



Diseño y contraste de nuevos modelos de estimación del potencial energético de biomasa forestal en el Territorio de Bizkaia mediante técnicas de análisis estadístico espacial usando herramientas GIS con datos LIDAR

Tesis Doctoral presentada por

Leyre Torre Tojal

bajo la dirección del

Dr. Javier M^a Sánchez Espeso

ÁREA DE INGENIERIA CARTOGRÁFICA, GEODESIA Y FOTOGRAMETRÍA

Santander, enero 2016

A mis raíces, mis aitas.

A mi presente, Iban.

A mi futuro, mi sol de invierno, Libe.

Quiero dar las gracias a mi familia, por estar siempre ahí, por ser mi punto de referencia, mi norte, mi todo. Gracias por haberme acompañado en los malos y buenos momentos que han acontecido en el transcurso de este trabajo.

Mi más sincero agradecimiento al director de esta tesis, Javier M^a Sánchez Espeso, por su apoyo y dedicación, por su implicación y por compartir sus vastos conocimientos conmigo. Gracias por creer en mí.

Agradecer a la UPV/EHU las facilidades dadas para la realización de este trabajo, incluyendo la concesión de licencias que han permitido una descarga parcial de mis obligaciones docentes que me ha permitido volcarme en este trabajo.

Quisiera agradecer al Servicio de Cartografía del Gobierno Vasco por su buen hacer y su entera disponibilidad, muy en especial a Ion Mtz. de Ilarduya por haber estado pendiente de mis peticiones en todo momento.

Quiero agradecer a Manuel Ángel Valbuena su implicación en este proyecto, su ayuda completamente desinteresada y su tiempo. Gracias por haberme enseñado tanto.

Agradecer a Ismael Barbero sus lecciones de estadística, su actitud siempre positiva y el tiempo desinteresadamente invertido en este proyecto.

Por último, pero no por ello menos importante, agradecer a mis compañeros/as de la sección de Topografía y a Ana Boyano del Departamento de Mecánica de la Escuela de Ingeniería de Vitoria-Gasteiz, que se han volcado en que este trabajo llegara a buen puerto. Gracias por su valiosísima ayuda, su apoyo técnico y sobre todo su apoyo moral en los peores momentos.

Listado de acrónimos

American Society for Photogrammetry and Remote Sensing	ASPRS
Comunidad Autónoma del País Vasco	CAPV
Comunidad Autónoma	CCAA
European Datum 50	ED50
Error Estándar	ES
Estaciones Totales (ET)	ET
Enhanced Thematic Mapper	ETM+
European Terrestrial Reference System 1989	ETRS 89
Geoscience Laser Altimetry System	GLAS
Global Positioning System	GPS
Proceso Gaussiano	GPS
Infraestructura de datos Espaciales	IDE
Distancia inversa ponderada	IDW
Cuarto Inventario Forestal Nacional	IFN4
Unidad de Medición Inercial	IMU
Interferometric Synthetic Aperture Radar	INSAR
Intergovernmental Panel of Climate Change	IPCC
Light Detection and Ranging	LiDAR
Asistida por el modelo	MA
Dependiente del modelo	MD
Modelo de Altura del Dosel	MDAD
Modelos Digitales de Elevaciones	MDE
Modelo Digital de Superficie	MDS
Modelo Digital del Terreno	MDT
Ministerio de Medio Ambiente	MIMA
Landsat Multispectral Scanner	MSS
Frecuencia de pulsos láser	PFR
Plan Nacional de Ortofotografía aérea	PNOA
error medio cuadrático elevado	RMSE
Sistemas de Información Geográfica	SIG
Scanning Lidar Imager of Canopies by Echo Recovery	SLICER
Shuttle Radar Topography Mission	STRM
Maquinas de Soporte Vectorial	SVM
Red de Triángulos Irregulares	TIN
Thematic Mapper	TM

Resumen

El objetivo de esta tesis doctoral es desarrollar un modelo que permita estimar la biomasa aérea para la especie *Pinus radiata* D. Don en la comarca de Arratia-Nervión, situada en Bizkaia, a partir del uso exclusivo de los datos del vuelo LiDAR realizado por Gobierno Vasco en 2012. Más del 23% de la población total de esta especie en la CCAA se encuentra en la comarca de Arratia Nervión, siendo además la especie más abundante.

En el proceso, se han utilizado los datos de campo del Inventario Forestal Nacional 4 como base para estimar la biomasa de contraste. Partiendo de las nubes de puntos LiDAR y tras su procesado, se han calculado diversas métricas provenientes de las mismas que se consideran como variables predictivas, entre ellas variables directamente relaciones con la altura y variables relacionadas con la densidad del dosel. Para la consecución del modelo, se ha aplicado la técnica de análisis estadístico de la regresión lineal múltiple.

El resultado obtenido ha revelado que el mejor modelo depende de dos variables: un parámetro directamente relacionado con la altura LiDAR y otro con la densidad del dosel. El modelo consigue explicar el 76% de la variabilidad del mismo con un error estándar que asciende a 0.26 ton/ha en unidades logarítmicas.

LISTADO DE FIGURAS	8
LISTADO DE TABLAS	10
1. INTRODUCCIÓN	11
2. OBJETIVOS	17
3. ANTECEDENTES	19
3.1. CARACTERIZACIÓN DE LA TECNOLOGÍA LIDAR EN EL ÁMBITO FORESTAL	20
3.2. PARÁMETROS VUELO LIDAR	23
3.2.1. DIVERGENCIA LÁSER	24
3.2.2. DIÁMETRO DE LA HUELLA LÁSER	24
3.2.3. ÁNGULO DE ESCANEADO	26
3.2.4. ALTITUD DE VUELO	26
3.2.5. FRECUENCIA DE PULSOS LÁSER (PRF)	27
3.2.6. DENSIDAD DE PUNTOS	27
3.3. FORMACIÓN DE PRODUCTOS CARTOGRÁFICOS DERIVADOS DE DATOS LIDAR	28
3.3.1. ALMACENAMIENTO DE LA NUBE DE PUNTOS	28
3.3.2. MODELO DIGITAL DEL TERRENO	30
3.3.3. MODELO DIGITAL DE SUPERFICIE	34
3.3.4. IMAGEN DE INTENSIDADES	35
3.4. DETERMINACIÓN DE LA BIOMASA	36
3.4.1. CÁLCULO DE BIOMASA UTILIZANDO ECUACIONES ALOMÉTRICAS EN FUNCIÓN DE VARIABLES DASOMÉTRICAS	36
3.4.2. CÁLCULO DE BIOMASA EN BASE A DATOS LIDAR	38
4. MATERIALES Y MÉTODOS	46
4.1. ZONA DE ESTUDIO Y MATERIAL	47
4.1.1. ZONA DE ESTUDIO	47
4.1.2. ESPECIE ARBÓREA ANALIZADA: PINO RADIATA	50
4.1.3. DATOS DE CAMPO	53
4.1.4. DATOS LIDAR	58
4.1.5. ORTOFOTOS	60
4.1.6. SOFTWARE UTILIZADO	61
4.2. PREPARACIÓN Y ANÁLISIS DE LOS DATOS	63
4.2.1. OBTENCIÓN DE LOS VALORES DE BIOMASA DE REFERENCIA	63
4.2.2. OBTENCIÓN DE MÉTRICAS EN BASE A LOS DATOS LIDAR	69
4.3. AJUSTE DE LOS MODELOS	82

5. RESULTADOS Y DISCUSIÓN	85
5.1. MODELOS DE REGRESIÓN PARA LA EVALUACIÓN DE LA BIOMASA	86
5.2. VALIDACIÓN DEL MODELO	121
5.3. COMPROBACIÓN DEL POSICIONAMIENTO DE LAS PARCELAS DE CAMPO	122
5.4. DISCUSIÓN	124
6. CONCLUSIONES	131
7. FUTURAS LÍNEAS DE INVESTIGACIÓN	133
8. BIBLIOGRAFÍA	135
9. ANEJOS	142
ANEJO I	143
ANEJO II	154
ANEJO III	168

LISTADO DE FIGURAS

Fig. 1 Simulación de la influencia de los factores naturales y antropogénicos en el incremento de temperatura. Fuente: IPCC, 2001	12
Fig. 2 . Esquema conceptual simplificado de funcionamiento del sistema LiDAR. Fuente: SRM Consulting	21
Fig. 3 Componentes láser escáner aerotransportado (Imagen Litte-Mapper). Fuente: IGI mbH	22
Fig. 4 Diferencias entre medición de retorno discreto y onda completa. Fuente: ASPRS	22
Fig. 5 Esquemas de escaneo. Fuente: SRM Consulting	23
Fig. 6 Diámetro de la huella láser	25
Fig. 7 Relación básica entre la altura, ángulo de escaneado y ancho de la pasada	26
Fig. 8 Datos de una parcela de control, clasificación por alturas	30
Fig. 9 Datos de una parcela de control, clasificación por categorías según la ASPRS	30
Fig. 10 Datos de una parcela de control filtrados a clase terreno (2) para la formación del MDT	32
Fig. 11 MDT para una parcela de control, modelizado como un ráster	33
Fig. 12 MDS correspondiente a una parcela de control	35
Fig. 13 Imagen de intensidades	36
Fig. 14 Mapa de situación de la zona de trabajo en la C.A.P.V.	47
Fig. 15 MDT de la comarca Arratia-Nervión	48
Fig. 16 Mapa de pendientes de la comarca deArratia-Nervión	49
Fig. 17 Distribución del Pino Radiata en la C.A.P.V. Fuente: IFN4	51
Fig. 18 Distribución de Pino Radiata en Arratia-Nervión según IFN4	53
Fig. 19 Mapa de distribución de las parcelas del IFN4 en Bizkaia	57
Fig. 20 Sensor láser escáner Litte Mapper 6800	58
Fig. 21 Distribución de las hojas de datos LiDAR en la C.A.P.V..	60
Fig. 22 Cliente gráfico de PostgreSQL	62
Fig. 23 Interface gráfica de R	62
Fig. 24 Interface gráfico de FME 2015.0	63
Fig. 25 Distribución 63 parcelas seleccionadas del IFN4 con ArcGis	64
Fig. 26 Resultado del índice I de Moran para la biomasa, la altura de árbol y el número de árboles	68
Fig. 27 Biomasa observada en las 63 parcelas	68
Fig. 28 Distribución de la densidad de punto por m ²	70
Fig. 29 Densidad por parcela de 50m de lado teniendo en cuenta todos lo retornos	71
Fig. 30 Densidad según parcela de 50m de lado teniendo en cuenta todos los retornos correspondientes a las clases 2, 4 y 5	72
Fig. 31 Flujo de trabajo desarrollado en FUSION	73
Fig. 32 Parcela 0443 clasificada según el estándar ASPRS, circular de 25m de radio	75
Fig. 33 MDT correspondiente a la extensión aproximada de la parcela de 1m de tamaño de píxel	76
Fig. 34 Parcela 0443. Modelo digital de superficies, de 1m de tamaño de píxel	77
Fig. 35 Parcela 0443. Modelo Digital de Alturas del Dosel, de 1m de tamaño de píxel	77
Fig. 36 Representación del movimiento simulado de la parcela 0443	80
Fig. 37 Ejemplo de métricas obtenidas con PostGIS	82
Fig. 38 Matriz de dispersión entre la biomasa y todas las variables	97
Fig. 39 Matriz de dispersión	112
Fig. 40 Gráficos de dispersión entre los residuos y los valores ajustados	115
Fig. 41 Gráfico QQ de los residuos	116
Fig. 42 Biomasa estimada en las 55 parcelas	119

<i>Fig. 43 Biomasa observada en las 55 parcelas</i>	<i>120</i>
<i>Fig. 44 Histograma de los residuos transformados obtenidos en el ajuste</i>	<i>124</i>
<i>Fig. 45 Diagramas de dispersión entre las variables explicativas del modelo y la Biomasa observada en campo</i>	<i>125</i>
<i>Fig. 46 Diagrama de dispersión entre el diámetro de inventario y la biomasa estimada</i>	<i>127</i>

LISTADO DE TABLAS

Tabla 1 Clasificación aplicada por Gobierno Vasco	29
Tabla 2 Balance global <i>Pinus Radiata</i> C.A.P.V.. Fuente: Montero et al., 2005	50
Tabla 3 Existencias de Pino radiata en la C.A.P.V.. Fuente: IFN4	51
Tabla 4 Distribución Pino Radiata en la comarca Arratia-Nerviión. Fuente: IFN 4	52
Tabla 5 Estratos definidos en Bizkaia según el mapa forestal	55
Tabla 6 Parámetros del vuelo LiDAR	58
Tabla 7 Factores de expansión	64
Tabla 8 Detalle del proceso de obtención de biomasa para la parcela 0443	65
Tabla 9 Datos generales	69
Tabla 10 Resultado del filtrado de puntos para la hoja 518_4764	74
Tabla 11 Resultados detallados del filtro obtenidos para la hoja 518_4764	74
Tabla 12 Listado de métricas obtenidas con FUSION	78
Tabla 13 Matriz de correlación entre la biomasa observada y cada una de las métricas obtenidas (* no significativa)	86
Tabla 14 Matriz de correlación entre la transformación logarítmica de la biomasa observada y cada una de las métricas obtenidas (* no significativa)	87
Tabla 15 Valor de SE y R^2 obtenido en modelos con una sola variable explicativa	98
Tabla 16 Resumen de los mejores modelos combinando variables dos a dos	100
Tabla 17 Matriz de correlación entre la biomasa observada y cada una de las métricas obtenidas (* no significativa)	101
Tabla 18 Matriz de correlación entre la transformación logarítmica de la biomasa observada y cada una de las métricas obtenidas (* no significativa)	102
Tabla 19 Resumen de modelos con una sola variable explicativa	112
Tabla 20 Resumen de mejores modelos	114
Tabla 21 Biomasa estimada aplicando el modelo desarrollado.	117
Tabla 22 Comparación modelos	120
Tabla 23 Resultado de la validación	122
Tabla 24 Coeficientes de concordancia Cohen-Kappa entre la parcela original y las creadas en las 8 direcciones	123
Tabla 25 Valoración del coeficiente Kappa según Landis y Koch	123

1. INTRODUCCIÓN

La convención marco de las Naciones Unidas sobre el cambio climático, en la que se basó el Protocolo de Kioto, reconoce en su primer párrafo que los cambios observados en el clima de la Tierra y sus efectos adversos se han convertido en una preocupación común de toda la humanidad. El incremento sustancial de las concentraciones de gases de efecto invernadero en la atmósfera provocará un calentamiento adicional de la superficie y la atmósfera de la Tierra que pueden afectar negativamente a los ecosistemas naturales y a la humanidad. Por lo que la estabilización de las concentraciones de gases de efecto invernadero en la atmósfera a un nivel que impida interferencias antropógenas peligrosas en el sistema climático se convierte en el objetivo principal (Naciones Unidas 1992).

El Intergovernmental Panel of Climate Change (IPCC) demostró que el clima de la tierra había variado tanto a escala global, como regional, y que parte de esos cambios eran atribuibles a actividades humanas (Intergovernmental Panel of Climate Change 2001). Comprobaron que al utilizar un modelo para simular el cambio de temperatura a escala global debido a causas naturales y antropogénicas, se observaba que la inclusión de los factores antropogénicos explicaba una parte substancial del cambio observado en la temperatura durante el siglo pasado (Fig. 1).




Fig. 1 Simulación de la influencia de los factores naturales y antropogénicos en el incremento de temperatura. Fuente: IPCC, 2001

Entre los gases de efecto invernadero, el más importante es el CO₂, cuyas concentraciones atmosféricas se han alterado gravemente a consecuencia de las perturbaciones causadas por el hombre en el ciclo mundial del carbono. Actualmente la concentración de CO₂ es de aproximadamente 370 ppmv (partes por millón en volumen), más elevada que en cualquier momento de los 420 000 años anteriores. Estas perturbaciones han sido de naturaleza directa e indirecta. En el primer grupo y de carácter más relevante, se encuentran la adición de nuevo carbono al ciclo mundial del carbono mediante quema de combustibles fósiles y la modificación de la estructura y distribución de la vegetación supone un 20% de las emisiones totales de CO₂. La deforestación es la que produce mayores efectos en el ciclo del carbono, supone un 20% de las emisiones totales de CO₂, al perder la capacidad fotosintética de la vegetación forestal eliminada y la liberación simultánea de grandes cantidad de carbono acumuladas en los ecosistemas forestales durante largos períodos de tiempo.

El desarrollo sostenible de la silvicultura puede contribuir en gran medida a mitigar el cambio climático a largo plazo, porque por un lado, evita la introducción de nuevo carbono en su ciclo activo, y por otro lado, suministra bienes y servicios a la sociedad. En la mayoría de los países europeos y norte de América, el volumen de la madera aprovechada anualmente es menor que el crecimiento anual de los bosques, por lo que el papel de los bosque como sumideros de CO₂ es cada vez más relevante.

Una parte importante del ciclo del carbono está relacionado con la cantidad de éste que queda retenido en la biomasa, y que posteriormente se intercambiará de manera natural con la atmósfera. La biomasa de la vegetación leñosa se define como la cantidad total de materia orgánica viva que existe por encima del suelo (incluyendo hojas, varas, ramas, fuste y corteza) expresada como peso anhidro (seco en estufa) en toneladas por unidad de área (Brown 1997). Por lo que una adecuada determinación de la biomasa forestal es primordial para poder determinar la cantidad de carbono y otros elementos existentes en las diferentes partes del árbol. Actualmente, aproximadamente las tres cuartas partes de las perturbaciones directas causadas por el hombre al ciclo mundial de carbono se deben a la quema de combustible fósil, cuyas emisiones superan actualmente 6 Gt C/año (gigatonnes de carbono por año) y siguen aumentando. No obstante, desde mediados del siglo XIX, la adición acumulativa de CO₂ antropogénico a la atmosfera por el cambio en la utilización de la tierra ha sido casi tan elevada (~156 Gt C) a la ocasionada por el uso de combustible fósil (~280 Gt C/ año) y continua siendo una importante emisión antropógena (~2,2 Gt C/ año)(Houghton 2003).

A partir de la cuantificación de la biomasa seca de una especie arbórea, se calcula la cantidad de CO₂ que almacena. Se estipula, que ante la ausencia de datos específicos, todas las maderas contienen, aproximadamente, un 50% de carbono (Intergovernmental Panel on Climate Change 1996). Mediante la proporción entre el peso de la molécula de dióxido de carbono y el peso del átomo del carbono, se obtendrá la relación que se aplicará para convertir los kg de CO₂ equivalente a partir de la cantidad de carbono presente en la biomasa ($44/12=3.67$). Por lo que, multiplicado el valor de biomasa por el contenido en carbono y por la relación anteriormente descrita se obtendrán los valor de dióxido de carbono acumulado.

Dentro de las estrategias de reducción de CO₂ relacionadas con el ámbito forestal se pueden diferenciar tres actuaciones fundamentales: conservación, gestión sostenible y reforestación

de la masa forestal (Montero, Alonso, Ruiz-Peinado 2002). Pero el comienzo para la efectiva aplicación de estas tres acciones implica, primero, cuantificar la biomasa para estimar posteriormente, la cantidad de Carbono secuestrado ó almacenado en la biomasa, hasta que éste retorne nuevamente a la atmósfera.

Tradicionalmente, y también en la actualidad, las estimaciones de biomasa se han realizado por 2 métodos principales: métodos directos e indirectos. Los métodos directos o destructivos, implican la corta de individuos para el posterior pesado de los fustes, ramas y hojas directamente, determinando posteriormente su peso seco (Montero, Ruiz-Peinado, Muñoz 2005).

Los métodos indirectos abogan por no destruir material y se apoyan en datos ya inventariados. Los datos comúnmente adquiridos son el diámetro del tronco a la altura del pecho (1.3 m) y la altura de los árboles situados en las parcelas de muestra, para poder, después, calcular volúmenes, áreas basimétricas y demás variables que en muchas ocasiones también aparecen inventariados. Dentro de los métodos indirectos se pueden dar diferentes aproximaciones: la primera partiría de datos de volumen de madera con corteza (m^3/ha) ya inventariados a los que se aplicarían factores de expansión de la biomasa. El factor de expansión es el ratio entre la biomasa aérea total y la biomasa del fuste y se suelen aplicar cuando no hay información detallada de un inventario forestal para las distintas variables que caracterizan a cada árbol. Una vez obtenida la cantidad de biomasa húmeda como el producto del volumen inventariado por el factor de expansión, quedaría calcular la cantidad de biomasa seca, que se obtendría al multiplicar la cantidad de biomasa húmeda por la densidad promedio específica de las especies (Brown 1997).

Otra aproximación sería la aplicación de la técnica de análisis estadístico de regresión en base a las variables más comunes obtenidas en los inventarios forestales: diámetro a la altura del pecho, altura de árbol, altura dominante ó área basal (Canga et al. 2013). Se basaría en el principio de alometría, según el cual a escala de una población existe una relación estadística entre la diferentes medidas de un individuo (Gould 1966), que permite predecir una medida de un árbol (biomasa) en función de otra medida (por ejemplo, diámetro). Todos los árboles que viven en las mismas condiciones obedecerán la misma regla, desde el más pequeño al más grande.

Pero uno de los principales inconvenientes de los inventarios forestales es que se trata de un proceso que conlleva una gran inversión de tiempo y dinero, tanto más, cuanto más extensa sea la zona a inventariar, pero que como se ha documentado son una fuente necesaria de datos.

Para paliar estas carencias, se han desarrollado y usado técnicas basadas en Teledetección, que permiten la obtención de datos de manera rápida y precisa en zonas extensas (Johansen, Phinn, Witte 2010). Como metodología alternativa, cada vez se está usando con mayor frecuencia, el LiDAR (Light Detection and Ranging) aerotransportado, que de hecho se ha convertido en una herramienta efectiva y precisa para la caracterización del dosel forestal. Esta metodología que se basa en la emisión de un láser embarcado en un avión o helicóptero barre la superficie terrestre registrando rebotes de cualquier elemento que encuentra en su

trayectoria, que supone el registro de inmensas nubes de puntos georreferenciadas que permitirán caracterizar el dosel vegetal.

Este tipo de sensores aerotransportados están proporcionando exitosamente variables forestales relacionadas con la estructura de la masa como la altura media, altura dominante ó el diámetro medio (Nelson, Krabill, MacLean 1984; Nilsson 1996; Næsset 2002). Si clásicamente se ha determinado la biomasa por correlación con variables forestales, y la tecnología LiDAR es capaz de predecir las mismas; la búsqueda de metodologías capaces de predecir directamente la biomasa a partir de los datos LiDAR ha surgido como la evolución lógica.

En esta línea indicar que la cuantificación de la biomasa ha inquietado a numerosos autores, que utilizando diferentes tipo de sensores láser (discreto y de onda completa), diferentes enfoques metodológicos, y en ocasiones combinando con otras fuentes de datos, han sido capaces de desarrollar modelos que, previamente apoyados en mediciones realizadas en campo, consiguen predecir la biomasa con distintos grados de exactitud.(Condés and Riaño 2005; Lefsky et al. 1999; Næsset 2011; Næsset and Gobakken 2008). Una metodología ampliamente utilizada ha sido el uso de técnicas estadísticas para correlacionar variables, en particular la regresión lineal múltiple, en la que métricas obtenidas de la nube de puntos LiDAR, tales como percentiles de altura, métricas sobre densidad de vegetación, etc... son relacionadas con valores de biomasa, que se han obtenido bien directamente, medidos en lentas y costosas campañas de campo, o bien se han obtenido indirectamente a partir de datos forestales realizados en campañas sistemáticas, en particular en España usando el Inventario Forestal Nacional.

El objetivo de este trabajo es desarrollar un modelo, utilizando como análisis estadístico la regresión lineal múltiple que relacione la biomasa estimada a partir de medidas de campo en el Cuarto Inventario Forestal Nacional (IFN4) y diversas métricas obtenidas a partir de la nube de puntos LiDAR. Para ello se ha utilizado el vuelo LiDAR realizado por el Gobierno Vasco en 2012, dentro del Plan Nacional de Ortofotografía Aérea que tiene como objetivo la obtención de ortofotografías aéreas digitales con resolución de 25 ó 50 cm y Modelos Digitales de Elevaciones (MDE) de alta precisión de todo el territorio español, con un período de actualización de 2 ó 3 años. Éste vuelo posee una baja densidad de pulso de 0.5 ptos/m², que pudiera ser insuficiente para determinadas aplicaciones, se pretende comprobar la idoneidad de la densidad de punto para la estimación de la biomasa de la especie *Pinus radiata* D. Don en la comarca de Arratia-Nerviión, ubicada al sur de Bizkaia. Para ello, aparte de contar con las métricas obtenidas por un software comercial especializado en tratamiento de datos LiDAR, se implementará un algoritmo que permitirá calcular nuevas métricas de densidades sobre el dosel que han demostrado ser significativas en modelos desarrollados por otros autores (Gobakken et al. 2012b; Naesset and Økland 2002; Næsset 2011; Næsset and Gobakken 2008). Posteriormente, se aplicará la técnica de la regresión lineal múltiple para estimar el modelo óptimo.

En la línea anteriormente expuesta, en la presente investigación se propone la obtención de la biomasa aérea para una masa forestal concreta, correspondiente a la especie *Pinus radiata* D.

Don, en principio en el ámbito de la CCAA del País Vasco, usando datos procedentes de bases de datos abiertas y públicas, cuya continuidad temporal está garantizada:

- Como fuente de datos básica se usará el vuelo LiDAR que se realiza en el marco del Plan Nacional de Ortofotografía aérea (PNOA), compartido entre el Estado y las CCAA. No es un vuelo LiDAR específico para esta finalidad, pero su persistencia temporal justifica su elección. Los últimos vuelos disponibles se caracterizan por una densidad de 0.5 puntos por metro cuadrado.
- La calibración del modelo se realizará a partir de los datos forestales básicos que proporciona el último IFN, correspondiente al año 2011, denominado IFN4.

Se planteará el desarrollo de una metodología altamente automática, que permita la actualización de los resultados de la biomasa analizada al disponer de nuevos datos, bien un nuevo vuelo LiDAR, bien un nuevo IFN; utilizando herramientas o entornos de trabajo libres, sin restricciones comerciales.

2. OBJETIVOS

El objetivo principal de esta investigación es la determinación de un modelo capaz de predecir la biomasa aérea para la especie *Pinus Radiata* en la comarca de Arratia-Nervi6n en la CAPV, en base al uso de datos LiDAR de baja densidad, dise1nando un proceso altamente autom1tico.

De esta forma se podr3a obtener una estimaci6n de la biomasa, que juega un papel fundamental tanto medio ambiental como econ6mico, de forma masiva en todo el territorio auton6mico usando bases de datos existentes y cuya continuidad temporal parece garantizada, en particular:

- Datos dasom6tricos de los sucesivos inventarios forestales nacionales.
- Datos LiDAR del Plan Nacional de ortofotograf3a a6rea, con periodicidades cada 2 o 4 a1os, o incluso menores en la CAPV.

No ser3a preciso en consecuencia la realizaci6n de captura de informaci6n espacial espec3fica para este objetivo, con la consiguiente econom3a.

Para la consecuci6n del objetivo enunciado, se plantean los siguientes objetivos parciales:

- Desarrollo y automatizaci6n de los procesos precisos destinados a la obtenci6n de m6tricas caracter3sticas de la masa arb6rea, usando entornos libres de manejo de informaci6n espacial.
- Obtenci6n de la biomasa para las parcelas de control a partir de los datos del 6ltimo IF, por aplicaci6n del mejor modelo alom6trico disponible.
- Selecci6n de variables, formulaci6n obtenci6n del mejor modelo de ajuste, usando regresi6n lineal m6ltiple.
- Validaci6n de la bondad del modelo.

3. ANTECEDENTES

3.1. Caracterización de la tecnología LiDAR en al ámbito forestal

Desde su invención a comienzos de los años 60, la evolución en la medición electrónica de distancias del láser ha sido determinante en el campo de la Geomática. El origen lo constituyen los primeros modelos de teodolitos electrónicos, que permitían medir distancias electrónicamente, y los cuales se convertirían en lo que hoy conocemos como Estaciones Totales (ET), al conseguir integrar la medición electrónica de distancias con las de ángulos. Sin duda la revolución vino de la mano de la ET motorizada, con posibilidad de movimiento autónomo. La evolución lógica ha sido imparable: ET robotizada, puntería automática, seguimiento automático de la puntería, uso del láser sin necesidad de reflector,... El incremento en la capacidad de observación, en número de puntos y ámbito de trabajo, ha dado lugar a los escáneres de distancias, en sus distintas modalidades, en particular en el campo de la Geomática: escáner terrestre, escáner lineal y escáner aerotransportado. Este último va montado en un avión o helicóptero, denominándose genéricamente LiDAR, que requerirá además de dispositivos específicos complementarios que permitan la georreferenciación de los datos.

Los primeros trabajos desarrollados sobre medición de distancias con láser aerotransportado, eran capaces de medir perfiles continuos del terreno (Miller 1965; Sheperd 1965), pero no servían para mediciones de una zona extensa del terreno. Dicha limitación se superó con la integración de mecanismos de escaneo, que permitiesen aumentar la zona cubierta por el sensor. Esta circunstancia aumentó significativamente los ámbitos de aplicación de esta metodología.

La tecnología LiDAR (Light Detection and Ranging) constituye un sistema activo de medición masiva de de posiciones de forma remota, basado en un sensor de barrido láser (región espectral del infrarrojo) que emite pulsos y registra los retornos contra la superficie. Cuando este sensor se ubica en un avión ó en un helicóptero, se denomina LiDAR aerotransportado como se ha indicado.

El LiDAR aerotransportado permite obtener una gran densidad superficial de medidas y con buenas precisiones altimétricas que dependen de las características del sensor, del vuelo efectuado y del sistema de orientación absoluta empleado, pudiéndose obtener actualmente de forma típica precisiones en torno a los 15cm, lo que le convierte sin duda en una potente metodología de adquisición de datos.

El sistema de medida del LiDAR se basa en el tiempo de respuesta obtenido para cada rebote, desde su emisión hasta su recepción en el sensor, una vez reflejado contra una superficie. Conocida la velocidad de la luz y el tiempo transcurrido, es inmediato conocer la distancia a la que se encuentra el objeto que ha generado el rebote, por lo que si se conoce el ángulo de apuntamiento (*pointing*) del láser en el momento de la medición, se podrá obtener coordenadas X,Y,Z de los objetos reflejados.




Fig. 2 . Esquema conceptual simplificado de funcionamiento del sistema LiDAR. Fuente: SRM Consulting

Un equipo LiDAR está formado esencialmente por:

1. Una unidad de medición de distancia, incluyendo sus transmisores y receptores ópticos.
2. Un mecanismo óptico de escaneo, como por ejemplo, un espejo rotatorio que permite el barrido del terreno.
3. Una unidad electrónica que comprende varios elementos de hardware que permiten funciones de control y proceso de todo el sistema.
4. Un software que se encargue de controlar y coordinar las operaciones de cada uno de los principales elementos del sistema y lleva a cabo el registro, almacenamiento y procesamiento preliminar de los datos medidos.
5. Un sistema de posicionamiento y orientación compuesto por un receptor Global Position System (GPS) y una Unidad de Medición Inercial (IMU).
6. Un dispositivo de captura de imagen, como por ejemplo una cámara digital o una videocámara.



Fig. 3 Componentes láser escáner aerotransportado (Imagen Litte-Mapper). Fuente: IGI mbH

La medición de distancias se puede efectuar según dos tecnologías: en modo de onda completa (full waveform) o registrando retorno discretos. En el primer caso, el sensor digitaliza la señal de retorno completa durante un intervalo de tiempo. En el segundo, el sensor registra los diferentes ecos del rayo al interceptar parcialmente el haz láser diferentes objetos en su trayectoria, si existen. Hoy en día existen equipos LiDAR que recogen un número elevado de retornos, aunque lo más habitual es registrar un máximo de 6 ecos.




Fig. 4 Diferencias entre medición de retorno discreto y onda completa. Fuente: ASPRS

Dentro de los dispositivos óptico mecánicos de escaneo se pueden encontrar dispositivos de refracción y de reflexión. Dado que los primeros no son habitualmente utilizados en la topografía aerotransportada, nos ceñiremos a los de reflexión. Se utilizan espejos oscilantes, que rotando hacia adelante y hacia atrás, barren extensas zonas de terreno. Los diferentes mecanismos de escaneo producirán diferentes patrones de escaneo, como se observa a continuación.




Fig. 5 Esquemas de escaneo. Fuente: SRM Consulting

Un componente clave del sistema lo constituye el sistema de posicionamiento y orientación, que proporciona la orientación absoluta del haz láser, y que está compuesto por un GPS diferencial y una IMU. Para garantizar las mejores precisiones, es necesario contar con estaciones de referencia en tierra. Para registrar la actitud, se emplea un sistema IMU, que suele ir montado lo más cerca posible del escáner.

3.2. Parámetros vuelo LiDAR

Un vuelo LiDAR queda caracterizado por una serie de parámetros que definen la precisión y cobertura de la nube de puntos capturada. A continuación se exponen los valores relevantes empleados en los vuelos LiDAR en la bibliografía consultada.

3.2.1. Divergencia láser

La divergencia láser (γ) describe el ángulo de apertura que sufre el rayo láser desde su emisión hasta su impacto contra la superficie.

$$\gamma = 2.44 \frac{\lambda}{D} \quad (1)$$

donde λ se refiere a la longitud de onda del pulso láser

La divergencia láser recomendada en aplicaciones forestales es estrecha (0.1-0.6mrad), ya que es un factor muy influyente junto a la altura de vuelo, al acondicionar el tamaño de la huella láser. En el caso de una láser volando a una altitud de 1000m con una divergencia del mismo de 0.3 mrad, supone un tamaño de huella de 30 cm aproximadamente. El hecho de que la divergencia sea pequeña, también permite alturas de vuelo superiores, sin que el tamaño de la huella aumente drásticamente (Laes et al. 2008).

3.2.2. Diámetro de la huella láser

Se define como el diámetro del cono al proyectar el rayo láser sobre la superficie. Este parámetro es función directa de la divergencia del haz y de la altura de vuelo (Baltsavias 1999):

$$A_L = D + 2h \tan\left(\frac{\gamma}{2}\right) \quad (2)$$

donde D es la apertura del láser y γ la divergencia del rayo. Pero al ser el valor de D pequeño:

$$A_L = 2h \tan\left(\frac{\gamma}{2}\right) \quad (3)$$

y al ser γ (en radianes) muy pequeño, finalmente:

$$A_L = h\gamma \quad (4)$$




Fig. 6 Diámetro de la huella láser

De modo que, para cada 100 m de altura de vuelo, el tamaño de la huella es 1/10 de la divergencia del rayo láser (en mili radianes).

Pese a que hay diferentes estudios que han demostrado los buenos resultados del LiDAR de huella grande (decenas de metros) en aplicaciones forestales (Lefsky et al. 1999; Means et al. 1999) y se han evidenciado sus ventajas tales como mayor facilidad para localizar el ápice del árbol, o la posibilidad de volar extensas zonas de masa forestal, la capacidad del LiDAR de huella pequeña para obtener métricas individuales para cada árbol, y la obtención de modelos del terreno de alta precisión, han conseguido consolidarlo como el preferido en el ámbito forestal (Evans, Roberts, Parker 2006).

Se recomienda utilizar un valor de huella pequeña, por diversos motivos:

- El aumento de la divergencia del rayo supone un mayor tamaño de huella, degradando la precisión de apuntamiento (*pointing*) (Bin et al. 2008).
- El efecto de la variabilidad de ecos debido a la estructura vertical del objetivo afecta a la precisión de la distancia (Baltsavias 1999).
- Diversos autores han constatado que tanto la componente sistemática como la aleatoria en el error de la determinación de la altura de árbol, crecen cuando aumenta la divergencia del rayo, (.Andersen, Reutebuch, McGaughey 2006).

Un valor apropiado de la huella en aplicaciones forestales se suele fijar en torno a los 20cm, ya que aporta más información sobre el follaje y tiene más precisión en la determinación de la distancia (White et al. 2013).

3.2.3. Ángulo de escaneado

Se trata del ángulo transversal al eje de vuelo (θ), en función del cual el láser cubre o barre una determinada área.




Fig. 7 Relación básica entre la altura, ángulo de escaneado y ancho de la pasada

En principio, el valor recomendado en aplicaciones forestales para el ángulo de escaneado se encuentra sobre los 12° (White et al. 2013).

Por otra parte, no se constata una influencia apreciable de este parámetro en la confección del Modelo Digital de Elevaciones (MDE) ó del Modelo de Altura del Dosel (MDAD). Pese a que el ángulo de escaneado no influye de manera determinante en los percentiles de alturas, sí puede apreciarse cierta influencia del tamaño de la corona de los árboles en los puntos *off-nadir*, siendo más evidente cuanto mayor es el tamaño de la corona. La densidad de la masa forestal también es un factor que puede hacer variar los percentiles de las alturas tanto por exceso, como por defecto, debido a la sombra de los árboles colindantes en función del ángulo de escaneado (Holmgren, Nilsson, Olsson 2003).

3.2.4. Altitud de vuelo

La altitud del vuelo influye en la subestimación de la altura de los árboles, aumentando ésta cuanto más se incrementa la altura, más subestimación mayor cuanto más se incrementa la altura, incrementándose también su desviación estándar. Esta circunstancia tampoco es igual en todas las especies. El aumento de la altura de vuelo también implica que decrezca la densidad de árboles detectados, decreciendo significativamente cuando la altura supera los 1500m (Nilsson 1996; Yu et al. 2004). Sin embargo, en otros estudios con toma de datos a dos alturas de vuelo diferentes (540 y 850m), no se han encontrado variaciones estadísticamente significativas ni entre los percentiles de las alturas, ni en las alturas medias, incluso con diferentes especies (Næsset 2004).

Los errores aleatorios del Modelo Digital del Terreno (MDT) también se incrementan al aumentar la altura de vuelo, principalmente debido al decremento en la densidad de los puntos y al aumento del error planimétrico, (sobre todo en zonas menos planas (Hyypä H. et al. 2005)).

3.2.5. Frecuencia de pulsos láser (PRF)

Se trata del número de pulsos emitidos por segundo, se suele medir en kilohercios (KHz). En el mercado existen equipos LiDAR con un PRF desde 35 KHz, hasta 800KHz. Lo más habitual es que este ratio oscile entre los 100 y 200KHz.

Se ha demostrado que el error medio en la determinación de la altura crece al aumentar la frecuencia, ya que la energía emitida por el pulso es menor y esta circunstancia puede provocar cierta degradación en la precisión en la medición de la distancia (Csanyi N. 2006).

3.2.6. Densidad de puntos

Se refiere al número de pulsos emitidos hacia la superficie por el sensor, por metro cuadrado.

La densidad de pulso ha resultado no ser un factor determinante en la estimación de las métricas básicas, tales como la altura de árbol, diámetro a la altura del pecho o área basal total, hasta que la densidad de pulso desciende a 1 pulso/m², en el caso de bosques de coníferas (Jakubowski, Guo, Kelly 2013). De manera similar, en bosque mixtos de coníferas en Canadá, no se encontraron grandes diferencias cuando la densidad pasó de ser 3.5 a 0.5 pulsos/m² (Treitz et al. 2012). Mientras que otros autores señalan, que tanto la desviación estándar como el sesgo de los datos LiDAR, decrecen según aumenta la densidad de pulsos, no siendo lineal la relación que las une (Anderson et al. 2006; Olsen, Puetz, Anderson 2009; Yu et al. 2004).

3.3. Formación de productos cartográficos derivados de datos LiDAR

Los productos más comúnmente utilizados a partir de la nube de puntos LiDAR son los siguientes:

3.3.1. Almacenamiento de la nube de puntos

La nube de puntos bruta adquirida por el LiDAR, habitualmente, se almacena en un fichero de formato .LAS. Dicho formato, en su versión 1.0, fue aprobada por la American Society for Photogrammetry and Remote Sensing (ASPRS) en Mayo del 2003, siendo la 1.4 su última versión aprobada en Noviembre del 2011. Se trata de un formato de archivo público para el intercambio de nubes de puntos tridimensionales almacenado en formato binario. Es importante remarcar que el formato .LAS no especifica un orden en los puntos registrados, por lo que no sería posible un acceso aleatorio a los datos en el formato nativo y será necesaria una futura indexación para poder paliarlo. Esta característica permite almacenar datos muy rápidamente (en tiempo real) durante la recolección de los mismos.

Los atributos básicos para cada punto observado que se proporciona en un fichero .LAS son los siguientes:

1. X,Y,Z: Coordenadas planimétricas y elevación del punto, inicialmente se almacenarán como números enteros.
2. Intensidad: El valor de intensidad es un entero que representa la magnitud del pulso de retorno. Se basa, en parte, en la reflectividad del objeto alcanzado por el pulso láser, que variará según la composición del objeto interceptado por el láser.
3. Tiempo GPS: Es el valor del tiempo GPS en el que el punto fue adquirido. Es un valor doble flotante.
4. Número de retorno: Hace referencia al número de retorno que corresponde a un punto concreto, de entre todos los retornos registrados en ese pulso. Un pulso puede tener varios retornos, y se deberán marcar según el orden de retorno. El primer retorno tendrá un valor en este campo de 1, el segundo de 2 y así sucesivamente, hasta llegar al último retorno, que será como máximo cinco. Se representa mediante un número entero.
5. Número de retornos: Hace referencia al número total de retornos registrados por cada pulso. Se representa mediante un número entero.
6. Ángulo de escaneado: Denota la dirección del espejo de escaneado en el momento de salida del pulso. Se considera positivo cuando el espejo se mueve desde el lado izquierdo hacia el derecho, según la dirección de la pasada, y negativo en caso contrario. Se trata de un número entero.

7. Extremo de línea de barrido: Este campo binario tendrá valor 1 cuando el punto se encuentre en el extremo de la línea de barrido y vaya a modificar su dirección de escaneo.
8. Clasificación: Este campo representa la clasificación asignada a cada punto en base a las siguientes categorías:

Tabla 1 Clasificación aplicada por Gobierno Vasco

Valor de Clasificación	Significado
0	Creado, nunca clasificado
1	No clasificado
2	Suelo
3	Vegetación Baja
4	Vegetación media
5	Vegetación Alta
6	Edificios
7	Ruido
8	Puntos clave
9	Agua
10	Definición reservada para la ASPRS
11	Definición reservada para la ASPRS
12	Puntos de solape
13-31	Definición reservada para la ASPRS

9. Valor de las bandas RGB: Se trata de los valores de los canales Rojo, Verde y Azul asociados a ese punto obtenidos a partir de las fotografías. Se trata de valores normalizados a 16 bits.

Para la finalidad de la investigación, los atributos básicos de interés son los siguientes:

- Categorías 2 (terreno), 4 y 5 (vegetación media y alta, respectivamente). El resto de puntos no son relevantes.
- Control del retorno del punto.




Fig. 8 Datos de una parcela de control, clasificación por alturas




Fig. 9 Datos de una parcela de control, clasificación por categorías según la ASPRS

3.3.2. Modelo Digital del Terreno

La principal aplicación de la nube de puntos LiDAR, es la confección de un MDT de precisión. Se define el MDT como una función continua que representa para cada posición planimétrica 2D su la elevación, $z=f(x,y)$. En el caso del LiDAR aerotransportado, el láser podrá penetrar hasta impactar contra la superficie terrestre, si no encuentra otro obstáculo en su recorrido. En las zonas de alta densidad arbórea, es muy probable que el láser no consiga impactar contra el suelo, y que, sin embargo, rebote varias veces, según vaya atravesando la estructura vertical del árbol, al encontrarse con las ramas y hojas. Por este motivo, se debe considerar que el hecho de que un rebote sea el último de un pulso, no quiere decir que obligatoriamente sea un punto del terreno, por lo que este criterio no es válido para clasificar los puntos que pertenecen al terreno. Dado que la precisión del MDT depende directamente de la correcta clasificación de los puntos de suelo, es necesario aplicar algoritmos que nos permitan su identificación.

En el ámbito de la investigación, la creación de este producto es un aspecto clave, pues del mismo se derivarán un grupo de métricas fundamental de la nube de puntos directamente relacionadas con la altura de la masa arbórea, precisándose en primer lugar la formación de la superficie correspondiente al terreno (Axelsson 1999).

La formación de este producto conlleva 2 fases básicas, filtrado e interpolación, y la exactitud del producto final depende directamente de los productos y procesos empleados en su obtención:

- 1- La calidad de la nube de puntos original escaneada: precisiones planimétrica y altimétrica, densidad, cobertura espacial, altura de vuelo y ángulo de escaneado, fundamentalmente
- 2- Se formará exclusivamente con los puntos clasificados como suelo, siendo fundamental que el resultado de la clasificación sea el mejor posible.
- 3- Finalmente será preciso la creación de la superficie continua, por lo que será necesario el uso de algún método de interpolación.

En referencia al proceso de clasificación, indicar que es un tema de investigación totalmente vigente, ya que si bien existen procesos automáticos con resultados aceptables, todavía se exige un proceso de revisión y edición manual cuando se precisa certeza en los resultados. Destacar que se distinguen, principalmente, 4 grandes grupos de filtros:

a. Filtros morfológicos

Este tipo de filtros son derivados de la matemática morfológica y se basan en la idea de que grandes diferencias en altura entre dos puntos muy próximos en el espacio entre sí, implican, seguramente, que el punto más alto no se trata de un punto perteneciente al terreno. Por lo que se define una superficie cuya altura aumentará en función de la distancia planimétrica entre los puntos, y todo punto que quede por debajo de esta superficie será considerado como terreno (Vosselman 2000).

b. Filtros basados en en la incorporación progresiva de puntos a superficies basadas en mallas irregulares de triángulos

Este tipo de filtros trabajan progresivamente, reconstruyendo el terreno por medio de la clasificación de más y más puntos que pertenezcan al mismo. Se basan en la triangulación del conjunto de datos LiDAR inicialmente clasificados como terreno para conformar una superficie de (Axelsson 2000; van HanseN and Vógtle 1999). Para cada triángulo, se determina un punto adicional todavía no clasificado situado en la columna vertical definida por el triángulo. Posteriormente, se analizarán las diferencias de estos puntos candidatos con la superficie triangulada, y si esas diferencias están por debajo de un umbral preestablecido se clasificará ese punto candidato como terreno.

c. Filtros basados en interpolación:

Al contrario que el grupo de filtros anterior, en este caso se asume inicialmente que todos los puntos pertenecen al terreno, comenzando un proceso iterativo. En la primera interacción, se construye una superficie con todos los puntos que se moverá entre los puntos de suelo y los puntos que no lo son, de manera que se esperarán residuos negativos para los puntos de suelo, mientras que, los puntos que no son suelo deberían tener o residuos negativos muy pequeños o residuos positivos. En esta primera iteración se ha considerado que todos los puntos tienen el mismo peso a la hora de generar la superficie continua, pero una vez calculados los primeros residuos, ellos mismos servirán para determinar el peso de cada punto para la siguiente iteración (Kraus and Pfeifer 1998).

d. Filtros basados en segmentación:

Se trata de analizar segmentos en lugar de puntos individuales a la hora de clasificar los puntos. Se elegirán diferentes criterios de homogeneización para deducir si un segmento pertenece al terreno o no, como por ejemplo, las diferencias de altura entre segmentos (Sithole and Vosselman 2004) o gradientes máximos y medias (Schiewe 2001).




Fig. 10 Datos de una parcela de control filtrados a clase terreno (2) para la formación del MDT

Una vez clasificada la nube de puntos, el siguiente paso es la modelización de la superficie correspondiente al terreno. Existen multitud de algoritmos que permiten interpolar una superficie a partir de un conjunto de puntos, pero es importante destacar 2 características específicas de los datos de trabajo:

- El volumen de datos es inmenso.
- El carácter de los puntos, en la clasificación convencional de formación de MDT, corresponde a puntos de relleno o aleatorios, no existiendo elementos con carácter de líneas de rotura.

La solución habitual al primer problema pasa por el uso de algoritmos de segmentación, que descomponen la zona en segmentos compuestos por un número mucho más pequeño de

puntos. Posteriormente, se realizará la interpolación de cada segmento (Filin and Pfeifer 2006).

Además, dado el carácter casi continuo que muestran los datos LiDAR, es muy habitual la elección de modelos de terreno de tipo ráster o rejilla, eligiendo una resolución geométrica adecuada, e interpolando a partir de los datos de partida.

Respecto a los algoritmos de interpolación más frecuentes, destacar:

1. Red de Triángulos Irregulares (TIN): Se basa en crear previamente una red irregular de vectores usando triángulos Delaunay para unir los puntos y posteriormente a cada celda ráster se le asigna una altura en función del TIN. Es el más usado.
2. Krigging: Procedimiento geoestadístico que presupone que la distancia o la dirección entre los puntos reflejan una correlación espacial que puede utilizarse para explicar la variación en la superficie a estimar.
3. Distancia inversa ponderada (IDW): Asigna a cada celda de salida el resultado de la media ponderada por la distancia a los puntos encontrados dentro de un radio de búsqueda determinado en la vecindad de dicha celda.
4. Vecino natural: Halla el subconjunto de muestras de entrada más cercano a un punto objetivo y aplica ponderaciones sobre ellas basándose en áreas proporcionales para interpolar el valor.




Fig. 11 MDT para una parcela de control, modelizado como un ráster

En relación a uso de datos LiDAR, indicar que en la bibliografía consultada se ha destacado que algunos parámetros de vuelo también han resultado tener influencia en la precisión del MDT. El relieve es un factor influyente en la precisión del MDT ya que a medida que crece la pendiente decrece su precisión. Los errores de elevación en las áreas que se encuentran debajo de los árboles, crecen notablemente con pendientes superiores a los 15°. Los resultados han demostrado que el sistema de interpolación es un factor importante en la precisión del MDT, y los errores de interpolación aumentan cuando aumenta la pendiente (Hyypä H. et al. 2005).

La altura de vuelo también es un factor importante a la hora de obtener el MDT, llegándose a observar un aumento del error aleatorio del MDT hasta 18 cm al producirse un incremento en la altura de vuelo de 400 a 1500m de altitud (Hyypä H. et al. 2005).

3.3.3. Modelo Digital de Superficie

A diferencia del MDT, el MDS incluye la elevación de los puntos que están ubicados en la parte más alta del terreno. En las zonas de edificación esta superficie representará los tejados de los mismo, pero cuando nos encontramos ante un terreno boscoso, la parte más alta del terreno serán las copas de los árboles, y se denomina Modelo Digital de Copas. En zonas abiertas el MDT y el MDS coincidirán.

La diferencia entre el MDS (Fig 12) y el MDT (Fig 11) , $nMDS(x,y) = MDS(x,y) - MDT(x,y)$, se denomina MDS normalizado ó Modelo Digital de Altura del Dosel (MDAD) cuando se trata de zonas boscosas, y nos proporcionará las altura de los objetos a estudiar, en éste caso, directamente alturas de árbol.

La experiencia el uso continuado del LiDAR en aplicaciones forestales ha demostrado la tendencia a subestimar la altura de obtenida mediante esta técnica. Esta subestimación es debida a que los ecos registrados no tienen por qué pertenecer al ápice del árbol, si no a posiciones que corresponden a a la zona más alta del mismo, denominada habitualmente como los “hombros” del árbol. (Nelson, Krabill, Tonelli 1988).




Fig. 12 MDS correspondiente a una parcela de control

3.3.4. Imagen de intensidades

Se trata de una imagen que recoge la magnitud de retorno del pulso láser para cada punto, basándose en la reflectividad del objeto impactado (Fig.13). La reflectividad variará al variar las características de los elementos, y esta información debería favorecer la clasificación de los puntos, y la extracción de entidades, tales como puentes, edificios, líneas eléctricas y demás elementos situados en la superficie terrestre. El inconveniente principal de las imágenes de intensidad es que los valores varían tanto en cada elemento, en función de su posición en el vuelo, en un mismo vuelo como entre los valores observados en vuelos diferentes, y por lo tanto obtendríamos valores relativos.

Considerando la intensidad registrada en cada punto LiDAR del terreno como si se tratase de una elevación, procediendo de forma análoga a la formación de los mapas de MDT y MDS, se obtiene un mapa de intensidades que se muestra en (Fig. 13).




Fig. 13 Imagen de intensidades

3.4. Determinación de la biomasa

3.4.1. Cálculo de biomasa utilizando ecuaciones alométricas en función de variables dasométricas

Tal y como se comentaba en el punto 1, el interés por estimar la biomasa ha obedecido históricamente a varias razones, de manera que los primeros intentos de estimación de biomasa, en este caso por motivos inherentes a la productividad maderera, datan de la década de los 40, pero el interés ecológico de la biomasa, ha provocado un gran interés en la comunidad científica, aumentando considerablemente los autores que han investigado sobre ello.

La inmensa mayoría de las ecuaciones alométricas, han relacionado el valor de la biomasa medida en campo (generalmente por métodos destructivos) con variables fácilmente obtenibles en campo, como diámetros y alturas.

Varios autores han recopilado las diferentes ecuaciones alométricas existentes para diversas especies. (Zianis and Seura 2005) se encargaron de realizar el estudio en Europa, (Ter-Mikaelian and Korzukhin 1997), lo hicieron en América, mientras que (Eamus, Burrows, McGuinness 2000), realizaron su investigación en Australia.

La gran mayoría de los modelos de regresión documentados, pertenecen a alguno de los grupos siguientes (Parresol 1999) :

1. Modelo lineal con error aditivo:

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_j X_j + e$$

2. Modelo no lineal con error aditivo:

$$Y = \beta_0 X_1^{\beta_1} X_2^{\beta_2} \dots X_j^{\beta_j} + e$$

2. Modelo no lineal con error multiplicativo:

$$Y = \beta_0 X_1^{\beta_1} X_2^{\beta_2} \dots X_j^{\beta_j} e$$

donde, Y representa la biomasa total, X_j la variable predictiva y e, el término de error.

A la hora de calcular la biomasa pueden seguirse dos variantes, calcular directamente la biomasa total del árbol, o la biomasa correspondiente a cada una de las fracciones del árbol., que sumadas darían la biomasa total.

Dentro de la primera aproximación, (Ter-Mikaelian and Korzukhin 1997) recopilaron distintos modelos de estimación de las distintas fracciones de la biomasa para 65 especies norteamericanas, para ello utilizaron modelos no lineales con el diámetro como única variable predictiva y obtuvieron valores para el coeficiente de determinación de entre 0.7 y 0.99, con un rango muy amplio en el caso del RMSE, demostrando la alta correlación existente entre la biomasa y el diámetro del árbol. Siguiendo el mismo enfoque, Montero et al, 2005, estimaron la biomasa de cada fracción y la biomasa total, para las especies que habitan en los bosques españoles. Calcularon la biomasa total de la especie *Pinus radiata* en función de su diámetro normal, con un valor para R^2 de 0.977 y un RMSE de 0.19 kg, y valores para R^2 de entre 0.669 y 0.976 para las fracciones de biomasa, con un RMSE de entre 0.2 y 0.62 kg.

(Moore 2010) sin embargo, estimó directamente la biomasa total para la especie Pino radiata, basándose en 637 mediciones individuales, donde se registraron tanto el diámetro a la altura del pecho, como la altura de cada árbol en una isla en Nueva Zelanda. Para ello, aplicó modelos lineales y no lineales, con lo que consiguió un valor para R^2 de entre 0.78 y 0.97 para la primera aproximación y valores de entre 0.92 y 0.95 en el caso de la segunda, con un valor para el RMSE no superior a los 0.3 kg. El estudio reveló la fuerte correlación existente entre la biomasa y el diámetro al cuadrado (d^2), o el producto de la altura por el diámetro al cuadrado (d^2h).

Dado que los modelos desarrollados pueden variar mucho dependiendo del área geográfica donde los apliquemos, (Canga et al. 2013) estimaron la biomasa en una zona mucho más reducida, que la asumida por (Montero, Ruiz-Peinado, Muñoz 2005), ya que estos últimos desarrollaron modelos a escala nacional. La zona de estudio de estos autores, fue Asturias, donde una muestra estaba compuesta por 27 pinos, pertenecientes a la especie Pino radiata, repartidos en 5 rodales diferentes. Aplicaron el método del muestreo destructivo, obteniendo submuestras para cada uno de los diferentes componentes de la biomasa (madera, corteza, y corona), que una vez secas fueron pesadas. Posteriormente, desarrollaron modelos lineales y

no lineales para cada fracción de la biomasa utilizando como predictores, al igual que ocurría en el caso de (Moore 2010) el diámetro al cuadrado (d^2), o el producto de la altura por el diámetro al cuadrado (d^2h). Los valores para el coeficiente de determinación para cada uno de los componentes, oscilaba entre 0.77 y 0.92 con un RMSE de entre 27.40 kg y 110.2 kg, en el caso de los componentes estudiados por separado. Finalmente, el modelo que evaluaba la biomasa total, aportaba un valor de R^2 de 0.9376 y un RMSE de 139 kg, teniendo en cuenta que la cantidad de biomasa seca medida en el laboratorio era de 605.2 kg, concluyendo que el modelo obtenido se comportaba mejor que el resto de modelos desarrollados en España para esta especie.

3.4.2. Cálculo de biomasa en base a datos LiDAR

La estimación de biomasa en utilizando datos LiDAR tiene diferentes enfoques en función del sensor utilizado (discreto o de onda continua) y del objeto de estudio, a nivel de parcela o por árbol individual.

3.4.2.1. LIDAR DE PULSO O DISCRETO

3.4.2.1.1. DETERMINACIÓN DE LA BIOMASA A NIVEL DE PARCELA

Las primeras experiencias de aplicación de datos LiDAR en el ámbito forestal con el fin de estimar variables dasométricas que permitan caracterizar la estructura del bosque, comenzaron en la década de los 80, utilizando sensores que eran capaces de realizar mediciones a lo largo de líneas o transectos, utilizando sistema de perfilado (*profiling*). (Nelson, Krabill, MacLean 1984) estimaron la altura de árbol con una diferencia inferior a 1m, en comparación con las alturas obtenidas por técnicas fotogramétricas. Posteriormente, (Nilsson 1996) utilizó un sistema LiDAR para estimar la altura de árbol y calcular por regresión lineal el volumen por parcela en una región de Estocolmo para la especie *Pinus Sylvestris*, ensayando varios tamaños de huella (0.75-3m). Consiguió una estimación del volumen de rodal con un coeficiente de determinación R^2 de 0.78, y no encontró diferencias significativas entre las alturas obtenidas para conjuntos de datos con diferente tamaño de huella.

Nelson et al. (Nelson, Krabill, Tonelli 1988) y Nelson et al. (Nelson, Oderwald, Gregoire 1997) calcularon la biomasa en dos zonas claramente diferenciadas; áreas de coníferas al sudeste de Georgia y bosques forestales de Costa Rica. Ambos estudios utilizaron la técnica de regresión lineal para obtener distintos modelos. En el primer caso, demostraron que el modelo que no incluía métricas de densidad conseguía explicar más porcentaje de variabilidad, pese a que los valores de R^2 obtenidos no superaban el 0.6 Encontraron diferencias entre la altura medida en campo y la medida por el LiDAR, debido a que el sistema no es capaz de detectar el ápice del árbol, sino puntos próximos a él de altura menor. Detectaron que la estratificación del arbolado por especies no mejoraba significativamente los ajustes, apuntando que esta

cuestión tendría mayor impacto en zonas de arbolado caduco. Concluyeron que el sistema tenía ciertas limitaciones a la hora de calcular la biomasa y el volumen, sobre todo en zonas de alta variabilidad diamétrica. En el estudio desarrollado en Costa Rica, los autores estudiaron la influencia en el modelo que suponía introducir la transformación logarítmica de la biomasa o no hacerlo. En este caso, sí resultaron significativas en el modelo métricas derivadas de la densidad del dosel, así como métricas derivadas de la altura del mismo, tal y como ocurría en el primer caso, consiguiendo un valor para R^2 de entre 0.48 y 0.74 para las 3 zonas de estudios contempladas pero con un error medio cuadrático elevado (RMSE) muy elevado, de hasta un 65%. Concluyeron que los modelos no transformados forzados a pasar por el origen, (constante=0), obtenían mejores resultados.

Una vez superadas las limitaciones de los láseres perfiladores, por la integración de diferentes sistemas de escaneo (Fig. 5) que permiten aumentar significativamente el área de barrido, (Næsset 2002) estimó la altura media de árbol, el diámetro medio, el número de troncos, el área basal y volumen de madera por parcela utilizando análisis de regresión. Empleó como predictores diversas métricas derivadas de altura y densidad de la vegetación, obteniendo valores para R^2 de entre el 50% y el 95%, correspondiendo los valores más bajos a aquellas variables que describen la estructura horizontal del dosel, como son el diámetro del tronco y número de troncos. Se realizó una estratificación en 3 grupos: población joven, población madura de baja calidad y de buena calidad. Para el cálculo de las métricas de densidad vegetativa se calcularon la proporción de primeros y últimos ecos láser por encima de los cuantiles 0, 10, ..., 90 de la altura sobre el número total de primeros o últimos ecos.

Condés y Riaño, (Condés and Riaño 2005) estimaron la biomasa foliar por parcela del *Pinus Sylvestris* en la provincia de Madrid. Para ello emplearon métodos destructivos, apeando los árboles y pesando la biomasa obtenida. Posteriormente, calcularon la biomasa en base a la altura máxima por parcela obtenida a partir de los datos LiDAR, obteniéndose un ajuste con un coeficiente R^2 de 0.82 y un error estándar inferior al 10%. Estos autores concluyeron que dicha metodología era perfectamente ampliable al cálculo de la biomasa total.

Næsset y Gobakken (Næsset and Gobakken 2008) obtuvieron modelos de regresión para la biomasa en Noruega para especies coníferas, utilizando 4 diferentes láseres y densidades de punto desde 0.7 hasta 1.2 por metro cuadrado. Se estimaron métricas de los datos LiDAR tales como el coeficiente de variación, los percentiles de las distribuciones de altura, altura media y medidas sobre la densidad de la vegetación. Para calcular las métricas sobre la densidad de vegetación, se estimó un límite inferior para considerar que un punto láser pueda ser considerado vegetación, fijado en este caso en 2m. Posteriormente se divide la diferencia de altura entre el límite inferior preestablecido y el percentil 95 de la altura en 10 capas de igual altura, y posteriormente se computa el porcentaje de puntos láser por encima de cada fracción de las 10 anteriormente definidas sobre el número total de puntos. En trabajos previos se había establecido que el percentil 95 de la altura demostraba ser más estable que la altura máxima, dado la mayor variabilidad relacionada con ésta última (Næsset 2004; Næsset and Gobakken 2005). Tras realizar una selección de las métricas láser obtenidas, finalmente se seleccionarán el percentil 90 y la proporción de puntos por encima de los 2m del número total de puntos como aquellas variables que consiguen explicar la mayor parte de variabilidad, el 82% en este caso y un RMSE de 0.25 ton /ha (Næsset and Gobakken 2008). Utilizando

métricas sobre densidad del dosel muy similares, (Næsset et al. 2011), aplicó modelos de regresión lineal múltiple, con modelos que emplean transformaciones logarítmicas y de tipo potencial en las variables explicativas y logarítmicas en la variable respuesta para estimar la biomasa, esta vez, en bosques jóvenes (la biomasa estimada en campo oscilaba entre 2.27 ton/ha y 90.42 ton/ha), teniendo en cuenta 3 diferentes umbrales de altura mínima para considera que un punto pertenezca a la vegetación (0.5, 13 y 2 m). Consiguió modelos con un R^2 entre 0.6-0.83, con un RMSE entre 0.08 y 118.9 Mg ha⁻¹. Apuntó que pese a que los modelos lineales son adecuados para la estimación de la biomasa, el problema de heterocedasticidad en este tipo de modelos debe ser tomada en cuenta. Concluyó que la variabilidad explicada por los modelos y su RMSE aumentaba al disminuir el umbral de altura mínima, hecho importante al tratarse de bosques jóvenes donde los árboles comienzan a tener ramas por debajo de los 2m, ya que un umbral demasiado elevado podría suponer pérdida de información sobre la vegetación, por interpretar puntos pertenecientes a la vegetación como puntos de suelo. Sin embargo, el umbral ampliamente utilizado de 2m, resultaba apropiado para su uso en bosques maduros.

García et al. (García et al. 2010) combinaron métricas obtenidas a partir de las alturas de los puntos láser con sus valores de intensidad para obtener la biomasa en bosques mediterráneos mixtos. En este trabajo consiguieron explicar el 58% de la variabilidad del modelo, pero la variabilidad explicada aumentó considerablemente al considerar modelos específicos por especie, consiguiendo así valores de R^2 de hasta 0.98 en el caso del roble y apoyándose mayoritariamente en percentiles de la altura y en valores de intensidad relacionados con la densidad de la cobertura vegetal.

Gobakken et al. (Gobakken et al. 2012b) se apoyaron en el inventario forestal nacional noruego como base de contraste para la estimación de la biomasa en el condado de Hedmark, donde más del 53% de las parcelas del inventario fueron sobrevoladas por un sensor LiDAR. En este caso, se calcularon distribuciones de alturas por separado, para los primeros y últimos ecos considerados como vegetación (aquellos cuya altura sea >1.3m), basándose en los buenos resultados obtenidos con esta metodología en anteriores trabajos (Næsset and Gobakken 2005). Utilizaron dos aproximaciones para realizar el muestro: la denominada dependiente del modelo (MD) (Ståhl et al. 2011) y la asistida por el modelo (MA) (Gregoire et al. 2011; Särndal, Swensson, Wretman 1992) Obtuvieron un coeficiente de determinación en los modelos que oscilaba entre 0.80 y 0.95 para las ocho clases o estratos determinados, con un RMSE máximo de casi 20 ton/ha. Concluyeron que la aproximación MA se encuentra limitada por requerir un gran número de muestras, pese a obtener modelos menos sesgados.

D'Oliveira et al. (d'Oliveira et al. 2012) calcularon la biomasa en un bosque forestal Amazónico en Brasilia. Obtuvieron modelos para la biomasa con valores para R^2 desde 0.63 hasta 0.72 y un RMSE que oscilaba entre 1.28 y 43.25 ton/ha. Utilizaron como predictores el percentil 25 de la altura, la altura media y la varianza de las alturas en una regresión lineal múltiple. En este trabajo reconocieron como fuente de error el hecho de haber utilizado ecuaciones alométricas dependientes únicamente del diámetro para estimar la biomasa en campo. También Kronseder et al. (Kronseder et al. 2012) estimaron la biomasa en un entorno forestal en dos diferentes escenarios: bosque de turba pantanoso y bosque dipterocárpeo de tierras bajas, característicos de Borneo. Se aplicó la misma técnica de regresión y se calcularon tanto

modelos específicos para cada tipo de bosque como generales. En el caso de del bosque de turba el valor de R^2 ascendió a 0.31 con un RMSE de 94.77 ton/ha (RMSE% 41.02), en el caso del bosque dipterocárpeo el valor obtenido fue 0.83 con un RMSE de 96.74 ton/ha (RMSE% 21.37) y el modelo general para ambos tipos, 0.71 con un RMSE de 115.20 ton/ha (RMSE% 33.85). Resultados comparables a los obtenidos por otros estudios en el caso del monte de turba, mientras que los resultados obtenidos en el bosque dipterocárpeo no pudieron ser comparados, al no existir estudios documentados al respecto. Ioki et al. (Ioki et al. 2014) también estimaron la biomasa en un entorno tropical, pero esta vez en Indonesia. Consiguieron modelos que explicaban el 81% de la variabilidad con un RMSE de 61.26 ton/ha. La metodología aplicada fue también la regresión lineal múltiple, pero en este caso, los mejores predictores resultaron ser altura media de la vegetación y el ratio de penetración del láser.

(Zhao, Guo, Kelly 2012) estimaron la biomasa utilizando dos diferentes ecuaciones alométricas: a nivel regional y nacional. Comprobaron su influencia en su posterior cálculo de la biomasa en base a datos LiDAR en un bosque dominado por coníferas, en las Montañas Nevadas, en California. Concluyeron que el uso de ecuaciones alométricas a nivel regional conseguía mejores ajustes en los modelos que cuando se partía de las ecuaciones a nivel nacional, sugiriendo que en la mayoría de los casos sería preferible utilizar ecuaciones alométricas a nivel regional.

Recientemente, Takagi et al. (Takagi et al. 2015) estimaron la biomasa en bosques con diversas especies de Japón con un coeficiente de determinación de 0.78 y un RMSE de 38.2 ton/ha. Calcularon, también, modelos específicos para bosques de coníferas, de frondosas y mixtos concluyendo que mientras que en las parcelas de bosque mixto, tanto el valor de R^2 como el RMSE se incrementaban (0.94 y 14.38 ton/ha, respectivamente), no ocurría lo mismo en las parcelas de coníferas y frondosas por separado, donde ambas magnitudes obtenían peores resultados.

3.4.2.1.2. DETERMINACIÓN DE LA BIOMASA DE ÁRBOL INDIVIDUAL

Las nuevas tecnologías de los sistemas LiDAR han permitido un aumento de la frecuencia de repetición de pulso, y por tanto, una mayor densidad de pulso, que ampliarán nuevos campos de aplicación, tales como la obtención de métricas de árbol individual. Por primera vez Hyppa y Inkinen, 1999 consiguieron estimar variables de árbol individual tales como la altura con una precisión inferior a 1m, cuando la precisión de un clinómetro en árbol con altura superior a 25m es de 1.5m, con un vuelo cuya densidad de pulso era de 4 ó 5 pulsos por metro cuadrado.

Tras estos primeros trabajos satisfactorios trabajando las variables a nivel individual (Popescu 2007) calculó la biomasa de la especie *Pinus Taeda* en Texas, trabajando con una densidad media de 2.6 puntos láser por metro cuadrado. Utilizaron 2 aproximaciones para el cálculo: una línea calcula la biomasa en base al diámetro de árbol derivado de los datos láser por medio de regresión lineal utilizando como predictores la altura y el diámetro de la corona de

árbol individual con un R^2 de 0.87, y la segunda alternativa calcula la biomasa directamente obtenida de los puntos LiDAR por medio de una regresión no lineal utilizando las mismas variables como predictores con un R^2 de 0.88.

Kaartinen y Hyppä, (Kaartinen and Hyppä 2008) estudiaron distintos métodos de extracción de árboles individuales, y aplicaron distintas densidades de pulso para estudiar su efecto en la precisión de la medida de la corona de árbol en Espoonlahti, a unos 15 km al oeste de Helsinki, en un área cuyas especies dominantes son *Pinus sylvestris*, *Picea abies* y *Betula pendula* y *Betula pubescens*. Concluyeron que al reducir la densidad de pulso de 8 a 2 metros cuadrados, no había un incremento significativo en la precisión de delineación de coronas, mientras que los distintos métodos de extracción utilizados sí parecían tener mayor impacto. No obstante, estimaron como densidad mínima 2 pulsos por metro cuadrado, para poder obtener medidas a nivel de árbol.

3.4.2.2. LIDAR DE ONDA CONTINUA

Lefsky et al, 1999 caracterizaron el volumen y la organización espacial de la materia vegetal y el espacio vacío en el dosel forestal en Oregón mediante un LiDAR full waveform (Scanning Lidar Imager of Canopies by Echo Recovery, SLICER) con un diámetro de huella de 10m, realizando una estratificación del arbolado en función de la edad (muy jóvenes, jóvenes, maduros y de viejo crecimiento). Calcularon la biomasa y el área basal usando como predictores, índices sobre la estructura del dosel con un valor de R^2 de 0.91 y 0.87 respectivamente, aplicando regresiones lineales múltiples por pasos. Demostraron que la variable que explicaba mayor parte de la variabilidad en el modelo de regresión era el volumen de relleno del dosel que se define como el análogo tridimensional de la fracción de cabida cubierta, lo que permite intuir que aparte de utilizar las métricas derivadas de las alturas para predecir la biomasa, también tenían cabida aquellas métricas específicas sobre densidades. Comprobó que la relación entre el diámetro del tronco y la biomasa no era lineal, y que aumentaba con la altura. Posteriormente, estimaron la biomasa en tres diferentes entornos: caduco templado, conífero templado y bosque boreal, concluyendo que la relación entre la biomasa y las métricas obtenidas a partir de la nube de puntos LiDAR era estable en diferentes biomedios. El hecho de estratificar la muestra en función del tipo de bosque no supuso mejoras significativas en las predicciones Lefsky et al. (Lefsky M. et al. 2002) (Lefsky et al. 1999) apuntaron, como aspecto crítico, el tamaño de la huella láser, no recomendando diámetros mayores a los 10m en aplicaciones forestales, pese a su mayor capacidad para obtener información de la estructura del dosel, ya que decrecía la precisión en las medidas de alturas. Por lo que, la gran mayoría de los estudios aquí citados corresponderán a sensores de huella pequeña, que implican retornos discretos, se especificará cuando esta característica varíe.

Drake et al. (Drake et al. 2002) calcularon la biomasa en bosques tropicales de Costa Rica con muy buenos resultados, obteniendo valores para el coeficiente de determinación de hasta 0.94 con un RMSE de 16 ton/ha al aplicar regresiones lineales múltiples. El modelo que explicaba la mayor parte de la variabilidad utilizaba como predictores cuantiles de la intensidad de la onda y su mediana.

Ahmed et al. (Ahmed, Siqueira, Hensley 2013) y calcularon la biomasa en bosques templados, en Nueva Inglaterra. Los resultados obtenidos en ambos estudios fueron bastante dispares. Se utilizaron como predictores las métricas RH (cuartiles del retorno de la onda), ya que presentaban mayor correlación con la biomasa que otras métricas extraídas de los puntos LiDAR más comúnmente utilizadas, como la altura media, la altura media cuadrática o su desviación estándar. El modelo óptimo alcanzaba un valor para el coeficiente de determinación de 0.66 con un RMSE 41.989 ton/ha. Al tratarse de una zona con un rango grande de cantidad de biomasa (420 ton/ha a nivel de parcela), muy superior al existente en otros estudios (Drake et al. 2002; Lefsky et al. 1999), achacaron los malos resultados a una posible saturación de la relación altura-biomasa, obteniendo peores resultados al aumentar la cantidad de biomasa (>300 ton/ha).

3.4.2.3. DATOS LIDAR COMBINADOS CON TORAS FUENTES DE DATOS

Naesset et al. (Naesset et al. 2011) calcularon la biomasa combinando datos LiDAR con datos provenientes de un sensor Radar de Apertura Sintética (Interferometric Synthetic Aperture Radar, INSAR) dentro de la misión topográfica Shuttle Radar Topography Mission (STRM). Obtuvieron modelos por regresión no lineal para los datos LiDAR y modelos lineales en el caso de los InSAR, utilizando como variables predictivas en todos los modelos un percentil de la altura y una métrica de densidad de vegetación con el primer conjunto de datos y con la altura en el segundo caso. Consiguieron ajustes con un valor para R^2 de entre 0.76-y 0.89 y un RMSE de entre 14.6 y 41.9 ton/ha en el caso de los datos LiDAR, un R^2 de entre 0.0-0.18 en el caso de los datos InSAR y un RMSE de entre 41.4-77.4 ton/ha, y un R^2 de entre 0.13-0.28 y un RMSE de entre 35.7-74.7 ton/ha en el caso de combinar ambos tipos de datos. Se achacó parte de la diferencia de biomasa obtenida entre ambos conjuntos de datos a posibles errores de correspondencia geográfica entre las parcelas y el píxel asignado a cada una de ellas, debido a diferencia de tamaño y alineación entre ambos conjuntos de datos.

3.4.2.4. OTROS ENFOQUES

Las tendencias más novedosas aplican técnicas de aprendizaje automatizado (“machine learning”) a las medidas obtenidas con el láser para la caracterización de los bosques y la obtención de variables derivadas como la biomasa. Estas técnicas se basan en algoritmos que permitan “enseñar” a la máquina a generalizar comportamientos en base al reconocimiento de patrones utilizando muestras de entrenamiento.

Zhao et al. (Zhao et al. 2011) aplicaron técnicas de machine learning a una zona boscosa prioritariamente de coníferas en Texas. Utilizaron los procedimientos de Maquinas de Soporte Vectorial (SVM) para clasificar el tipo de bosque y el proceso Gaussiano (GP) para estimar 10 variables estructurales de la vegetación, entre ellas la biomasa. Ambos algoritmos se basan en la búsqueda de hiperplanos, en el caso de SVM el hiperplano buscado será aquel que separe los puntos pertenecientes a una categoría de los pertenecientes a otra y una vez realizada la

clasificación de las muestras de entrenamiento, será capaz de predecir la clasificación de cualquier punto. En el caso del GP, se encontrará la función que minimice la diferencia entre el valor observado de cada una de las variables estructuradas y su valor predicho. Calcularon la biomasa con un valor para el coeficiente de determinación de 0.513 y un RMSE de 0.298 ton/ha, obteniendo ajustes muy superiores en el caso de otras variables como la altura de Lorey (corresponde a la media ponderada de las alturas en base a sus correspondientes secciones normales) para la que obtuvieron un valor para R^2 de 0.894 ton/ha.

Gleason et al. (Gleason and Im 2012) compararon la efectividad de 4 diferentes métodos de análisis para la estimación de la biomasa: regresión lineal, Random Forest, SVR y Cubist en un bosque mixto de coníferas y caducas en el estado de Nueva York. La técnica Random Forest es una técnica no-paramétrica que es comprendida por multitud de árboles de decisión. Esta técnica muestrea aleatoria e iterativamente los datos y las variables para generar un extenso grupo (bosque) de árboles de clasificación y regresión. El árbol que posea el error más pequeño se elegirá como el clasificador más robusto. El algoritmo SVR se basará en el anteriormente descrito SVM para clasificación. SVR asume que a cada conjunto de variables entrada le corresponderá una única relación con la variable respuesta, y que las interrelaciones entre los predictores serán capaces de identificar las reglas para la predicción del valor de la variable respuesta. En este caso el concepto de hiperplano relacionará cada variable predictiva con un plano, en lugar de hacerlo con una categoría como ocurría en el estudio anterior. Cubist es un software comercial utilizado para realizar regresiones basándose en reglas. Concluyeron que el algoritmo SVR conseguía ajustes más precisos, pero menos estables, siendo la regresión lineal la que peores resultado obtuvo.

También Ahmed et al. (Ahmed et al. 2015) estimaron la estructura del dosel aplicando de forma comparada análisis de regresión lineal múltiple y técnicas Random Forest en bosques templados en Canadá, compuestos por coníferas en un 65% y caducas en un 16%. Para realizar sus estimaciones sobre la cobertura y altura de vegetación, combinaron datos LiDAR con imágenes Landsat Multispectral Scanner (MSS), Thematic Mapper (TM) y Enhanced Thematic mapper (ETM+). En el caso de los datos Landsat se obtuvieron índices a partir de la transformación Tasseled Cup de los mismos. Concluyeron que el método Random Forest obtenía valores para el coeficiente de determinación más altos y RSME más bajos que el método de regresión en los tres diferentes grupos estipulados: arbolado joven, maduro y mixto. Los resultados para el método Random Forest explicaban hasta el 72% de la variabilidad del modelo en el caso de la cobertura de la vegetación y hasta el 88% en caso de la altura de la misma, con un RMSE% máximo de 0.0746 en el primer caso y de 0.1573 en el segundo. Para el análisis de regresión se obtuvieron valores máximos de R^2 de 0.64 y 0.69 para la cobertura de vegetación y la altura respectivamente, con un RMSE máximo de 3.75m y 4.66m. Los mejores resultados se obtuvieron en las masa maduras para ambas técnicas, para detrimento de las masas jóvenes y mixtas.

A modo de síntesis Zolkos et al. (Zolkos, Goetz, Dubayah 2013) realizaron una revisión bibliográfica sobre los modelos desarrollados para la estimación de la biomasa, analizando diferentes factores tales como el tipo de sensor utilizados, el tipo de bosque estudiado y el tamaño de la parcela de muestreo. Respecto al tipo de sensor utilizado para la adquisición de los datos, contemplaron los siguientes: LiDAR discreto, full-waveform o LiDAR espacial full

waveform. Se observaron modelos con mejor coeficiente de determinación en los dos primeros casos. La mayoría de los estudios realizados con el tercer tipo de LiDAR se hicieron con el sensor Geoscience Laser Altimetry System (GLAS), éste no estaba diseñado para estudios de vegetación y cometía mayores errores en la estimación de alturas de la vegetación. Al analizar los resultados en diferentes tipos de bosques, observaron diferencias significativas entre los diferentes tipos de bosques más comúnmente estudiados. Los bosques forestales obtuvieron mejores ajustes que los realizados en bosques templados de coníferas, bosques templado de caducadas y bosques boreales, mientras que no se observaron diferencias significativas entre los tres últimos tipos de bosques. Pese a que no se conocen con exactitud las razones de estas diferencias, se consideran como fuentes de error la diferente estructura de árbol propia de cada especie y la relación entre la vegetación y la topografía del terreno.

4. MATERIALES Y MÉTODOS

4.1. Zona de estudio y material

4.1.1. Zona de estudio

La zona de estudio abarcará la comarca de Arratia-Nervión, dicha comarca se encuentra ubicada en el Territorio Histórico de Bizkaia, entre el valle del Idiazabal y la Sierra del Gorbea. Arratia-Nervión colinda al Sur y al Oeste con la provincia de Álava, al norte con las comarcas de Las Encartaciones y Gran Bilbao y al Este con el Duranguesado. La componen los siguientes municipios: Arantzazu, Arakaldo, Areatza, Artea, Arrankudiaga, Dima, Igorre, Orduña, Otxandio, Ubidea, Ugao-Miraballes y Zeanuri y Zeberio. Se trata de la segunda comarca más extensa de Bizkaia, comprendiendo una superficie de 40.043 ha, y al mismo tiempo posee la densidad de población más baja de la provincia, 52.7hab/km².




Fig. 14 Mapa de situación de la zona de trabajo en la C.A.P.V.

Esta comarca está formada por una serie de valles estrechos que discurren en dirección Noroeste-Sudeste, como los valles de Zeberio y Orozko, y otros en dirección Norte-Sur, como los de Arratia y Dima, siendo en éstos últimos donde se concentran los principales núcleos de población comarcales.

La ciudad de Orduña, enclave vizcaíno en tierras alavesas, sería un caso aparte, ya que sus características físicas difieren en gran manera del resto de la comarca, al estar situada en el centro de una amplia vega cerrada al Sur por la Peña de Orduña. Dado que este trabajo se

concentra en la parte de la comarca ubicada en Bizkaia, a partir de ahora se caracterizará únicamente dicha zona.

Arratia-Nervi6n se inscribe en el gran Anticlinal de Bizkaia, que junto a los valles fluviales de Arratia e Indusi, confieren a la zona de un relieve extremadamente accidentado. Los valles son paralelos entre s3 y perpendiculares a la direcci6n de los principales r3os, dada la alternancia de materiales blandos y duros. Numerosas fallas y fractura inciden de forma importante en este conjunto estructural, destacando la gran falla de direcci6n Noreste-Sudeste, que recorre el eje del anticlinal.

En el 1rea noroccidental se encuentra el macizo del Ganegokorta, que establece el l3mite entre Arratia-Nervi6n y Encartaciones, mientras que en la zona m1s al sur, est1 el macizo del Gorbea, cuya cumbre posee una altura de 1482m sobre el nivel del mar y donde se encuentra el puerto de monta1a de Barazar, unos de los pasos m1s importante entre Bizkaia y 1lava.

La comarca posee una altitud media de 465 m, estableci6ndose la cumbre del Gorbea como el punto m1s alto de la misma, y encontrando cotas en m3nimas en torno a los 70m de altura en la zona Norte de la misma, mientras que las m1s altas se dan al sur de la comarca, en el Parque del Gorbea.




Fig. 15 MDT de la comarca Arratia-Nervi6n

Las pendientes de la zona llegan a alcanzar los casi 79°, con una pendiente media de 18,6°, existiendo zonas de alta pendiente de entre 30 y 45° distribuidas casi por toda la comarca.




Fig. 16 Mapa de pendientes de la comarca de Arratia-Nerviión

Las condiciones bioclimáticas en esta comarca son muy similares a las del territorio vizcaíno en general, se clasifica dentro del clima templado de tipo oceánico. La temperatura media ronda los 12.5 ° C, sin variaciones bruscas de temperaturas debido a la influencia del mar.

La precipitación media anual se estima en unos 1200mm, registrándose los máximos mensuales en noviembre y diciembre, mientras que los mínimos se sitúan en septiembre y octubre. El resto del año el régimen de lluvias se mantiene regular, exceptuando tormentas de origen ciclónico durante los meses de verano.

Respecto a la vegetación, la progresiva sustitución de las especies autóctonas (encinar, hayedo, matorral y prados) por la plantación de coníferas y otras especies de rápido crecimiento han propiciado que los pinares constituyen la principal formación arbórea de la comarca. Por otro lado, la mayoría de frondosas se localizan en el municipio de Orozko, en torno a los ríos Arbaizta y Orrotegi.

En altitudes menores a los 700m, aparecen las especies arbustivas y arbóreas, entre las que predominan las encinas y los madroños. La vegetación de ribera la forman alisos, sauces y fresnos, bordeando cursos de agua.

4.1.2. Especie arbórea analizada: Pino radiata

En la actualidad, el Pino Radiata sigue siendo una de las especies más codiciadas en el sector maderero, debido a sus características físico-mecánicas, pero ha sido posteriormente, cuando a raíz de la necesidad de conocer la estimación de secuestro de carbono de los bosques por su relación con el cambio climático, ésta especie ha cobrado mayor importancia. Teniendo en cuenta que los bosques españoles fijaban ya en 2004 alrededor del 19% de las emisiones totales de CO₂, producidas en el país.

Debido a su elevada presencia en la C.A.P.V., se ha consolidado como una importante fuente de CO₂. La estimación de CO₂ fijado por la especie Radiata en la C.A.P.V. en el año 2004 (Tabla 3, Montero et al. 2005) representa más del 64% de la fijación estatal y el 24% sobre el total fijado en superficie arbolada en el País Vasco, según el IFN4, por lo que los bosques de Radiata se convierten en importantes reservas de CO₂ para la comunidad.

Tabla 2 Balance global Pinus Radiata C.A.P.V.. Fuente: Montero et al., 2005

	Biomasa aérea				Acículas	Total aérea	Biomasa radical	Biomasa total
	Fuste	Ramas						
		R>7 cm	R 2-7 cm	R<2 cm				
BIOMASA TOTAL (1990)	12.465.235	406.607	999.124	515.748	325.356	14.712.071	3.735.201	18.447.272
INC.ANUAL BIOMASA	924.588	33.786	70.789	35.286	22.921	1.087.369	265.976	1.353.345
CO ₂ FIJADO TOTAL (1990)	22.736.465	741.646	1.822.393	940.719	593.447	26.834.670	6.812.970	33.647.640
INC. CO ₂ FIJADO ANUAL	1.686.440	61.626	129.118	64.360	41.807	1.983.351	485.137	2.468.488
EXTRACCIONES ANUALES	755.889	24.657	60.587	31.275	19.730	892.137	225.502	1.118.638
CO ₂ FIJADO EN 2004	35.764.173	1.259.214	2.781.829	1.403.917	902.536	42.111.670	10.433.866	52.545.536

Teniendo en cuenta lo expuesto anteriormente y al tratarse de la formación más importante en superficie del País Vasco se ha optado por la especie Pinus Radiata D. Don ó Pino insigne para realizar el análisis en esta investigación.

El Pino Radiata proviene de la región de Monterey (California), se asienta en territorios de cota baja (hasta 600 m.s.n.m.) donde impera un clima templado-húmedo de influencia oceánica. Se trata de una especie de crecimiento rápido que se instauró en la C.A.P.V. en la primera mitad del siglo XIX al calor del desarrollo industrial vasco, en concreto, de la industria papelera.

Debido a las exigencias edafológicas y climáticas del pino radiata, son propicios suelos que van desde silíceos sueltos a calizos de compacidad media, temperaturas medias superiores a 10°C con precipitación anual mayor de 800mm., con humedad ambiental, sequía estival poco pronunciada y sin fuertes heladas.

Estos pinares ocupan 125.000 hectáreas que suponen el 32% de la superficie arbolada autonómica y, a nivel nacional, suponen el 49% de la superficie de esta formación arbolada. Su importancia también queda reflejada en las cifras de existencias: estos pinares aportan el 23% de los pies mayores de la comunidad y el 44% del volumen con corteza. Según los datos del IFN4 aunque la variación en superficie respecto al IFN3 es mínima, se ha detectado menos superficie de repoblaciones jóvenes y, por el contrario, un aumento de masas más maduras, con mayor densidad de volumen.

Tabla 3 Existencias de Pino radiata en la C.A.P.V.. Fuente: IFN4

	IFN3	IFN4	Variación(%)
Nº pies mayores	58.820.909	56.589.944	-3.79
VCC (m³)	23.874.531	27.688.992	15.98
Nº pies menores	46.625.870	41.185.328	-11.67




Fig. 17 Distribución del Pino Radiata en la C.A.P.V. Fuente: IFN4

Los bosques de pino radiata, repoblaciones de carácter productor, se presentan en altitudes inferiores a los 600 metros, por todo el territorio de Guipúzcoa y Bizkaia, y en el extremo noroccidental de Araba/Álava (coincidiendo con los terrenos de menor cota de esta provincia). Más del 53% de la población total de pino radiata en la C.A.P.V. se concentra en la provincia de Bizkaia y más del 23% de ese porcentaje se encuentra en la comarca de Arratia Nervión, representando, a su vez, casi el 60% de la población total de especies de la comarca. La Tabla 2

muestra la distribución de Pino Radiata para los distintos estados de la masa en función de su desarrollo y aspectos morfológicos. Se distinguen los siguientes estados de la masa:

1. Repoblado: Des el fin del diseminado hasta que hay tangencia de copas o hasta que se alcanza la altura de 1.3m Empieza a manifestarse competencia en arbolado.
2. Monte Bravo. Desde el inicio de la tangencia de copas hasta el momento en que el efecto de la ausencia de luz suficiente en la parte baja del fuste, provoque la pérdida de las ramas inferiores (poda natural). La Competencia se intensifica.
3. Latizal: Desde el comienzo de la poda natural hasta que los árboles alcanzan un diámetro normal de 20cm. Se distingue entre:
 - a. Bajo latizal: cuando el diámetro normal es inferior a 10 cm.
 - b. Alto latizal: cuando el diámetro normal se sitúa entre 10 y 20 cm.
4. Fustal: El diámetro medio es superior a los 20cm. Se subdivide, a su vez en:
 - a. Bajo o joven fustal: cuando el diámetro normal oscila entre los 20 y 35 cm.
 - b. Fustal medio: cuando el diámetro normal está entre los 35 y 50 cm.
 - c. Fustal viejo o alto fustal: el diámetro normal es superior a los 50 cm.

Tabla 4 Distribución Pino Radiata en la comarca Arratia-Nervión. Fuente: IFN 4

	Distribución especies forestales (ha)							
	Estado de la masa					Densidad		
	Talas	Rep/MB	Latizal	Fustal	Total	Baja	Media	Alta
Pinus radiata	493	3746	3804	8216	16260	1436	2427	10551
Total coníferas	542	4425	4496	10770	20233	1662	2764	13562
Total frondosas	39	852	2944	3998	7832	292	1682	5627
Total especies	581	5277	7440	14768	28065	1954	4446	19189




Fig. 18 Distribución de Pino Radiata en Arratia-Nerviión según IFN4

4.1.3. Datos de campo

La obtención de los datos dendrométricos para la especie analizada que permitirán, por aplicación de ecuaciones alométricas la obtención de la biomasa en las parcelas de referencia en la investigación son los proporcionados por el cuarto Inventario Forestal de la CAPV, realizado entre el 17 de Enero y el 15 de Junio de 2011.

El Cuarto Inventario Forestal del País Vasco es la cuarta fase de una estadística decenal, cuyo objetivo es el reconocimiento y la estimación de valores e indicadores para una parte importante de estas funciones productivas, protectoras, ecológicas y recreativas. Este inventario es responsabilidad del Órgano Estadístico del Departamento de Medio Ambiente, Planificación Territorial, Agricultura y Pesca del Gobierno Vasco, y cuenta con la colaboración financiera y operativa de la Diputación Foral de Álava, Diputación Foral de Bizkaia y Diputación Foral de Gipuzkoa.

El Inventario Forestal se apoya en el Mapa Forestal de la C.A.P.V. (2010-2011), donde se midieron en campo unas 4.000 parcelas repartidas por toda la superficie forestal vasca.

El Mapa Forestal de la C.A.P.V. ha sido elaborado por fotointerpretación sobre pantalla, basándose en ortofotos en color, para un vuelo efectuado en mayo de 2009 y tamaño mínimo de píxel 25 cm. El tamaño mínimo de la tesela (mancha de vegetación homogénea) es de 0.15-0,2 ha, de forma que pudiera englobar parcelas de inventario de campo con radio 25 m (superficie máxima de muestreo cercana a 0,2 ha).

Las fases que se han seguido en el trabajo de fotointerpretación han sido:

- Recogida de la información: las Diputaciones Forales enviaron datos catastrales de las parcelas en las que se habían registrado peticiones de corta de arbolado o ayudas por reforestación. También se contaba con los mapas de rodales actualizados de montes públicos. De esta forma, se contaba con una referencia geográfica de la ubicación de cortas y plantaciones forestales en los últimos años.
- Transformaciones temporales: dado el plazo de 5 años entre el anterior mapa y el nuevo, en el caso de las plantaciones forestales se ha supuesto que lógicamente han evolucionado con la edad; así, los arbolados en estado de masa repoblado en 2005 han pasado 5 años después al estado monte bravo, los arbolados en estado de masa monte bravo en 2005 han pasado 5 años después al estado latizal y los arbolados en estado de masa latizal en 2005 han pasado 5 años después al estado fustal. Las zonas que en 2005 aparecían como Talas y no han sido plantadas ni regeneradas en estos 5 años, dejan de considerarse Talas para pasar a ser Matorral o Herbazal en cada caso
- Teselado: tomando como base el anterior mapa forestal 2004-2005, se fueron fotointerpretando directamente en pantalla los cambios detectados en la vegetación sobre ortofoto en color
- Codificación: las teselas, visualizadas en pantalla, fueron codificadas siguiendo las normas del mapa forestal MFE25, incluido en el IFN4. Con vistas a que los fotointerpretores tuvieran mejores referencias del tipo de vegetación de cada tesela, se ha contado con la información aportada por anteriores ortofotos anuales, cartografía de vegetación Eunis 2005 y las propias parcelas de campo del Inventario forestal 2005 (incluido en el IFN3).
- Corrección de errores: una vez codificadas las teselas de las distintas hojas, se comprobaba que no existieran teselas con campos vacíos o con valores erróneos y que no hubiera bordes defectuosos en las teselas, concentrados sobre todo en los límites entre hojas.

El Mapa Forestal 2010-2011 fue terminado con fecha febrero de 2011 y sus distintas fases abarcaron un periodo cercano al año. Sin embargo, puede presentar zonas de corta final o plantación reciente, cuya vegetación pudiera no haber sido actualizada a fecha 2011 como consecuencia de emplear una ortofoto de mediados de 2009.

Se ha seguido el límite oficial de la C.A.P.V. y de cada Territorio Histórico aportado por el Ministerio de Medio Ambiente (MMA), aunque se ha ampliado esta superficie cartografiada del País Vasco en una distancia de 1 km para evitar vacíos de información en los bordes.

En los Territorios Históricos de Bizkaia y Gipuzkoa, las Diputaciones Forales aportaron cartografía digitalizada de los rodales de diversos montes públicos, a escala aproximada de trabajo 1/5.000. En el caso de Álava, donde no se dispone de rodalización de los montes públicos, la propia guardería forestal realizó el trabajo de corrección y actualización del mapa de vegetación.

Teniendo en cuenta el interés de esta información referente a montes públicos y su grado de exactitud, se creyó conveniente emplearla en el Mapa Forestal. Una vez depurada y actualizada, se creó una capa de información de montes públicos con fecha mediados de 2010, manteniendo el número y límites de cada rodal de los citados montes públicos e incluyendo los campos propios del Mapa Forestal.

Cada parcela de campo es asignada a un estrato en función de la información del mapa forestal. Los estratos se definen en función de la especie forestal, densidad del arbolado y estado de masa o rango de edad. Se busca en la definición de estratos una homogeneidad de las teselas que lo componen en cuanto a la variable principal a estimar en el inventario: volumen de madera. Los estratos se definen de forma que tengan una superficie mínima que asegure una suficiente representación de parcelas de campo que evite que los errores de muestreo sean muy elevados, la búsqueda de esta superficie mínima lleva en ocasiones a agrupar en un estrato teselas de diferentes especies.

Se han definido 18 estratos en Álava, 12 en Bizkaia y 14 en Gipuzkoa. Los estratos correspondientes a la provincia de Bizkaia son:

Tabla 5 Estratos definidos en Bizkaia según el mapa forestal

Estrato	Formación forestal dominante	Ocupación(%)	Estado de la masa	Fracción de cabida cubierta (%)
01	Pinus radiata	>=70	Fustal. Latizal	70-100
02	Pinus radiata	>=70	Fustal. Latizal	5-69
03	Pinus radiata	>=70	Monte bravo. Repoblado	40-100
04	Pinus radiata y Pinus nigra con Quercus robur, Castanea sativa y Árboles de ribera	>=70;30<=Esp.<70	Monte bravo. Repoblado	5-39
05	Chamaecyparis lawsoniana, Pseudotsuga menziesii y Larix spp.	>=70	Todos	5-100
06	Pinus pinaster y Pinus nigra	>=70	Fustal. Latizal	5-100
07	Quercus robur y Quercus robur con Castanea sativa, Corylus avellana, Arbutus unedo o con Pinus radiata	>=70;30<=Esp.<70	Todos	5-100
08	Quercus ilex y Quercus ilex con Quercus faginea, Arbutus unedo o con Quercus robur	>=70;30<=Esp.<70	Todos	5-100
09	Eucalyptus spp.	>=70;30<=Esp.<70	Fustal. Latizal	5-100
10	Eucalyptus spp. Y Eucalyptus spp. Con Pinus radiata	>=70;30<=Esp.<70	Monte bravo. Repoblado	5-100
11	Fagus sylvatica y Fagus sylvatica con Betula spp, Castanea sativa o con Quercus robur	>=70;30<=Esp.<70	Todos	5-100
12	Árboles de ribera	>=70;30<=Esp.<70	Todos	5-100

Se han adoptado como parcelas de muestreo los vértices de la malla kilométrica de la cartografía UTM, en el sistema de referencia ED50, que están dentro de las zonas clasificadas como arbolado. De esta manera, se trata de un reparto de la muestra en los estratos con fijación proporcional, establecimiento sistemático de arranque aleatorio e intensidad de muestreo, generalmente, de una parcela por kilómetro cuadrado. Por motivos estrictamente presupuestarios, en esta cuarta edición del Inventario se midió una de cada dos parcelas.

El IFN 4 se apoya en las versiones anteriores del mismo, siguiendo la misma metodología aplicada en el IFN2, (I.C.O.N.A. 1990) donde las parcelas se materializan clavando un rejón metálico tubular de unos 15 cm de longitud y 3 cm de diámetro en el centro de cada parcela, que queda oculto y que posteriormente podrá ser localizado por un detector de metales. Las parcelas se dividen en 4 subparcelas de 5, 10 15 y 25m de radio. A la hora de medir los árboles se hará de manera selectiva en función de su diámetro normal. Según el inventario, se considerarán pies mayores aquellos árboles cuyo diámetro normal supere los 7.5cm, y pies menores, los que su diámetro oscile entre 2.5-7.5 cm y su altura supere los 1.3m. No se tendrán en cuenta ejemplares con diámetros inferiores a las 2.5 cm. Primeramente, se medirán todos aquellos árboles cuyo diámetro oscile entre 7.5-12.5cm, cuya distancia al rejón sea menor o igual a 5m. Posteriormente, se tomarán aquellos árboles cuyo diámetro oscile entre 12.5 y 22.5 cuya distancia al rejón sea igual o menor a 10m. En una tercera fase, se tomarán aquellos árboles cuyo diámetro oscile entre 22.5-42.5 cuya distancia al rejón sea menor o igual a 15m. Por último, se toman los árboles cuyo diámetro sea superior a 42.5cm y su distancia al rejón sea igual o menor a 25m. Bravo et al. (Bravo et al. 2001) demostraron que no existen diferencias significativas cuando se utilizan parcelas de 25 metros con respecto a las parcelas de 15 metros, concluyendo que se podría obviar el último radio.

El uso de parcelas de radio variable para la toma de datos de campo, implica la necesidad de utilizar factores de expansión para poder conocer los resultados por unidad de superficie. (Bravo et al. 2002). El factor de expansión es el coeficiente que multiplicado adecuadamente, convierte las parcelas concéntricas en estimaciones de las parcelas “reales” del radio máximo considerado. El factor de expansión se calcula según la siguiente expresión.

$$f = \frac{10000}{p_i * R^2} \quad (5)$$

Donde R es el radio de la parcela. De cada pie mayor se toman lo siguiente datos:

- N° de Árbol: Número correlativo de identificación del árbol, comienza en 1.
- Rumbo: Es el ángulo que forma la visual lanzada al eje del árbol con el norte magnético.
- Distancia al rejón: Distancia desde el eje del rejón hasta el mismo punto del árbol que se ha visado con la brújula.
- Especie: Especie arbórea botánica a la que pertenece
- Diámetro: Diámetro normal medido a 1.3m del suelo con forcípula.
- Altura normal: Se utiliza un hipsómetro para su medición.

- Calidad del árbol: Para analizar este parámetro se tendrán en cuenta el estado sanitario, la conformación con respecto al ideal de la especie de que se trate, la posibilidad de suministrar más o menos bienes de superior condición, el rebasamiento de la edad madura y la situación en el ecosistema.
- Forma de cubicación: El objetivo de este parámetro es separar los árboles de una misma especie en grupos más homogéneos con respecto a su forma de cubicación y así aplicarles distintas ecuaciones más ajustadas a cada perfil.
- Parámetros especiales: Información especial del árbol como corcho, resinación, aspecto, etc..

En el caso de los pies menores, se cuentan todos los que se encuentren en un círculo de radio de 5 m. Los datos tomados en campo son los siguientes:

- Especie: Especie arbórea botánica a la que pertenece
- Número de ejemplares
- Altura: Altura total media en decímetro
- Regeneración con una estimación cuantitativa

Una vez finalizada la etapa de campo, en gabinete, por aplicación de los modelos necesarios, se calculan el área basimétrica, el volumen maderable con corteza, el volumen maderable sin corteza, el volumen de leñas gruesas y el incremento anual del volumen con corteza.

Un total de 581 parcelas fueron medidas en el territorio de Bizkaia, de las cuales 118 se encuentran localizadas en la comarca de Arratia-Nervión:




Fig. 19 Mapa de distribución de las parcelas del IFN4 en Bizkaia

4.1.4. Datos LiDAR

Los datos de la nube de puntos fueron obtenidos del vuelo LiDAR de la Comunidad Autónoma del País Vasco realizado entre los días 12 de julio y el 28 de agosto del 2012.

Los componentes integrados en el sistema LiDAR fueron:

- Sistema Lite Mapper 6800 con sensor IGI LM6800i
- Sistema de Navegación: CCNS-4 de IGI
- G.P.S.: NovAtel OEM4 L12LVHW. Frecuencia de registro: 2 Hz.
- I.N.S.: AEROCONTROL IID. Frecuencia de registro: 256 Hz.



Fig. 20 Sensor láser escáner Lite Mapper 6800

Para la configuración del vuelo se utilizaron los siguientes parámetros:

Tabla 6 Parámetros del vuelo LiDAR

Características técnicas parámetros vuelo LiDAR	
Ángulo de escaneo	60 °
Frecuencia de repetición de pulso (PRR)	100 kHz
Frecuencia de escaneo	70 kHz
Divergencia del haz	<0.5 mrad
Velocidad de la aeronave	51.4 m/s
Densidad de punto	0.5 puntos/ m ²
Altura de vuelo	1500 m
Recubrimiento transversal	15%

Se trata de un vuelo genérico, integrado en el PNOA, por lo que si se analizan los parámetros del vuelo utilizado con respecto a los valores aconsejados para la realización de vuelos

destinados al análisis de masas forestales, como se ha expuesto con anterioridad en el Capítulo 1, cabe destacar los siguientes aspectos:

- Ángulo de escaneado: Un valor apropiado para este parámetros sería 12°, y tal y como se puede apreciar en la Tabla 5, el valor máximo asciende a 60°, estando muy por encima del valor recomendado.
- Divergencia del haz: El valor recomendado oscila entre 0.1 y 0.6 mrad, por lo que podemos decir que este parámetro goza de un valor apropiado para esta aplicación (0.5 mrad).
- Densidad del puntos: Pese a que la densidad de punto no ha resultado ser un parámetro determinante en la estimación de las métricas básicas, se recomienda un valor 1 punto por m², superior a la densidad nominal proporcionada.
- Altura del vuelo: El valor de la altura media para este vuelo es de 1500 m, que relacionada con una divergencia del haz de 0.5 mrad, proporciona una tamaño de huella de 0.75m, considerándose una huella de tamaño pequeño.

El sistema de referencia geodésico de los datos LiDAR es el ETRS89 (European Terrestrial Reference System 1989), basándose exclusivamente en la Red GPS de Euskadi o vértices REGENTE de la Red Geodésica Nacional. La proyección cartográfica empleada fue la UTM (Universal Transversal Mercator), referida al Huso 30 Norte. Las alturas elipsoidales fueron referidas a ETRS89 en todos los procesos de cálculo, utilizando como superficie de referencia el elipsoide GRS80. Para realizar la transformación de cotas elipsoidales a ortométricas, se utilizó el modelo de geoide EGM2008-REDNAP.

La distribución de la hojas LiDAR se basa en la cuadrícula MTN50, dividiendo cada hoja del mismo en una malla de 8x8, obteniéndose una cuadrícula de hojas de un tamaño 2x2 km.




Fig. 21 Distribución de las hojas de datos LiDAR en la C.A.P.V..

La descarga de datos se realizó en línea desde la Infraestructura de datos Espaciales (IDE) del País Vasco (<http://www.geo.euskadi.eus/s69-15375/es/>). En total se descargaron 134 hojas que albergan un total de 416.387.163 puntos, con un rango altimétrico desde 45 m hasta 1482.66 m de altitud.

4.1.5. Ortofotos

Se han empleado las ortofotos de 25 cm de píxel obtenidas a partir de los fotogramas del vuelo fotogramétrico digital efectuado entre el 23 de julio y 8 de agosto de 2012, tanto para la comprobación del estado de las parcelas como para la verificación de posibles anomalías entre los datos del IFN4 y los correspondientes datos LiDAR.

Se han obtenido en la IDE del país Vasco (Gobierno Vasco): ftp://ftp.geo.euskadi.net/cartografia/Cartografia_Basica/Ortofotos/ORTO_2012/Hojas_JPG/5000/. El sistema geodésico de referencia utilizado es el ETRS89 y como sistema de referencia de coordenadas, el UTM huso 30N.

4.1.6. Software utilizado

Actualmente existen diversas herramientas que permiten procesar nubes de puntos LiDAR. En referencia a los entornos SIG, indicar que el tratamiento de datos LiDAR es una funcionalidad que ya prácticamente incorporan de forma estándar los más comunes (ArcGIS, QGIS, Geomedia, etc...), pero las herramientas disponibles tienen una funcionalidad limitada, insuficiente para un procesado flexible de los datos.

Dentro de los programas especializados en tratamiento de este tipo de datos se pueden encontrar diferentes opciones, pero ha elegido la herramienta FUSION, versión 3.42, por varias razones: carácter de software libre en entorno Windows, ampliamente utilizado en procesado de datos LiDAR en aplicaciones forestales, con funcionalidades específicas, así como por no tener limitaciones en el volumen de datos a procesar, como ocurre con ejemplo con otro entorno también muy popular, LasTools. Destacar que permite procesar los datos usando archivos por lotes en línea de comandos, en un entorno MS-DOS, circunstancia que posibilita la automatización en el procesado de la información.

Para analizar en profundidad y con flexibilidad la nube de puntos LiDAR se optó por un gestor de BBDD de distribución libre con implementación de procesos relacionados con los datos espaciales, en particular la extensión Postgis del gestor PostgreSQL. Se ha utilizado la versión 2.1 de Postgis, bajo la versión 9.3 de PostgreSQL. PostgreSQL es un gestor de base de datos objeto-relacional, que mediante su extensión PostGis permite almacenar objetos SIG en una base de datos. Permite trabajar tanto con datos vectoriales como raster, ya que mediante la integración de una extensión raster puede almacenar y gestionar información raster en tablas como si fuera vectorial y ejecutar operaciones de análisis entre ambos tipos de datos (Martínez, 2012). PostgreSQL dispone de dos clientes para acceder a PostgreSQL: un cliente de texto de línea de comandos; *psql* y un cliente gráfico más amigable; *pgAdminIII*. Con esta herramienta se ha procedido a la implementación de los algoritmos precisos para la obtención de nuevos estadísticos.




Fig. 22 Cliente gráfico de PostgreSQL

Para el análisis estadístico de las métricas obtenidas mediante los software anteriormente descritos, se eligió el paquete estadístico R, versión 3.1.2 (R Core Team 2015) por ser, también, de carácter libre y con un alto grado de desarrollo, al ser parte de un proyecto cooperativo. R proporciona un amplio abanico de herramientas estadísticas y gráficas para el completo análisis de los datos. El interfaz más amable de R es R Commander, donde se pueden ejecutar las herramientas más básicas (Fig. 23).




Fig. 23 Interface gráfica de R

Para la visualización y análisis de datos se utilizó el S.I.G. de escritorio, ArcGIS Desktop Advanced, versión 10.2. Este sistema permite visualizar, analizar y procesar datos espaciales.

Finalmente indicar que se ha empleado FME Workbench 2015.0, un potente editor con capacidad de transformación y análisis de datos espaciales. Se ha utilizado para conversión de datos, de sistemas de referencia, etc... de los datos LiDAR (Fig. 24).




Fig. 24 Interface gráfico de FME 2015.0

4.2. Preparación y análisis de los datos

4.2.1. Obtención de los valores de biomasa de referencia

De las 118 parcelas ubicadas en la comarca de Arratia-Nerviión, se seleccionaron aquellas cuya especie predominante fuera el pino radiata con más de un 80% de ocupación, obteniendo una muestra compuesta de 67 parcelas, de la que se desecharon 4 parcelas por no tener casi arbolado, obteniendo finalmente una muestra de 63 parcelas (Fig. 4).




Fig. 25 Distribución 63 parcelas seleccionadas del IFN4 con ArcGis

En primer lugar, y conforme se ha explicado anteriormente, se procede al cálculo de los factores de expansión para conseguir valores de biomasa por hectárea:

Tabla 7 Factores de expansión

Diámetro árbol (cm)	Radio subparcela (m)	Factor de expansión
10-12.5	5	127.324
12.5-22.5	10	31.831
22.5-42.5	15	14.147
> 42.5	25	5.093

Para la obtención de los valores de biomasa por árbol individual, en función de los datos obtenidos en campo, se aplican las ecuaciones basadas en diámetro y altura detalladas en (Canga et al. 2013), donde se midieron los diámetros y las alturas de cada árbol por métodos destructivos, obteniendo un modelo por regresión lineal múltiple capaz de explicar el 94% de la variabilidad con un RMSE de 139 kg.:

$$W_{total} = 0.009892(d^2h)^{1.023} - 0.00434d^2h + 61.57 - 6.978d + 0.3463d^2 \quad (6)$$

Una vez calculada la biomasa de cada árbol, se procedió a calcular la biomasa total por hectárea referida a cada parcela acumulando la biomasa de cada árbol multiplicada por el factor de expansión que le corresponde. A modo de ejemplo, a continuación se muestra su obtención para una cierta parcela de la muestra:

Tabla 8 Detalle del proceso de obtención de biomasa para la parcela 0443

Estadillo	nArbol	Rumbo	Distanci	Especie	Dn1	Dn2	Ht	Dm	Radio	FE	Biomasa
0443	1	3	7.9	028	223	208	19.1	21.55	10	31.8310	4.5094
	2	22	5.5	028	245	228	15.3	23.65	15	14.1471	2.2260
	3	26	11.6	028	346	326	24.2	33.6	15	14.1471	6.2436
	4	50	14.1	028	248	248	18.9	24.8	15	14.1471	2.7398
	5	68	3.6	028	330	340	20.7	33.5	15	14.1471	5.7324
	6	75	11.1	028	228	224	21	22.6	15	14.1471	2.3419
	7	85	11.4	028	269	264	20.9	26.65	15	14.1471	3.3991
	8	92	7.9	028	277	285	18.4	28.1	15	14.1471	3.6080
	9	125	7.2	028	294	273	20.2	28.35	15	14.1471	3.8527
	10	126	10.1	028	231	228	20.1	22.95	15	14.1471	2.3693
	11	139	9	028	212	208	18.4	21	10	31.8310	4.1783
	12	157	9.7	028	267	273	19.8	27	15	14.1471	3.4086
	13	157	6.3	028	306	292	20.6	29.9	15	14.1471	4.3989
	14	173	14.5	028	340	345	20.4	34.25	15	14.1471	5.9906
	15	200	11.4	028	244	226	19.5	23.5	15	14.1471	2.4613
	16	209	4.5	028	135	138	9.3	13.65	10	31.8310	1.3901
	17	214	13.6	028	260	259	17.2	25.95	15	14.1471	2.9074
	18	217	7.1	028	248	241	17.4	24.45	15	14.1471	2.5482
	19	235	10.9	028	270	262	17.1	26.6	15	14.1471	3.0706
	20	259	8.4	028	255	255	18.3	25.5	15	14.1471	2.8752
	21	284	4.9	028	105	107	13	10.6	5	127.3240	4.7440
	22	291	12	028	281	276	15.5	27.85	15	14.1471	3.2717


Estadillo	nArbol	Rumbo	Distanci	Especie	Dn1	Dn2	Ht	Dm	Radio	FE	Biomasa
	23	299	6.8	028	230	246	18.9	23.8	15	14.1471	2.4939
	24	326	8	028	132	133	14.7	13.25	10	31.8310	1.5690
	25	327	14.3	028	265	288	21.4	27.65	15	14.1471	3.7445
	26	334	2.7	028	198	210	18.6	20.4	10	31.8310	3.9414
	27	352	14.2	028	315	316	23.5	31.55	15	14.1471	5.3226
	28	358	7.7	028	321	311	23.9	31.6	15	14.1471	5.3896
	29	382	12.7	028	342	348	22.6	34.5	15	14.1471	6.4046

donde:


- Estadillo: Se corresponde con el código de la parcela.
- nArbol: Número de árbol medido dentro de cada parcela.
- Rumbo: Rumbo de la línea que une el centro de la parcela con cada árbol en grados centesimales.
- Distancia: Distancia del árbol al centro de la parcela en metros.
- Especie: Código IFN.
- Dn1: Diámetro normal del árbol en milímetros.
- Dn2: Diámetro normal del árbol en milímetros.
- Ht: Altura total del árbol en metros.
- Dm: Media aritmética de los dos diámetros normales medidos en centímetros.
- Radio: Radio de la subparcela en la que se ubica cada árbol.
- FE: Factor de expansión.
- Biomasa: Biomasa observada en ton/ha.

En la bibliografía consultada se comprueba correlación entre variables dendrométricas. A continuación se muestran las relaciones, para las parcelas de control, entre variables que se podrían obtener a partir de los datos LiDAR y la biomasa obtenida, para conocer cuál puede ser el grado de correlación en los datos de muestra, en particular: nTree (número de árboles), Ht (valores de altura medios promediados por el factor de expansión a la parcela) con la biomasa.

Para comprobar si se puede considerar que los valores de control están agrupados en algún cluster o siguen un patrón espacial aleatorio, se ha aplicado el operador de auto correlación espacial I de Moran (Goodchild 1986; Griffith 1987) a las variables biomasa, altura de árbol y número de árboles. El índice I de Moran ofrece una medida resumen de la intensidad de la autocorrelación de los territorios considerados. El índice I de Moran varía entre los valores -1 y +1; cuanto más cercano a 1 sea el indicador, mayor será el nivel de autocorrelación espacial.



Given the z-score of -0.716441481447, the pattern does not appear to be significantly different than random.



Given the z-score of -1.75430434594, there is a less than 10% likelihood that this dispersed pattern could be the result of random chance.




Fig. 26 Resultado del índice I de Moran para la biomasa, la altura de árbol y el número de árboles

Tal y como se puede observar el Fig. 26 mientras que la biomasa y el número de árboles no muestran ningún nivel de agrupamiento resultando ser variables con un patrón totalmente aleatorio, no ocurre lo mismo con la altura de árbol, donde se sí se aprecia cierto nivel de agrupamiento, de tipo disperso, para una probabilidad del 0.90.




Fig. 27 Biomasa observada en las 63 parcelas

4.2.2. Obtención de métricas en base a los datos LiDAR

4.2.2.1. ANÁLISIS DEL VUELO LIDAR

Para cubrir la totalidad de la zona de estudio, se precisan un total de 134 ficheros .LAS, con una extensión de 2x2 km², y una media de dos millones de puntos por fichero. A continuación se presenta un análisis global más detallado, indicando el número de retornos por categoría de punto, clasificados conforme al estándar ASPRS. La información detallada se puede consultar en el Anejo I.

Tabla 9 Datos generales

Rango espacial	Minimo	Máximo
Coordenada X	492000	530000
Coordenada Y	4758000	4784000
Altitud	45.42	1482.66

Numero puntos por retorno	Cantidad	Porcentaje
Return1	381962402	91.7%
Return2	32079525	7.7%
Return3	2123779	0.5%
Return4	198003	0.0%
Return5	23454	0.0%
Return6	0	0.0%
Return7+	0	0.0%
Total Returns	416387163	

Categoría	Número puntos	Interpretacion
0	0	Created, never classified
1	26348.25	Unclassified
2	144894.31	Ground
3	48201484	Low Vegetation
4	17611152	Medium Vegetation
5	176795016	High Vegetation
6	1897663	Building
7	143143	Low Point (noise)
10	495649	Reserved

Si bien la densidad media está en 0.78 puntos por m², su distribución por hoja .LAS es irregular (Fig. 28). Destacar que en principio, respecto a la distribución por hojas, el número de ficheros por debajo de las especificaciones del vuelo, fijadas en 0.5 puntos por m², es muy bajo.




Fig. 28 Distribución de la densidad de punto por m²

Es importante recordar que otros vuelos LiDAR para este tipo de investigación han considerado el valor de 0.5 puntos por m² como límite inferior, con un enfoque de análisis por parcela, requiriéndose mayores densidades para otras metodologías.

Con objeto de analizar en mayor detalle este parámetro, se va a proceder a determinar la densidad según una parcela cuadrada de 50 m de lado, del orden de la parcela de control, considerando la totalidad de los puntos .LAS. El resultado que se obtiene se muestra en la figura siguiente, mostrándose en tonos verdes parcelas por encima del valor esperado, y en rojo la situación contraria. Destacar que existen zonas dispersas con valores por debajo de lo esperado, sin que haya encontrado una justificación válida para todas las zonas.




Fig. 29 Densidad por parcela de 50m de lado teniendo en cuenta todos los retornos

Si además se tiene en cuenta que, según la clasificación de los ficheros .LAS, los puntos que se van a usar responden a las categorías de terreno, vegetación media y alta, los puntos realmente disponibles se reducen al 42.4% de los iniciales, disminuyendo en consecuencia la densidad real. Si se genera nuevamente el mapa de densidades anterior, para las tres categorías indicadas, se obtendría el resultado que se muestra a continuación.




Fig. 30 Densidad según parcela de 50m de lado teniendo en cuenta todos los retornos correspondientes a las clases 2, 4 y 5

Como se puede observar, la densidad disponible para determinar la altura de los árboles es significativamente inferior a la esperada.

A continuación se procede a determinar las métricas de referencia para los valores LiDAR en las 63 parcelas de control. Este proceso se ha automatizado al máximo posible. Indicar que se han empleado dos entornos diferentes: FUSION y postGIS.

4.2.2.2 PROCESADO DE DATOS CON FUSION

En primer lugar se plantea obtener un conjunto de métricas estandarizado, asociadas a cada parcela de análisis, usando la herramienta FUSION, aprovechando la capacidad que ofrece para automatizar procesos usando ficheros por lotes desarrollados a medida.

Se ha elegido una parcela de control de la misma forma y dimensiones que la considerada en el IF, es decir, circular de 25m de radio, recortándose previamente los ficheros .LAS originales

El flujo de trabajo seguido para el procesado de los datos LiDAR es el siguiente (Fig. 31):




Fig. 31 Flujo de trabajo desarrollado en FUSION

En primer lugar es necesario asegurarse de que los datos LiDAR puedan considerarse exentos de puntos altimétricamente erróneos, debiendo tener presente que se espera que esta situación haya sido verificada por parte del proveedor de los datos. Con este objetivo se aplicó a cada uno de los ficheros originales .LAS un proceso, con la herramienta FME, para identificar y filtrar puntos erróneos. El algoritmo planteado parte de la premisa de que los puntos correctos deberán ser contiguos altimétricamente, de manera se procede como se indica:

- Se divide el rango altimétrico en un conjunto de capas altimétricas, de espesor constante, y se asigna cada punto a la capa correspondiente.
- Se detectará qué capas tienen puntos y cuáles aparecen vacías.
- Una capa se considera que contiene puntos anómalos cuando esté rodeada de capas vacías y alejada de la zona donde se concentran capas contiguas que contienen puntos, que aparecerán agrupadas lógicamente.

Con este proceso se han filtrado 172619 puntos, con un desnivel por capa de 15m, que suponen un 0.06% de los puntos, que si bien porcentualmente no son significativos, sus resultados en el análisis podrían ser desconcertantes. A modo de ejemplo, en las Tablas 10 y 11 se muestran los resultados del análisis para una cierta hoja, en la que se ha filtrado un

conjunto significativo de puntos. Indicar que en, en general, los puntos eliminados corresponden a puntos que han quedado por encima de la zona de trabajo.

Tabla 10 Resultado del filtrado de puntos para la hoja 518_4764

Número de puntos inicial	4739874
Altura máxima inicial	2296.84
Altura mínima inicial	790.73
Porcentaje puntos	99.705857
Número de puntos correctos	4725932
Altura máxima final	1360.73
Altura mínima inicial	790.73

Tabla 11 Resultados detallados del filtro obtenidos para la hoja 518_4764

Número e puntos filtrados	X min	Rango x	y Min	Rango x	z Min	Rango xz
13902	518989.3	1010.6	4762752.0	1065.4	2119.7	177.2
31	518723.3	13.3	4763400.9	35.9	1444.6	5.3
3	519006.6	769.1	4763203.1	437.5	1706.2	38.4
2	518478.2	0.5	4763461.9	0.9	1507.9	0.1
2	519004.6	5.3	4762101.8	1067.3	1621.5	0.6
1	519741.7	0.0	4762817.6	0.0	1671.0	0.0
1	518923.7	0.0	4762215.3	0.0	1479.0	0.0

Posteriormente, se pasó a extraer los puntos correspondientes a las parcelas del inventario de las hojas LiDAR.

Se comienza con el filtrado de los puntos pertenecientes al terreno. FUSION implementa un algoritmo de filtrado de puntos de terreno (Kraus and Pfeiffer, 1998), de carácter iterativo basado en el uso de superficies de ajuste. Se parte de una superficie inicial, donde todos los puntos tienen el mismo peso, que ajusta la nube de puntos a una altura que se debería situar entre los puntos de terreno y los de vegetación. Se parte de la hipótesis de que los puntos pertenecientes al terreno deberían ser más propensos a tener residuos negativos y los puntos de vegetación a aparecer con pequeños residuos negativos o residuos positivos. En base a la magnitud y sentido de los residuos obtenidos, se recalculan los pesos de cada punto y se repite el proceso iterativamente. Indicar que el peso de cada punto depende a su vez de varios parámetros, que han resultados complejos de estimar localmente. Por esta razón, para la realización de esta fase se procedió a utilizar la clasificación disponible en los .LAS, que según se ha indicado se ha realizado usando el software TerraScan de TerraSolid.

Para el desarrollo de esa rutina, se combinaron procesos de FME con el comando ClipData de FUSION para extracción de puntos mediante unas coordenadas dadas, obteniendo un .LAS con los puntos seleccionados.

Posteriormente se creó el MDT de 1 x1 m de resolución, mediante el comando de FUSION GridSurfaceCreate tomando como entrada los archivos que contenían únicamente los puntos

terreno. No se ha aplicado ningún suavizado al tratarse de puntos ya preclasificados como terreno, ya que estos filtros se suelen utilizar cuando hay presencia de retornos de vegetación. El valor otorgado a cada píxel será el valor de la media de la altura de los puntos incluidos en el píxel.




Fig. 32 Parcela 0443 clasificada según el estándar ASPRS, circular de 25m de radio




Fig. 33 MDT correspondiente a la extensión aproximada de la parcela de 1m de tamaño de píxel

Una vez confeccionados los MDTs, se procederá al cálculo del modelo digital de superficies (MDS), que combinado con el MDT permitirá la obtención del modelo de altura de dosel (MDAD), también denominado Canopy Height Model o modelo de alturas normalizado del terreno. Con este objetivo el cuarto proceso utiliza el comando CanopyModel, que usa un algoritmo que otorga a cada celda el valor del retorno más alto.

$$MDS - MDT = MDAD \quad (7)$$




Fig. 34 Parcela 0443. Modelo digital de superficies, de 1m de tamaño de píxel




Fig. 35 Parcela 0443. Modelo Digital de Alturas del Dosel, de 1m de tamaño de píxel

En el quinto y último proceso, se calculan una serie de estadísticas descriptivas para la nube de puntos en cada parcela, mediante el comando GridMetrics de FUSION. Para el cálculo de las estadísticas se tuvieron en cuenta todos aquellos puntos de la nube que fueron registrados como primer retorno y cuya altura fuera superior a 2m. Éste umbral ha sido ampliamente utilizado en la bibliografía consultada, (Gobakken et al. 2012b; Næsset 2002; Næsset 2004; Næsset et al. 2013). No se optó por filtrar las clases 4 y 5, correspondientes a alta y media vegetación respectivamente, ya que se asume que los primeros retornos por encima de 2m en zonas de denso arbolado, corresponden a puntos de vegetación. Evidentemente, se verificó que no existiesen puntos pertenecientes a otras categorías que pudiesen interferir en los resultados.

FUSION proporciona una extensa lista de valores estadísticos, tanto sobre los valores de altura como los de intensidad:

Tabla 12 Listado de métricas obtenidas con FUSION

Variable	Descripción
Total return count above 2.00	Número de retornos por encima de la altura mínima
Elev minimum	Altura mínima
Elev maximum	Altura máxima
Elev mean	Altura media
Elev mode	Moda de la altura
Elev stddev	Desviación estándar de la altura
Elev variance	Varianza de la altura
Elev CV	Coficiente de variación de la altura
Elev IQ	Rango intercuartílico de la altura
Elev skewness	Asimetría de la altura
Elev kurtosis	Curtosis de la altura
Elev AAD	Desviación media absoluta de la altura
Elev L1, L2, L3, L4	Momentos muestrales de orden 1,2,3 y 4 de la altura
Elev L CV	Coficiente de variación del momento muestral
Elev L skewness	Asimetría del momento muestral
Elev L kurtosis	Curtosis del momento muestral
Elev P01	Percentil 1 de la altura
Elev P05	Percentil 5 de la altura
Elev P10	Percentil 10 de la altura
Elev P20	Percentil 20 de la altura
Elev P25	Percentil 25 de la altura
Elev P30	Percentil 30 de la altura
Elev P40	Percentil 40 de la altura
Elev P50	Percentil 50 de la altura
Elev P60	Percentil 60 de la altura
Elev P70	Percentil 70 de la altura
Elev P75	Percentil 75 de la altura
Elev P80	Percentil 80 de la altura
Elev P90	Percentil 90 de la altura
Elev P95	Percentil 95 de la altura
Elev P99	Percentil 99 de la altura
Return 1 count above 2.00	Número de primeros retornos por encima de la altura

Variable	Descripción
Return 2 count above 2.00	Número de segundos retornos por encima de la
Return 3 count above 2.00	Número de terceros retornos por encima de la
Return 4 count above 2.00	Número de cuartos retornos por encima de la
Return 5 count above 2.00	Número de quintos retornos por encima de la
Return 6 count above 2.00	Número de sextos retornos por encima de la
Return 7 count above 2.00	Número de séptimos retornos por encima de la
Return 8 count above 2.00	Número de octavos retornos por encima de la
Return 9 count above 2.00	Número de novenos retornos por encima de la
Percentage first returns above 2.00	Porcentaje de primeros retornos por encima de la
Percentage all returns above 2.00	Porcentaje de retornos por encima de la altura
(All returns above 2.00) / (Total first	Porcentaje de retornos por encima de la altura
First returns above 2.00	Primeros retornos por encima de la altura mínima
All returns above 2.00	Todos los retornos por encima de la altura mínima
Percentage first returns above mean	Porcentaje de primeros retornos por encima de la
Percentage first returns above mode	Porcentaje de primeros retornos por encima de la
Percentage all returns above mean	Porcentaje de retornos por encima de la altura
Percentage all returns above mode	Porcentaje de retornos por encima de la moda de
(All returns above mean) / (Total first	Porcentaje de retornos por encima de la altura
(All returns above mode) / (Total first	Porcentaje de retornos por encima de la moda de
Elev MAD median	Mediana de las desviaciones absolutas sobre la
Elev MAD mode	Mediana de las desviaciones absolutas sobre la
Canopy relief ratio	Ratio de compensación del dosel
Elev quadratic mean	Media cuadrática de la altura media
Elev cubic mean	Media ccúbica de la altura media

Por último, se convirtieron los modelos obtenidos del formato nativo de FUSION para modelos del terreno “.dtm” a “.asc” ó ASCII, para su posterior integración en un S.I.G. Para esta tarea se utilizó el comando DTM2ASCII de FUSION.

4.2.2.3 INCERTIDUMBRE EN EL POSICIONAMIENTO DE LAS PARCELAS DEL IFN4

Es relevante conocer que al analizar el proceso de toma de datos en campo, en la fase de señalización de las parcelas del IF, la observación de las coordenadas correspondientes al centro de cada parcela, materializado por un rejón, fue realizada empleando un navegador GPS, constituyendo en consecuencia una observación autónoma, sin corrección diferencial alguna, por lo que se debe asumirse para la misma el error de un posicionamiento absoluto, típicamente entre 5 y 10 m en planimetría, con una fiabilidad del 95%, en buenas condiciones de observación.

Si bien esta situación no ha sido relevante hasta la fecha, si lo es cuando se pretende comparar los resultados del IF con otros datos posicionalmente mucho más precisos, como es el caso del LiDAR.

Para solventar esta situación se valoraron 2 situaciones:

- Proceder a identificar y dotar de coordenadas precisas en el sistema de referencia actual al rejón, con trabajo de campo, usando las técnicas topográfico – geodésico adecuadas.
- Plantear la hipótesis de asumir la incertidumbre anteriormente indicada, que podría ser asumida en el supuesto de que el entorno de cada parcela, desde un punto de vista de masa forestal, se mantuviese homogéneo.

Se desechó la primera opción, tanto por causas económicas evidentes como prácticas, al no tener seguridad de poder encontrar cada rejón en campo. Y con el objeto de verificar la hipótesis planteada anteriormente, se ha procedido a observar distintas parcelas próximas a la inicial, para obtener en las mismas los valores estadísticos característicos del LiDAR y analizar si los mismos son significativamente semejantes, aceptando en consecuencia que la falta de exactitud no tiene relevancia en los resultados.

En concreto se ha procedido a extraer 8 muestras, también circulares de 25m de radio, desplazadas 10m en las direcciones de una rosa de los vientos. Una vez determinados los estadísticos relevantes en el modelo de ajuste seleccionado, se procederá a validar el mismo en cada conjunto de 9 parcelas, en el siguiente capítulo.

A continuación se muestra un ejemplo de las parcelas extraídas, para una cierta parcela de la muestra.




Fig. 36 Representación del movimiento simulado de la parcela 0443

4.2.2.4. PROCESADO CON POSTGIS

La idea de obtener nuevas métricas que permitan obtener información sobre la densidad de puntos de vegetación se ha desarrollado ampliamente en números estudios por parte de varios autores, fundamentalmente en la experiencia en los países del Norte de Europa con sensores LiDAR, desde los primeros estudios (Næsset 1997), donde se han empleado estimadores sencillos, una única medida de densidad que relacionaba el número de puntos de vegetación con el número total de pulsos transmitidos, que han evolucionado a métricas más complejas (Næsset 2002), con el fin de encontrar aquellas que se ajusten mejor a la variable estudiada, en este caso la biomasa.

Para la obtención de estas métricas, y tal y como se ha argumentado anteriormente, se eligió PostGIS, complemento de PostgreSQL para desempeñar esta tarea.

Primeramente, indicar que ha sido preciso convertir los datos LiDAR en un formato entendible por PostGIS. Por lo que el primer paso fue diseñar una rutina, realizada con FME, que convierta los archivos .LAS en archivos shape (.shp), asociando a cada punto todos los atributos precisos.

Una vez transformados los datos a formato shape, una segunda fase requiere integrar estos datos directamente a PostGIS, mediante la utilidad shp2pgsql. De esta manera se ha conseguido integrar todos los datos en una única base de datos, conservando los puntos de cada parcela en tablas separadas, y manteniendo su geometría para realizar posteriores análisis espaciales.

Adicionalmente también es preciso incorporar la altitud del terreno para determinar alturas de árbol, y por consistencia con los valores obtenidos con anterioridad, se deberá usar el MDT generado en la fase anterior. Para integrar esta información en la base de datos, se utilizó el comando raster2pgsql, que análogamente al comando anterior, transforma la matriz de columnas y filas que componen la imagen, en una tabla que guarda tanto el valor de cada píxel, como su geometría.


Una vez aunada toda la información en la base de datos, se procedió a modificar las tablas correspondientes a los pulsos de cada parcela. Se añadió un campo para poder almacenar la altura terreno de cada punto extraído del MDT. Posteriormente se aplicó la función st_value que permite asignar a cada punto el valor del píxel del MDT que contenga a dicho punto y almacenarlo en el nuevo campo creado.

El siguiente paso sería añadir un campo más a cada tabla, donde se guarde la diferencia entre la elevación de cada punto menos el valor del terreno en esa misma posición, obteniendo así directamente alturas de la vegetación y una nube de puntos normalizada.

También se filtraron aquellos puntos registrados como primer retorno, tal y como se procedió al procesar los datos con FUSION, mediante sentencias SQL.

Una vez editados los datos de las parcelas de control como se ha indicado, se procedió a diseñar distintos algoritmos destinados a generar métricas de densidades por parcela. El algoritmo finalmente empleado divide la nube de puntos en 10 capas, de manera que cada capa abarca una décima parte de la diferencia entre el percentil 95 de la altura y la altura mínima predefinida, 2m. En este caso, se utiliza el percentil 95 de la altura en lugar de la altura máxima, por haber resultado ser un valor más estable (Næsset 2004 , Næsset y Gobakken, 2005).

Una vez realizada la distribución de la nube de puntos en capas, se procede a contabilizar cuantos puntos se encuentran por encima del límite inferior de cada capa y por debajo del valor correspondiente al percentil 95 de la altura, es decir, los puntos acumulados incluidos por encima de cada capa. Una vez calculado, se computa la proporción que representan esos puntos con respecto al número total de puntos, obteniendo un total de 10 densidades de puntos de vegetación para cada parcela. A estos nuevos parámetros se les ha llamado deciles tr_1, tr_2, ..., tr_10, respectivamente.



id	coordx	coordy	total_ret	h_p95	tr_1	tr_2	tr_3	tr_4	tr_5	tr_6	tr_7	tr_8	tr_9	tr_10
integer	double precis	double precis	integer	double precis										
1	503917.54	4782726.28	0	21.5357	0	0	0	0	0	0	0	0	0	0
2	503867.54	4782776.28	0	21.5357	0	0	0	0	0	0	0	0	0	0
3	503917.54	4782776.28	0	21.5357	0	0	0	0	0	0	0	0	0	0
4	503867.54	4782726.28	1152	21.5357	0.638888888	0.633680555	0.618055555	0.607638888	0.552083333	0.457465277	0.357638888	0.228298611	0.1171875	0.044270833

Fig. 37 Ejemplo de métricas obtenidas con PostGIS

En un último paso, se exportaron los resultados obtenidos por medio del comando ogr2ogr, para su futura integración con el resto de métricas de cada parcela.

Una vez obtenidas el conjunto de métricas de ambas fuentes, se confeccionaron los ficheros definitivos que contendrían las métricas conjuntas para un primer análisis.

4.3. Ajuste de los modelos

Una vez obtenidas todas las variables, se procedió al análisis estadístico de los datos para su posterior modelización. Tal y como se mencionaba anteriormente, el software elegido para desarrollar este trabajo fue el paquete estadístico R, de libre distribución.

La inmensa mayoría de los estudios realizados anteriormente sobre modelos de biomasa con datos LiDAR, han demostrado que el tipo de regresión más adecuado ha resultado ser la lineal, es por ello que, basándose en la amplia experiencia existente en este campo, se optó por este tipo de modelos (Nelson 1988; Drake 2002; Naeset y Gobakken 2008; García et al. 2010; Ioki 2014). Primeramente, al tener un gran número de variables se optó por calcular la matriz de correlación entre la variable biomasa y el resto de variables, para poder cuantificar la relación lineal entre las variables de entrada, tanto su fuerza, como su sentido. Dicha matriz calcula la correlación entre variables en base al índice de correlación de Pearson, que a su vez, estudia la

relación entre la covarianza de ambas variables y el producto de sus desviaciones típicas. El valor del coeficiente de correlación será ± 1 cuando la correlación lineal sea perfecta, tanto positiva como negativamente, mientras que adoptará el valor 0 cuando no se encuentre relación lineal entre ambas variables. También se introdujo en la matriz el valor del logaritmo neperiano de la biomasa como variable, ya que por experiencias previas (Valbuena 2014), es conocido que el utilizar la variable biomasa, suele presentar problemas de homocedasticidad en el modelo.

Posteriormente, se realizó un análisis visual de los datos que corroborase la tendencia nos proporcione una primera idea sobre la relación entre las variables, para decantarnos por un tipo de modelo u otro. Para ello se confeccionará la matriz de dispersión entre la variable explicada, la biomasa, y todas las variables explicativas calculadas. Tras esta primera inspección, conoceremos que tipo de relación (lineal, no lineal) une a la variable biomasa con cada una de las variables contempladas, y también, conoceremos la tendencia de los residuos, que puede o no ser constante (Picard, Saint-André, Henry 2012). Para apoyar el resultado visual, se calculará la matriz de correlación, en función del coeficiente de Pearson, obteniendo finalmente el conjunto de variables relevantes para la posterior modelización de la biomasa. Dicho coeficiente cuantifica la relación lineal existente entre la variable estimada y las explicativas, tomando valores entre -1 y +1. Cuando el valor del coeficiente sea ± 1 , implicará una relación lineal perfecta entre las variables, con pendiente positiva o negativa, caso que sólo ocurriría cuando la varianza fuese igual a 0. Mientras que un valor del coeficiente igual a 0 supondría que la relación lineal es inexistente, y que la variable explicativa es cuestión no sirve para predecir la variable deseada.

Una vez seleccionadas las variables mas correlacionadas, se procederá a verificar si cumplen con los requisitos de la distribución de normalidad, por medio del Test de normalidad de Shapiro-Wilk. Ésta prueba se basa en estudiar el ajuste de los datos sobre un gráfico probabilístico en el que cada dato es un punto cuyo valor de abscisa es el valor observado de probabilidad y el de la ordenada el valor esperado de probabilidad. Cuanto mayor sea el estadístico W de esta prueba, mayor será el desacuerdo con la recta de normalidad, y podrá rechazarse la hipótesis nula que asume la normalidad de la variable.

Posteriormente, se aplicarán técnicas de regresión lineal múltiple entre la variable observada biomasa, y el conjunto de variables explicativas seleccionadas anteriormente. El concepto de análisis de regresión hace referencia a encontrar la mejor relación entre las variable Y (a estimar) y el conjunto de variables explicativas (x_1, \dots, x_k) , cuantificando la fuerza de esa relación, y empleando métodos que permitan predecir los valores de la respuesta dados los valores del conjunto de regresores. Se basa en método de ajustes de mínimos cuadrados, donde se pretende calcular el valor de los coeficientes de regresión de manera que la suma de los cuadrados de los residuos sea mínima.

$$\hat{y} = b_0 + b_1x_1 + \dots + b_kx_k \quad (8)$$

donde b_0, \dots, b_k corresponden a los coeficientes de regresión

La inmensa mayoría de los estudios realizados anteriormente sobre modelos de biomasa con datos LiDAR, han demostrado que el tipo de regresión más adecuado ha resultado ser la lineal,

es por ello que, basándose en la amplia experiencia existente en este campo, se optó por este tipo de modelos (Drake et al. 2002; García et al. 2010; Nelson, Krabill, Tonelli 1988; Næsset and Gobakken 2008). Primeramente, al tener un gran número de variables se optó por calcular la matriz de correlación entre la variable biomasa y el resto de variables, para poder cuantificar la relación lineal entre las variables de entrada, tanto su fuerza, como su sentido. Dicha matriz calcula la correlación entre variables en base al índice de correlación de Pearson, que a su vez, estudia la relación entre la covarianza de ambas variables y el producto de sus desviaciones típicas. El valor del coeficiente de correlación será ± 1 cuando la correlación lineal sea perfecta, tanto positiva como negativamente, mientras que adoptará el valor 0 cuando no se encuentre relación lineal entre ambas variables. También se introdujo en la matriz el valor del logaritmo neperiano de la biomasa como variable, ya que por experiencias previas (Valbuena 2014), es conocido que el utilizar la variable biomasa, suele presentar problemas de homocedasticidad en el modelo.

Se utilizará como medida de la calidad del ajuste el coeficiente de determinación denominado R^2 . Éste valor mide la proporción de la variabilidad explicada por el modelo ajustado (Walpole et al. 2012). Este valor oscila entre 0 y 1, correspondiendo a 1 un ajuste perfecto donde todos los residuos serían igual a 0.

5. RESULTADOS Y DISCUSIÓN

5.1. Modelos de regresión para la evaluación de la biomasa

Una vez obtenidas todas las métricas de las nubes de puntos de cada una de las 63 parcelas seleccionadas en la muestra, el primer paso para poder identificar las variables más significativas a incluir en la regresión será calcular el coeficiente de correlación de Pearson, obteniendo el siguiente resultado, donde (*) indicará una correlación estadísticamente significativa de las variables a un nivel de confianza del 95%. Se calcularon tanto las correlaciones entre la biomasa observada y todas las métricas obtenidas, como la correlación existente entre las mismas y la transformación logarítmica de la biomasa estimada.

Tabla 13 Matriz de correlación entre la biomasa observada y cada una de las métricas obtenidas (* no significativa)

Variable	Coef. Pearson
Elev P90	0.72
Elev P80	0.72
Elev P75	0.72
Elev P70	0.72
Elev P95	0.71
Elev cubic mean	0.71
Elev P60	0.70
Elev P99	0.70
Elev quadratic mean	0.70
Elev maximum	0.70
Elev P50	0.68
Elev L1	0.68
Elev mean	0.68
Elev P40	0.66
Elev stddev	0.64
Elev L2	0.63
Elev variance	0.61
Elev AAD	0.61
Elev P30	0.60
Elev mode	0.59
Elev MAD median	0.55
Elev P25	0.54
tr10	0.52
Elev IQ	0.51
tr9	0.51
Elev P20	0.50
tr8	0.49
tr7	0.44
tr6	0.38
Elev P10	0.36
Canopy relief ratio	0.34

Variable	Coef. Pearson
tr5	0.33
Elev L4	0.32
(All returns above mean) / (Total first returns) * 100	0.32
Percentage all returns above mean	0.32
Percentage first returns above mean	0.32
tr4	0.28
tr3	0.26
tr1	0.25
tr2	0.25
Return 1 count above 2.00	0.25
Total return count above 2.00	0.25
Elev P05	0.24*
Elev MAD mode	0.22*
(All returns above 2.00) / (Total first returns) * 100	0.20*
Percentage all returns above 2.00	0.20*
Percentage first returns above 2.00	0.20*
Elev CV	0.03*
Elev L CV	0.03*
(All returns above mode) / (Total first returns) * 100	0.03*
Percentage all returns above mode	0.03*
Percentage first returns above mode	0.03*
Elev kurtosis	-0.02*
Elev L kurtosis	-0.04*
Elev P01	-0.05*
Elev minimum	-0.07*
Elev L skewness	-0.41
Elev skewness	-0.42
Elev L3	-0.51


Tabla 14 Matriz de correlación entre la transformación logarítmica de la biomasa observada y cada una de las métricas obtenidas (* no significativa)


Variable	Coef. Pearson
Elev P90	0.74
Elev P80	0.74
Elev P75	0.73
Elev P70	0.73
Elev P95	0.73
Elev maximum	0.73
Elev cubic mean	0.72
Elev P99	0.72
Elev P60	0.71
Elev quadratic mean	0.71
Elev P50	0.69
Elev L1	0.69
Elev mean	0.69
Elev P40	0.66
Elev stddev	0.64


Variable	Coef. Pearson
Elev L2	0.63
Elev AAD	0.61
Elev variance	0.59
Elev P30	0.59
Elev mode	0.57
Elev MAD median	0.56
Elev P25	0.54
Elev IQ	0.53
Elev P20	0.51
tr9	0.48
tr10	0.47
tr8	0.47
tr7	0.43
Elev P10	0.39
tr6	0.38
Canopy relief ratio	0.34
tr5	0.34
Elev L4	0.31
tr4	0.29
(All returns above mean) / (Total first returns) * 100	0.26
Percentage all returns above mean	0.26
Percentage first returns above mean	0.26
tr3	0.26
tr1	0.26
tr2	0.26
Elev P05	0.26
Return 1 count above 2.00	0.25
Total return count above 2.00	0.25
Elev MAD mode	0.24*
(All returns above 2.00) / (Total first returns) * 100	0.16*
Percentage all returns above 2.00	0.16*
Percentage first returns above 2.00	0.16*
Elev L CV	0.05*
Elev CV	0.04*
(All returns above mode) / (Total first returns) * 100	0.02*
Percentage all returns above mode	0.02*
Percentage first returns above mode	0.02*
Elev P01	-0.02
Elev kurtosis	-0.05*
Elev L kurtosis	-0.06*
Elev minimum	-0.06*
Elev L skewness	-0.42
Elev skewness	-0.45
Elev L3	-0.48


Tal y como se puede observar en las tablas 13 y 14, las variables, en casi su totalidad, correlan ligeramente mejor con el logaritmo de la biomasa, que con los valores de biomasa directamente estimados. Los percentiles más altos de la altura son los que poseen mayor nivel de correlación en ambos casos, siendo el percentil 90 de la altura el que apunta el valor más alto, 0.723 en el caso de la biomasa directamente estimada y 0.737 en el caso de aplicar su logaritmo. Pese a que las 10 métricas de densidad del dosel no tienen una relación tan fuerte con la biomasa, todas resultan ser, significativas, presentando los tramos más altos (tr7, tr8, tr9 y tr10) mayor correlación que aquellas métricas de densidad provistas por FUSION. Una vez verificada la correlación, se seleccionaron aquellas variables que presentaban una correlación estadísticamente significativa con el logaritmo de la biomasa, obviando el resto.


Posteriormente se procedió a verificar éstas relaciones gráficamente, tal y como se recomienda en (Picard, Saint-André, Henry 2012). Para ello, se calcularon los diagramas de dispersión entre el logaritmo de la biomasa y cada una de las variables significativas.























Fig. 38 Matriz de dispersión entre la biomasa y todas las variables

Tal y como se puede comprobar en la (Fig. 38) la relación entre el logaritmo de la biomasa y las variables seleccionadas, presentaba una relación lineal, con más o menos fuerza, reforzando de esta manera los resultados obtenidos en la prueba anterior. Es también evidente la intensa relación entre los distintos percentiles de la altura, y entre las métricas de densidades de los diferentes tramos. Este hecho advierte que la inclusión de más de un percentil en el modelo, pese a presentar altos valores de correlación, puede acarrear problemas de multicolinealidad al mismo. Una vez verificada la relación lineal entre la variable explicada y las explicativas, tal y como se adelantaba en base a la bibliografía consultada, se procede a calcular el mejor modelo utilizando la técnica de análisis de la regresión lineal múltiple.

Un concepto clave en el ajuste de un modelo lo constituyen los residuos, de modo que el ajuste de un modelo será mejor cuanto menores sean los mismos, siendo el residuo la diferencia entre el valor observado de la variable de respuesta y su predicción. Los residuos deben cumplir con ciertas hipótesis, acordes con el modelo empleado. La primera de ellas es consecuencia de asumir que las observaciones son independientes, que supone en consecuencia que también los residuos son independientes. Esta hipótesis se deberá asegurar con el método de muestreo elegido, y de hecho se ha verificado con anterioridad.

Otra de las hipótesis asume que la distribución de los residuos sea normal de esperanza cero, en principio, y por último, la tercera hipótesis parte de que la varianza de los residuos sea constante. Todas estas hipótesis se deben verificar a posteriori, ya que se trata de analizar los residuos y no las observaciones, no siendo posible calcularse hasta efectuar un primer ajuste. Se resumen las tres hipótesis en la siguiente ecuación:

$$\varepsilon_{iid} \sim N(0, \sigma) \quad (9)$$

donde $N(\mu, \sigma)$ designa la ley normal de esperanza μ y la desviación estándar σ , " ϵ_{iid} " indica que está independiente e idénticamente distribuido.

Por lo tanto, es necesario realizar una primera aproximación con la muestra compuesta de las 63 parcelas y las variables previamente mencionadas. Para ello se evalúa la influencia de todas las variables por separado en el modelo, así como las combinaciones de dos y tres variables.

Tabla 15 Valor de SE y R^2 obtenido en modelos con una sola variable explicativa

Variable	SE	R2
Elev P90	0.38	0.55
Elev P80	0.38	0.55
Elev P95	0.38	0.54
Elev P75	0.39	0.54
Elev P70	0.39	0.54
Elev maximum	0.39	0.54
Elev P99	0.39	0.53
Elev cubic mean	0.39	0.53
Elev quadratic mean	0.40	0.51
Elev P60	0.40	0.51
Elev mean	0.41	0.48
Elev L1	0.41	0.48
Elev P50	0.41	0.48
Elev P40	0.42	0.44
Elev stddev	0.43	0.42
Elev L2	0.44	0.40
Elev AAD	0.45	0.38
Elev P30	0.46	0.36
Elev variance	0.46	0.35
Elev mode	0.46	0.34
Elev MAD median	0.47	0.32
Elev P25	0.48	0.30
Elev IQ	0.48	0.28
Elev P20	0.49	0.26
tr_9	0.50	0.24
Elev L3	0.50	0.23
tr_10	0.50	0.23
tr_8	0.50	0.22
Elev skewness	0.51	0.20
tr_7	0.51	0.19
Elev L skewness	0.52	0.17
Elev P10	0.52	0.16
tr_6	0.52	0.15
Canopy relief ratio	0.53	0.12
tr_5	0.54	0.12
Elev L4	0.54	0.10
tr_4	0.54	0.09
tr_1	0.55	0.07
tr_3	0.55	0.07

Variable	SE	R2
Percentage all returns above mean	0.55	0.07
Percentage first returns above mean	0.55	0.07
(All returns above mean) / (Total first returns) * 100	0.55	0.07
Elev P05	0.55	0.07
tr_2	0.55	0.07
Total return count above 2.00	0.55	0.06
Return 1 count above 2.00	0.55	0.06
Elev MAD mode	0.55	0.06
Percentage all returns above 2.00	0.56	0.03
Percentage first returns above 2.00	0.56	0.03
(All returns above 2.00) / (Total first returns) * 100	0.56	0.03
Elev minimum	0.57	0.00
Elev L kurtosis	0.57	0.00
Elev kurtosis	0.57	0.00
Elev L CV	0.57	0.00
Elev CV	0.57	0.00
Elev P01	0.57	0.00
Percentage all returns above mode	0.57	0.00
Percentage first returns above mode	0.57	0.00
(All returns above mode) / (Total first returns) * 100	0.57	0.00

Tal y como se puede observar en la Tabla 15 el valor de R^2 máximo corresponde al modelo cuya única variable independiente es el percentil 90 de la altura, con un valor de 0.55. Los modelos que consiguen mayor coeficiente de determinación dependen de métricas obtenidas a partir de la altura LiDAR únicamente, siendo la variable tr_9 (correspondiente al ratio de densidad de puntos de la 9ª capa) la que presenta una mayor valor para R^2 en el ajuste, 0.24, claramente inferior al valor obtenido utilizando como variable el percentil 70.

Posteriormente se calcularon las combinaciones de variables dos a dos, para verificar si la inclusión de otra variable explicativa sería estadísticamente significativa en el modelo, que supone más de 1700 combinaciones, mostrándose únicamente los resultados obtenidos para los mejores modelos, pudiendo consultarse un extracto del resto de los modelos obtenidos en el Anejo III.

Una vez realizadas las regresiones lineales, es necesario verificar si los modelos cumplen con las hipótesis de partida de esta técnica de análisis. Para ello se aplicaran diferentes test estadísticos basados en hipótesis a un nivel de confianza del 95%:

- En primer lugar, se procede a aplicar a los residuos del ajuste el test de normalidad de Shapiro-Wilk, que plantea como hipótesis nula que una muestra x_1, \dots, x_n proviene de una población normalmente distribuida (Shapiro and Wilk 1965).
- El segundo paso sería comprobar la homocedasticidad de los residuos, o dicho de otra manera, analizar si la varianza de los residuos es constante. Para ello se utilizará el test de Breusch-Pagan, que fija como hipótesis nula que los residuos son homocedásticos.

- El siguiente paso comprueba que el nivel de autocorrelación de la regresión mediante el test de Durbin-Watson, para desechar posibles dependencias entre los datos que incumplirían uno de los principios fundamentales de la aplicación de la regresión lineal. Se parte de la hipótesis nula de que la autocorrelación es cero.
- Posteriormente, se procede a detectar la existencia de posibles problemas de colinealidad en el modelo, que ocurre cuando una variable del modelo es combinación lineal de otras también incluidas en el mismo. En este caso, aplicaremos el factor de inflación (VIF) de la varianza como medida de colinealidad, siendo 1 su valor óptimo, que implicaría la ausencia total de la misma (Kleinbaum, Kupper, Muller 1991)
- Otro aspecto a verificar es la linealidad del modelo. Con este objetivo se aplica el test de linealidad RESET de Ramsey, que indica si el valor esperado de la variable dependiente depende linealmente de las variables independientes, es decir, esta prueba verifica si las combinaciones no lineales de los valores ajustados ayudan a explicar la variable de respuesta. La hipótesis nula parte de considerar que sí hay dependencia lineal.
- Por último, se verifica la ausencia de valores atípicos, según el test estadístico de Bonferroni, que a un nivel de confianza del %95 por ciento, indica que no existen valores atípicos estadísticamente significativos. En este caso se parte de la hipótesis nula de la inexistencia de valores atípicos en la muestra.

Los resultados obtenidos una vez aplicados todos los test mencionados se muestran en la Tabla 16, en la que para los distintos test enumerados se proporciona el p-value, excepto para el VIF.:

Tabla 16 Resumen de los mejores modelos combinando variables dos a dos

Variables	SE	R2	R2 Ajust.	Shapiro-Wilk	Breusch-Pagan	Durbin-Watson	VIF	RESET	Bonferro ni
Elev P70-Canopy relief ratio	0.36	0.59	0.58	0.28	0.50	0.48	1.98	0.92	0.00
Elev P75-Canopy relief ratio	0.37	0.59	0.57	0.22	0.53	0.47	1.89	0.94	0.00
Elev P80-Canopy relief ratio	0.37	0.58	0.57	0.21	0.62	0.49	1.79	0.93	0.00

Tal y como se pudo deducir de la tabla, los tres modelos expuestos cumplen con casi todas las premisas de la regresión lineal, obteniendo valores muy similares tanto para el coeficiente de determinación como para el error estándar. Observar que los tres modelos evidencian la presencia de valores atípicos en la muestra con un p-value de 0.00. Para detectar si realmente se trata de parcelas clasificables como errores groseros, se ha procedido a la comprobación visual de los datos obtenidos. Se integraron los datos LiDAR, las métricas obtenidas tanto de PostGIS como de FUSION, y se revisaron sobre las ortofotos del País Vasco de los años 2011 y 2012. Se comprobó que algunas parcelas señaladas presentaban claras diferencias entre los datos del inventario y la información registrada por el sensor, tales como un número de rebotes ilógico en comparación con la biomasa estimada en campo. En varias parcelas, se identificaron errores en la clasificación de la nube de puntos, en otros 2 casos se detectó la

evidencia de tratamientos silvícolas y, por último, una parcela presentaba un valor muy bajo de biomasa (< 30 ton/ha). Tras la verificación de dichas incongruencias, se procedió a la eliminación de la muestra de 8 parcelas obteniéndose una nueva muestra final compuesta por 55 parcelas.

De nuevo se procede a recalcular la nueva matriz de correlación para poder observar los cambios producidos en la muestra.

Tabla 17 Matriz de correlación entre la biomasa observada y cada una de las métricas obtenidas (* no significativa)

Variable	Coef. Pearson
Elev P95	0.80
Elev P90	0.80
Elev P99	0.79
Elev P80	0.79
Elev P75	0.79
Elev P70	0.79
Elev cubic mean	0.78
Elev maximum	0.77
Elev P60	0.77
Elev quadratic mean	0.77
Elev P50	0.76
Elev L1	0.75
Elev mean	0.75
Elev P40	0.74
Elev stddev	0.72
Elev L2	0.70
Elev mode	0.69
Elev variance	0.69
Elev P30	0.68
Elev AAD	0.66
Elev P25	0.62
tr10	0.61
tr9	0.59
Elev MAD median	0.58
tr8	0.58
Elev P20	0.57
tr7	0.54
Elev IQ	0.51
Elev L4	0.50
tr6	0.49
(All returns above mean) / (Total first returns) * 100	0.49
Percentage all returns above mean	0.49
Percentage first returns above mean	0.49
tr5	0.44
Canopy relief ratio	0.41
Elev P10	0.39
tr4	0.38

Variable	Coef. Pearson
Percentage all returns above 2.00	0.36
(All returns above 2.00) / (Total first returns) * 100	0.35
Percentage first returns above 2.00	0.35
tr3	0.35
tr1	0.35
tr2	0.34
Return 1 count above 2.00	0.33
Total return count above 2.00	0.33
Elev MAD mode	0.26
Elev P05	0.23*
(All returns above mode) / (Total first returns) * 100	0.10*
Percentage all returns above mode	0.10*
Percentage first returns above mode	0.10*
Elev L kurtosis	0.07*
Elev CV	0.04*
Elev L CV	0.02*
Elev kurtosis	0.02*
Elev P01	0.00*
Elev minimum	-0.10*
Elev skewness	-0.40
Elev L skewness	-0.50
Elev L3	-0.60


Tabla 18 Matriz de correlación entre la transformación logarítmica de la biomasa observada y cada una de las métricas obtenidas (* no significativa)


Variable	Coef. Pearson
Elev P95	0.86
Elev P99	0.86
Elev P90	0.85
Elev maximum	0.85
gElev P80	0.84
Elev P75	0.84
Elev P70	0.83
Elev cubic mean	0.83
Elev P60	0.82
Elev quadratic mean	0.82
Elev P50	0.80
Elev L1	0.79
Elev mean	0.79
Elev P40	0.78
Elev stddev	0.76
Elev L2	0.74
Elev mode	0.71
Elev P30	0.71
Elev variance	0.70
Elev AAD	0.70
Elev P25	0.65


Variable	Coef. Pearson
Elev MAD median	0.63
tr10	0.60
tr9	0.60
tr8	0.60
Elev P20	0.60
tr7	0.57
Elev IQ	0.56
tr6	0.53
(All returns above mean) / (Total first returns) * 100	0.53
Percentage all returns above mean	0.53
Percentage first returns above mean	0.53
Elev L4	0.51
tr5	0.48
Canopy relief ratio	0.44
Elev P10	0.44
tr4	0.43
Percentage all returns above 2.00	0.41
(All returns above 2.00) / (Total first returns) * 100	0.41
Percentage first returns above 2.00	0.41
tr3	0.40
tr1	0.40
tr2	0.39
Return 1 count above 2.00	0.39
Total return count above 2.00	0.39
Elev MAD mode	0.30
Elev P05	0.26
(All returns above mode) / (Total first returns) * 100	0.16*
Percentage all returns above mode	0.16*
Percentage first returns above mode	0.16*
Elev CV	0.05*
Elev L CV	0.05*
Elev L kurtosis	0.04*
Elev kurtosis	0.00*
Elev P01	0.00
Elev minimum	-0.10*
Elev skewness	-0.50
Elev L skewness	-0.50
Elev L3	-0.50


Se puede observar como que la matriz de correlación mejora en su generalidad, aumentando el índice de Pearson para todas las variables, por lo que aumenta también el número de variables estadísticamente significativas. Tal y como ocurría con la muestra inicial, los percentiles de altura más altos son los que correlan mejor, y también parece existir una relación más correlada de la biomasa con las métricas de densidades obtenidas por PostGIS que las obtenidas por FUSION. Por último, también son significativamente mejores los resultados con la transformación logarítmica de la biomasa que con su valor directo.


Se sigue el mismo proceso de verificación visual expuesto anteriormente, confirmando la existencia de una relación lineal entre algunas variables, procediéndose a calcular las nuevas regresiones. Primeramente se obtiene la influencia de cada variable significativamente correlacionada con la biomasa en el modelo.























Fig. 39 Matriz de dispersión

La tabla resumen de los modelos obtenidos es la siguiente:

Tabla 19 Resumen de modelos con una sola variable explicativa

Variable	SE	R2
Elev P99-	0.26	0.75
Elev P95-	0.26	0.74
Elev P90-	0.27	0.73
Elev maximum-	0.27	0.73
Elev P80-	0.28	0.72
Elev P75-	0.28	0.71
Elev P70-	0.28	0.70
Elev cubic mean-	0.28	0.70
Elev P60-	0.29	0.68
Elev quadratic mean-	0.29	0.68
Elev P50-	0.31	0.65
Elev mean-	0.31	0.64
Elev L1-	0.31	0.64
Elev P40-	0.32	0.61
Elev stddev-	0.33	0.59
Elev L2-	0.34	0.56
Elev P30-	0.36	0.51
Elev mode-	0.36	0.50
Elev AAD-	0.37	0.50
Elev variance-	0.37	0.49
Elev P25-	0.39	0.43
Elev MAD median-	0.40	0.40
Elev P20-	0.41	0.37
tr_90-	0.41	0.36
tr_80-	0.41	0.36
tr_100-	0.41	0.36

Variable	SE	R2
tr_70-	0.42	0.33
Elev IQ-	0.43	0.32
Elev L skewness-	0.43	0.30
Elev skewness-	0.43	0.30
Percentage all returns above mean-	0.44	0.29
Percentage first returns above mean-	0.44	0.29
(All returns above mean) / (Total first returns) * 100-	0.44	0.29
tr_60-	0.44	0.28
Elev L4-	0.44	0.27
tr_50-	0.45	0.23
Canopy relief ratio-	0.46	0.20
Elev P10-	0.46	0.20
tr_40-	0.47	0.19
Percentage all returns above 2.00-	0.47	0.17
Percentage first returns above 2.00-	0.47	0.17
(All returns above 2.00) / (Total first returns) * 100-	0.47	0.17
tr_10-	0.47	0.16
tr_30-	0.47	0.16
Total return count above 2.00-	0.47	0.16
Return 1 count above 2.00-	0.47	0.16
tr_20-	0.47	0.16
Elev MAD mode-	0.49	0.09

Tal y como se puede observar en la Tabla 18, se obtiene nuevamente mayor correlación con la transformación logarítmica de la biomasa que con los valores directos, por lo que resulta apropiado centrarse en los modelos con variable dependiente transformada. Los coeficientes de correlación más altos corresponden a los mayores percentiles de altura, tal y como pronosticaban los valores obtenidos en la Tabla 15. Tal y como ha ocurrido con la primera muestra, las métricas obtenidas con PostGis parecen tener mayor poder de correlación con los valores de la biomasa observada.

Posteriormente se ha calculado las combinaciones entre todas las variables significativas 2 a 2. Los modelos con mayor coeficiente de determinación fueron analizados para corroborar que cumplieran con las hipótesis inherentes a la regresión lineal tal y como se ha detallado anteriormente.

El resultado de los diferentes test aplicados a los modelos que poseían un mayor coeficiente de determinación se puede consultar en la Tabla 20, donde aparece el valor de R^2 , el error estándar residual (SE) y el valor para los p-value correspondientes a cada uno de los test aplicados, excepto para VIF.

Tabla 20 Resumen de mejores modelos

	Variables	R²	R² ajust.	SE	Shapiro-Wilk	Breustch-Pagan	Durbin-Watson	VIF	RESET	Bonferro ni
1	Elev P99-(All returns above mean) / (Total first returns) * 100	0.77	0.76	0.26	0.10	0.12	0.54	1.28	0.62	0.04
2	Elev P95-(All returns above mean) / (Total first returns) * 100	0.77	0.76	0.26	0.07	0.23	0.55	1.27	0.64	0.06
3	Elev P95-tr_30	0.76	0.75	0.26	0.30	0.24	0.54	1.11	0.25	0.05
4	Total return count above 2.00-Elev P95	0.76	0.75	0.26	0.13	0.19	0.69	1.10	0.96	0.05
5	Elev P95-(All returns above 2.00) / (Total first returns) * 100	0.76	0.75	0.26	0.18	0.20	0.61	1.12	0.49	0.05
6	Elev P95-tr_20	0.76	0.75	0.26	0.10	0.23	0.58	1.10	0.28	0.06
7	Elev P95-tr_10	0.76	0.75	0.26	0.18	0.20	0.60	1.11	0.51	0.05
8	Elev P95-tr_40	0.76	0.75	0.26	0.08	0.23	0.52	1.14	0.14	0.05
9	Elev P90-(All returns above mean) / (Total first returns) * 100-	0.76	0.75	0.26	0.03	0.29	0.57	1.27	0.56	0.05

Tal y como se aprecia en la Tabla 20, hay dos modelos con idéntico nivel de determinación (0.76) y error estándar residual (0.26 ton/ha en unidades logarítmicas): el formado por el valor del percentil 99 de la altura y el porcentaje del número de retornos por encima de la media sobre el número total de retornos (Modelo 1), y el que incluye como variables predictivas el percentil 95 de la altura y la misma métrica sobre densidades utilizada en el modelo anterior (Modelo 2). El tercer modelo más influyente con un valor para R² de 0.75 y un Error Estándar (ES), idéntico al de los dos modelos anteriores, de 0.26, incluye como variable explicativa una de las métricas de densidad calculadas con PostGIS, en este caso el percentil 95 de la elevación y la métrica de densidad de puntos de vegetación correspondiente a la 3ª capa (tr3), dentro de la división de 10 capas explicada anteriormente. Tal y como se puede comprobar en la Tabla 20, el último modelo presenta problemas de normalidad en los residuos, por lo que se desecharía. Los valores para R² no difieren significativamente de uno a otro modelo, por lo que el nivel de cumplimiento de las hipótesis de partida de la técnica de regresión lineal múltiple, será decisivo a la hora de decantarse por un modelo final.

Revisando la tabla anterior, el modelo que presenta mayor coeficiente de determinación y que cumple con mayor significación estadística (mayor p-value) en los distintos tests es el modelo compuesto por el percentil 95 de la altura y la métrica de densidad correspondiente a la 3ª

capa (tr_3), ya que tanto en los test de Shapiro Wilk, Breusch-Pagan y Durbin-Watson, que son los test que confirman las hipótesis de la regresión lineal, presenta valores más alto para el p-value, aumentando de esta manera la confianza de los resultados. También en el VIF el valor es mejor, semejante en Bonferroni pero ligeramente peor en RESET, pero admisible.

A continuación, y para verificar también los resultados analíticos de los test, se realizó una verificación gráfica de los resultados de los modelos para comprobar la tendencia de los residuos. Para ello se representaron los valores ajustados y los residuos por un parte (Fig. 39), y la gráfica QQ-plot de los residuos estandarizados frente a los cuantiles teóricos por otra (Fig.40), que verificaron la homocedasticidad y normalidad de los residuos.




Fig. 40 Gráficos de dispersión entre los residuos y los valores ajustados




Fig. 41 Gráfico QQ de los residuos

Como se puede comprobar, no se observa tendencia alguna.

Por último, se realizaron las regresiones correspondientes a la combinaciones de variables tres a tres, pero en ningún caso la tercera variable resultaba ser significativa en ninguno de los modelos calculados, a un nivel de confianza del 95% con un nivel de determinación similar al conseguido con las combinaciones entre dos variables, por lo que se ha optado por considerar únicamente los modelos con mayor coeficiente de determinación formados por dos variables explicativas. Un extracto de los resultados obtenidos se pueden consultar en el Anexo III.

Por lo que se concluye que la ecuación correspondiente al mejor modelo es el siguiente:

$$\ln \text{Biomasa} = 3.237172 + (0.063358 * \text{Elev } p95) + (0.475342 * \text{tr}_3) + e \quad (10)$$

Debido a que el valor ajustado ha sido el logaritmo de la biomasa, y no directamente el valor de la biomasa, es necesaria una transformación de la ecuación para poder obtener valores directos de biomasa. El hecho de tener que transformar el modelo de unidades logarítmicas a aritméticas, implica una cierta asimetría en la distribución en unidades aritméticas, que produce, a su vez, una subestimación de la biomasa, ya que la tendencia no será hacia la media, sino hacia la moda (Baskerville 1972). Para paliar este sesgo introducido en el modelo, se debe aplicar un factor de corrección, calculado en función del error estándar de estimación de la regresión, debiendo determinarse en primer lugar siguiendo la siguiente expresión:

$$SEE = \sqrt{\frac{\ln Y_i - \ln \hat{Y}_i}{N - n}} \quad (11)$$

donde: $\ln Y_i$ se refiere al logaritmo natural de los valores i de la variable dependiente, $\ln \hat{Y}_i$ al logaritmo natural de los valores i de las estimaciones del modelos, N número de casos de la muestra y n , número de parámetros ajustados en el modelos con transformación logarítmica.

Una vez determinado, el factor de corrección se define como:

$$FC = e^{\left(\frac{SEE^2}{2}\right)} \quad (12)$$

En este caso, el factor de corrección adquiriría un valor de 1.034162913, por lo que la ecuación una vez transformada sería:

$$Biomasa \text{ (ton / ha)} = 1.034162913 * EXP(3.237172 + (0.063358 * Elev p95) + (0.475342 * tr_3)) \quad (13)$$

La biomasa obtenida en cada una de las parcelas según los el modelo desarrollado es la siguiente:

Tabla 21 Biomasa estimada aplicando el modelo desarrollado.

Estadillo	Biomasa	Diferencia
443	107.133	-29.04
477	111.125	-29.05
479	317.977	27.59
481	91.418	-32.87
495	49.880	-16.20
497	109.524	-23.47
815	210.235	-39.56
833	189.874	17.63
835	153.535	21.61
935	129.014	-4.23
937	107.702	-66.03

Estadillo	Biomasa	Diferencia
947	113.576	-35.18
949	151.481	-6.15
951	125.179	-3.57
953	171.293	-66.87
957	238.834	28.14
959	64.710	-60.38
965	165.627	-26.04
967	206.093	28.71
971	91.494	-8.66
973	99.771	23.27
975	145.567	12.65
989	90.907	14.56
993	254.395	34.91
997	146.949	20.54
1005	62.686	-21.18
1007	122.596	17.64
1021	175.534	-3.81
1025	130.292	-27.58
1039	224.317	12.50
1043	58.982	-28.42
1061	69.647	-27.97
1077	117.304	-63.10
1079	216.599	-12.62
1083	278.398	-2.34
1087	269.602	25.21
1099	247.260	6.28
1101	74.008	-20.98
1103	135.345	1.92
1109	185.036	12.33
1123	330.915	27.98
1139	64.976	-18.35
1143	85.128	-30.35
1145	155.517	14.98
1149	94.051	-52.57
1163	122.694	-0.88
1169	311.820	20.93
1171	362.181	17.44
1187	99.029	-2.86
1193	133.874	-21.98
1201	85.667	-35.34
1203	58.855	3.06
1237	96.172	31.92
1243	251.363	13.95
2131	43.757	10.25

Los resultados se pueden visualizar en el siguiente mapa:




Fig. 42 Biomasa estimada en las 55 parcelas




Fig. 43 Biomasa observada en las 55 parcelas

El resultado demostró que el número de retornos registrados como 2º pulso ó superior por encima de los 2m, era muy pequeño en comparación con el número total de puntos. Tan sólo se encontraron diferencias reseñables en 2 parcelas, donde la diferencia entre el número total de puntos y los primeros retornos ascendía al 20% y 33%, por lo que la muestra no variaba demasiado. No obstante se calculó el modelo más adecuado teniendo en cuenta todos los retornos, obteniendo idénticos resultados que al contemplar únicamente los primeros retornos. En este caso dos fueron los modelos que obtuvieron los mejores resultados, respecto al coeficiente de determinación y el valor del SE: 0.75 y 0.26 para el primer modelo y 0.74 y 0.26 para el segundo modelo. El primero de ellos coincidía con el aplicado en el caso de los primeros retornos, teniendo como variables de entrada el percentil 95 de la altura y la métrica de densidad de puntos de vegetación correspondiente a la 3ª capa (Modelo 1), mientras que el segundo se decantaba por el percentil 99 y la misma métrica de densidad como las variables más significativas en el modelo (Modelo 2).

Tal y como ocurrió con el modelo obtenido para los primeros retornos, se aplicaron los test pertinentes para la diagnosis del modelo con los dos nuevos modelos obtenidos con el siguiente resultado:

Tabla 22 Comparación modelos

Test	Modelo 1	Modelo 2	Modelo elegido
	p-value	p-value	p-value
R ²	0.75	0.74	0.75
SE	0.26	0.26	0.26
Shapiro-Wilk	0.16	0.16	0.30
Breusch-Pagan	0.21	0.27	0.24
Durbin-Watson	0.66	0.66	0.54
V.I.F.	1.1	1.09	1.11
Reset Ramsey	0.26	0.15	0.25
Bonferroni	0.047	0.04	0.05

Tal y como podemos apreciar en la Tabla 21, las diferencias para los tres test no son significativas, cumpliendo los 3 modelos con todas las premisas requeridas para la aplicación de la técnica de regresión lineal múltiple. Por lo que, se concluye que el usos de todos los retornos no aporta grandes diferencias al modelo, mientras que los primeros retornos tiene la ventaja de mostrarse más estables ante diferentes alturas de vuelo y diferentes sensores, y por lo tanto serán menos sensibles a las distintas zonas de aplicación del modelo, potenciando su utilización.

5.2. Validación del modelo

Una vez obtenido el modelo, es necesario su validación, este proceso consiste en comparar las predicciones con las observaciones independientes a las usadas para el ajuste de mismo (Rykiel 1996.). Pero cuando no se dispone de un conjunto de datos independiente, se puede subdividir la muestra inicial en varios subconjuntos, dando lugar a la validación cruzada “K veces” ó “leave-one-out”, que divide el conjunto de datos en K partes más o menos iguales y usa cada parte una vez como conjunto de datos de validación, ajustándose el modelo en función de las K-1 partes restantes. La ausencia de superposición entre los conjuntos de datos usados para el ajuste del modelo y aquellos utilizados para calcular el criterio de validación garantiza la validez de esta práctica. Este método exige más cálculos que una validación simple pero aprovecha todas las observaciones disponibles para el ajuste del modelo. El algoritmo aplicado consta de los siguientes pasos:

1. Subdivisión del conjunto de datos S_n en K subconjuntos de datos de tamaños aproximadamente iguales: $S_n^{(1)}, \dots, S_n^{(K)}$
2. Para k que va de 1 a K:
 - a. Ajustar el modelo a partir del conjunto de datos sin su k-ésima parte:

$$\frac{S_n}{S_n^{(k)}} = S_n^{(1)} \cup \dots \cup S_n^{(k-1)} \cup S_n^{(k+1)} \cup \dots \cup S_n^{(K)} \quad (14)$$

- b. Calcular el criterio de validación de dicho modelo ajustado tomando la parte restante $S_n^{(k)}$
3. Calcular el promedio de los K criterios de validación calculados.

Una vez aplicado el algoritmo con 5 subconjuntos ($K=5$), con un total de 11 elementos por subconjunto. El criterio de validación utilizado será la suma de los cuadrados de los residuos:

$$SCE = \sum_{i=1}^{n'} (Y_i' - \hat{Y}_i')^2 \quad (15)$$

Los resultados obtenidos para cada subconjunto fueron:

Tabla 23 Resultado de la validación

Subconjunto	M.S.E.	M.S.E. total
1	0.08	0.07
2	0.08	
3	0.06	
4	0.07	
5	0.05	

El valor medio de la suma de los cuadrados de los residuos oscila entre a 0.0674 y 0.0682 unidades logarítmicas, que una vez transformado a unidades aritméticas, adquiriría un valor de de aproximadamente el 0.7% del valor de biomasa medio medido en campo, por lo que el error es muy pequeño, admitiendo en consecuencia que el modelo es de aplicación a otros conjuntos similares de datos.

5.3. Comprobación del posicionamiento de las parcelas de campo

Anteriormente se ha comentado la problemática existente en el posicionamiento de las parcelas del IF, planteándose que la incidencia sería mínima si el entorno de estas parcelas fuese homogéneo. Con esta finalidad, se obtuvieron también las métricas correspondientes a las 8 nuevas parcelas generadas en el entorno de cada parcela original, trasladadas 10 metros en las 8 direcciones principales.

Para valorar la similitud, se ha elegido aplicar el test de concordancia de Cohen-Kappa, (Cohen 1960) que tiene como objetivo estimar hasta que punto dos observadores coinciden en su medición. En este caso, el observador cambiante se referiría a las 9 posibles posiciones del centro de la parcela. El coeficiente de Kappa puede tomar valores entre -1 y +1, correspondiendo a el valor +1 el mayor grado de concordancia inter-observador, mientras que el valor más cercano a -1, mostrará mayor grado de discordancia inter-observador. Un valor del coeficiente igual a 0, implicaría que la concordancia observada es causada exclusivamente por el azar. El índice de Kappa se define por:

$$k = \frac{P_o - P_e}{1 - P_e} \quad (16)$$

donde P_o es la proporción de concordancia observada (en tanto por 1) y P_e es la proporción de concordancia esperada por puro azar. En caso de acuerdo perfecto la proporción de concordancia será 1, por lo que $1 - P_e$ representa el margen de acuerdo posible no atribuible al azar.

Para calcular el error, se tomó como medida de referencia el valor del percentil 95 de la altura obtenido para cada parcela, en cada una de sus 9 posiciones. El resultado, ha sido el siguiente:

Tabla 24 Coeficientes de concordancia Cohen-Kappa entre la parcela original y las creadas en las 8 direcciones

	0	1	2	3	4	5	6	7	8
0	1	0.987	0.99	0.9652	0.955	0.977	0.977	0.98	0.98
1	0	1.000	0.99	0.9581	0.936	0.950	0.953	0.97	0.98
2	0	0.000	1.000	0.9754	0.949	0.952	0.946	0.96	0.96
3	0	0.017	0.000	1.0000	0.983	0.976	0.937	0.93	0.91
4	0	0.0000	0.0000	0.0000	1.000	0.976	0.937	0.93	0.91
5	0	0.0000	0.0000	0.0000	0.017	1.000	0.984	0.97	0.95
6	0	0.0000	0.017	-0.0003	0.017	0.017	1.000	0.99	0.96
7	0	0.0000	0.0000	0.0000	0.0000	0.017	0.017	1.000	0.98
8	0	0.017	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	1.000

Tal y como se puede observar en la tabla, los coeficientes correspondientes a la parte superior de la diagonal son muy cercanos a 1. Según la valoración del coeficiente Kappa realizada por Landis y Koch, (Landis and Koch 1977), tendríamos la siguiente tabla:

Tabla 25 Valoración del coeficiente Kappa según Landis y Koch

Coeficiente kappa	Fuerza de la concordancia
0.00	Pobre
0.01-0.20	Leve
0.21-0.40	Aceptable
0.41-0.60	Moderada
0.61-0.80	Considerable
0.81-1.00	Casi perfecta

Por lo que se puede concluir que la variabilidad introducida en la muestras por el efecto del error de posicionamiento a la hora de materializar el rejón de cada parcela, no es influyente, ya que las muestras trasladadas tiene una concordancia casi perfecta entre ellas, sin excepción, ya que el valor más bajo obtenido para el coeficiente Kappa ha sido 0.91, que

supera ampliamente el umbral de 0.81, a partir del cual se considera que la concordancia es casi perfecta, pudiéndose en consecuencia admitir la hipótesis de entornos muy homogéneos en las zonas de control para toda la muestra.

5.4. Discusión

El modelo que se ha obtenido ajusta el logaritmo de la biomasa, obtenida por aplicación de un modelo alométrico con valores dasométricos procedentes del IF4, con dos variables independientes obtenidas a partir de datos de un vuelo LiDAR, un percentil de altura y una métrica de densidad de alturas, explicando el 75.24% de la varianza de la muestra con un valor del SE de 0.26 en unidades logarítmicas




Fig. 44 Histograma de los residuos transformados obtenidos en el ajuste

La verificación de la bondad del modelo se ha efectuado analizando los residuos del ajuste, tanto a nivel analítico como gráfico. Analíticamente se ha verificado normalidad, homocedasticidad, falta de autocorrelación, colinealidad, linealidad e inexistencia de valores atípicos.

En el análisis visual de los resultados, el gráfico cuantil – cuantil o Q-Q corrobora la normalidad, pero apunta a una distribución normal con tendencia aplanada. Para analizar en profundidad esta cuestión se muestra el histograma de residuos en la figura 42. Se pueden apreciar colas moderadas, ligeramente más pesada a la derecha del gráfico, que indicaría que los residuos pierden normalidad al aumentar su valor, lo que supondría en consecuencia una cierta subestimación de la biomasa medida en campo. Se han revisado los datos, y aparecen se detectan 6 parcelas que presentan errores elevados, de más del 40% sobre la biomasa medida en campo para cada parcela, todas pertenecientes a la misma fase de desarrollo, fustal, que engloba a pies con diámetros normales superiores a 20 cm.

Si bien los residuos muestran que no hay una tendencia clara de subestimación o sobreestimación en la determinación de la biomasa, indicar que si se ha detectado una cierta sobreestimación de la altura media obtenida con los datos LiDAR respecto a la medida en campo, del orden de hasta 10m. Se esperaba una pequeña subestimación de la altura obtenida en campo, dado que la altura máxima registrada por el láser no tiene por qué coincidir con el ápice del árbol, sino con puntos situados en sus inmediaciones, que poseerán siempre menos altura (Nilsson 1996), por lo que valores tan elevados pueden ser debidos bien a errores en la toma de datos en campo, bien a desfases entre la toma de datos y el vuelo LiDAR, o a errores en la determinación de la altura con los datos LiDAR.




Fig. 45 Diagramas de dispersión entre las variables explicativas del modelo y la Biomasa observada en campo

Tal y como se puede observar en los gráficos de dispersión pertenecientes a la variable explicada con las dos variables explicativas, en la figura 43 la relación del logaritmo neperiano de la biomasa con el percentil 95 de la altura presenta una clara relación lineal, aumentando la dispersión al aumentar el valor de la biomasa.

Respecto a la métrica correspondiente a la densidad acumulada de puntos de vegetación de la tercera capa vertical obtenida al dividir en 10 capas de igual altura la nube de puntos LiDAR, desde los 2m hasta el percentil 95 de la altura, es evidente que no presenta una relación lineal con la biomasa tan clara, si bien tampoco muestra otras tendencias, como podría ser una relación exponencial o logarítmica. Si se constata una elevada dispersión, tal y como se había comprobado al observar la significación de las variables explicativas dentro del modelo, donde la mayor parte de la variabilidad del modelo lineal se explica con la variable percentil 95, mientras que la variabilidad explicada por la densidad era mucho menor.

Finalmente, y como se observa en la figura Fig. 40, que corresponde al diagrama de dispersión entre los valores ajustados de la biomasa y los residuos, el carácter aleatorio de los resultados evidencia que no hay una tendencia que nos haga pensar en otro ajuste que no sea lineal, interpretación también reforzada por el test de linealidad. En consecuencia, se puede considerar que la varianza de los residuos es constante, también contrastado por el test de homocedasticidad de Breusch-Pagan.

Por tanto, respecto a la adecuación del modelo empleado a los datos usados, con las particularidades indicadas, se puede considerar satisfactorio.

Aunque hay una clara relación lineal entre la biomasa obtenida y el diámetro medio por parcela medido en inventario, se puede observar que al aumentar la biomasa, aumenta la dispersión entre ambas variables, como se muestra en la figura 46. A este respecto, indicar que es un fenómeno conocido en el uso de modelos estadísticos cuando se trabaja con fenómenos biológicos: el aumento de la variabilidad que se observa en los resultados al aumentar la variable estudiada.




Fig. 46 Diagrama de dispersión entre el diámetro de inventario y la biomasa estimada

Tal y como se puede observar en la Figura 46 aunque hay una clara relación lineal entre la Biomasa obtenida y el diámetro medio por parcela medido en inventario, se puede observar que al aumentar la biomasa, se incrementa la dispersión entre ambas variables. Hay que tener en cuenta que al trabajar con fenómenos biológicos aparece mucha variabilidad y que dimensiones iguales de troncos pueden ó no tener la misma biomasa, en función de las condiciones de crecimiento de los árboles.

En contraste con otros modelos, indicar que (Næsset and Gobakken 2008) consiguieron estimar la biomasa empleando un modelo lineal con un R^2 de 0.88, y un RMSE de 0.25, utilizando una muestra de 1395 parcelas circulares de tamaño variable de entre 200 y 400 m² distribuidas en 10 diferentes zonas del sur de Noruega, en bosques boreales de *Pinus Sylvestris* y *Picea Abies* principalmente. Al igual que ha ocurrido en el modelo aquí presentado, se incluyeron en el ajuste únicamente los primeros retornos. Las variables explicativas fueron en su caso, el percentil 90 de la altura y una métrica de densidad, concretamente la proporción

de primeros retornos por encima de los 2m sobre el total de puntos. Tal y como ocurre con el modelo obtenido en esta investigación, encontró necesarias una métrica procedente de uno de los percentiles altos y una de las métricas de densidad de puntos de vegetación correspondientes a las capas más bajas, para poder explicar la biomasa. Aunque bien es cierto que el valor para R^2 es superior en el caso de Naeset, el valor del RMSE es muy parecido. De forma semejante a los resultados obtenidos en esta investigación, en los que los valores parciales de R^2 para cada variable por separado han sido de 0.736 y 0.147 para el percentil y la densidad respectivamente, en Noruega los valores ascendían a 0.61 y 0.21 respectivamente. El valor de la biomasa media obtenido en ambos estudios ronda los 150 ton/ha, y tampoco se ha aplicado ninguna estratificación, por lo que las condiciones son, en principio, comparables con las Bizkaia. El modelo obtiene buenos resultados, pero difiere bastante entre las diferentes regiones estudiadas, por lo que se podría esperar encontrar diferencias al comparar los coeficientes de determinación del modelo de ambos estudios por tratarse de dos zonas geográficas claramente diferentes. De hecho, se aplicó el modelo propuesto por Naeset a las parcelas ubicadas en Arratia-Nervión y el valor de R^2 decreció, aunque sólo ligeramente, probando que la variabilidad de la muestra y los factores geográficos propios de cada región son factores influyentes a la hora de obtener mejores ajustes en los modelos.

Los resultados obtenidos son acordes con los expuestos por otros autores, tal y como Hall (Hall et al. 2005) que revelaba resultados similares a los aquí obtenidos, estimando la biomasa con un valor para R^2 de 0.74 y un SE de 0.2 (en unidades logarítmicas) mediante una relación exponencial, usando también el valor transformado de la biomasa para el ajuste. En su caso, se trataba de una zona ubicada en Colorado, USA, para las especies *Pinus ponderosa* y *Pseudotsuga menziesii* en 14 parcelas con una área media de 0.32 ha y una biomasa media medida en campo de 105 ton/ha. Los datos LiDAR tenían una densidad de retornos de 1.23 puntos /m². En la experiencia de Hall, el mejor modelo para la estimación de la biomasa resultó ser exponencial, y utiliza como única variable explicativa la proporción de retornos clasificados como suelo que también son primeros retornos, sin introducir ninguna variable derivada directamente de la altura de árbol.

Los resultados en Bizkaia también están en concordancia con los obtenidos por Naeset (Næsset et al. 2011), que calculó la biomasa para una zona del sur de Noruega de 960 km² de extensión, compuesta por 35 parcelas de 1000 m² y con una densidad de puntos para el vuelo LiDAR varía entre 0.9 y 1.2 puntos/m². Naeset realizó una estratificación de la masa arbórea en 4 estratos, de los cuales el primero sería el más parecido, en relación a la biomasa media medida en campo, con la zona de trabajo seleccionada para la realización de esta tesis. Este estrato se caracteriza por ser la *Picea* la especie dominante, en estado maduro y en lugares mediana o altamente productivos. Utilizó como variables predictoras de la biomasa el percentil 50 de las alturas de los primeros retornos y el porcentaje de puntos de vegetación por encima de los 2m, del cómputo total de últimos retornos. Se usa un modelo exponencial, obteniendo la biomasa con un RMSE de 19.5% y un valor para R^2 de 0.76.

Næsset probó nuevamente métricas de densidades muy similares a las utilizadas en este estudio (Næsset et al. 2011) en bosques jóvenes situados al sur de Noruega. Dividió las muestras en 3 conjuntos, 39 parcelas circulares experimentales de 7.98 m con una biomasa media de 13.64 ton/ha, 40 parcelas de 8.61m de radio y una biomasa media de 24.52 ton/ha, y

finalmente, otras 20 parcelas cuadradas de 61x61 m² y 35.39 ton/ha de biomasa media. En el caso de bosques jóvenes, Næsset experimentó que las regresiones lineales presentaban problemas de homocedasticidad en bastantes casos, aunque finalmente obtuvo modelos lineales y no lineales con un rango para el coeficiente de determinación de 0.62 a 0.98, con un RMSE máximo de 79.5 ton/ha, con una precisión del 20-30% de la biomasa media medida en campo. Obtuvo grandes diferencias entre los RMSE de los tres tipos de muestra, que achacó a la presencia de distintas especies con distintas características biológicas y a la diferencia de biomasa media existente entre los tres grupos, ya que a mayor cantidad de biomasa mayor obtuvo mayor RMSE. Aunque el valor del coeficiente de determinación obtenido por Naesset es superior, también se observan grandes valores del RMSE al aumentar la cantidad de biomasa estimada, tal y como ocurre en Arratia-Nervión. Naesset concluyó que esta metodológica era perfectamente aplicable a masas más maduras.

Nuevamente resultaron exitosas en la estimación de la biomasa métricas indicativas de la proporción de puntos de vegetación, al realizar una estratificación de 7 clases en una zona mucho más amplia (27.390 km²) y un total de 2309 parcelas circulares de 250 m² de superficie pertenecientes al inventario forestal nacional más 127 parcelas adicionales (Gobakken et al. 2012a). En esta ocasión se realizó una clasificación de las parcelas en función del tipo de terreno mediante fotointerpretación, dividiendo la masa forestal en 4 clases en función de su productividad. Se obtuvieron modelos para las 4 clases forestales con valor para R² de entre 0.86 y 0.94 y con un RMSE máximo del 44.89% de la biomasa media medida en campo, consiguiendo los peores resultados para las masas más jóvenes. También en esta oportunidad se separaron los primeros y últimos retornos, para obtener sus métricas por separado. Tal y como se esperaba, los modelos utilizaron como variables predictivas en todos los casos, combinaciones de métricas de densidad de vegetación de ambos tipos de retornos con valores de altura obtenidos de la nube de puntos LiDAR. Los resultados fueron mejores para las clases forestales más maduras creciendo sustancialmente el valor del coeficiente de determinación (0.92) y reduciendo el RMSE hasta el 15%, valor mucho menor que el obtenido en Arratia-Nervión.

González-Ferreiro et al. (González-Ferreiro, Aranda, Miranda 2012) estimaron la biomasa para la misma especie, Pinus Radiata Don, en una muestra compuesta por 54 parcelas cuadradas de 225 m² de superficie, distribuidas en una zona de 36 km² en Galicia. En este caso el mejor modelo resultó ser exponencial, utilizando como variables de entrada un percentil de altura, la desviación estándar de la altura y su asimetría. El valor obtenido para el coeficiente de determinación del modelo fue 0.74, y el RMSE de 40.469 ton/ha, valores muy similar a los obtenidos en este estudio, aplicando el modelo a la misma especie y en dos zonas geográficas relativamente cercanas y de características similares (en ambos estudios la biomasa media=150bton/ha) y con idéntica densidad de punto. Es interesante destacar que en el estudio gallego, la densidad de pulso original era muy elevada, de 8 ptos/m², pero se realizaron tareas de “thinning” para reducir el número de pulsos de forma artificial, hasta llegar a una densidad deseada de 0.5 ptos/m², con el objetivo de poder evaluar la influencia de la densidad de punto en la precisión del modelo. Concluyeron que la reducción de la densidad de puntos no implicaba una pérdida significativa de información, apuntando que la

densidad media de 0.5 ptos/m² establecida como estándar en el PNOA puede ser suficiente para este tipo de aplicaciones.

Montealegre et al. (Montealegre et al. 2015) estimaron la biomasa del *Pinus Halapensis* mediante regresión lineal múltiple utilizando también datos públicos procedentes de los vuelos LiDAR a escala nacional, con una densidad de punto media para los datos LiDAR de 0.5 ptos/m² en la provincia de Zaragoza. Obtuvieron un modelo por regresión lineal múltiple obteniendo un R² de 0.89 y un RMSE de 7326,12 kg/ha, suponiendo un 23% de la biomasa media medida en campo. Su muestra constaba de 45 parcelas de 15m de radio distribuidas mediante un muestreo aleatorio estratificado, con una biomasa media de 30 ton/ha y una biomasa máxima de 100 ton/ha, significativamente inferior a la biomasa observada en las parcelas incluidas en este estudio. Tal y como ha ocurrido en este trabajo, las mayores correlaciones de la biomasa, según el índice de Pearson, ocurrían con los percentiles de la altura, creciendo el índice al aumentar el porcentaje o fracción de la variable, hecho lógico dado que a mayor altura mayor cantidad de ramas y acículas que pueden quedar interceptadas en el camino del láser. Análogamente a los resultados de este estudio, las métricas de densidad de dosel, tanto teniendo en cuenta todos los retornos como únicamente los primeros retornos, presentaban también alta correlación con la biomasa. A diferencia de lo acontecido en Bizkaia, la asimetría de la altura aparecía también altamente correlacionada con la biomasa, por lo que fue incluida en el modelo. Finalmente, el modelo utilizó el percentil 95 de la altura, la asimetría de la distribución de alturas y la métrica de densidad del dosel que evalúa el número de retornos por encima del umbral de 1m. A diferencia de lo observado en este estudio, pese a que la asimetría de la altura presentaba un índice de Pearson significativo a un nivel de 95% de confianza, al incluirla en el modelo resultaba no ser significativa al mismo nivel de confianza, y por lo tanto no se incluyó en el modelo final. En el caso de Zaragoza, no hubo necesidad de transformar la biomasa a su logaritmo neperiano para conseguir el mejor ajuste y cumplir los supuestos de una regresión lineal múltiple. Hay que tener en consideración que este estudio se realizó en masas monoespecíficas de *Pinus Halapensis*, donde no ha existido la variabilidad de especies ni de biomasa que sí existe en Arratia-Nerviión, por lo que es plausible que Montealegre sea capaz de explicar más variabilidad de la biomasa con su modelo.

Finalmente indicar que también se han efectuado pruebas con los valores de intensidad del vuelo LiDAR. En particular, se ha calculado la matriz de correlación de las intensidades de los primeros retornos, para aquellas parcelas con pino en estado 4, en un total de 43 parcelas, y la correlación decrecía significativamente. Se ha calculado también la matriz de correlación para aquellas parcelas con pino en un 100% de su ocupación en todos los estados, pero al estimar el modelo no se ha conseguido R² mayores de 0.643 y un RMSE de 0.283, con p99 y tr10, superando los distintas verificaciones analíticas de bondad del modelo, incluido Bonferroni.

6. CONCLUSIONES

Se destacan las siguientes conclusiones en esta investigación

1. Tal y como se proponía en el objetivo general de este trabajo, se ha obtenido un modelo capaz de estimar la biomasa aérea en ton/ha, para la especie *Pinus Radiata* D. Don en la comarca de Arratia-Nerviión y explicar su variabilidad en un 74%, por aplicación de la metodología de regresión lineal múltiple entre la biomasa y métricas obtenidas exclusivamente de una nube de puntos LiDAR con una baja densidad de punto de 0.5 pts/m². El resultado es acorde con el obtenido por otros autores aplicando metodologías similares (Hall et al. 2005; Næsset et al. 2011).
2. Se han obtenido errores de estimación significativos (60%) en algunas de las parcelas, todas ellas pertenecientes al estado de la masa 4 o Fustal, donde se suponen masas de diámetro normal superior a los 20 cm, y por tanto mayor contenido en biomasa.

Este hecho se supone relacionado con la variabilidad de la muestra. En otros estudios con mejores residuos y condiciones aparentemente semejantes, como por ejemplo (Montealegre et al. 2015) , se relata un rango de la biomasa de 70 ton/ha frente a las 319 ton/ha obtenidas en Arratia-Nerviión.

Por otro lado, la comarca de estudio muestra un relieve mucho más abrupto y con pendientes más pronunciadas, hecho que influye negativamente en la confección del MDT, como indican diversos estudios que han constatado que aumenta el error al aumentar la pendiente. También las condiciones del vuelo difieren de las recomendaciones: los valores aconsejados proponen utilizar ángulos de escaneo inferiores a los 15°, pero en el vuelo utilizado éstos valores se han visto ampliamente superados, llegando a los 25° (Su 2006). Parece lógico admitir que errores en el MDT, influirán en las métricas LiDAR, y por tanto en los resultados obtenidos.

3. El posicionamiento de las parcelas realizado con GPS y sin postproceso, que constituía una fuente de error cierta, ha resultado no tener influencia práctica en este ámbito, asumiendo un error máximo cometido de 10m, al verificarse la homogeneidad del entorno de la muestra en todas las parcelas sin excepción.
4. La transformación logarítmica de la biomasa ha proporcionado un ajuste mejor y sin problemas de heterocedasticidad, como se ha verificado que ocurre con la biomasa sin transformar.

7. FUTURAS LÍNEAS DE INVESTIGACIÓN

En base a las conclusiones anteriores, y fruto del desarrollo de la investigación, se plantean las siguientes líneas de investigación:

1. Siguiendo la misma metodología, continuando con el uso de vuelos LiDAR del PNOA y los procesos desarrollados para la obtención de las métricas, aplicarlo a otras especies arbóreas.
2. Con objeto de analizar en detalle la influencia de la morfología del terreno en la obtención de las métricas LiDAR, analizar los resultados en otros entornos claramente diferentes, con relieves más llanos, como pueden ser territorios diferentes a la cornisa Cantábrica.
3. En relación a la investigación de algoritmos alternativos a los modelos de regresión lineal múltiple, ensayar:
 - con algoritmos de minería de datos.
 - con otras fuentes de datos complementarias al LiDAR, en concreto, al uso de imágenes. En principio, por resolución geométrica, se plantea emplear los vuelos fotogramétricos del PNOA, en concreto las imágenes de cuatro bandas RGB y NIR (Infrarrojo cercano).
4. A efectos de modelar mejor el almacenamiento de carbono y gestionar los bosques de forma sostenible, para poder analizar de forma más precisa la posibilidad de la explotación comercial de la biomasa, sería adecuado estimar la biomasa desagregada en fracciones (fuste, rama, hojas y raíces).

8. BIBLIOGRAFÍA

- Andersen H, Reutebuch S, McGaughey R. 2006. A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. *Can. J. Remote Sensing*, 32(5):355-366.
- Ahmed OS, Franklin SE, Wulder MA, White JC. 2015. Characterizing stand-level forest canopy cover and height using landsat time series, samples of airborne LiDAR, and the random forest algorithm. *ISPRS Journal of Photogrammetry and Remote Sensing* 101:89-101.
- Ahmed R, Siqueira P, Hensley S. 2013. A study of forest biomass estimates from lidar in the northern temperate forests of new england. *Remote Sens Environ* 130:121-35.
- Anderson ES, Thompson JA, Crouse DA, Austin RE. 2006. Horizontal resolution and data density effects on remotely sensed LiDAR-based DEM. *Geoderma* 132(3-4):406-415.
- Axelsson P. 2000. DEM generation from laser scanner data using adaptive TIN models. *IAPRS* 34(3/W13,Istanbul, Turkey).
- Axelsson P. 1999. Processing of laser scanner data—algorithms and applications. *ISPRS Journal of Photogrammetry and Remote Sensing* 54(2-3):138-47.
- Baltsavias EP. 1999. Airborne laser scanning: Basic relations and formulas. *ISPRS Journal of Photogrammetry & Remote Sensing* 54:199-214.
- Baskerville G. 1972. Use of logarithmic regression in the estimation of plant biomass. *Canadian Journal of Forest Research* 2(1):49-53.
- Bin X, Fangfei L, Keshu Z, Zongjian L. 2008. Laser footprint size and pointing precision analysis for LiDAR systems. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37. Part1.Beijing.
- Bravo F, Del Río M, Pando V, San Martín R, Montero G, Ordoñez C, Cañellas I. 2002. El diseño de las parcelas del inventario forestal nacional y la estimación de variables dasométricas - fundación general de la universidad. .
- Bravo F, Del Río M, Pando V, San Martín R, Montero G, Ordoñez C, Cañellas I. 2001. Comprobación de los factores de expansión utilizados en las parcelas del segundo inventario forestal nacional. III Congreso Forestal De España .
- Brown S. 1997. Estimating biomass and biomass change of tropical forests: A primer. *FAO Forestry Paper* 134(Rome):55pp.
- Canga E, Dieguez-Aranda I, Afif-Khoury E, Camara-Obregon A. 2013. Above-ground biomass equations for *Pinus radiata* D. don in Asturias. *Forest Systems (INIA)* 22(3):408-415.
- Cohen J. 1960. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement* 20:37-46.

- Condés S and Riaño D. 2005. El uso del escáner láser aerotransportado para la estimación de la biomasa foliar del pinus sylvestris L. en canencia (madrid). Cuadernos De La Sociedad Española De Ciencias Forestales. 19:63-70.
- Csanyi N. CK. 2006. LiDAR data accuray: The impact of pulse repetition rate . MAPPS/ASPRS 2006 Fall Conference .
- d'Oliveira MVN, Reutebuch SE, McGaughey RJ, Andersen H. 2012. Estimating forest biomass and identifying low-intensity logging areas using airborne scanning lidar in antimary state forest, acre state, western brazilian amazon. Remote Sens Environ 124(0):479-91.
- Drake JB, Dubayah RO, Knox RG, Clark DB, Blair JB. 2002. Sensitivity of large-footprint lidar to canopy structure and biomass in a neotropical rainforest. Remote Sens Environ 81(2-3):378-92.
- Eamus D, Burrows W, McGuinness K. 2000. Review of allometric relationships for estimating woody biomass for queensland, the northern territory and western australia. Australian Greenhouse Office.
- Evans DL, Roberts SD, Parker RC. 2006. LiDAR A new tool for forest measurements. The Forestry Chronicle 82(2):211-218.
- Filin S and Pfeifer N. 2006. Segmentation of airborne laser scanning data using a slope adaptive neighborhood. ISPRS Journal of Photogrammetry and Remote Sensing 60(2):71-80.
- García M, Riaño D, Chuvieco E, Danson FM. 2010. Estimating biomass carbon stocks for a mediterranean forest in central spain using LiDAR height and intensity data. Remote Sens Environ 114(4):816-30.
- Gleason CJ and Im J. 2012. Forest biomass estimation from airborne LiDAR data using machine learning approaches. Remote Sens Environ 125:80-91.
- Gobakken T, Næsset E, Nelson R, Bollandsås OM, Gregoire TG, Ståhl G, Holm S, Ørka HO, Astrup R. 2012a. Estimating biomass in hedmark county, norway using national forest inventory field plots and airborne laser scanning. Remote Sensing of Environment 123:443.
- Gobakken T, Næsset E, Nelson R, Bollandsås OM, Gregoire TG, Ståhl G, Holm S, Ørka HO, Astrup R. 2012b. Estimating biomass in hedmark county, norway using national forest inventory field plots and airborne laser scanning. Remote Sens Environ 123(0):443-56.
- González-Ferreiro E, Aranda U, Miranda D. 2012. Estimation of stand variables in pinus radiata D. don plantations using different LiDAR pulse densities. Forestry, 85(2).
- Goodchild MF. 1986. Spatial autocorrelation . Catmog 47, Geo Books. :6-25.
- Gould SJ. 1966. Allometry and size iin ontogeny and phylogeny. Biological Reviews 41(4):587-638.

- Gregoire T, Ståhl G, Næsset E, Nelson R, Holm S. 2011. Model-assisted estimation of biomass in a LiDAR sample survey in hedamark county, norway. *Canadian Journal of Forest Research* 41:83-95.
- Griffith D. 1987. *Spatial autocorrelation: A primer*. Resource Publications in Geography, Association of American Geographers .
- Hall SA, Burke IC, Box DO, Kaufmann MR, Stoker JM. 2005. Estimating stand structure using discrete-return lidar: An example from low density, fire prone ponderosa pine forests. *For Ecol Manage* 208(1–3):189-209.
- Holmgren J, Nilsson M, Olsson H. 2003. Simulating the effects of lidar scanning angle for estimation of mean tree height and canopy closure. *Can. J. Remote Sensing* 29(5):623-632.
- Houghton RA. 2003. Why are estimates of the terrestrial carbon balance so different? *Global Change Biology* 9:500-509.
- Hyyppä H., Yu X., Hyyppä J., Kaartinen H., Kaasalainen S., Honkavaara E., Ronnholm P. 2005. Factors affecting the quality of DTM generation in forested areas. *ISPRS WG III/3, III/4, V/3 Workshop "Laser Scanning 2005"*, Enschede, the Netherlands, 36.
- I.C.O.N.A. 1990. Segundo inventario forestal nacional. explicaciones y métodos. 1986-1995. .
- Intergovernmental Panel on Climate Change. 1996. *Climate change 1995: The science of climate change*. cambridge university press, cambridge, UK, 572 pp. Cambridge University Press, Cambridge, UK :572 pp.
- Intergovernmental Panel of Climate Change. 2001. *Climate change 2001; synthesis report*. .
- Ioki K, Tsuyuki S, Hirata Y, Phua M, Wong WVC, Ling Z, Saito H, Takao G. 2014. Estimating above-ground biomass of tropical rainforest of different degradation levels in northern borneo using airborne LiDAR. *For Ecol Manage* 328:335-41.
- Jakubowski MK, Guo Q, Kelly M. 2013. Tradeoffs between lidar pulse density and forest measurement accuracy. *Remote Sens Environ* 130:245-53.
- Johansen K, Phinn S, Witte C. 2010. Mapping of riparian zone attributes using discrete return LiDAR, QuickBird and SPOT-5 imagery: Assessing accuracy and costs. *Remote Sens Environ* 114(11):2679-91.
- Kaartinen H and Hyyppä J. 2008. EuroSDR/ISPRS project, commission II "tree extraction" final report, euro SDR official publication. *European Spatial Data Research*:Dublin, Ireland 53.
- Kleinbaum D, Kupper L, Nizam A, Rosenberg E. 2014. *Applied regression analysis and other multivariable methods*. 3^o ed. Cengage Learning.
- Kleinbaum DG, Kupper LL, Muller KE. 1991. *Applied regression analysis and other multivariable methods*. 2nd Ed ed. International Thomson Publishing.

- Kraus K and Pfeifer N. 1998. Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry & Remote Sensing* 53:193-203.
- Kronseder K, Ballhorn U, Böhm V, Siegert F. 2012. Above ground biomass estimation across forest types at different degradation levels in central kalimantan using LiDAR data. *International Journal of Applied Earth Observation and Geoinformation* 18:37-48.
- Laes D, Reutebuch S, McGaughey B, Maus P, Mellin T, Wilcox C, Anhold J, Finco M, Brewer K. 2008. Practical LiDAR-acquisition considerations for forestry applications. RSASC-0111-BRIEF1. Salt Lake City, UT: U.S. Department of Agriculture, Forest Service, Remote Sensing Applications Center. :1-32.
- Landis JR and Koch GG. 1977. () . :159-174. the measurement of observer agreement for categorical data. *Biometrics* 33:159-174.
- Lefsky M., Cohen W., Harding D., Parker G., Acker S. Gower S. 2002. LiDAR remote sensing of above-ground biomass in three biomes. *Global Ecology & Biogeography* (11):393-399.
- Lefsky MA, Cohen WB, Acker SA, Parker GG, Spies TA, Harding D. 1999. Lidar remote sensing of the canopy structure and biophysical properties of douglas-fir western hemlock forests. *Remote Sens Environ* 70(3):339-61.
- Means JE, Acker SA, Harding DJ, Blair JB, Lefsky MA, Cohen WB, Harmon ME, McKee WA. 1999. Use of large-footprint scanning airborne lidar to estimate forest stand characteristics in the western cascades of oregon. *Remote Sens Environ* 67(3):298-308.
- Miller B. 1965. Laser altimetry may aid photo mapping. *Aviation Week & Space Technology* :4 pp.
- Montealegre AL, Lamelas MT, de la Riva J, García-Martín A, Escribano F. 2015. Cartografía de la biomasa aérea total en masas de pinus halepensis mill. en el entorno de zaragoza mediante datos LiDAR-PNOA y trabajo de campo . *Análisis Espacial y Representación Geográfica: Innovación y Aplicación Universidad de Zaragoza*:769-776.
- Montero G, Ruiz-Peinado R, Muñoz M. 2005. Producción de biomasa y fijación de CO₂ por los bosques españoles. *Monografías INIA: Serie Forestal* 13:274pp.
- Montero G, Alonso A, Ruiz-Peinado R. 2002. Cuantificación del potencial de las principales especies forestales españolas para el almacenamiento de carbono a medio y largo plazo. *Bosques, Sociedad y Cambio Climático. Universidad Internacional Menéndez Pelayo* :23 pp.
- Moore JR. 2010. Allometric equations to predict the total above-ground biomass of radiata pine trees. *Ann for Sci* 67(8):806.
- Naciones Unidas. 1992. Convención marco de las naciones unidas sobre el cambio climático. .
- Næsset E. 2011. Estimating above-ground biomass in young forests with airborne laser scanning *International Journal of Remote* 32(2):473.

- Næsset E and Økland T. 2002. Estimating tree height and tree crown properties using airborne scanning laser in a boreal nature reserve. *Remote Sens Environ* 79(1):105-15.
- Næsset E. 2004. Effects of different flying altitudes on biophysical stand properties estimated from canopy height and density measured with a small-footprint airborne scanning laser. *Remote Sens Environ* 91(2):243-55.
- Næsset E. 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sens Environ* 80(1):88-99.
- Næsset E. 1997. Estimating timber volume of forest stands using airborne laser scanner data. *Remote Sens Environ* 61(2):246-53.
- Næsset E and Gobakken T. 2008. Estimation of above- and below-ground biomass across regions of the boreal forest zone using airborne laser. *Remote Sens Environ* 112(6):3079-90.
- Næsset E and Gobakken T. 2005. Estimating forest growth using canopy metrics derived from airborne laser scanner data. *Remote Sens Environ* 96(3-4):453-65.
- Næsset E, Bollandsås OM, Gobakken T, Gregoire TG, Ståhl G. 2013. Model-assisted estimation of change in forest biomass over an 11 year period in a sample survey supported by airborne LiDAR: A case study with post-stratification to provide "activity data". *Remote Sens Environ* 128:299-314.
- Næsset E, Gobakken T, Solberg S, Gregoire TG, Nelson R, Ståhl G, Weydahl D. 2011. Model-assisted regional forest biomass estimation using LiDAR and InSAR as auxiliary data: A case study from a boreal forest area. *Remote Sensing of Environment* 115:3599.
- Nelson R, Oderwald R, Gregoire TG. 1997. Separating the ground and airborne laser sampling phases to estimate tropical forest basal area, volume, and biomass. *Remote Sens Environ* 60(3):311-26.
- Nelson R, Krabill W, Tonelli J. 1988. Estimating forest biomass and volume using airborne laser data. *Remote Sens Environ* 24(2):247-67.
- Nelson R, Krabill W, MacLean G. 1984. Determining forest canopy characteristics using airborne laser data. *Remote Sens Environ* 15(3):201-12.
- Nilsson M. 1996. Estimation of tree heights and stand volume using an airborne lidar system. *Remote Sens Environ* 56(1):1-7.
- Olsen RC, Puetz AM, Anderson B. 2009. Effects of lidar point density on bare earth extraction and DEM creation. *American Society for Photogrammetry and Remote Sensing Baltimore, Maryland*.
- Parresol BR. 1999. Assessing tree and stand biomass: A review with examples and critical comparisons. *For Sci* 45(4):573-93.
- Picard N, Saint-André L, Henry M. 2012. Manual for building tree volume and biomass allometric equations: From field measurement to prediction. *Food and Agricultural*

- Organization of the United Nations, Rome and Centre Coop ration Internationale En Recherche Agronomique Pour Le D veloppement, Montpellier :215 pp.
- Popescu SC. 2007. Estimating biomass of individual pine trees using airborne lidar. *Biomass Bioenergy* 31(9):646-55.
- R Core Team. 2015. R: A language and environment for statistical computing. URL [computer program]. R Foundation for Statistical Computing, Vienna, Austria.: .
- Rykiel EJ, Jr. 1996. Testing ecological models: The meaning of validation. *Ecological Modeling* 90:229-244.
- S rndal C-, Swensson B, Wretman J. 1992. Model assisted survey sampling. .
- Schiewe J. 2001. Ein regionen-basiertes verfahren zur extraktion der gel ndeoberfl che aus digitalen oberfl chen-modellen. *Photogrammetrie, Fernerkundung, Geoinformation* 2:81-90.
- Shapiro SS and Wilk MB. 1965. An analysis of variance test for normality (complete samples) *Biometrika* 52(3/4):591-611.
- Sheperd EC. 1965. Laser to watch height. *New Scientist* :33 pp.
- Sithole G and Vosselman G. 2004. Experimental comparison of filter algorithms for bare-earth extraction from airborne laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* 59(1-2):85-101.
- St hl G, Holm S, Gregoire T, Gobakken T, N sset E, Nelson R. 2011. Model-based inference for biomass estimation in a LiDAR sample survey in the county of hedmark county, norway. *Canadian Journal of Forest Research* 41:96-107.
- Su J and Bork E. 2006. Influence of vegetation, slope and lidar sampling angle on DEM accuracy. *Photogrammetric Engineering & Remote Sensing* 72:1265-1274.
- Takagi K, Yone Y, Takahashi H, Sakai R, Hojyo H, Kamiura T, Nomura M, Liang N, Fukazawa T, Miya H, et al. 2015. Forest biomass and volume estimation using airborne LiDAR in a cool-temperate forest of northern hokkaido, japan. *Ecological Informatics* 26, Part 3:54-60.
- Ter-Mikaelian MT and Korzukhin MD. 1997. Biomass equations for sixty-five north american tree species. *For Ecol Manage* 97(1):1-24.
- Treitz P, Lim K. W, M., Pitt D, Nesbitt D, Etheridge D. 2012. LiDAR sampling density for forest resource inventories in ontario, canada *Remote Sensing* 4:830-848.
- Valbuena MA. 2014. Determinaci n de variables forestales de masa y de  rboles individuales mediante delineaci n de copas a partir de datos LiDAR aerotransportado. .
- van HanseN N and V gtle T. 1999. Extraktion de gel ndeoberfl che aus flugzeuggetragenen laserscanner-aufnahmen. *Photogrammetrie, Fernerkundugn, Geoinformation* 4:229-236.
- Vosselman G. 2000. Slope based filtering of laser altimetry data. *IAPRS*, V 43.

- Walpole RE, Myers RH, Myers SL, Ye K. 2012. Probabilidad y estadística para ingeniería y ciencias. Novena ed. Pearson Educational.
- White JC, Wulder MA, Varhola A, Vastaranta M, Coops NC, Cook BD, Pitt D, Woods M. 2013. A best practices guide for generating forest inventory attributes from airborne laser scanning data using an area-based approach (version 2.0). .
- Yu X, Hyyppä J, Hyyppä H, Maltamo M. 2004. Effects of flight altitude on tree height estimation using Airborne laser scanning. International Archives of the International Society for Photogrammetry and Remote Sensing 36(8/W2).
- Zhao F, Guo Q, Kelly M. 2012. Allometric equation choice impacts lidar-based forest biomass estimates: A case study from the sierra national forest, CA. Agric for Meteorol 165:64-72.
- Zhao K, Popescu S, Meng X, Pang Y, Agca M. 2011. Characterizing forest canopy structure with lidar composite metrics and machine learning. Remote Sens Environ 115(8):1978-96.
- Zianis D and Seura SM. 2005. Biomass and stem volume equations for tree species in europe. Finnish Society of Forest Science, Finnish Forest Research Institute.
- Zolkos SG, Goetz SJ, Dubayah R. 2013. A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing. Remote Sens Environ 128:289-98.

9. ANEJOS

ANEJO I

1. Resumen de datos dasométricos de las parcelas :del IFN4

- D_medio: Diámetro medio de la parcela (cm)
- Ht_media: Altura media de la parcela (m)
- Clase: Clase diámetrica a la que pertenece
- N_arboles: N° de árboles expandido por parcela
- Biomasa_total: Biomasa total por parcela (ton/ha)

Estadillo	D_medio	Ht_media	Clase	N_arboles	Biomasa_total
443	21.64	17.41	3	120.14	107.13
477	24.11	21.97	2	106.25	111.12
479	36.94	20.67	3	67.25	317.98
481	27.47	20.23	2	67.36	91.42
495	12.86	10.82	2	225.00	49.88
497	24.38	20.42	2	106.94	109.83
813	20.96	18.91	2	77.78	56.98
815	41.65	32.35	2	47.00	210.24
833	35.13	21.99	2	76.22	189.87
835	18.17	16.37	4	286.42	153.53
933	50.89	25.59	2	18.78	117.62
935	23.27	17.36	4	120.06	129.01
937	33.59	24.89	2	43.89	107.70
939	27.76	24.22	3	54.08	100.14
947	26.11	21.11	2	88.89	113.58
949	23.30	19.82	2	143.75	151.48
951	27.62	21.43	2	88.19	125.18
953	45.23	25.55	2	35.89	171.29
957	42.31	19.91	2	62.33	238.83
959	27.11	19.25	2	48.61	64.71
965	45.68	27.58	2	33.11	165.63
967	51.38	31.33	2	29.78	206.09
969	16.36	11.97	2	61.81	22.29
971	26.38	20.34	2	75.69	91.49
973	25.75	16.13	2	94.44	99.77
975	29.11	24.36	2	86.81	145.57
987	32.58	25.74	2	112.11	250.96
989	18.67	16.68	3	161.11	90.91
993	33.51	25.15	3	99.58	254.39
997	33.56	23.04	1	66.67	146.95
1005	18.09	13.32	2	138.89	62.69
1007	37.41	17.20	2	48.44	122.60
1021	31.66	24.79	3	82.25	175.53

Estadillo	D_medio	Ht_media	Clase	N_arboles	Biomasa_total
1025	31.47	24.42	3	62.03	130.29
1039	19.46	18.07	4	299.92	224.32
1043	15.34	13.24	2	187.50	58.98
1061	14.29	13.95	3	227.78	69.65
1065	16.51	15.77	3	127.78	51.63
1077	33.82	26.23	2	47.44	117.30
1079	44.64	29.39	2	43.89	216.60
1083	55.52	34.74	1	32.00	278.40
1087	41.70	22.82	3	68.03	269.60
1099	48.95	33.86	2	37.56	247.26
1101	16.95	12.66	3	172.92	74.01
1103	34.85	23.21	3	49.14	135.34
1109	26.86	20.20	3	117.97	185.04
1123	40.72	30.78	2	80.00	330.91
1139	16.84	14.01	1	168.75	64.98
1143	24.24	19.41	2	81.25	85.13
1145	31.55	21.78	3	78.69	155.52
1149	23.67	15.49	3	48.25	94.05
1163	22.63	21.28	3	126.69	122.69
1165	26.49	18.70	3	107.92	163.12
1169	53.64	30.81	2	40.56	311.82
1171	30.25	18.20	3	96.25	362.18
1187	25.15	18.44	2	90.97	99.03
1193	44.36	25.76	2	29.11	133.87
1201	22.67	17.10	3	101.69	85.67
1203	19.16	12.80	2	124.31	58.86
1221	36.72	18.46	3	76.75	273.64
1237	17.91	12.19	3	227.08	96.17
1243	54.28	29.72	2	32.78	251.36
2131	33.72	14.26	2	23.22	43.76

- Radio: Radio de la parcela (m)
- N_inv: N° de árboles inventariados en la parcela
- N_exp: N° de árboles expandido por parcela
- Biomasa_min: Biomasa mínima observada mínima por parcela (kg)
- Biomasa_max: Biomasa máxima observada mínima por parcela (kg)
- Biomasa_media: Biomasa media observada mínima por parcela (kg)
- Biomasa_total: Biomasa total observada mínima por parcela (kg)

Estadillo	Radio	N_inv	N_exp	Biomasa_min	Biomasa_max	Biomasa_media	Biomasa_total
443	10	5	31	43.7	141.7	97.9	489.7
443	15	23	64	157.3	452.7	266.8	6135.6
443	5	1	25	37.3	37.3	37.3	37.3
477	10	5	31	89.6	146.2	117.7	588.5
477	15	27	75	170.1	420.8	241.9	6530.9
479	10	1	6	88.6	88.6	88.6	88.6
479	25	36	36	980.9	3438.7	1693.0	60949.1
479	5	1	25	37.3	37.3	37.3	37.3
481	10	1	6	113.8	113.8	113.8	113.8
481	15	22	61	159.7	542.4	282.1	6205.9
495	10	16	100	42.0	75.6	50.3	804.9
495	5	5	125	36.8	40.5	38.1	190.5
497	10	6	38	106.8	159.4	132.9	797.1
497	15	25	69	169.3	371.4	238.8	5970.2
813	10	8	50	51.2	156.5	105.0	840.1
813	15	10	28	177.0	267.0	213.7	2137.3
815	15	9	25	389.1	910.3	652.1	5868.5
815	25	22	22	839.8	1628.4	1135.4	24978.3
833	15	26	72	178.0	744.9	468.6	12184.3
833	25	4	4	725.3	1001.4	859.1	3436.5
835	10	31	194	50.0	156.5	97.0	3006.6
835	15	15	42	131.9	296.0	203.3	3049.7
835	25	1	1	906.3	906.3	906.3	906.3
835	5	2	50	36.1	43.0	39.6	79.1
933	15	1	3	551.4	551.4	551.4	551.4
933	25	16	16	660.3	2707.2	1347.7	21562.5
935	10	6	38	60.4	156.2	114.0	683.8
935	15	20	56	149.4	582.1	332.7	6654.0
935	25	2	2	798.9	891.6	845.2	1690.5
935	5	1	25	35.4	35.4	35.4	35.4
937	15	14	39	225.6	773.1	418.9	5864.9
937	25	5	5	805.5	1079.3	971.2	4855.9
939	10	3	19	47.7	117.2	74.0	222.1

Estadillo	Radio	N_inv	N_exp	Biomasa_min	Biomasa_max	Biomasa_media	Biomasa_total
939	15	12	33	313.4	690.6	487.2	5845.8
939	25	2	2	924.8	1110.7	1017.7	2035.5
947	10	4	25	94.4	159.0	125.7	502.8
947	15	23	64	155.9	578.9	299.9	6897.0
949	10	11	69	43.1	154.0	90.8	998.9
949	15	27	75	163.9	668.3	313.3	8460.1
951	10	3	19	129.8	163.9	151.6	454.7
951	15	25	69	157.5	582.2	313.0	7825.3
953	15	5	14	427.5	675.7	555.7	2778.6
953	25	22	22	735.4	1705.9	1177.9	25914.8
957	15	12	33	156.3	716.5	446.8	5361.1
957	25	29	29	705.7	1842.5	1103.6	32003.0
959	10	2	13	69.4	161.4	115.4	230.9
959	15	13	36	198.3	479.6	311.9	4054.6
965	15	4	11	430.2	803.7	618.4	2473.5
965	25	22	22	817.5	1638.5	1165.9	25650.1
967	15	1	3	617.2	617.2	617.2	617.2
967	25	27	27	959.1	2689.6	1435.3	38751.8
969	10	9	56	42.6	104.8	62.6	563.2
969	15	2	6	153.7	154.6	154.2	308.3
971	10	1	6	144.1	144.1	144.1	144.1
971	15	25	69	153.9	401.8	245.7	6143.1
973	10	4	25	97.0	126.1	112.3	449.4
973	15	25	69	154.1	532.0	241.7	6041.3
975	10	1	6	163.9	163.9	163.9	163.9
975	15	29	81	164.3	638.1	342.1	9920.7
987	15	40	111	166.0	755.8	435.0	17399.2
987	25	1	1	945.6	945.6	945.6	945.6
989	10	16	100	45.7	141.1	91.9	1470.6
989	15	13	36	145.7	339.0	207.9	2703.1
989	5	1	25	46.0	46.0	46.0	46.0
993	10	1	6	72.3	72.3	72.3	72.3
993	15	30	83	184.4	846.4	456.1	13681.7
993	25	10	10	891.1	1380.3	1149.4	11493.7
997	15	24	67	292.1	570.5	432.8	10387.2
1005	10	20	125	45.4	137.0	79.8	1595.5
1005	15	5	14	142.2	198.5	168.2	841.1
1007	15	16	44	284.3	659.7	454.9	7279.1
1007	25	4	4	759.1	1324.8	963.0	3851.9
1021	10	1	6	123.4	123.4	123.4	123.4
1021	15	27	75	172.8	789.7	434.9	11741.3
1021	25	1	1	1079.9	1079.9	1079.9	1079.9
1025	10	1	6	167.6	167.6	167.6	167.6

Estadillo	Radio	N_inv	N_exp	Biomasa_min	Biomasa_max	Biomasa_media	Biomasa_total
1025	15	19	53	160.4	727.9	413.6	7857.5
1025	25	3	3	816.7	994.1	902.9	2708.7
1039	10	21	131	42.2	154.9	95.8	2012.8
1039	15	33	92	142.4	845.7	291.6	9621.4
1039	25	2	2	786.3	833.6	809.9	1619.8
1039	5	3	75	38.7	43.9	41.6	124.7
1043	10	26	163	46.9	111.2	65.0	1690.7
1043	5	1	25	40.6	40.6	40.6	40.6
1061	10	24	150	44.9	146.4	68.3	1638.5
1061	15	1	3	209.2	209.2	209.2	209.2
1061	5	3	75	36.7	39.3	38.0	114.1
1065	10	16	100	49.8	151.1	84.8	1356.5
1065	15	1	3	170.3	170.3	170.3	170.3
1065	5	1	25	47.5	47.5	47.5	47.5
1077	15	16	44	312.6	797.0	460.1	7361.4
1077	25	3	3	840.7	896.4	861.5	2584.4
1079	15	5	14	411.5	812.8	605.9	3029.7
1079	25	30	30	834.4	2115.5	1137.1	34113.5
1083	25	32	32	921.7	2831.3	1708.2	54663.4
1087	10	1	6	145.2	145.2	145.2	145.2
1087	15	10	28	223.3	653.3	507.0	5070.5
1087	25	34	34	684.7	2011.5	1116.0	37944.3
1099	15	2	6	315.4	715.9	515.6	1031.3
1099	25	32	32	1015.2	2149.6	1427.6	45684.6
1101	10	17	106	43.5	127.4	95.5	1622.7
1101	15	6	17	144.0	202.7	167.2	1003.3
1101	5	2	50	31.8	32.3	32.0	64.1
1103	10	1	6	38.3	38.3	38.3	38.3
1103	15	14	39	372.7	775.4	578.8	8103.8
1103	25	4	4	848.4	1025.4	956.2	3824.8
1109	10	7	44	45.6	116.2	70.8	495.9
1109	15	26	72	154.8	704.6	436.7	11354.1
1109	25	2	2	777.5	915.7	846.6	1693.2
1123	15	18	50	366.7	887.9	610.9	10995.3
1123	25	30	30	866.5	1793.0	1147.7	34432.3
1139	10	27	169	46.1	137.6	75.6	2041.3
1143	10	5	31	70.6	133.0	98.6	493.1
1143	15	18	50	160.2	416.1	272.7	4907.9
1145	10	1	6	135.6	135.6	135.6	135.6
1145	15	25	69	199.1	732.8	388.8	9719.5
1145	25	3	3	833.6	992.5	896.6	2689.7
1149	10	1	6	41.1	41.1	41.1	41.1
1149	25	17	17	740.6	1432.4	1021.8	17369.8

Estadillo	Radio	N_inv	N_exp	Biomasa_min	Biomasa_max	Biomasa_media	Biomasa_total
1149	5	1	25	33.6	33.6	33.6	33.6
1163	10	13	81	87.3	159.4	129.1	1678.4
1163	15	16	44	175.2	327.9	236.1	3777.6
1163	25	1	1	3107.7	3107.7	3107.7	3107.7
1165	10	9	56	46.1	153.6	106.1	955.2
1165	15	15	42	184.2	787.9	338.9	5083.9
1165	25	10	10	831.0	1652.6	1193.6	11935.6
1169	15	2	6	442.1	762.1	602.1	1204.2
1169	25	35	35	892.7	3020.5	1653.7	57880.8
1171	10	1	6	100.8	100.8	100.8	100.8
1171	25	40	40	870.3	3359.7	1723.8	68951.8
1171	5	2	50	30.5	30.8	30.6	61.3
1187	10	3	19	48.0	109.8	88.1	264.3
1187	15	26	72	151.5	440.8	246.4	6405.2
1193	15	4	11	282.5	768.2	560.1	2240.2
1193	25	18	18	749.6	1829.5	1114.6	20063.3
1201	10	9	56	48.7	148.2	114.3	1029.1
1201	15	16	44	150.9	285.1	201.6	3225.2
1201	25	1	1	1429.9	1429.9	1429.9	1429.9
1203	10	19	119	61.7	129.5	90.5	1719.3
1203	15	2	6	142.6	149.1	145.9	291.7
1221	10	3	19	34.6	79.0	56.4	169.2
1221	15	9	25	121.5	665.0	305.6	2750.0
1221	25	33	33	788.7	2584.0	1364.6	45032.6
1237	10	31	194	45.9	126.2	86.0	2665.2
1237	15	3	8	135.4	171.5	147.4	442.2
1237	5	1	25	39.9	39.9	39.9	39.9
1243	15	1	3	682.8	682.8	682.8	682.8
1243	25	30	30	887.4	2822.7	1581.9	47458.4
2131	15	8	22	132.8	556.3	356.3	2850.3
2131	25	1	1	674.1	674.1	674.1	674.1

- D_min: Diámetro mínimo por parcela (cm)
- D_max: Diámetro máximo por parcela (cm)
- D_medio: Diámetro medio por parcela (cm)
- Ht_min: Altura mínima por parcela (m)
- Ht_max: Altura máxima por parcela (m)
- Ht_media: Altura media por parcela (m)
- Anchura_min: Anchura de corona mínima por parcela
- Anchura_max: Anchura de corona máxima por parcela
- Anchura_media: Anchura de corona media por parcela

Estadillo	Radio	D_min	D_max	D_medio	Ht_min	Ht_max	Ht_media	Anchura_min	Anchura_max	Anchura_media
443	10	13.3	21.6	18.0	9.3	19.1	16.0	2.5	3.5	3.1
443	15	22.6	34.5	27.8	15.3	24.2	19.8	3.6	5.1	4.3
443	5	10.6	10.6	10.6	13.0	13.0	13.0	2.1	2.1	2.1
477	10	17.6	21.4	19.5	18.4	22.6	20.2	3.0	3.4	3.2
477	15	22.6	32.2	26.0	20.0	26.7	22.7	3.5	4.5	3.9
479	10	17.9	17.9	17.9	16.8	16.8	16.8	3.1	3.1	3.1
479	25	45.6	78.3	57.6	21.5	36.5	29.3	5.8	8.9	7.1
479	5	12.0	12.0	12.0	9.2	9.2	9.2	2.6	2.6	2.6
481	10	19.8	19.8	19.8	17.9	17.9	17.9	3.3	3.3	3.3
481	15	23.0	37.1	28.3	16.9	24.8	20.5	3.7	5.4	4.3
495	10	12.6	17.6	14.2	9.5	13.1	11.4	2.6	3.3	2.8
495	5	11.4	12.4	11.8	9.6	11.2	10.3	2.4	2.6	2.5
497	10	19.0	22.3	20.9	17.1	20.9	18.9	3.1	3.6	3.4
497	15	22.7	32.0	26.3	17.5	24.6	21.2	3.5	4.7	4.0
813	10	13.4	22.5	18.5	15.7	19.4	18.2	2.5	3.7	3.1
813	15	23.1	28.1	25.4	18.0	23.3	20.3	3.6	4.3	4.0
815	15	31.0	41.8	37.1	25.2	36.4	31.1	4.2	5.3	4.8
815	25	42.7	53.5	46.9	28.9	40.0	33.8	5.3	6.5	5.8
833	15	24.5	40.9	34.6	12.6	28.1	21.9	4.0	5.7	5.0
833	25	43.1	47.0	45.4	20.9	27.1	23.2	6.1	6.3	6.2
835	10	13.1	22.5	18.3	9.0	19.7	16.8	2.4	3.8	3.2
835	15	22.6	29.3	25.1	12.9	22.2	19.2	3.7	4.4	4.0
835	25	46.2	46.2	46.2	24.0	24.0	24.0	6.2	6.2	6.2
835	5	10.6	12.4	11.5	11.7	13.0	12.4	2.2	2.4	2.3
933	15	36.6	36.6	36.6	25.5	25.5	25.5	5.1	5.1	5.1
933	25	42.7	71.3	53.4	14.7	31.3	25.6	6.0	8.4	6.9
935	10	15.8	21.8	19.3	10.1	21.9	18.0	2.9	3.5	3.3
935	15	22.8	39.5	30.3	16.6	26.7	21.2	3.7	5.7	4.5
935	25	42.7	44.9	43.8	26.4	26.7	26.6	5.7	5.9	5.8
935	5	12.1	12.1	12.1	7.2	7.2	7.2	2.8	2.8	2.8
937	15	25.0	41.3	32.0	18.4	30.5	24.5	3.7	5.6	4.6
937	25	43.3	47.8	46.0	25.4	32.4	27.9	5.8	6.3	6.0

Estadillo	Radio	D_min	D_max	D_medio	Ht_min	Ht_max	Ht_media	Anchura_min	Anchura_max	Anchura_media
939	10	12.8	19.6	15.5	15.4	19.8	17.1	2.4	3.2	2.7
939	15	28.6	39.3	33.5	24.2	31.2	27.9	4.1	5.2	4.6
939	25	44.9	47.6	46.2	28.3	31.3	29.8	5.8	6.0	5.9
947	10	18.1	22.3	20.6	14.7	20.6	17.9	3.1	3.6	3.4
947	15	22.6	37.7	28.3	17.5	29.9	22.4	3.6	5.2	4.2
949	10	13.5	22.1	17.3	9.5	23.4	16.6	2.6	3.6	3.0
949	15	23.1	39.6	28.8	14.8	26.8	22.8	3.7	5.4	4.3
951	10	21.7	22.5	22.2	15.4	21.2	19.0	3.5	3.7	3.6
951	15	23.3	37.9	29.1	16.7	25.5	22.1	3.7	5.3	4.3
953	15	33.2	41.5	37.5	20.4	26.0	22.9	4.7	5.9	5.3
953	25	43.6	58.5	50.1	19.4	36.0	27.2	5.6	7.3	6.5
957	15	24.9	41.9	35.6	9.5	25.3	16.6	4.5	6.3	5.5
957	25	43.0	60.7	50.0	16.6	29.7	23.7	5.8	7.6	6.7
959	10	17.3	22.5	19.9	11.0	20.4	15.7	3.4	3.6	3.5
959	15	24.8	35.6	29.6	17.9	22.3	20.5	3.9	5.1	4.5
965	15	33.1	42.0	38.1	23.8	28.8	25.8	4.7	5.5	5.2
965	25	43.1	58.5	49.5	24.4	33.8	28.5	5.7	7.4	6.3
967	15	38.0	38.0	38.0	27.0	27.0	27.0	5.1	5.1	5.1
967	25	45.0	67.5	52.8	17.0	40.8	31.8	5.5	8.3	6.5
969	10	12.6	20.0	15.7	8.3	14.5	11.7	2.5	3.6	3.0
969	15	23.5	23.7	23.6	14.7	15.0	14.9	4.0	4.0	4.0
971	10	22.0	22.0	22.0	18.2	18.2	18.2	3.6	3.6	3.6
971	15	22.6	33.0	26.8	18.2	22.7	20.5	3.6	4.9	4.1
973	10	19.3	22.3	20.5	12.6	16.6	14.6	3.4	4.0	3.6
973	15	23.0	38.8	27.6	14.2	20.0	16.7	3.8	5.8	4.5
975	10	22.2	22.2	22.2	22.2	22.2	22.2	3.4	3.4	3.4
975	15	22.7	38.8	29.6	20.5	28.0	24.5	3.6	5.3	4.3
987	15	22.6	40.8	32.5	17.0	30.2	25.7	3.5	5.4	4.6
987	25	46.3	46.3	46.3	26.0	26.0	26.0	6.1	6.1	6.1
989	10	12.6	21.9	17.7	11.2	20.0	16.5	2.4	3.7	3.1
989	15	22.6	31.9	25.5	15.2	20.5	18.4	3.6	4.9	4.1
989	5	12.5	12.5	12.5	15.0	15.0	15.0	2.4	2.4	2.4
993	10	16.6	16.6	16.6	15.0	15.0	15.0	3.0	3.0	3.0
993	15	23.6	42.0	33.1	8.6	31.6	25.0	3.6	5.9	4.7
993	25	42.6	52.0	47.6	29.7	36.5	32.8	5.4	6.4	5.9
997	15	28.8	37.5	33.6	21.1	26.1	23.0	4.3	5.2	4.8
1005	10	12.6	22.4	17.3	11.7	14.8	13.3	2.4	3.9	3.2
1005	15	23.7	26.5	24.8	11.8	15.8	13.8	4.0	4.5	4.3
1007	15	30.4	42.0	36.4	12.8	20.4	16.9	4.9	6.7	5.6
1007	25	44.8	56.3	48.8	19.1	21.1	20.5	6.4	7.6	6.8
1021	10	20.0	20.0	20.0	20.1	20.1	20.1	3.2	3.2	3.2

Estadillo	Radio	D_min	D_max	D_medio	Ht_min	Ht_max	Ht_media	Anchura_min	Anchura_max	Anchura_media
1021	15	23.4	41.5	32.4	19.8	29.8	25.1	3.7	5.5	4.6
1021	25	46.4	46.4	46.4	32.8	32.8	32.8	5.8	5.8	5.8
1025	10	22.5	22.5	22.5	21.9	21.9	21.9	3.5	3.5	3.5
1025	15	22.8	41.0	31.8	19.0	29.3	24.6	3.6	5.5	4.5
1025	25	43.8	46.1	44.8	24.8	29.0	27.3	5.8	5.9	5.9
1039	10	12.9	21.9	17.9	9.8	22.6	17.0	2.5	3.6	3.1
1039	15	22.7	42.5	27.5	15.1	30.1	22.9	3.5	5.5	4.1
1039	25	42.8	43.2	43.0	25.5	27.4	26.5	5.7	5.8	5.7
1039	5	11.4	12.0	11.7	12.3	15.3	13.9	2.3	2.3	2.3
1043	10	13.3	20.3	15.8	11.8	15.6	13.6	2.6	3.5	2.9
1043	5	12.4	12.4	12.4	10.8	10.8	10.8	2.6	2.6	2.6
1061	10	12.9	22.0	15.6	12.1	18.6	14.8	2.4	3.6	2.8
1061	15	25.5	25.5	25.5	19.6	19.6	19.6	4.0	4.0	4.0
1061	5	10.6	12.2	11.2	10.5	13.1	12.0	2.2	2.5	2.3
1065	10	13.8	22.5	17.3	10.7	17.9	15.6	2.6	3.7	3.1
1065	15	23.3	23.3	23.3	19.6	19.6	19.6	3.7	3.7	3.7
1065	5	12.5	12.5	12.5	16.2	16.2	16.2	2.3	2.3	2.3
1077	15	28.9	41.6	33.2	22.2	29.9	26.1	4.1	5.4	4.6
1077	25	42.8	44.9	43.5	26.8	29.5	28.4	5.5	5.9	5.7
1079	15	32.7	42.5	37.4	24.0	29.0	26.5	4.7	5.6	5.1
1079	25	42.6	62.8	48.0	24.8	36.2	30.7	5.4	7.4	6.0
1083	25	44.0	68.8	55.5	26.3	40.4	34.7	5.6	7.8	6.6
1087	10	22.4	22.4	22.4	17.0	17.0	17.0	3.7	3.7	3.7
1087	15	30.4	40.5	36.3	7.6	25.7	21.2	4.8	5.9	5.3
1087	25	42.7	64.0	49.7	17.2	31.2	25.2	5.7	7.9	6.6
1099	15	31.3	40.0	35.7	16.9	28.5	22.7	4.9	5.3	5.1
1099	25	44.0	61.2	51.3	31.4	38.8	35.8	5.4	7.0	6.1
1101	10	14.0	21.3	18.7	8.3	17.4	15.0	3.0	3.6	3.3
1101	15	22.9	25.5	24.0	14.1	18.2	16.3	3.7	4.3	4.0
1101	5	10.7	11.1	10.9	6.3	6.5	6.4	2.6	2.7	2.6
1103	10	13.1	13.1	13.1	7.1	7.1	7.1	3.0	3.0	3.0
1103	15	31.2	42.5	37.2	23.2	28.3	25.5	4.5	5.7	5.1
1103	25	44.2	47.1	46.3	25.7	28.6	26.5	5.9	6.2	6.1
1109	10	12.7	21.1	16.0	12.2	17.3	15.2	2.4	3.7	2.9
1109	15	23.0	40.0	33.0	9.0	28.7	23.0	3.6	5.8	4.8
1109	25	42.6	43.8	43.2	25.6	30.9	28.3	5.6	5.7	5.7
1123	15	31.6	42.1	36.7	22.2	35.8	29.5	4.5	5.3	4.9
1123	25	42.8	58.2	47.4	25.0	38.0	33.0	5.4	7.1	5.9
1139	10	13.2	22.1	16.8	11.9	17.1	14.0	2.6	3.9	3.1
1143	10	16.6	21.2	18.6	14.0	20.9	16.9	3.0	3.6	3.2
1143	15	22.8	33.5	27.8	13.0	23.6	21.0	3.6	4.9	4.2

Estadillo	Radio	D_min	D_max	D_medio	Ht_min	Ht_max	Ht_media	Anchura_min	Anchura_max	Anchura_media
1145	10	22.3	22.3	22.3	14.8	14.8	14.8	3.8	3.8	3.8
1145	15	25.5	41.9	31.8	17.6	28.4	22.2	4.0	5.7	4.6
1145	25	43.2	47.3	45.1	25.3	27.4	26.2	5.7	6.2	6.0
1149	10	13.8	13.8	13.8	7.1	7.1	7.1	3.1	3.1	3.1
1149	25	42.7	57.3	47.3	20.3	30.9	27.0	5.5	7.6	6.2
1149	5	10.1	10.1	10.1	9.8	9.8	9.8	2.2	2.2	2.2
1163	10	17.7	22.3	20.2	14.0	23.8	20.5	2.9	3.6	3.3
1163	15	22.8	29.6	25.9	18.0	25.3	22.4	3.5	4.3	3.9
1163	25	75.4	75.4	75.4	32.3	32.3	32.3	8.7	8.7	8.7
1165	10	15.5	22.5	19.5	5.4	18.7	15.2	3.1	3.8	3.4
1165	15	24.0	42.5	30.0	16.6	26.4	21.8	3.5	5.7	4.5
1165	25	44.6	62.2	51.3	10.4	31.3	25.8	5.8	9.9	6.8
1169	15	33.9	41.3	37.6	23.5	28.0	25.8	4.8	5.5	5.1
1169	25	44.1	75.4	56.2	23.9	37.5	31.6	5.7	8.8	6.8
1171	10	15.7	15.7	15.7	33.2	33.2	33.2	2.3	2.3	2.3
1171	25	45.5	74.5	56.7	23.7	38.9	32.8	5.8	8.7	6.8
1171	5	10.9	11.1	11.0	4.3	5.0	4.7	2.8	3.0	2.9
1187	10	14.7	19.6	17.8	9.0	17.7	14.8	3.1	3.3	3.2
1187	15	22.8	34.1	27.1	16.2	23.0	19.4	3.7	5.0	4.2
1193	15	27.7	42.1	37.7	18.0	26.2	21.8	4.1	6.1	5.4
1193	25	42.9	60.5	48.5	22.7	36.1	28.2	5.5	7.4	6.2
1201	10	13.4	22.5	19.9	13.7	18.9	16.3	2.6	3.7	3.4
1201	15	22.6	29.0	25.4	6.9	21.1	17.8	3.7	5.4	4.1
1201	25	53.8	53.8	53.8	30.1	30.1	30.1	6.7	6.7	6.7
1203	10	16.0	22.0	19.0	10.0	14.8	12.7	3.0	3.8	3.5
1203	15	23.1	23.4	23.3	13.8	14.3	14.1	4.0	4.0	4.0
1221	10	12.6	18.6	15.7	5.3	10.6	8.2	3.1	3.6	3.4
1221	15	22.7	41.3	29.7	9.9	22.7	16.3	4.3	5.8	4.8
1221	25	43.6	71.6	53.9	19.9	29.9	26.0	5.6	8.8	7.0
1237	10	13.4	22.1	18.4	10.0	15.0	12.3	2.6	4.1	3.4
1237	15	22.7	24.6	23.4	12.6	15.3	13.8	4.0	4.1	4.1
1237	5	12.3	12.3	12.3	10.7	10.7	10.7	2.5	2.5	2.5
1243	15	40.8	40.8	40.8	23.9	23.9	23.9	5.6	5.6	5.6
1243	25	44.7	68.4	55.5	21.4	42.2	30.3	5.9	8.1	6.9
2131	15	23.6	40.4	33.3	10.0	19.0	14.1	4.5	6.2	5.4
2131	25	43.4	43.4	43.4	17.0	17.0	17.0	6.5	6.5	6.5

ANEJO II

ANEJO III

1. Combinaciones 2 a 2 de la muestra compuesta por 63 parcelas

Variables	R²
Elev P70-Canopy relief ratio	0.59
Elev P75-Canopy relief ratio	0.59
Elev P80-Canopy relief ratio	0.58
Elev P60-Canopy relief ratio	0.58
Elev mean-Elev MAD median	0.57
Elev L1-Elev MAD median	0.57
Elev MAD median-Elev quadratic mean	0.57
Elev IQ-Elev P20	0.57
Elev MAD median-Elev cubic mean	0.57
Elev P70-Elev MAD median	0.57
Elev L CV-Elev P70	0.57
Elev CV-Elev P70	0.57
Elev P90-Canopy relief ratio	0.57
Elev P75-Elev MAD median	0.57
Elev mean-Elev L CV	0.57
Elev L1-Elev L CV	0.57
Elev L CV-Elev P75	0.57
Elev P80-Elev MAD median	0.57
Elev CV-Elev P75	0.57
Elev mean-Elev IQ	0.57
Elev IQ-Elev L1	0.57
Elev AAD-Elev P10	0.57
Elev P20-Elev MAD median	0.57
Elev skewness-Elev P80	0.57
Elev P60-Elev MAD median	0.57
Elev L CV-Elev P60	0.57
Elev L skewness-Elev P80	0.57
Elev P40-Elev MAD median	0.57
Elev CV-Elev P80	0.57
Elev L CV-Elev P80	0.57
Elev L skewness-Elev P70	0.57
Elev L skewness-Elev P75	0.57
Elev IQ-Elev quadratic mean	0.57
Elev mean-Elev P30	0.57
Elev L1-Elev P30	0.57
Elev skewness-Elev P75	0.57
Elev CV-Elev P60	0.57
Elev P50-Elev MAD median	0.57
Elev P90-Elev MAD median	0.57
Elev IQ-Elev P80	0.57
Elev mean-Elev P25	0.57
Elev L1-Elev P25	0.57
Elev P30-Elev P70	0.57
Elev P30-Elev MAD median	0.57

Elev IQ-Elev cubic mean	0.57
Elev P25-Elev P80	0.57
Canopy relief ratio-Elev cubic mean	0.56
Elev IQ-Elev P70	0.56
Variables	R²
Elev maximum-Elev P80	0.56
Elev IQ-Elev P25	0.56
Elev IQ-Elev P75	0.56
Elev P25-Elev P75	0.56
Elev maximum-Elev P70	0.56
Elev P30-Elev P75	0.56
Elev mean-Elev CV	0.56
Elev CV-Elev L1	0.56
Elev P25-Elev P70	0.56
Elev maximum-Elev P75	0.56
Elev L2-Elev P10	0.56
Elev P30-Elev P80	0.56
Elev L CV-Elev quadratic mean	0.56
Elev P25-Elev quadratic mean	0.56
Elev IQ-Elev P90	0.56
Canopy relief ratio-Elev quadratic mean	0.56
Elev P30-Elev quadratic mean	0.56
Elev IQ-Elev P30	0.56
Elev L CV-Elev P50	0.56
Elev P25-Elev cubic mean	0.56
Elev P40-Elev P70	0.56
Elev L CV-Elev cubic mean	0.56
Elev maximum-Elev P90	0.56
Elev P20-Elev P80	0.56
Elev L4-Elev P90	0.56
Elev CV-Elev quadratic mean	0.56
Elev skewness-Elev P90	0.56
Elev mean-Elev AAD	0.56
Elev AAD-Elev L1	0.56
Elev AAD-Elev P80	0.56
Elev P25-Elev P90	0.56
Elev P30-Elev cubic mean	0.56
Elev AAD-Elev P70	0.56
Elev AAD-Elev P75	0.56
Elev L CV-Elev P90	0.56
Elev L skewness-Elev P90	0.56
Elev CV-Elev P90	0.56
Elev P20-Elev P75	0.56
Elev P25-Elev MAD median	0.56
Elev maximum-Elev P60	0.56
Elev L kurtosis-Elev P90	0.56
Elev IQ-Elev P60	0.56
Elev P40-Elev P75	0.56
Elev CV-Elev P50	0.56
Elev L2-Elev P80	0.56
Elev P20-Elev P70	0.56
Elev P80-Elev quadratic mean	0.56

Elev P30-Elev P90	0.56
Elev CV-Elev cubic mean	0.56

2. Combinaciones 2 a 2 de la muestra compuesta por 55 parcelas

Variables	R ²
Elev P99-(All returns above mean) / (Total first returns) * 100-	0.77
Elev P99-Percentage first returns above mean-	0.77
Elev P99-Percentage all returns above mean-	0.77
Elev P99-All returns above mean-	0.77
Elev P99-First returns above mean-	0.77
Elev P95-(All returns above mean) / (Total first returns) * 100-	0.77
Elev P95-Percentage first returns above mean-	0.77
Elev P95-Percentage all returns above mean-	0.77
Elev P95-All returns above mean-	0.76
Elev P95-First returns above mean-	0.76
Elev P99-tr_30-	0.76
Elev P99-tr_40-	0.76
Elev P99-All returns above 2.00-	0.76
Elev P99-First returns above 2.00-	0.76
Elev P99-Return 1 count above 2.00-	0.76
Total return count above 2.00-Elev P99-	0.76
Elev P99-tr_20-	0.76
Elev P99-tr_50-	0.76
Elev P99-(All returns above 2.00) / (Total first returns) * 100-	0.76
Elev P99-Percentage first returns above 2.00-	0.76
Elev P99-Percentage all returns above 2.00-	0.76
Elev P99-tr_10-	0.76
Elev P99-tr_100-	0.76
Elev P95-tr_30-	0.76
Elev P95-All returns above 2.00-	0.76
Elev P95-First returns above 2.00-	0.76
Elev P95-Return 1 count above 2.00-	0.76
Total return count above 2.00-Elev P95-	0.76
Elev P95-(All returns above 2.00) / (Total first returns) * 100-	0.76
Elev P95-Percentage first returns above 2.00-	0.76
Elev P95-Percentage all returns above 2.00-	0.76
Elev P95-tr_20-	0.76
Elev P95-tr_10-	0.76
Elev P95-tr_40-	0.76
Elev P99-tr_60-	0.76
Elev P99-tr_70-	0.76
Elev P99-tr_80-	0.76
Elev P99-tr_90-	0.76
Elev P95-tr_50-	0.76
Elev P90-(All returns above mean) / (Total first returns) * 100-	0.76
Elev P90-Percentage first returns above mean-	0.76
Elev P90-Percentage all returns above mean-	0.76
Elev L3-Elev P99-	0.76
Elev P90-All returns above mean-	0.75

Elev P90-First returns above mean-	0.75
Elev P99-Total all returns-	0.75

Variables	R ²
Elev P05-Elev P99-	0.75
Elev L2-Elev P99-	0.75
Elev P99-Elev MAD median-	0.75
Elev P90-(All returns above 2.00) / (Total first returns) * 100-	0.75
Elev P90-Percentage first returns above 2.00-	0.75
Elev P90-Percentage all returns above 2.00-	0.75
Elev P95-tr_60-	0.75
Elev P90-tr_10-	0.75
Elev P90-All returns above 2.00-	0.75
Elev P90-First returns above 2.00-	0.75
Elev P90-Return 1 count above 2.00-	0.75
Total return count above 2.00-Elev P90-	0.75
Elev P90-tr_30-	0.75
Elev stddev-Elev P99-	0.75
Elev P90-tr_20-	0.75
Elev P95-tr_100-	0.75
Elev L skewness-Elev P99-	0.75
Elev AAD-Elev P99-	0.75
Elev P99-All returns above mode-	0.75
Elev P99-First returns above mode-	0.75
Elev variance-Elev P99-	0.75
Elev P20-Elev P99-	0.75
Elev P95-tr_70-	0.75
Elev P90-tr_40-	0.75
Elev IQ-Elev P99-	0.75
Elev P10-Elev P95-	0.75
Elev P95-tr_80-	0.75
Elev P99-Elev MAD mode-	0.75
Elev P25-Elev P99-	0.75
Elev P95-All returns above mode-	0.75
Elev P95-First returns above mode-	0.75
Elev P99-Elev cubic mean-	0.75
Elev P99-Elev quadratic mean-	0.75
Elev L1-Elev P99-	0.75
Elev mean-Elev P99-	0.75
Elev P50-Elev P99-	0.75
Elev L4-Elev P99-	0.75
Elev P95-Total all returns-	0.75
Elev P95-Total first returns-	0.75
Elev P99-Canopy relief ratio-	0.75
Elev P40-Elev P99-	0.75
Elev P60-Elev P99-	0.75
Elev P30-Elev P99-	0.75
Elev P95-Elev P99-	0.75
Elev maximum-Elev P99-	0.75
Elev P99-Percentage all returns above mode-	0.75

Elev P99-(All returns above mode) / (Total first returns) * 100-	0.75
Elev P99-Percentage first returns above mode-	0.75

3. Combinaciones 3 a 3 de la muestra compuesta por 55 parcelas:

Variables	R ²
Elev P99-Percentage first returns above mean-Percentage all returns above mode	0.78
Elev P99-Percentage all returns above mode-(All returns above mean) / (Total first returns) * 100	0.78
Elev P99-Percentage first returns above mean-Percentage first returns above mode	0.78
Elev P99-Percentage first returns above mean-(All returns above mode) / (Total first returns) * 100	0.78
Elev P99-Percentage first returns above mode-(All returns above mean) / (Total first returns) * 100	0.78
Elev P99-(All returns above mean) / (Total first returns) * 100-(All returns above mode) / (Total first returns) * 100	0.78
Elev P99-Percentage all returns above mean-Percentage all returns above mode	0.78
Elev P99-Percentage first returns above mode-Percentage all returns above mean	0.78
Elev P99-Percentage all returns above mean-(All returns above mode) / (Total first returns) * 100	0.78
Total return count above 2.00-Elev P99-First returns above mean	0.78
Total return count above 2.00-Elev P99-All returns above mean	0.78
Elev P99-Return 1 count above 2.00-First returns above mean	0.78
Elev P99-Return 1 count above 2.00-All returns above mean	0.78
Elev P99-First returns above 2.00-First returns above mean	0.78
Elev P99-First returns above 2.00-All returns above mean	0.78
Elev P99-All returns above 2.00-First returns above mean	0.78
Elev P99-All returns above 2.00-All returns above mean	0.78
Elev AAD-Elev L2-Elev P05	0.78
Elev P99-First returns above mean-First returns above mode	0.78
Elev P99-First returns above mean-All returns above mode	0.78
Elev P99-First returns above mode-All returns above mean	0.78
Elev P99-All returns above mean-All returns above mode	0.78
Elev L3-Elev P99-First returns above mean	0.78
Elev L3-Elev P99-All returns above mean	0.78
Elev P01-Elev P99-First returns above mean	0.78
Elev P01-Elev P99-All returns above mean	0.78
Elev P99-Percentage first returns above 2.00-Percentage all returns above mode	0.78
Elev P99-(All returns above 2.00) / (Total first returns) * 100-Percentage all returns above mode	0.78
Elev P99-Percentage first returns above 2.00-Percentage first returns above mode	0.78
Elev P99-Percentage first returns above 2.00-(All returns above mode) / (Total first returns) * 100	0.78
Elev P99-(All returns above 2.00) / (Total first returns) * 100-Percentage first returns above mode	0.78
Elev P99-(All returns above 2.00) / (Total first returns) * 100-(All returns above mode) / (Total first returns) * 100	0.78
Elev P99-Percentage all returns above 2.00-Percentage all returns above mode	0.78
Elev P99-Percentage all returns above 2.00-Percentage first returns above mode	0.78
Elev P99-Percentage all returns above 2.00-(All returns above mode) / (Total first returns) * 100	0.78
Elev maximum-Elev P99-Percentage first returns above mean	0.77
Elev maximum-Elev P99-(All returns above mean) / (Total first returns) * 100	0.77
Elev maximum-Elev P99-Percentage all returns above mean	0.77
Elev P99-Percentage first returns above mean-tr_10	0.77
Elev P99-(All returns above mean) / (Total first returns) * 100-tr_10	0.77
Elev P99-Percentage all returns above mean-tr_10	0.77
Elev mode-Elev P99-Percentage first returns above mean	0.77

Variables	R ²
Elev L3-Elev P99-All returns above 2.00	0.77
Elev mode-Elev P99-Percentage all returns above mean	0.77
Elev P99-Percentage all returns above mode-tr_10	0.77
Elev P99-Percentage first returns above mode-tr_10	0.77
Elev P99-(All returns above mode) / (Total first returns) * 100-tr_10	0.77
Elev mode-Elev P99-First returns above mean	0.77
Elev mode-Elev P99-All returns above mean	0.77
Elev P99-Percentage all returns above 2.00-Percentage first returns above mean	0.77
Elev P99-Percentage all returns above 2.00-(All returns above mean) / (Total first returns) * 100	0.77
Elev P99-Percentage first returns above 2.00-Percentage first returns above mean	0.77
Elev P99-Percentage first returns above 2.00-(All returns above mean) / (Total first returns) * 100	0.77
Elev P99-(All returns above 2.00) / (Total first returns) * 100-Percentage first returns above mean	0.77
Elev P99-(All returns above 2.00) / (Total first returns) * 100-(All returns above mean) / (Total first returns) * 100	0.77
Elev P99-Percentage all returns above 2.00-Percentage all returns above mean	0.77
Elev L3-Elev P99-Percentage first returns above mean	0.77
Elev L3-Elev P99-(All returns above mean) / (Total first returns) * 100	0.77
Elev L3-Elev P99-Percentage all returns above mean	0.77
Elev P99-Percentage first returns above 2.00-Percentage all returns above mean	0.77
Elev P99-(All returns above 2.00) / (Total first returns) * 100-Percentage all returns above mean	0.77
Elev P40-Elev P95-Elev cubic mean	0.77
Elev P99-Percentage first returns above mean-First returns above mean	0.77
Elev P99-Percentage first returns above mean-All returns above mean	0.77
Elev P99-(All returns above mean) / (Total first returns) * 100-First returns above mean	0.77
Elev P99-(All returns above mean) / (Total first returns) * 100-All returns above mean	0.77
Elev P99-Percentage all returns above mode-tr_20	0.77
Elev P99-Percentage all returns above mean-First returns above mean	0.77
Elev P99-Percentage all returns above mean-All returns above mean	0.77
Elev minimum-Elev P99-First returns above mean	0.77
Elev minimum-Elev P99-All returns above mean	0.77
Elev P99-Percentage first returns above mode-tr_20	0.77
Elev P99-(All returns above mode) / (Total first returns) * 100-tr_20	0.77
Elev P99-First returns above mean-tr_100	0.77
Elev P99-All returns above mean-tr_100	0.77
Elev P01-Elev P95-First returns above mean	0.77
Elev P01-Elev P95-All returns above mean	0.77
Elev P99-Percentage all returns above mode-tr_30	0.77
Elev P99-Percentage first returns above mode-tr_30	0.77
Elev P99-(All returns above mode) / (Total first returns) * 100-tr_30	0.77
Elev P01-Elev P99-tr_40	0.77
Elev P99-Percentage first returns above mean-Total all returns	0.77
Elev P99-(All returns above mean) / (Total first returns) * 100-Total all returns	0.77
Elev P99-Percentage first returns above mean-Total first returns	0.77
Elev P99-(All returns above mean) / (Total first returns) * 100-Total first returns	0.77
Elev P99-Percentage all returns above mean-Total all returns	0.77
Elev P99-Percentage all returns above mean-Total first returns	0.77

Elev L3-Elev P99-Percentage first returns above 2.00	0.77
Elev L3-Elev P99-(All returns above 2.00) / (Total first returns) * 100	0.77