 -
    datos_LiDAR_H0_validacion$predichos.Model.1) /
    datos_LiDAR_H0_validacion$H0)*100))

datos_LiDAR_H0_validacion
summary(datos_LiDAR_H0_validacion)
```

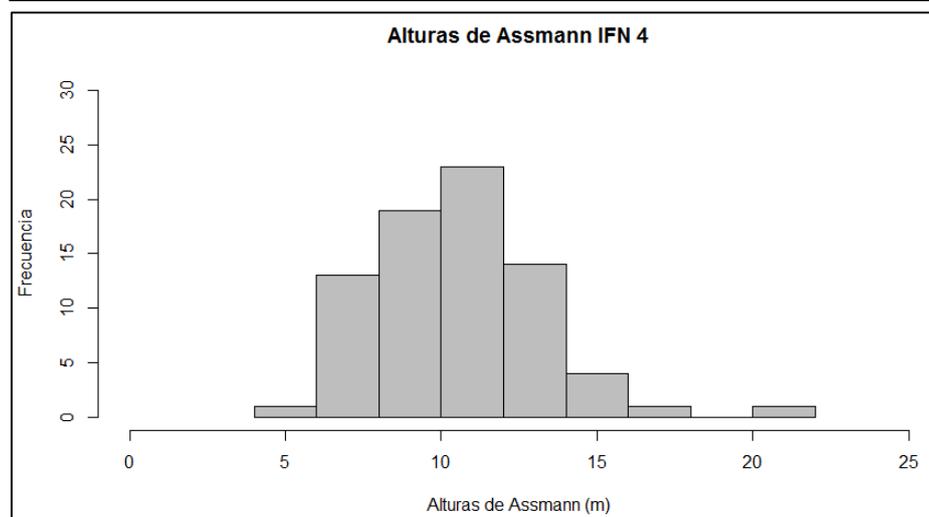
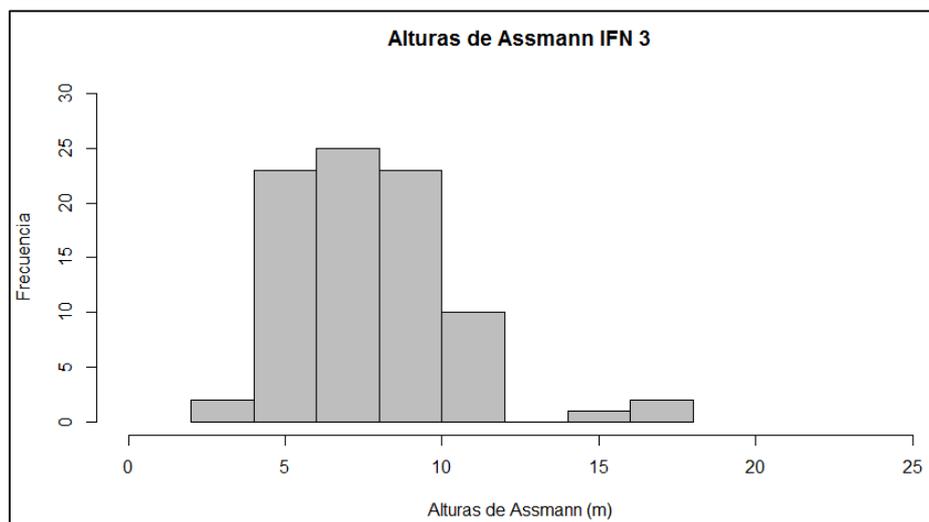
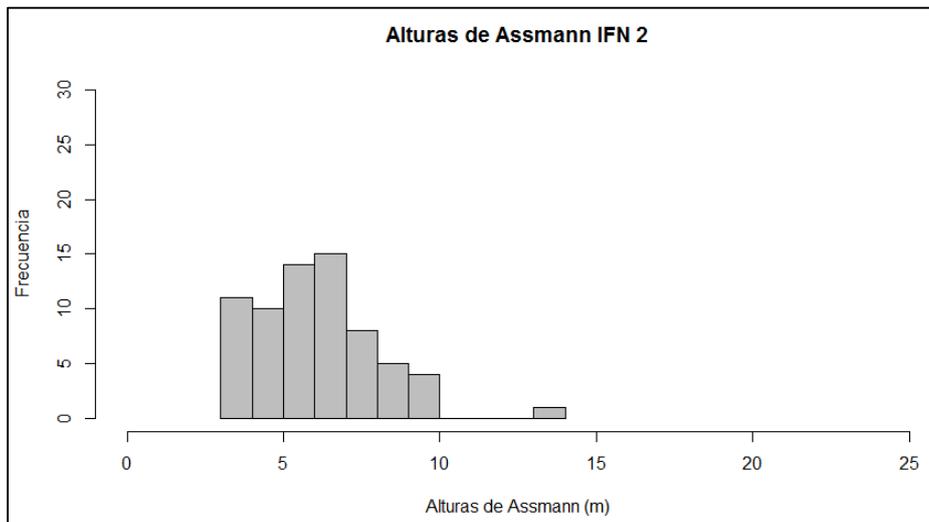


## **ANEJO 4**

### **Salidas de R**



## **Histogramas de alturas dominantes de Assman de las parcelas IFN**



## CURVAS DE CALIDAD DE ESTACIÓN ANAMÓRFICAS

### Mod.1 [ $H_0$ ~edad] –Hossfeld I (mod.) lineal

```
> summary(Hossfeld.lineal_1)
```

Call:

```
lm(formula = datos_calidad_estacion_LR$vardep1 ~ (datos_calidad_estacion_LR  
$varindep1))
```

Residuals:

| Min       | 1Q        | Median    | 3Q       | Max      |
|-----------|-----------|-----------|----------|----------|
| -0.131413 | -0.043856 | -0.008785 | 0.039265 | 0.177857 |

Coefficients:

|   | Estimate | Std. Error | t value | Pr(> t )    |
|---|----------|------------|---------|-------------|
| a | 0.28929  | 0.01021    | 28.344  | < 2e-16 *** |
| b | 0.28929  | 0.01021    | 28.344  | < 2e-16 *** |

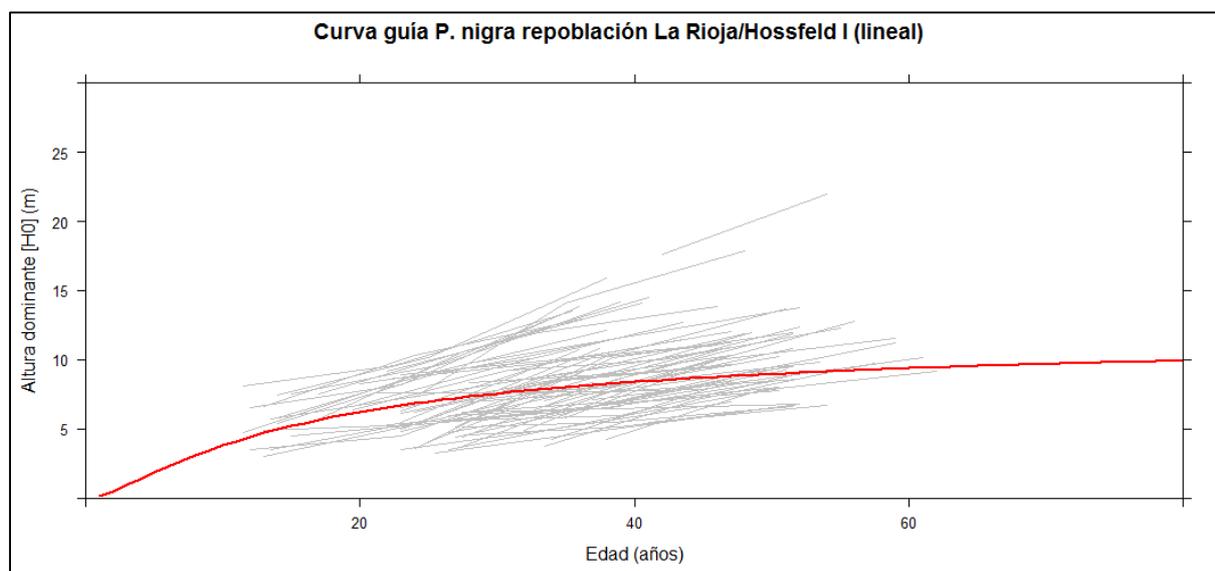
---

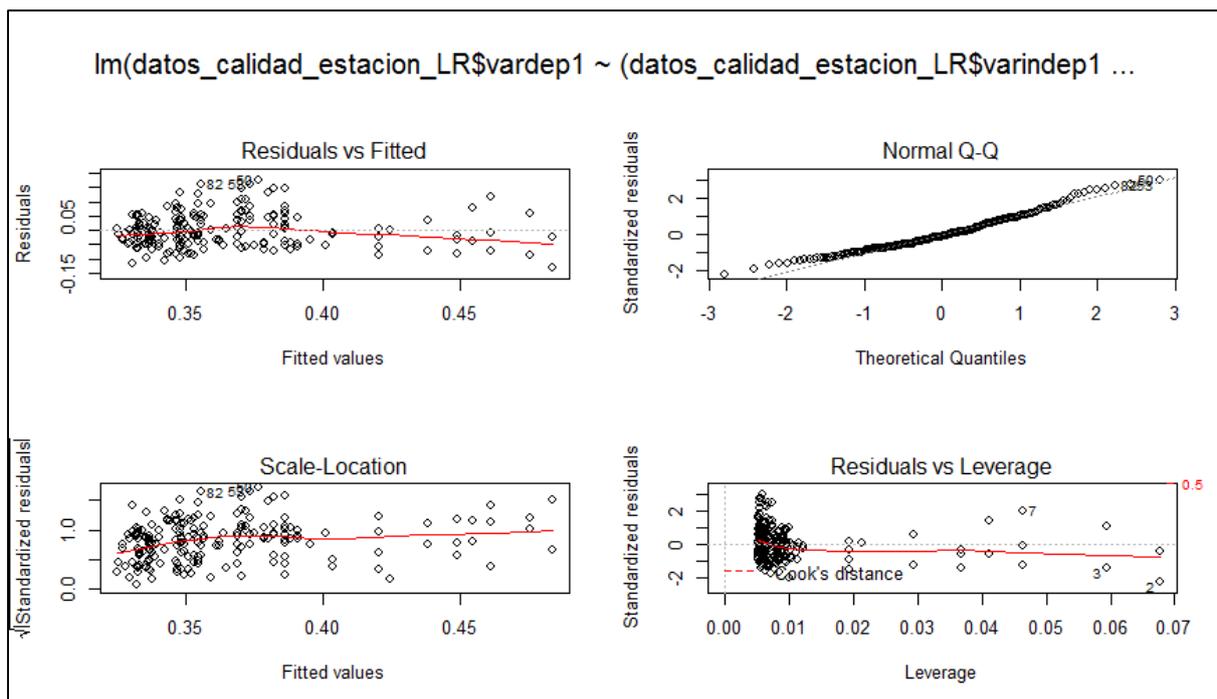
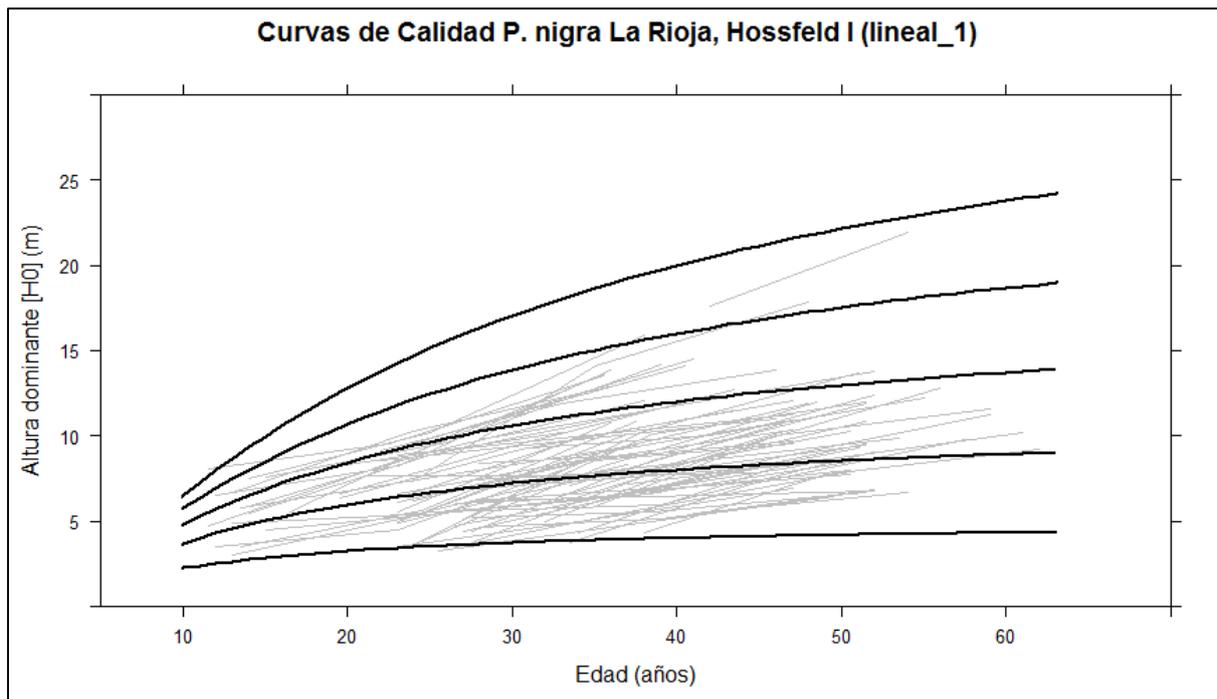
Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.05968 on 192 degrees of freedom

Multiple R-squared: 0.2513, Adjusted R-squared: 0.2474

F-statistic: 64.45 on 1 and 192 DF, p-value: 9.663e-14





### Mod.1 [H<sub>0</sub>~edad] –Hossfeld I (mod.) no lineal

```
> summary(nlmod.Hossfeld_1)
```

```
Formula: datos_calidad_estacion_LR$H0 ~ (datos_calidad_estacion_LR$Edad^2)/  
((a +  
  b * datos_calidad_estacion_LR$Edad)^2)
```

#### Gauss-Newton Algorithm:

Parameters:

|   | Estimate | Std. Error | t value | Pr(> t ) |     |
|---|----------|------------|---------|----------|-----|
| a | 2.79780  | 0.40141    | 6.97    | 4.95e-11 | *** |
| b | 0.25945  | 0.01133    | 22.89   | < 2e-16  | *** |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2.639 on 192 degrees of freedom

Number of iterations to convergence: 4

Achieved convergence tolerance: 5.709e-06

```
> summary(nlmod_marq_Hossfeld)
```

```
Formula: datos_calidad_estacion_LR$H0 ~ (datos_calidad_estacion_LR$Edad^2)/  
((a +  
  b * datos_calidad_estacion_LR$Edad)^2)
```

#### Levenberg-Marquardt Algorithm:

Parameters:

|   | Estimate | Std. Error | t value | Pr(> t ) |     |
|---|----------|------------|---------|----------|-----|
| a | 2.79780  | 0.40141    | 6.97    | 4.95e-11 | *** |
| b | 0.25945  | 0.01133    | 22.89   | < 2e-16  | *** |

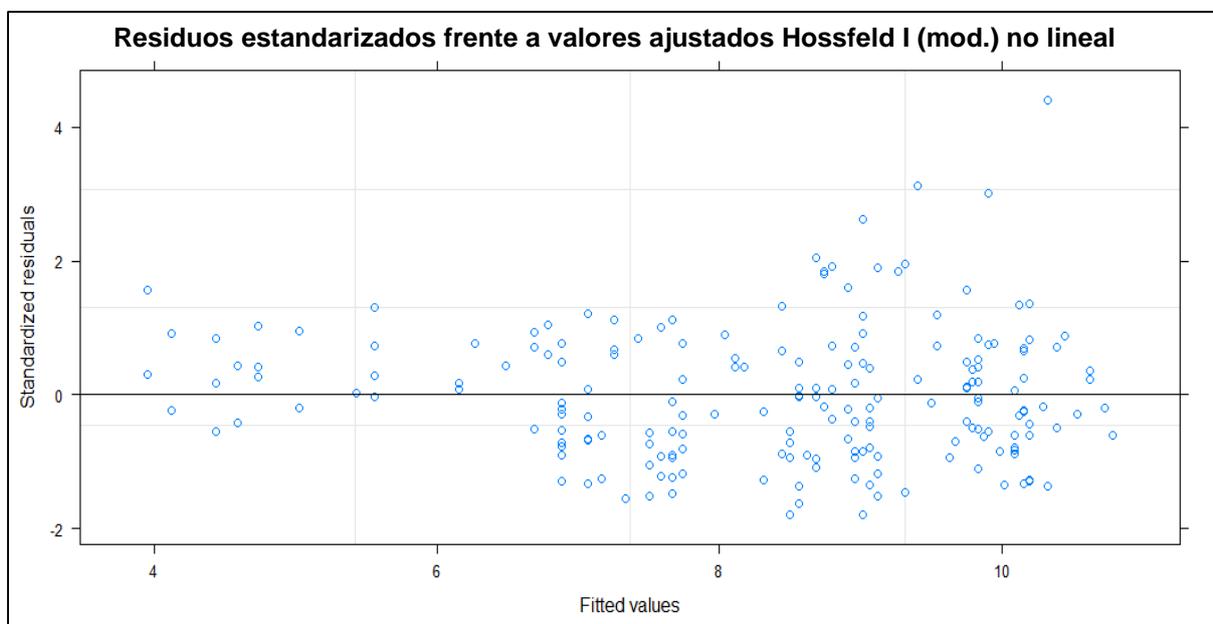
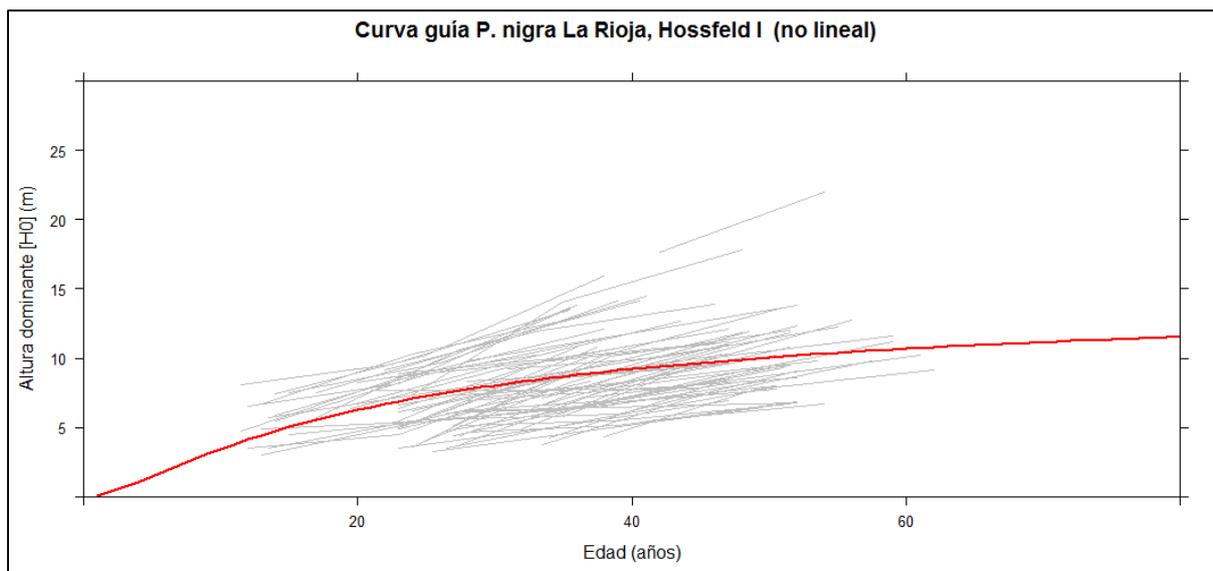
---

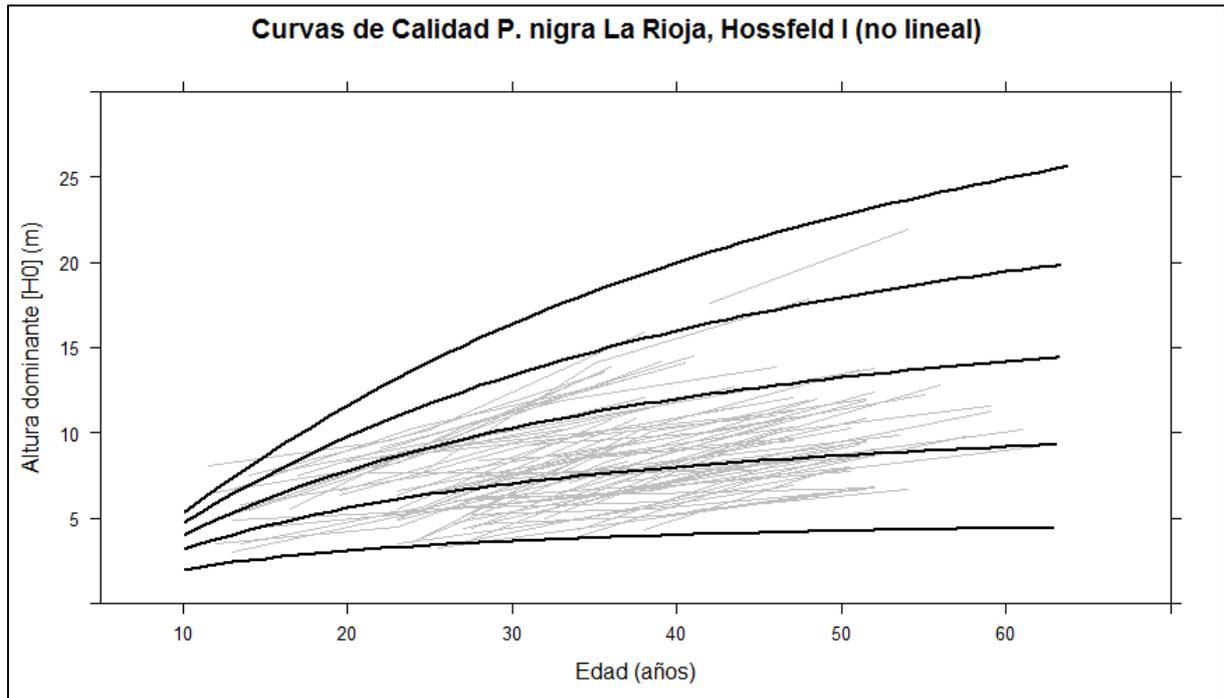
Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2.639 on 192 degrees of freedom

Number of iterations to convergence: 4

Achieved convergence tolerance: 1.49e-08





## Mod.2 [H<sub>0</sub>~edad] –Mitscherlich I lineal

```
> summary(Richards.lineal)
```

Call:

```
lm(formula = datos_calidad_estacion_LR$vardep ~ (datos_calidad_estacion_LR$varindep))
```

Residuals:

| Min      | 1Q       | Median  | 3Q      | Max     |
|----------|----------|---------|---------|---------|
| -0.76803 | -0.22109 | 0.00902 | 0.23808 | 0.80543 |

Coefficients:

|        | Estimate | Std. Error | t value | Pr(> t )     |
|--------|----------|------------|---------|--------------|
| Exp(a) | 2.56290  | 0.06259    | 40.947  | < 2e-16 ***  |
| b      | 0.20     | -          | -       | -            |
| c      | 0.67160  | 0.07758    | 8.657   | 1.95e-15 *** |

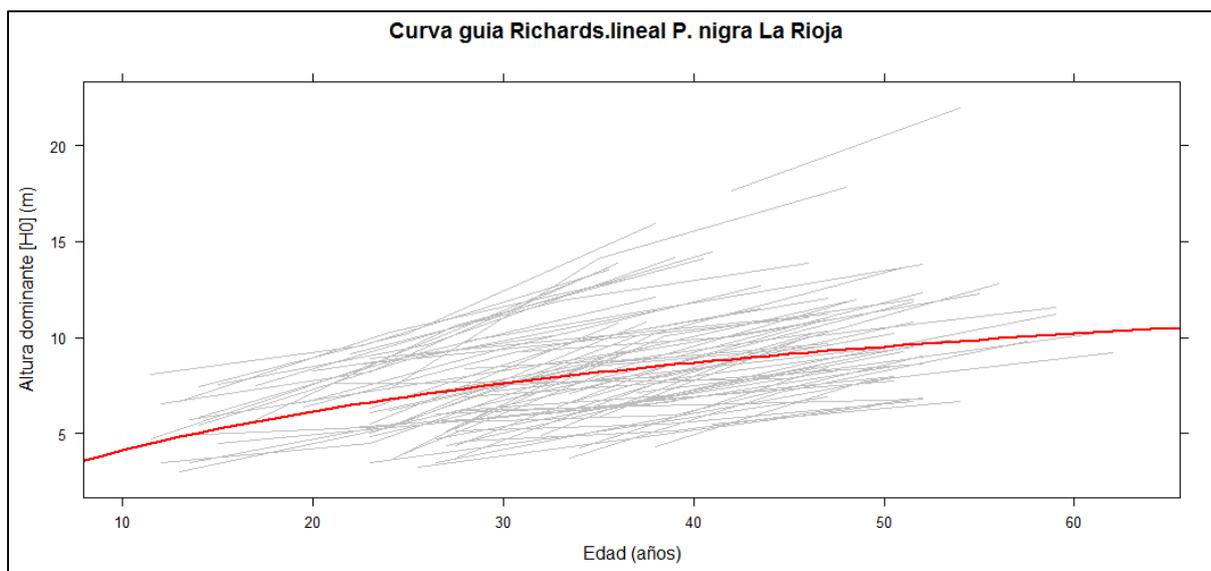
---

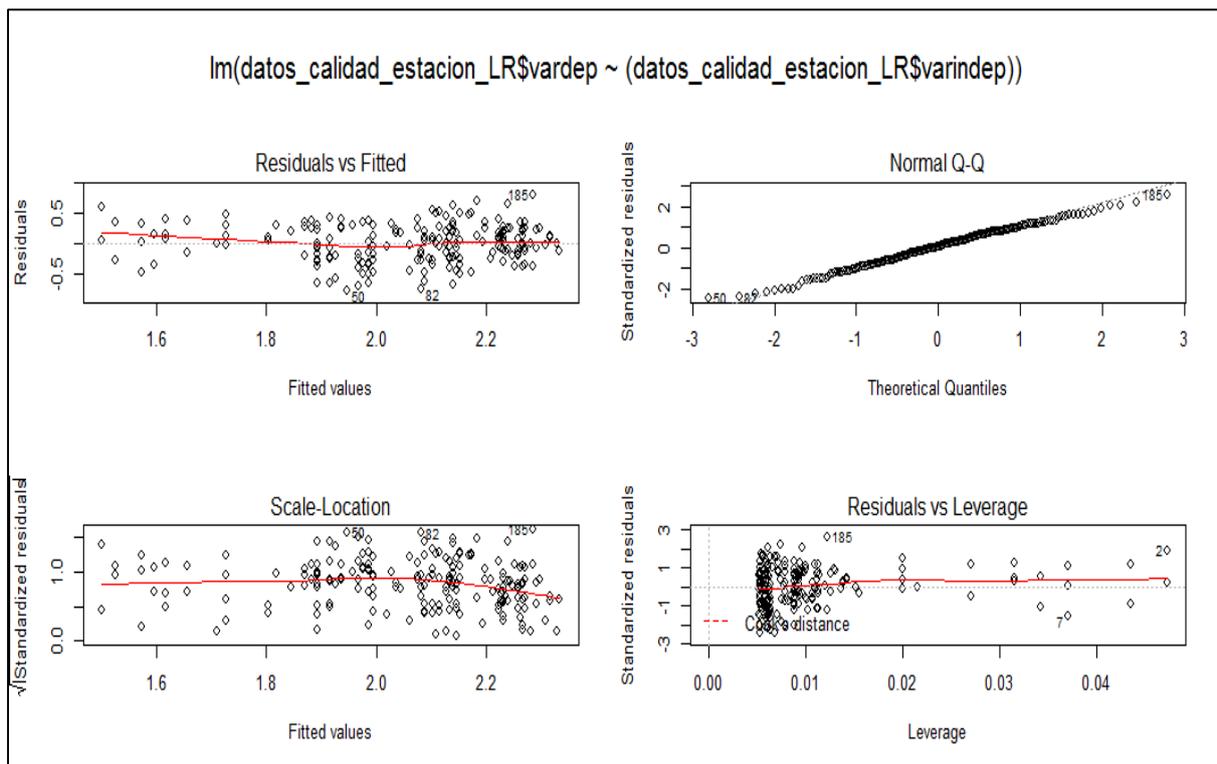
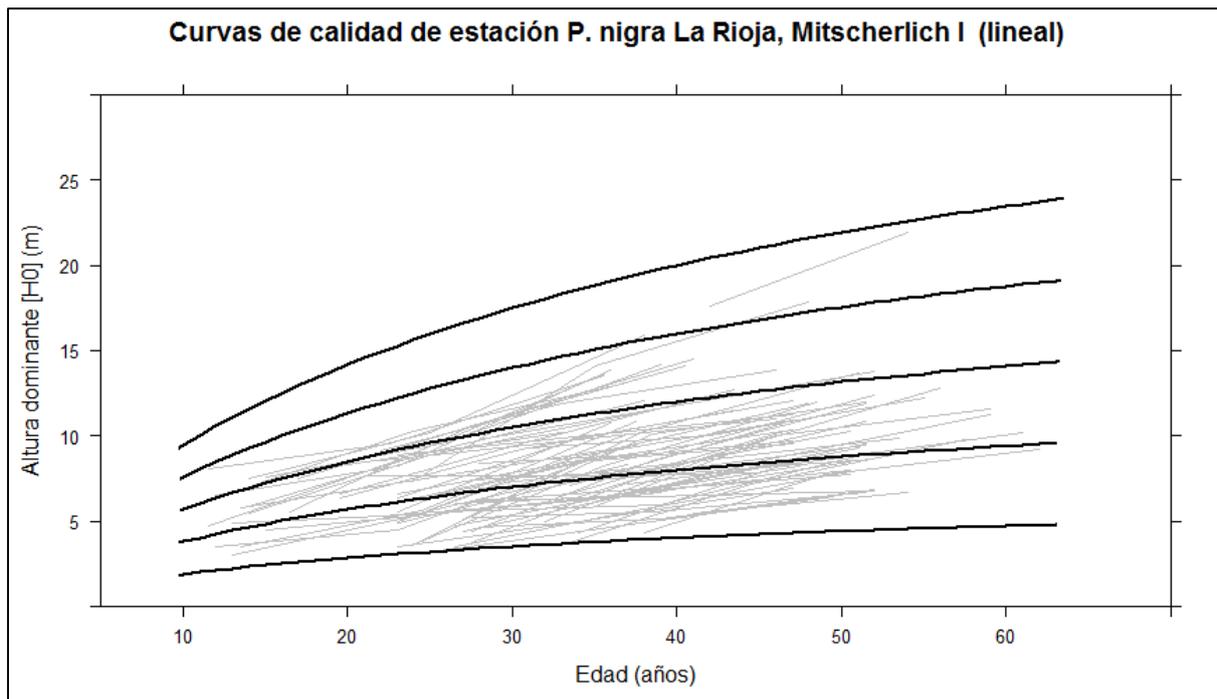
Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.3137 on 192 degrees of freedom

Multiple R-squared: 0.2808, Adjusted R-squared: 0.277

F-statistic: 74.95 on 1 and 192 DF, p-value: 1.952e-15





## Mod.2 [H<sub>0</sub>~edad] –Mitscherlich I no lineal

```
> summary(nlmod_marq_Richards)
```

```
Formula: datos_calidad_estacion_LR$H0 ~ (a * ((1 - exp(-b * datos_calidad_estacion_LR$Edad))^c))
```

### Levenberg-Marquardt Algorithm:

Parameters:

|   | Estimate  | Std. Error | t value | Pr(> t ) |
|---|-----------|------------|---------|----------|
| a | 3.286e+02 | 2.474e+05  | 0.001   | 0.999    |
| b | 2.505e-05 | 3.643e-02  | 0.001   | 0.999    |
| c | 5.194e-01 | 3.239e-01  | 1.604   | 0.110    |

Residual standard error: 2.622 on 191 degrees of freedom

Number of iterations to convergence: 306

Achieved convergence tolerance: 1.49e-08

## **MODELO ALTURA DOMINANTE DE ASSMANN~LIDAR**

### **ESTUDIO DE CORRELACIONES**

#### **PEARSON CORRELATIONS:**

|              | H0     | Elev.maximum | Elev.mean | Elev.mode | Elev.P95 | Elev.P99 |
|--------------|--------|--------------|-----------|-----------|----------|----------|
| H0           | 1.0000 | 0.9032       | 0.9681    | 0.9376    | 0.9665   | 0.9493   |
| Elev.maximum | 0.9032 | 1.0000       | 0.8887    | 0.8497    | 0.9305   | 0.9791   |
| Elev.mean    | 0.9681 | 0.8887       | 1.0000    | 0.9697    | 0.9830   | 0.9486   |
| Elev.mode    | 0.9376 | 0.8497       | 0.9697    | 1.0000    | 0.9483   | 0.9071   |
| Elev.P95     | 0.9665 | 0.9305       | 0.9830    | 0.9483    | 1.0000   | 0.9811   |
| Elev.P99     | 0.9493 | 0.9791       | 0.9486    | 0.9071    | 0.9811   | 1.0000   |

Number of observations: 53

#### **Pairwise two-sided p-values:**

|              | H0     | Elev.maximum | Elev.mean | Elev.mode | Elev.P95 | Elev.P99 |
|--------------|--------|--------------|-----------|-----------|----------|----------|
| H0           |        | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.maximum | <.0001 |              | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.mean    | <.0001 | <.0001       |           | <.0001    | <.0001   | <.0001   |
| Elev.mode    | <.0001 | <.0001       | <.0001    |           | <.0001   | <.0001   |
| Elev.P95     | <.0001 | <.0001       | <.0001    | <.0001    |          | <.0001   |
| Elev.P99     | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   |          |

#### **Adjusted p-values (Holm's method)**

|              | H0     | Elev.maximum | Elev.mean | Elev.mode | Elev.P95 | Elev.P99 |
|--------------|--------|--------------|-----------|-----------|----------|----------|
| H0           |        | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.maximum | <.0001 |              | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.mean    | <.0001 | <.0001       |           | <.0001    | <.0001   | <.0001   |
| Elev.mode    | <.0001 | <.0001       | <.0001    |           | <.0001   | <.0001   |
| Elev.P95     | <.0001 | <.0001       | <.0001    | <.0001    |          | <.0001   |
| Elev.P99     | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   |          |

**SPEARMAN CORRELATIONS:**

|              | H0     | Elev.maximum | Elev.mean | Elev.mode | Elev.P95 | Elev.P99 |
|--------------|--------|--------------|-----------|-----------|----------|----------|
| H0           | 1.0000 | 0.9173       | 0.9359    | 0.8883    | 0.9427   | 0.9272   |
| Elev.maximum | 0.9173 | 1.0000       | 0.9093    | 0.8475    | 0.9558   | 0.9839   |
| Elev.mean    | 0.9359 | 0.9093       | 1.0000    | 0.9561    | 0.9727   | 0.9235   |
| Elev.mode    | 0.8883 | 0.8475       | 0.9561    | 1.0000    | 0.9172   | 0.8505   |
| Elev.P95     | 0.9427 | 0.9558       | 0.9727    | 0.9172    | 1.0000   | 0.9724   |
| Elev.P99     | 0.9272 | 0.9839       | 0.9235    | 0.8505    | 0.9724   | 1.0000   |

Number of observations: 53

**Pairwise two-sided p-values:**

|              | H0     | Elev.maximum | Elev.mean | Elev.mode | Elev.P95 | Elev.P99 |
|--------------|--------|--------------|-----------|-----------|----------|----------|
| H0           | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.maximum | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.mean    | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.mode    | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.P95     | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.P99     | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |

**Adjusted p-values (Holm's method)**

|              | H0     | Elev.maximum | Elev.mean | Elev.mode | Elev.P95 | Elev.P99 |
|--------------|--------|--------------|-----------|-----------|----------|----------|
| H0           | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.maximum | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.mean    | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.mode    | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.P95     | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |
| Elev.P99     | <.0001 | <.0001       | <.0001    | <.0001    | <.0001   | <.0001   |

**PARTIAL CORRELATIONS:**

|              | H0       | Elev.maximum | Elev.mean | Elev.mode | Elev.P95 | Elev.P99 |
|--------------|----------|--------------|-----------|-----------|----------|----------|
| H0           | 0.00000  | 0.01038      | 0.34640   | 0.04772   | -0.00108 | 0.08280  |
| Elev.maximum | 0.01038  | 0.00000      | -0.04810  | 0.20090   | -0.57886 | 0.92030  |
| Elev.mean    | 0.34640  | -0.04810     | 0.00000   | 0.51943   | 0.48556  | -0.08863 |
| Elev.mode    | 0.04772  | 0.20090      | 0.51943   | 0.00000   | 0.15719  | -0.23897 |
| Elev.P95     | -0.00108 | -0.57886     | 0.48556   | 0.15719   | 0.00000  | 0.79207  |
| Elev.P99     | 0.08280  | 0.92030      | -0.08863  | -0.23897  | 0.79207  | 0.00000  |

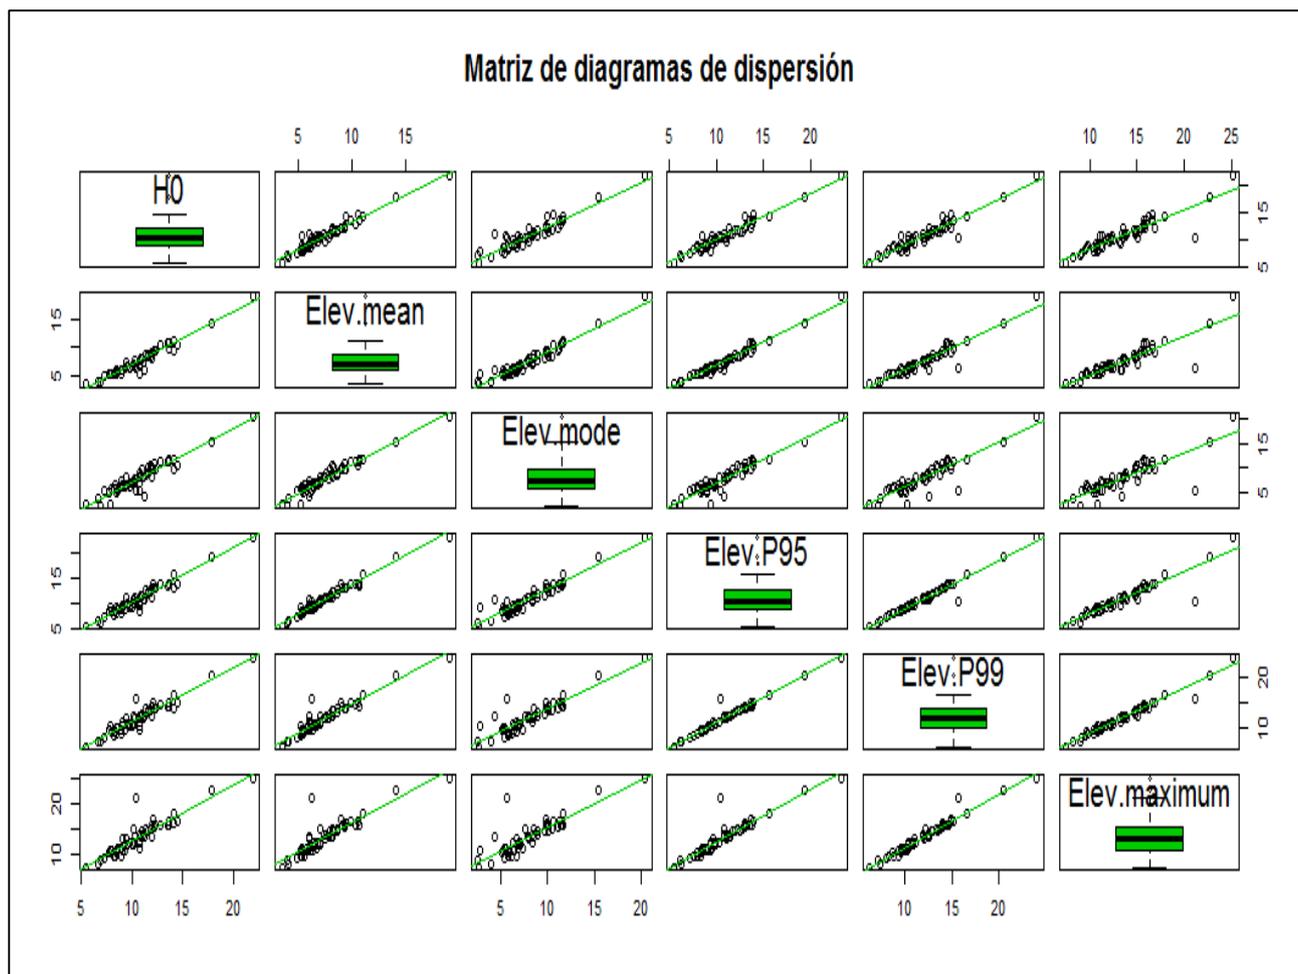
Number of observations: 53

**Pairwise two-sided p-values:**

|              | H0     | Elev.maximum | Elev.mean | Elev.mode | Elev.P95 | Elev.P99 |
|--------------|--------|--------------|-----------|-----------|----------|----------|
| H0           |        | 0.9436       | 0.0148    | 0.7447    | 0.9941   | 0.5717   |
| Elev.maximum | 0.9436 |              | 0.7428    | 0.1663    | <.0001   | <.0001   |
| Elev.mean    | 0.0148 | 0.7428       |           | 0.0001    | 0.0004   | 0.5448   |
| Elev.mode    | 0.7447 | 0.1663       | 0.0001    |           | 0.2808   | 0.0982   |
| Elev.P95     | 0.9941 | <.0001       | 0.0004    | 0.2808    |          | <.0001   |
| Elev.P99     | 0.5717 | <.0001       | 0.5448    | 0.0982    | <.0001   |          |

**Adjusted p-values (Holm's method)**

|              | H0     | Elev.maximum | Elev.mean | Elev.mode | Elev.P95 | Elev.P99 |
|--------------|--------|--------------|-----------|-----------|----------|----------|
| H0           |        | 1.0000       | 0.1476    | 1.0000    | 1.0000   | 1.0000   |
| Elev.maximum | 1.0000 |              | 1.0000    | 1.0000    | 0.0002   | <.0001   |
| Elev.mean    | 0.1476 | 1.0000       |           | 0.0016    | 0.0045   | 1.0000   |
| Elev.mode    | 1.0000 | 1.0000       | 0.0016    |           | 1.0000   | 0.8838   |
| Elev.P95     | 1.0000 | 0.0002       | 0.0045    | 1.0000    |          | <.0001   |
| Elev.P99     | 1.0000 | <.0001       | 1.0000    | 0.8838    | <.0001   |          |



### Model.1 [H0~Elev.mean]

> summary(Model.1)

Call:

```
lm(formula = H0 ~ Elev.mean, data = datos_LiDAR_H0)
```

Residuals:

| Min     | 1Q      | Median  | 3Q     | Max    |
|---------|---------|---------|--------|--------|
| -1.1888 | -0.3992 | -0.1577 | 0.3396 | 2.3513 |

Coefficients:

|             | Estimate | Std. Error | t value | Pr(> t )    |
|-------------|----------|------------|---------|-------------|
| (Intercept) | 3.0595   | 0.3941     | 10.40   | 3.3e-14 *** |
| Elev.mean   | 1.0149   | 0.0368     | 27.58   | < 2e-16 *** |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.7164 on 51 degrees of freedom

Multiple R-squared: 0.9331, Adjusted R-squared: 0.9309

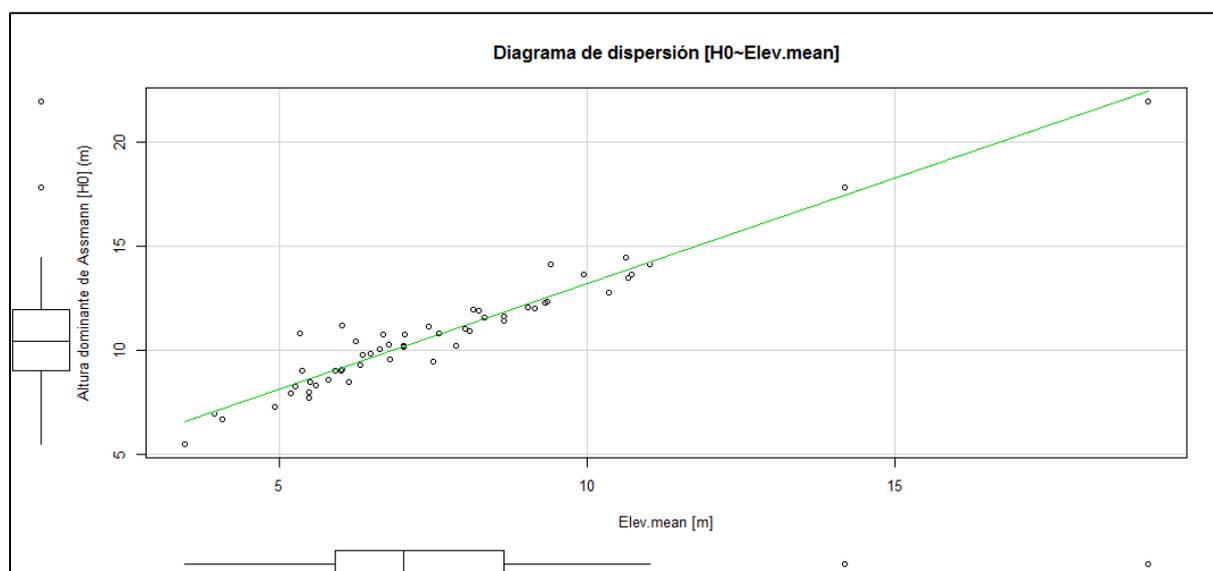
F-statistic: 760.4 on 1 and 51 DF, p-value: < 2.2e-16

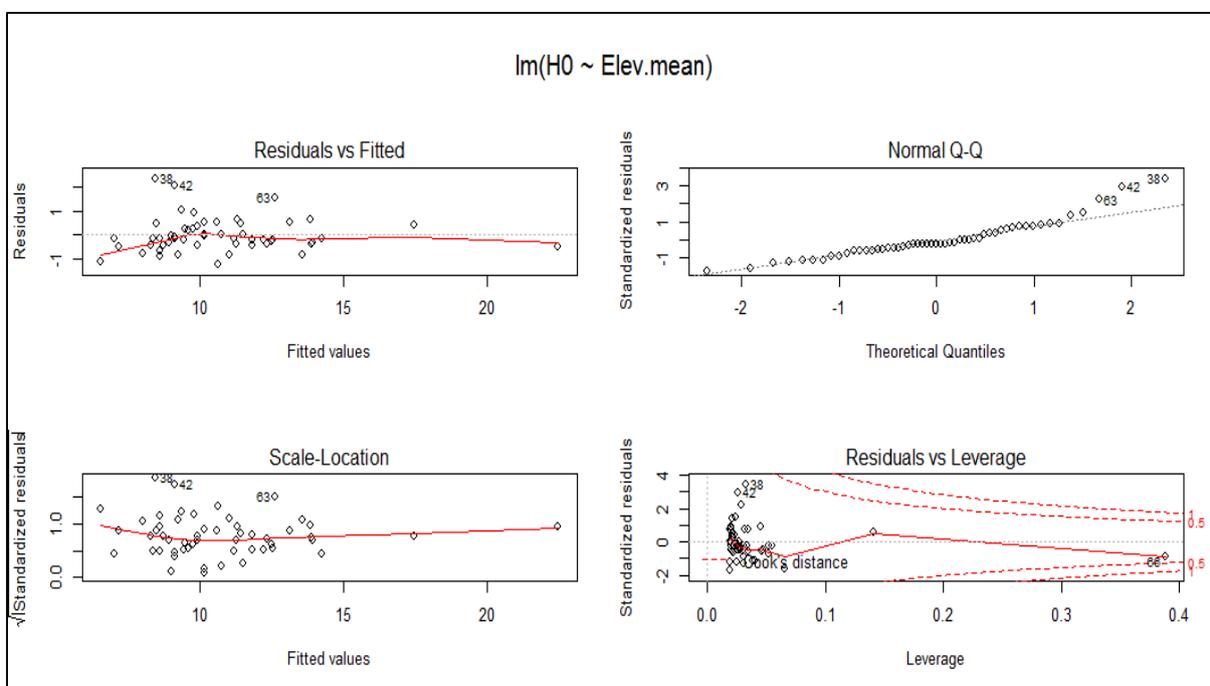
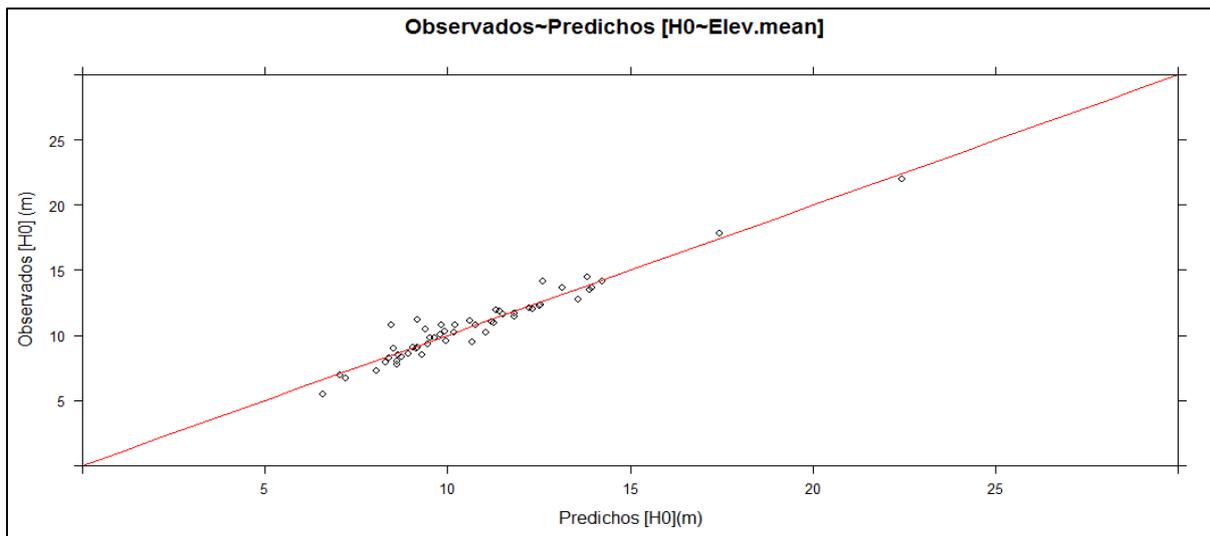
> AIC(Model.1)

|         | df | AIC      |
|---------|----|----------|
| Model.1 | 3  | 126.5355 |

> BIC(Model.1)

|         | df | BIC      |
|---------|----|----------|
| Model.1 | 3  | 132.4464 |





### Model.2 [H0~Elev.mode]

> summary(Model.2)

Call:

```
lm(formula = H0 ~ Elev.mode, data = datos_LiDAR_H0)
```

Residuals:

| Min     | 1Q      | Median  | 3Q     | Max    |
|---------|---------|---------|--------|--------|
| -1.2986 | -0.6342 | -0.1945 | 0.3212 | 3.4475 |

Coefficients:

|             | Estimate | Std. Error | t value | Pr(> t )     |
|-------------|----------|------------|---------|--------------|
| (Intercept) | 4.11782  | 0.36803    | 11.19   | 2.44e-15 *** |
| Elev.mode   | 0.82866  | 0.04303    | 19.26   | < 2e-16 ***  |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.9706 on 51 degrees of freedom

Multiple R-squared: 0.8791, Adjusted R-squared: 0.8767

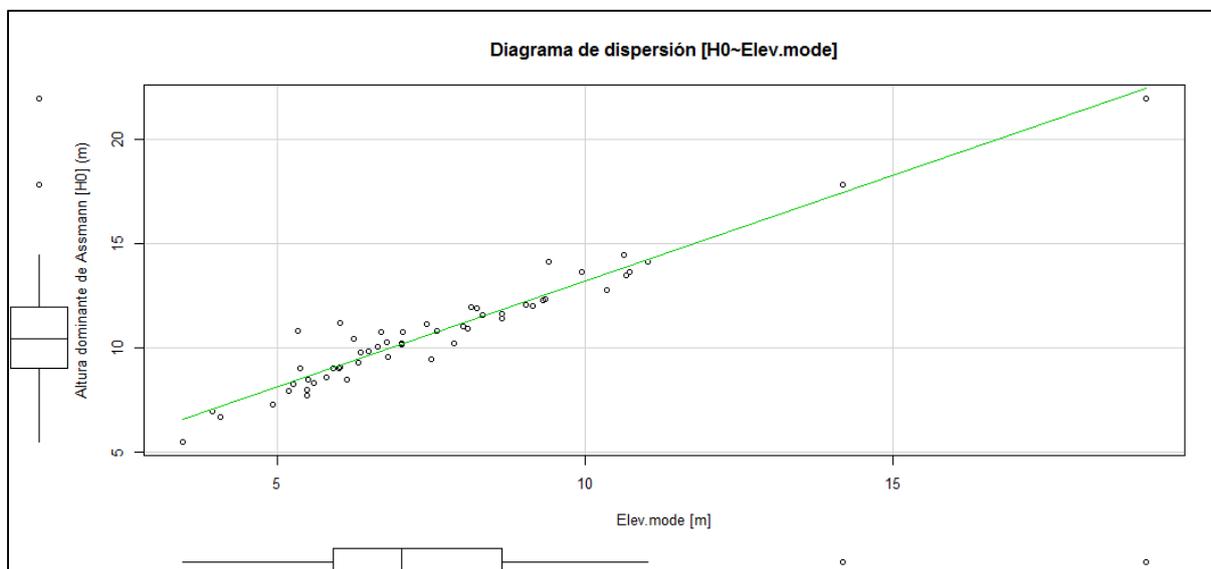
F-statistic: 370.9 on 1 and 51 DF, p-value: < 2.2e-16

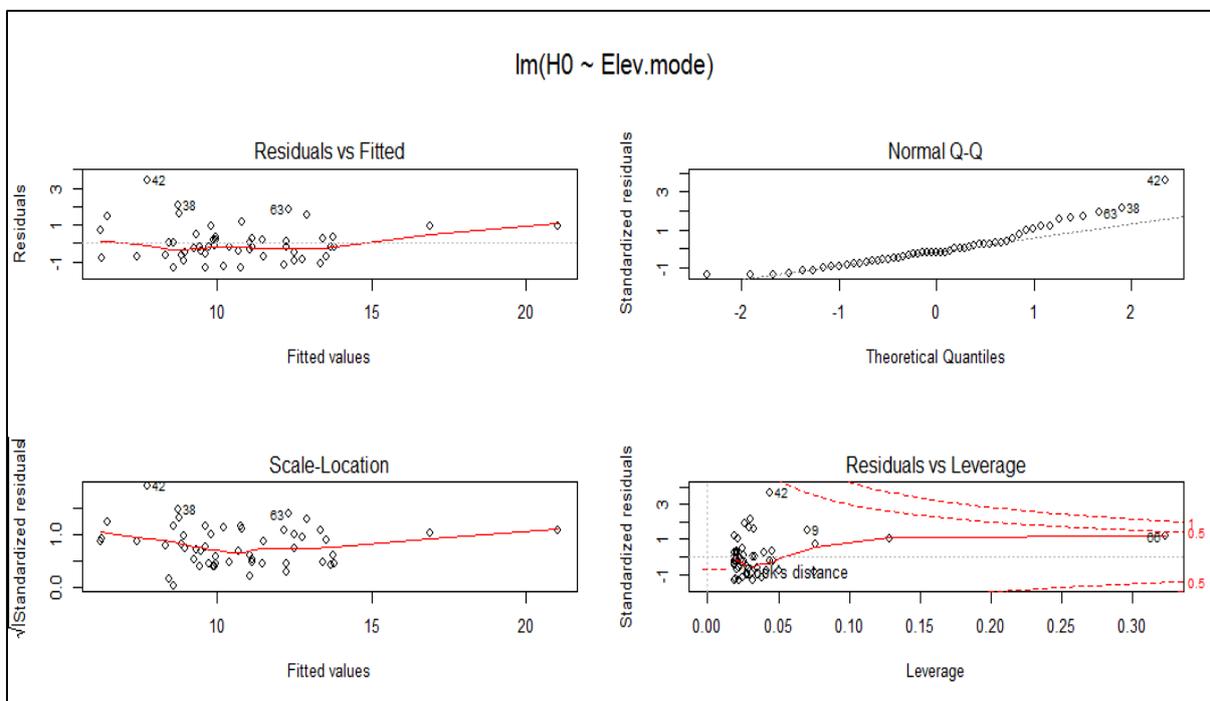
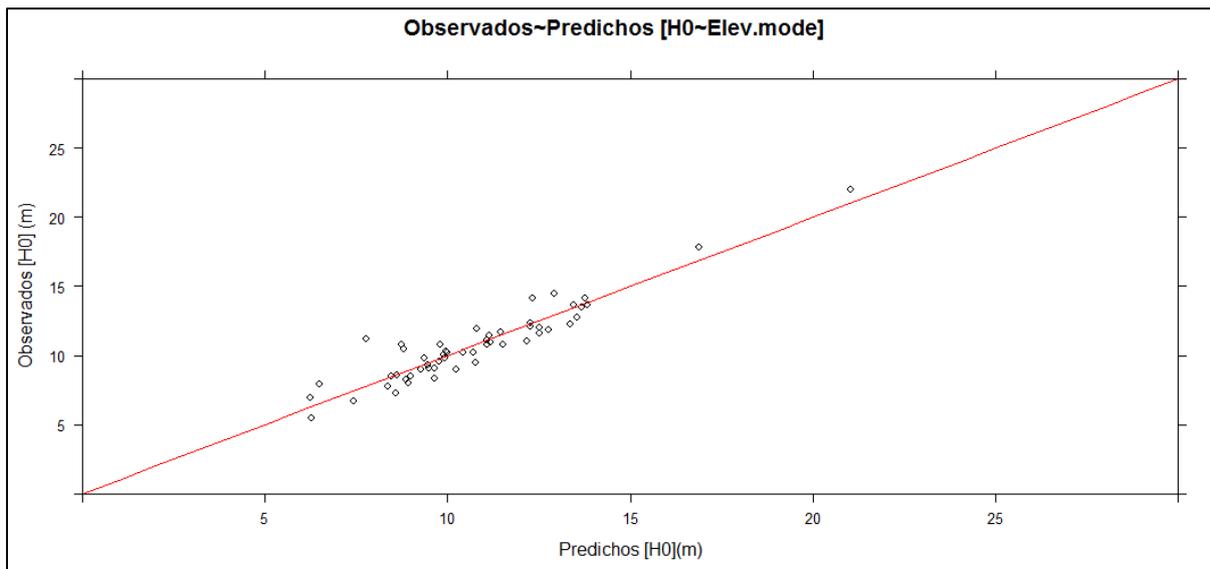
> AIC(Model.2)

|         | df | AIC      |
|---------|----|----------|
| Model.2 | 3  | 151.2020 |

> BIC(Model.2)

|         | df | BIC      |
|---------|----|----------|
| Model.2 | 3  | 157.1128 |





### Model.3 [H0~Elev.maximum]

> summary(Model.3)

Call:

```
lm(formula = H0 ~ Elev.maximum, data = datos_LiDAR_H0)
```

Residuals:

| Min     | 1Q      | Median | 3Q     | Max    |
|---------|---------|--------|--------|--------|
| -5.8936 | -0.5371 | 0.0109 | 0.5283 | 2.7676 |

Coefficients:

|              | Estimate | Std. Error | t value | Pr(> t )   |
|--------------|----------|------------|---------|------------|
| (Intercept)  | 0.94785  | 0.67118    | 1.412   | 0.164      |
| Elev.maximum | 0.72698  | 0.04839    | 15.025  | <2e-16 *** |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 1.198 on 51 degrees of freedom

Multiple R-squared: 0.8157, Adjusted R-squared: 0.8121

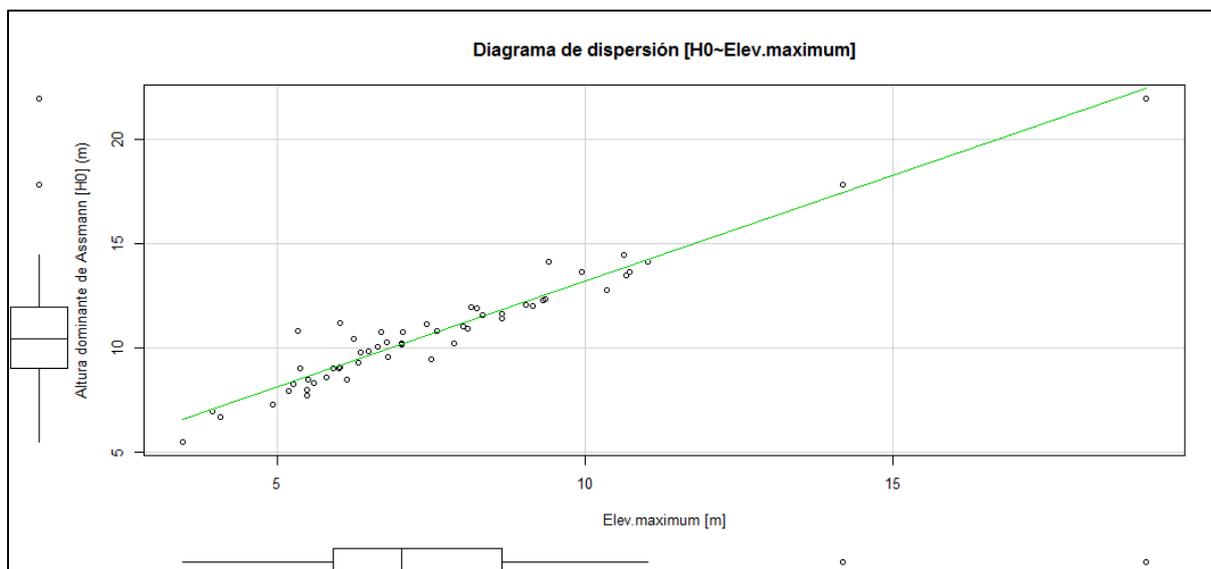
F-statistic: 225.7 on 1 and 51 DF, p-value: < 2.2e-16

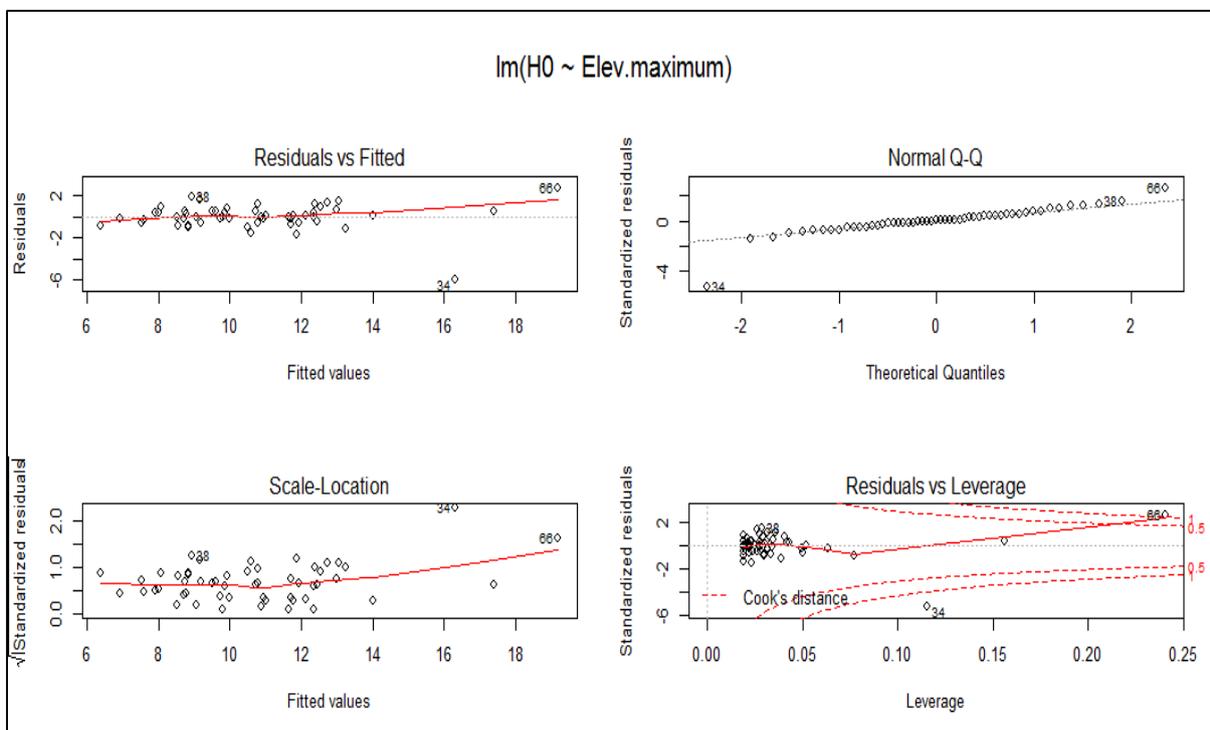
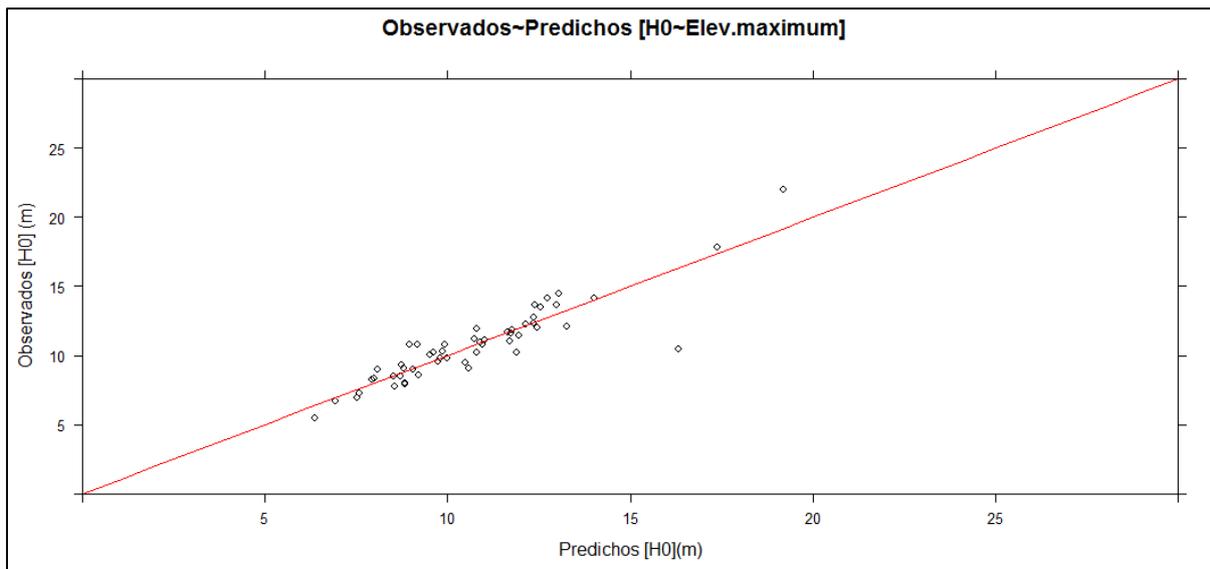
> AIC(Model.3)

|         | df | AIC      |
|---------|----|----------|
| Model.3 | 3  | 173.5496 |

> BIC(Model.3)

|         | df | BIC      |
|---------|----|----------|
| Model.3 | 3  | 179.4605 |





### Model.4 [H0~Elev.P95]

> summary(Model.4)

Call:

```
lm(formula = H0 ~ Elev.P95, data = datos_LiDAR_H0)
```

Residuals:

| Min      | 1Q       | Median   | 3Q      | Max     |
|----------|----------|----------|---------|---------|
| -1.46612 | -0.50397 | -0.05939 | 0.39192 | 2.20365 |

Coefficients:

|             | Estimate | Std. Error | t value | Pr(> t )     |
|-------------|----------|------------|---------|--------------|
| (Intercept) | 1.35528  | 0.36200    | 3.744   | 0.000461 *** |
| Elev.P95    | 0.86190  | 0.03205    | 26.894  | < 2e-16 ***  |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.6998 on 51 degrees of freedom

Multiple R-squared: 0.9341, Adjusted R-squared: 0.9328

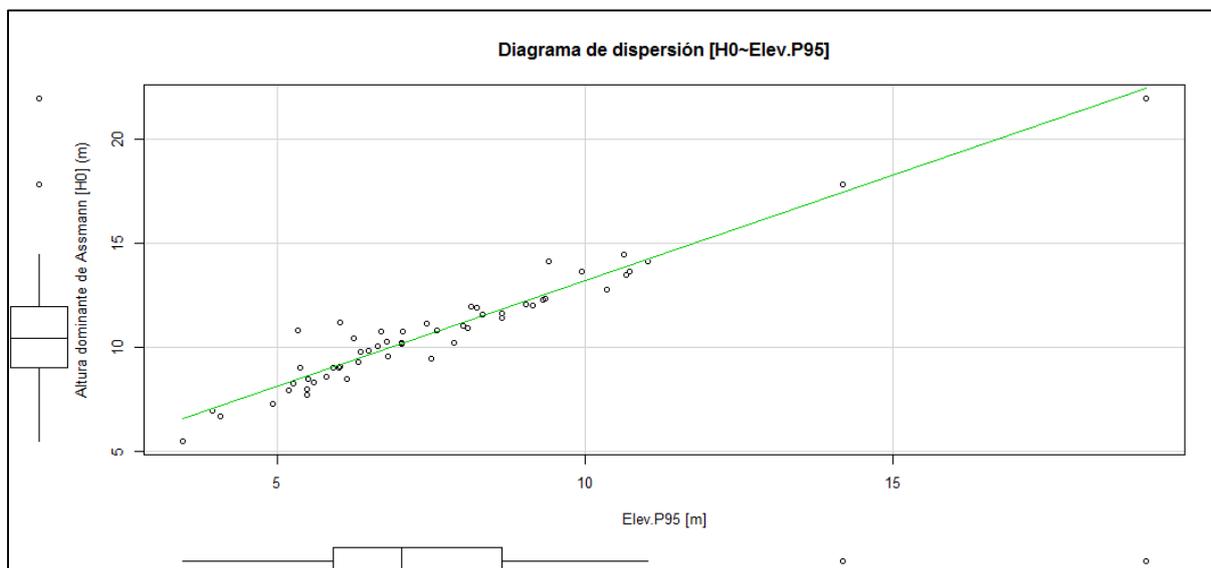
F-statistic: 723.3 on 1 and 51 DF, p-value: < 2.2e-16

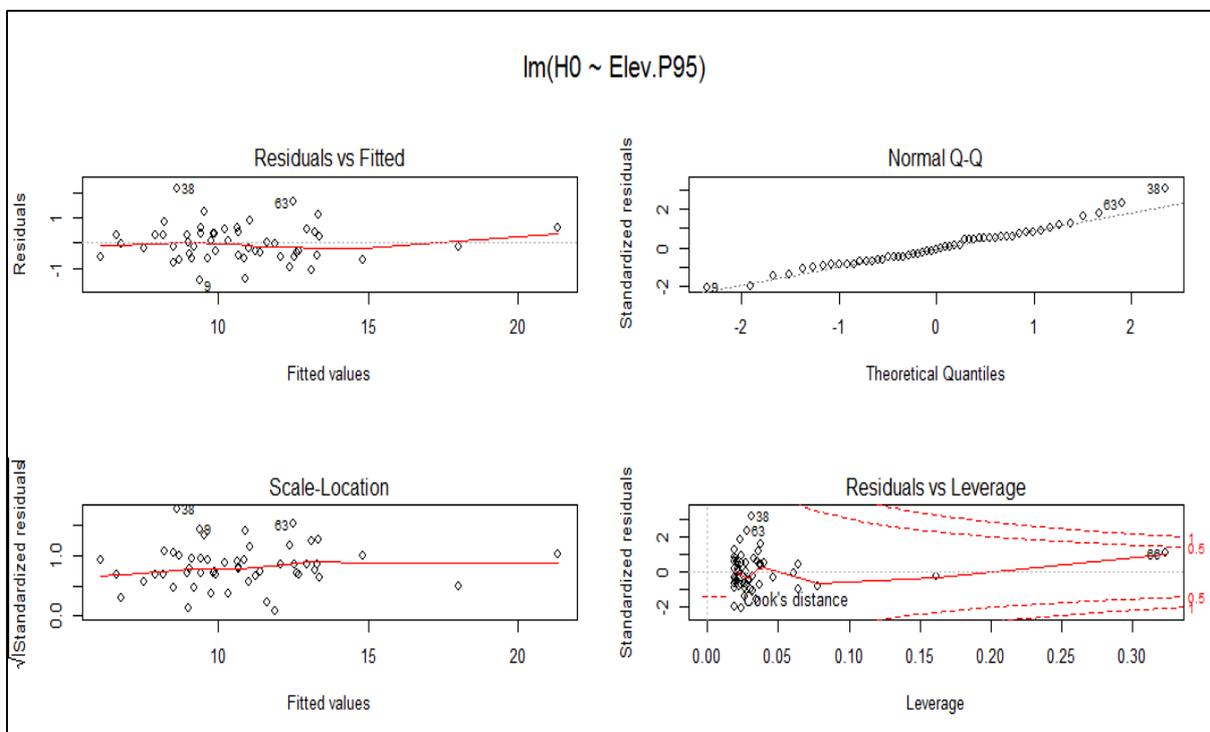
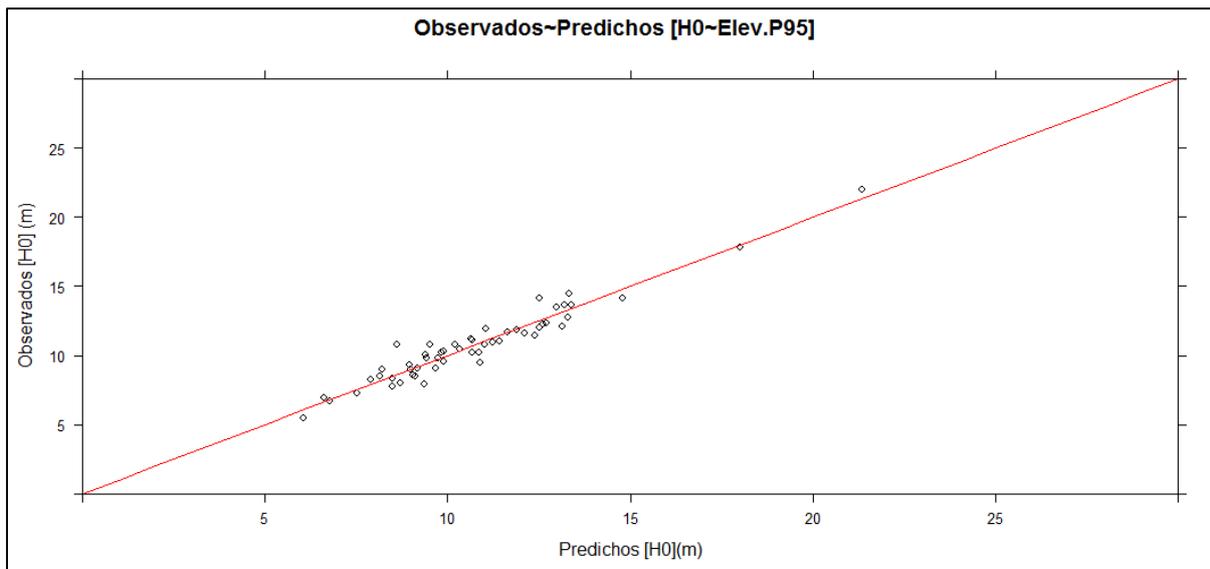
> AIC(Model.4)

|         | df | AIC      |
|---------|----|----------|
| Model.4 | 3  | 119.0209 |

> BIC(Model.4)

|         | df | BIC      |
|---------|----|----------|
| Model.4 | 3  | 124.9318 |





### Model.5 [H0~Elev.P99]

> summary(Model.5)

Call:

```
lm(formula = H0 ~ Elev.P99, data = datos_LiDAR_H0)
```

Residuals:

| Min     | 1Q      | Median  | 3Q     | Max    |
|---------|---------|---------|--------|--------|
| -3.3698 | -0.4680 | -0.0956 | 0.4802 | 2.0352 |

Coefficients:

|             | Estimate | Std. Error | t value | Pr(> t )   |
|-------------|----------|------------|---------|------------|
| (Intercept) | 0.83207  | 0.47420    | 1.755   | 0.0853 .   |
| Elev.P99    | 0.82703  | 0.03834    | 21.569  | <2e-16 *** |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.8774 on 51 degrees of freedom

Multiple R-squared: 0.9012, Adjusted R-squared: 0.8993

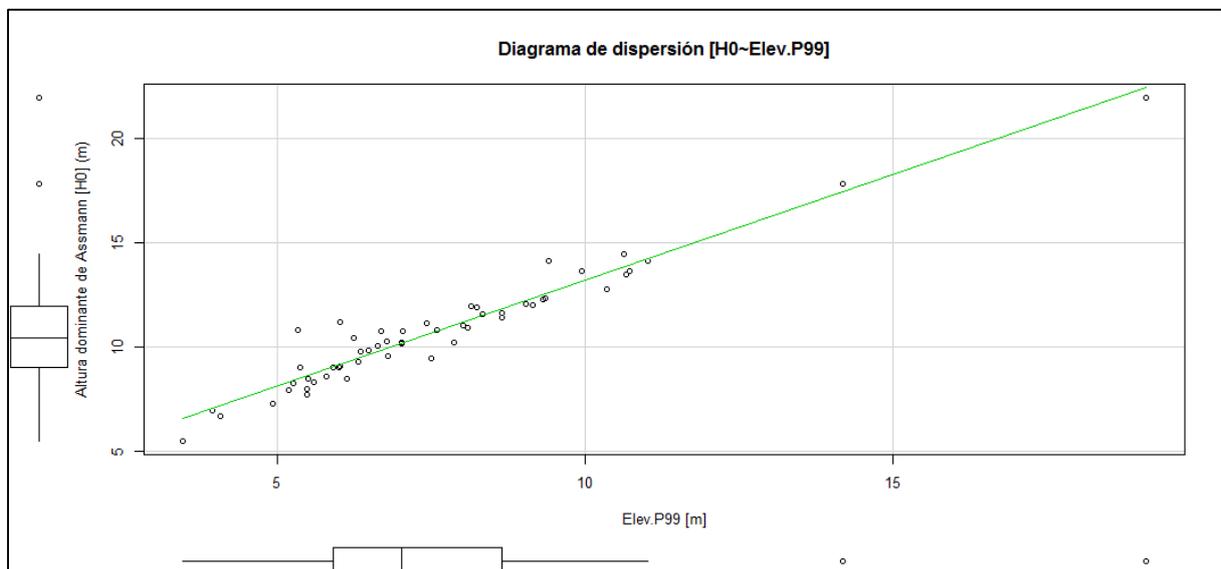
F-statistic: 465.2 on 1 and 51 DF, p-value: < 2.2e-16

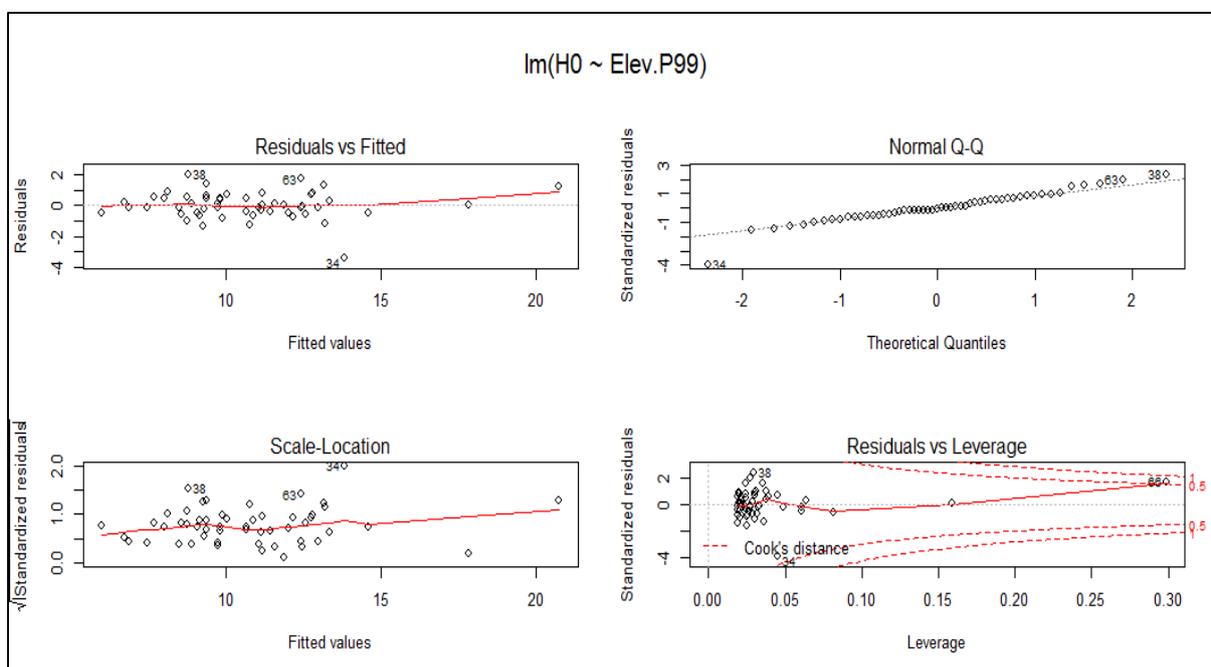
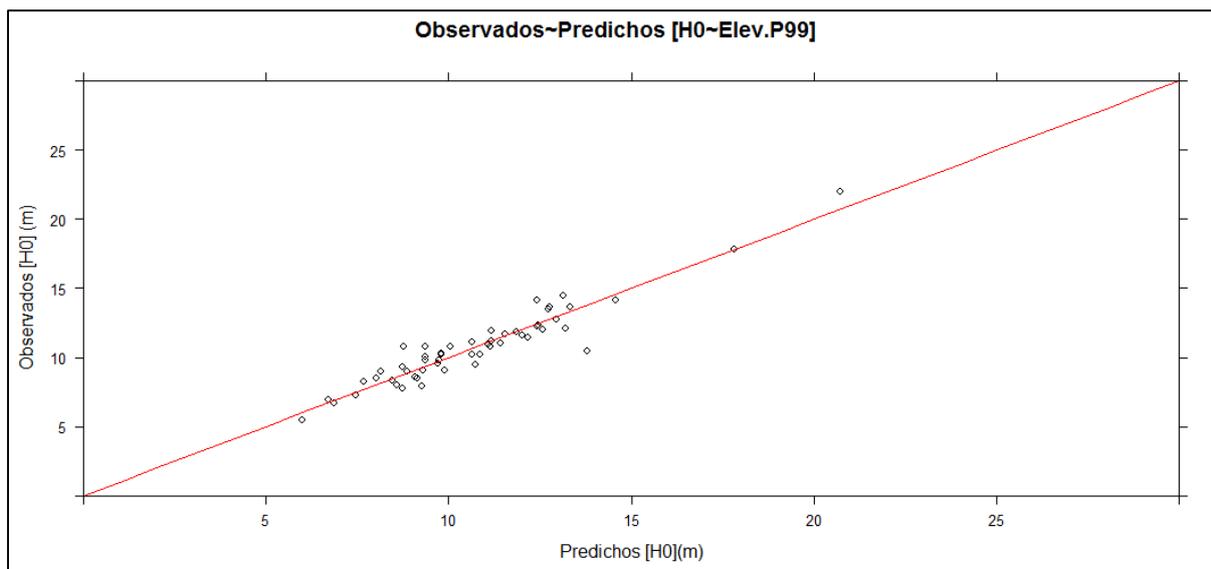
> AIC(Model.5)

|         | df | AIC      |
|---------|----|----------|
| Model.5 | 3  | 140.5076 |

> BIC(Model.5)

|         | df | BIC      |
|---------|----|----------|
| Model.5 | 3  | 146.4185 |





### Model.6 [H0~Elev.mean + Elev.P95]

> summary(Model.6)

Call:

```
lm(formula = H0 ~ Elev.P95 + Elev.mean, data = datos_LiDAR_H0)
```

Residuals:

| Min      | 1Q       | Median   | 3Q      | Max     |
|----------|----------|----------|---------|---------|
| -1.29248 | -0.36599 | -0.08046 | 0.32541 | 2.30297 |

Coefficients:

|             | Estimate | Std. Error | t value | Pr(> t )     |
|-------------|----------|------------|---------|--------------|
| (Intercept) | 2.2150   | 0.4480     | 4.944   | 9.01e-06 *** |
| Elev.P95    | 0.3941   | 0.1628     | 2.420   | 0.01918 *    |
| Elev.mean   | 0.5594   | 0.1914     | 2.922   | 0.00521 **   |

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.6687 on 50 degrees of freedom

Multiple R-squared: 0.9437, Adjusted R-squared: 0.9415

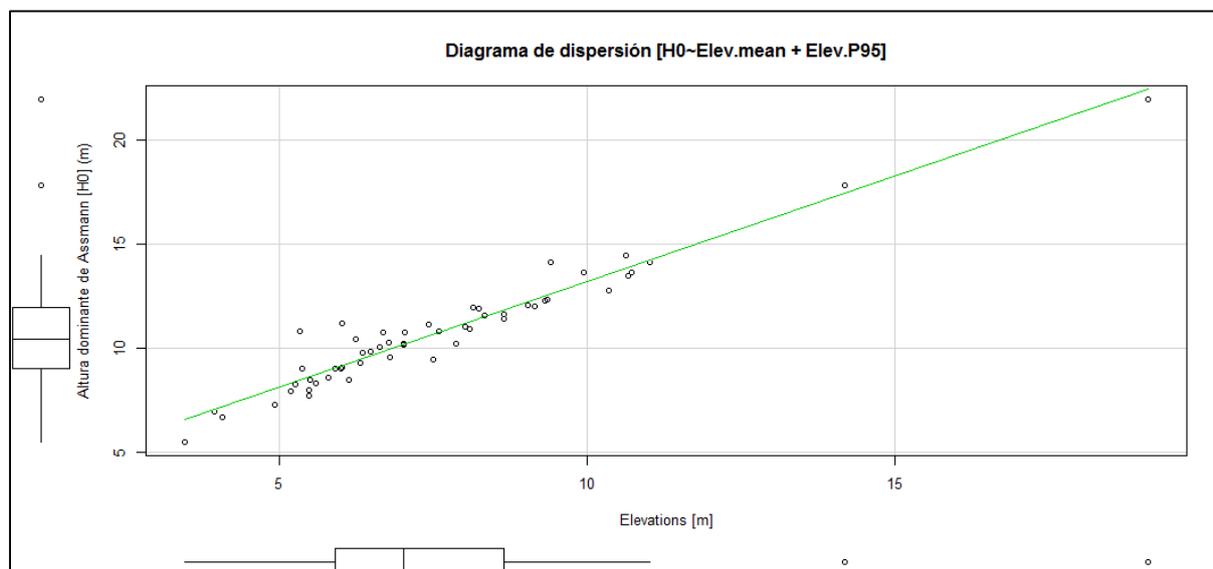
F-statistic: 419.4 on 2 and 50 DF, p-value: < 2.2e-16

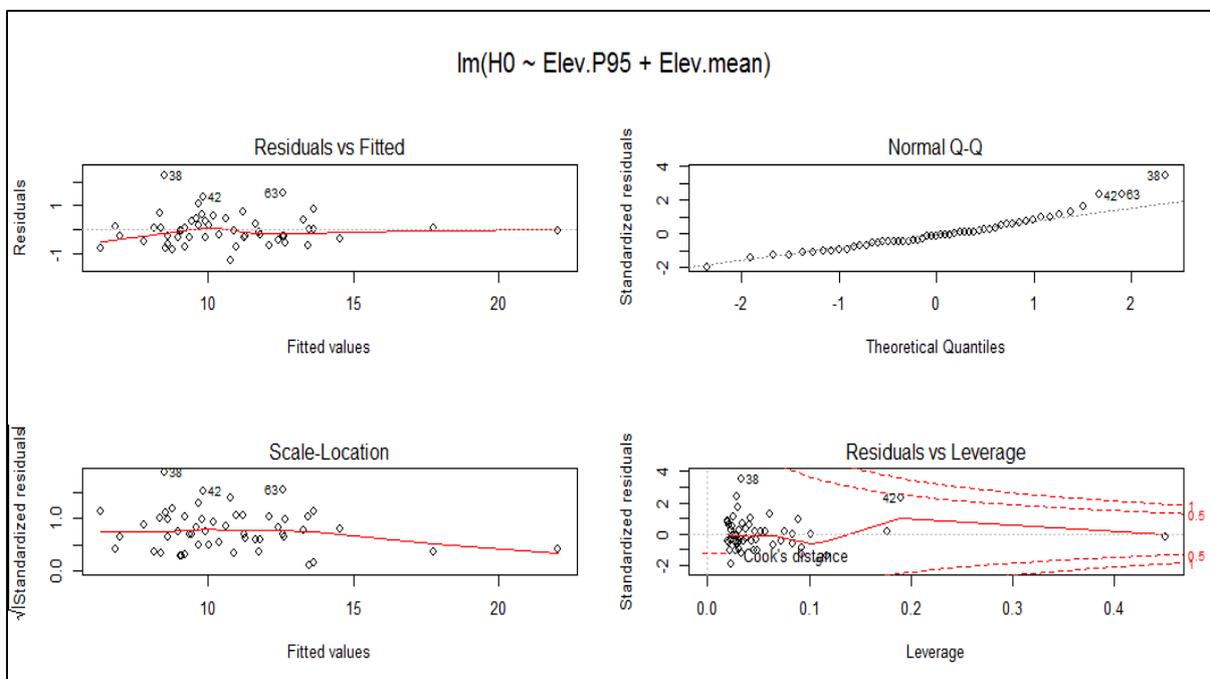
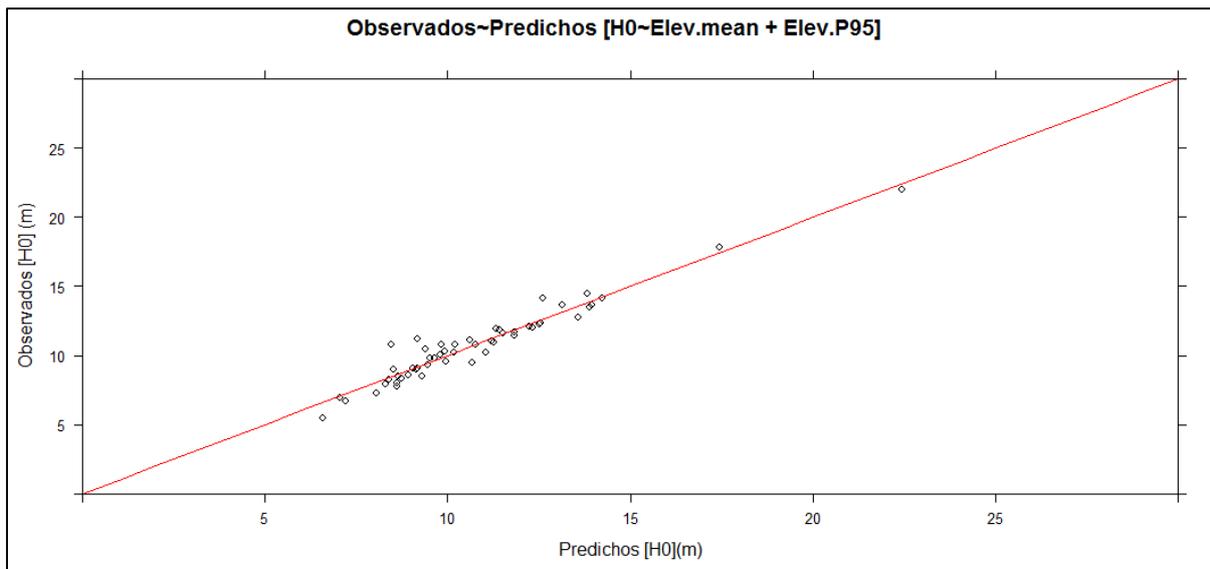
> AIC(Model.6)

|         | df | AIC      |
|---------|----|----------|
| Model.6 | 4  | 112.6637 |

> BIC(Model.6)

|         | df | BIC      |
|---------|----|----------|
| Model.6 | 4  | 120.5449 |







## AGRADECIMIENTOS

Con estas líneas quiero agradecer a todas las personas que, durante la realización de mi trabajo, me han dedicado su tiempo y ayuda.

Al Dr. Felipe Bravo Oviedo, tutor de este trabajo, por haber confiado en mí para la realización de este estudio, por haberme prestado su tiempo y por sus valiosos comentarios y aportes, que han sido de gran ayuda. Le agradezco además especialmente el haberme puesto en contacto con el Dr. Manuel Á. Valbuena Rabadán y por haber intercedido para obtener los datos del Cuarto Inventario Forestal Nacional.

Al Dr. Manuel Ángel Valbuena Rabadán, que desinteresadamente aceptó colaborar en este trabajo, invirtiendo su tiempo y cuyos conocimientos han sido muy valiosos para mí.

A D. Wilson Lara Henao por su tiempo y ayuda con las rutinas de R, que han sido esenciales para concluir este estudio.

A D. Roberto Vallejo Bombín, por haberme facilitado los datos de inventario del Cuarto Inventario Forestal Nacional en La Rioja, sin los cuales no habría sido posible este trabajo.

Al Dr. Valentín Pando Fernández, profesor del departamento de Estadística e Investigación Operativa de la E.T.S.I.I.A.A. de Palencia, por haberme prestado su ayuda en la estadística de este trabajo. Tus aportes han sido muy valiosos para mí.

Al personal de la Dirección General del Medio Natural, especialmente a D. Jesús Laría Llorente, D. Juan Francisco Martínez Rodríguez, D. David Bengoa Martínez de Mandojana, D. Ignacio Tejedor de la Asunción, Dña. Esther Prieto Lezaun, Dña. Yolanda Delgado Pérez, D. José Antonio Ruiz de los Ríos, Dña. Miriam Soto Rey, D. Juan Ignacio Ibáñez Ulargui, D. José Lorenzo Mendieta Henville, D. Félix Manuel Pinillos Herrero, D. Hector Alonso Martínez y Dña. Leire Serna García, por haberme dedicado su tiempo y haberme facilitado los datos de las edades de las repoblaciones de laricio, ya que sin ellos no habría podido llevar a cabo este trabajo.

Al Dr. Javier Becerra Elcinto y a D. Luis Armando Rodríguez, por haberme dado todas las facilidades y el tiempo que he necesitado para poder concluir este trabajo.

Finalmente, a mis padres y a mi hermano por haberme apoyado en todo momento de manera incondicional.

