



**6º CONGRESO FORESTAL
ESPAÑOL**

6CFE01-432

Montes: Servicios y desarrollo rural
10-14 junio 2013
Vitoria-Gasteiz



Edita: Sociedad Española de Ciencias Forestales
Vitoria-Gasteiz, 10-14 junio de 2013
ISBN: 978-84-937964-9-5

© Sociedad Española de Ciencias Forestales

Influencia del inventario de campo en el error de muestreo obtenido en un inventario con tecnología Lidar

CONDÉS, S.¹, FERNANDEZ-LANDA, A.² y RODRIGUEZ, F.³

¹ Dept. Economía y Gestión Forestal. Escuela Técnica Superior de Ingenieros de Montes. Universidad Politécnica de Madrid. Ciudad Universitaria s/n. 28040 Madrid

² Agresta Soc. Coop. y Universidad Politécnica de Madrid

³ Fundación Cesefor.

Resumen

Habitualmente se considera que en los inventarios forestales realizados con tecnología LiDAR no existe error de muestreo. El error en la estimación de las variables se asimila a la bondad de ajuste obtenida en la regresión que se usa para la predicción de dichas variables. Sin embargo el inventario LiDAR puede ser considerado como un muestreo en dos fases con estimador de regresión, por lo que es posible calcular el error que se comete en dicho inventario.

Se presenta como aplicación el inventario de los montes de Utilidad Pública números 193 y 194 de la provincia de Soria, poblados principalmente con masas de repoblación de *Pinus sylvestris*. Se ha trabajado con una muestra de 50 parcelas circulares de 11 metros de radio y una densidad media de datos LiDAR de 2 puntos/m². Para la estimación del volumen maderable (V) se ha ajustado una regresión lineal con un coeficiente de determinación $R^2=0,8985$. Los resultados muestran que los errores obtenidos en un inventario LiDAR son sustancialmente menores que los obtenidos en un muestreo sistemático por parcelas (5,1% frente a 14.9% en el caso analizado). También se observa que se consigue un error de muestreo mínimo para la estimación del volumen cuando la regresión se realiza píxeles de tamaño igual al de la parcela de muestreo en campo y que para minimizar el error a nivel de rodal es necesario maximizar el rango de aplicación de la regresión.

Palabras clave

Doble muestreo por regresión, inventario forestal, error de muestreo.

1. Introducción

En los procesos de planificación forestal aproximadamente la mitad de los costes (10 €/ha) son imputables a la adquisición de información (Fabra-Crespo, 2012). En consecuencia, el coste de inventario de la superficie arbolada en España, con la precisión necesaria para la gestión forestal, sería de unos 180 M€ En España se considera adecuada una repetición de los inventarios forestales como mínimo cada 10 años, por lo que se podrían considerar unos costes de inventario anuales de 18 M€ Actualmente esto es inasumible, por lo que resulta imprescindible ofrecer soluciones alternativas. Estas alternativas se basan por supuesto en la aplicación de las nuevas tecnologías, entre las que sin duda figura LiDAR (Light Detection And Ranging), que contribuyen a la evolución de los inventarios forestales, reduciendo su error (Means *et al.*, 2000; Næsset, 2004) y disminuyendo su coste (Eid *et al.*, 2004).

El LiDAR es un sistema de sensor remoto análogo al radar pero que utiliza luz láser. El sistema emite pulsos láser que son reflejados por la superficie del terreno y las ramas y hojas de la vegetación, y registrados en el escáner aerotransportado (Dubayah & Drake, 2000). El tiempo transcurrido entre la emisión y el retorno del pulso láser al sensor permite obtener una nube de puntos del territorio que incluye altimetrías. La aplicación de esta tecnología al inventario forestal da como resultado una mayor densidad en el muestreo que la obtenida con cualquier otro sistema conocido, con la ventaja adicional de que todas las medidas capturadas son objetivas y homogéneas. Un adecuado procesamiento de la nube de puntos LiDAR permite estimar variables como la fracción de cabida cubierta arbórea (F_{cc}), las alturas máximas de la vegetación, la altura dominante, la presencia de matorral o regeneración avanzada, la existencia o no de continuidad vertical u horizontal de los combustibles. El ajuste de modelos estadísticos que relacionen la información LiDAR con información tomada en campo permite estimar variables tan importantes para la gestión forestal como el número de pies (N), el área basimétrica (G), el volumen de madera de fuste (V), el diámetro cuadrático medio (d_g), la altura dominante (H_o) o la biomasa foliar o la biomasa de ramas. Son muchos los autores que han utilizado la información LiDAR de forma exitosa para estimar biomasa sobre el suelo tanto a escala rodal como a escala árbol (Lim & Treitz, 2004; Bortolot & Wynne, 2005; Popescu, 2007; Næsset & Gobakken, 2008). Además el progresivo abaratamiento de esta tecnología está haciendo que, en muchos casos, la aplicación de los métodos clásicos de inventario forestal y generación de cartografía temática empiecen a perder sentido.

Desde hace décadas ha quedado claramente establecido el interés del doble muestreo como una técnica de inventariación. El objetivo de este método de muestreo consiste en estimar una variable objetivo, como puede ser el volumen de la masa, cuya medición resulta costosa, explotando su relación con otra auxiliar de medición más sencilla y económica (altura dominante, área basimétrica, etc). En la práctica requiere dos fases de muestreo: una primera fase en la que se mide la variable auxiliar en un número elevado de parcelas, obteniendo a partir de dichas medidas el valor medio y la varianza, y una segunda fase en la que, en un número relativamente pequeño de parcelas, que puede ser una submuestra de la muestra anterior, se miden tanto la variable objetivo como la variable auxiliar y se correlacionan en un modelo de regresión (Cochran, 1963). Durante mucho tiempo se han utilizado fotografías aéreas como base para la obtención de la variable auxiliar, sin embargo la medición de la altura sobre las mismas siempre ha supuesto una dificultad. En los últimos años se han sustituido las fotografías aéreas por datos provenientes de sensores remotos y en particular de vuelos LiDAR (Næsset, 2002; Parker & Evans, 2004; Andersen & Breidenbach, 2007). El uso del doble muestreo es particularmente interesante cuando lo que se pretende es la reducción del coste de los inventarios, sin disminuir su eficacia.

2. Objetivos

El objetivo de este trabajo es determinar la mejora (disminución del error) en la estimación de las principales variables dasométricas al combinar información LiDAR junto a la toma de datos convencional en parcelas de campo. Este objetivo se ha articulado mediante la respuesta a dos preguntas: (i) ¿Deben las parcelas de campo realizadas y los píxeles de información LiDAR deben tener el mismo tamaño?, y si no es así ¿Cuál es su repercusión sobre el error?, y (ii) ¿Cómo cambia el error en la estimación del volumen maderable en pie en función del número de parcelas en campo realizadas?

La respuesta a estas preguntas va a permitir disminuir sensiblemente el error de muestreo y por tanto disminuir su coste.

3. Metodología

Descripción del área de estudio

El área de estudio seleccionada tiene una superficie de 1.121 ha y corresponde con el estrato de masas puras de repoblación de *P. sylvestris* de los montes de utilidad pública números 193 y 194 de la provincia de Soria, términos municipales de Yanguas y Villar del Río respectivamente. Las repoblaciones se realizaron entre los años 1960 y 1972 por lo que actualmente las masas tienen una edad comprendida entre 40 y 52 años.

Descripción de la información de campo

Se levantaron 50 parcelas circulares de 11 metros de radio distribuidas de forma sistemática por la zona de estudio en una malla cuadrada de 450 metros. El trabajo de campo se realizó entre los meses de marzo y abril de 2010. En cada parcela se midió el diámetro normal de todos los árboles (se consideró 10 cm como diámetro mínimo inventariable), y la altura de cuatro árboles elegidos de forma sistemática. Para la cubicación de los árboles se utilizaron las ecuaciones de perfil de castilla y León incorporadas en el software cubiFOR (Rodríguez & Broto, 2010). El resumen de las principales variables dasométricas de las 50 parcelas de campo se muestra en la Tabla 1.

Tabla 1. Resumen de las variables dasométricas de las parcelas de campo

	Mínimo	Media	Desviación típica	Máximo
N (pies/ha)	105,2	970,7	481,8	1.867,8
G (m²/ha)	2,9	29,6	12,4	57,6
V (m³/ha)	10,3	156,4	84,0	405,2
d_g (cm)	15,6	20,2	3,3	34,6
H₀ (m)	8,3	12,7	2,8	19,0

Descripción y procesado de la información LiDAR

La información LiDAR fue capturada en abril de 2010 por una aeronave Cessna 402-C equipada con un sensor Leica ALS60 II. Con el diseño del vuelo y la configuración del sensor elegida se obtuvo información LiDAR con una densidad de 2 primeros retornos por m². La clasificación de la nube de puntos y la generación de los Modelos Digitales de Elevaciones (MDE con 1 metro de paso de malla) fue realizada por la empresa proveedora de los datos LiDAR. Para el cálculo de estadísticos de estructura de vegetación (a partir de los retornos clasificados como vegetación en la nube de puntos) se utilizó el software FUSION desarrollado por el servicio forestal de los Estados Unidos (Mcgaughey & Carson, 2003). Para el cálculo de los estadísticos de vegetación se utilizaron únicamente los retornos por encima de 2 metros del suelo, de esta forma se incluyeron en el cálculo únicamente los puntos de vegetación correspondientes al estrato de pinar evitando incluir en el computo retornos del láser correspondientes a matorral. Los principales estadísticos calculados fueron los diferentes percentiles de alturas sobre el suelo L_{p_i} (Nilsson, 1996) y la estimación de la fracción de

cabida cubierta L_{FCC} calculada como el porcentaje de primeros retornos por encima de 2 metros de altura (Hopkinson & Chasmer, 2009).

Se procesó la información LiDAR, extrayendo los percentiles de alturas sobre el suelo de los retornos de vegetación y la cobertura arbórea, en toda el área de estudio para 5 tamaños de pixel diferentes. Se eligió un tamaño de pixel coincidente con la superficie de las parcelas de campo (380,1 m²) y se eligieron dos tamaños por encima y dos tamaños por debajo de ese valor tal y como se muestra en la tabla 2.

Tabla 2. Tamaños de píxeles utilizados para procesar la información LiDAR

	Superficie (m ²)	Lado de pixel (m)	Radio de la parcela circular equivalente (m)
Tamaño 1	153,9	12,4	7
Tamaño 2	254,5	16,0	9
Tamaño 3	380,1	19,5	11
Tamaño 4	530,9	23,0	13
Tamaño 5	706,9	26,6	15

Cálculo del modelo y el error de muestreo

Para la estimación del volumen maderable V en el pinar de repoblación se asimila el proceso a un doble muestreo por regresión en dos fases. La primera fase consiste en el cálculo de la variable X en la totalidad de los m píxeles en los que se ha rasterizado la nube de puntos LiDAR y, a partir de dicha variable, la estimación de la media y la varianza. La segunda fase consiste en la toma de una submuestra de pequeño tamaño (50 en este trabajo) estimando en las parcelas de campo la variable objetivo V , y se relacionándola con la variable X calculada, sobre la nube de puntos LiDAR, en los n píxeles correspondientes a los puntos de muestreo en campo.

Se utiliza un modelo matemático lineal de la forma: $V = a + b \cdot X$, donde X , es el producto entre el percentil 50 de las alturas y la fracción de cabida cubierta obtenida en LiDAR todo elevado al cuadrado $(L_{P_{50}} \cdot L_{FCC})^2$, ya que es con la variable que se ha obtenido la mejor correlación. Se ha optado por un modelo lineal simple por ser para este tipo de modelos para los que está desarrollado el cálculo del error de muestreo en dos fases con estimador de regresión. Los coeficientes a y b se obtienen ajustando el modelo por mínimos cuadrados ordinarios a los pares de valores formados por los V estimados en las 50 parcelas de campo de radio 11 metros y los valores X correspondientes a cada una de las parcelas de campo (píxeles de tamaño 3).

Una vez obtenido el modelo matemático se puede estimar el valor medio del volumen del monte \hat{V} a partir del valor \bar{X}_m media la variable X en todos los m píxeles de la imagen LiDAR: $\hat{V} = a + b\bar{X}_m$.

El error en la estimación del volumen de la zona de muestreo se puede calcular como: $s = t S_p$, donde t es el valor de la t de Student al 95% de probabilidad y S_p la desviación típica del estimador por regresión del volumen. Dicha desviación se calcula como (Cochran, 1963):

$$S_{\hat{y}}^2 = S_{res}^2 \left[\frac{1}{n} + \frac{(\bar{X}_m - \bar{X}_n)^2}{\sum_{i=1}^n (X_i - \bar{X}_n)^2} \right] + \frac{b^2 S_{X_m}^2}{m}$$

donde n es el número de parcelas de campo, es decir 50; m el número de píxeles LiDAR en los que se ha rasterizado la nube de puntos, b el coeficiente obtenido en el ajuste de la regresión, \bar{X}_m y \bar{X}_n los valores medios de la variable X obtenidos respectivamente a partir de la totalidad de los m píxeles en la imagen LiDAR y en los n píxeles equivalentes a las parcelas de campo. S_{res}^2 es la varianza residual que se obtiene a partir de los como:

$$S_{res}^2 = \frac{1}{n-2} \left[\sum_{i=1}^n (V_i - V_n)^2 - b^2 \sum_{i=1}^n (X_i - \bar{X}_n)^2 \right] = \frac{\sum (V_i - \hat{V}_i)^2}{n-2}$$

y $S_{X_m}^2$ es la varianza de la variable X entre los m píxeles del raster proveniente de la nube de puntos LiDAR.

$$S_{X_m}^2 = \frac{1}{m} \sum_{i=1}^m (X_i - \bar{X}_m)^2$$

Se observa en definitiva que el error de muestreo depende del tamaño n de la muestra en campo, del número m de píxeles del LiDAR, que a su vez dependerá del tamaño elegido para dichos píxeles (en general equivalente al tamaño de las parcelas medidas en campo), y de la varianzas de las variables X e Y en el área objeto de estudio, es decir de la homogeneidad de dicha zona.

Variación del tamaño y el número de las parcelas de campo

Además de ajustar el modelo lineal y calcular el error de muestreo con las $n = 50$ parcelas de campo de 11 metros de radio y los píxeles correspondientes de tamaño 3; y con la idea de dar respuesta a las dos preguntas planteadas en los objetivos, se han llevado a cabo dos tareas adicionales:

- i) En primer lugar se han realizado los ajustes del modelo lineal empleando las mismas 50 parcelas de campo de 11 metros de radio, pero utilizando diferentes tamaños de los píxeles de la imagen LiDAR (tabla 2). Esto permitirá determinar si es posible flexibilizar el procesado de la imagen LiDAR, usando tamaños de píxel no equivalentes al tamaño de las parcelas de campo, disminuyendo así el tiempo de procesado.
- ii) En segundo lugar se repiten los ajustes y el cálculo de errores variando el número n de parcelas de muestreo en la segunda fase entre 20 y 50. Las parcelas se seleccionan aleatoriamente entre las 50 parcelas reales. Para evitar la casualidad consecuencia de una selección determinada, se repite el proceso hasta 100 veces (100 combinaciones distintas para cada número de parcelas) y se calculan los valores medios. Esto permitirá estudiar la influencia del muestreo de campo en el error de muestreo, y tomar decisiones sobre la mejor forma de realizar este muestreo.

En todos los casos se calcula el error que se hubiese obtenido con un muestreo sistemático equivalente con el mismo número de parcelas:

$$e_{sist} = \pm t S_P = \pm t \frac{S_V}{\sqrt{n}} \sqrt{1 - \frac{n}{m}}$$

4. Resultados

El modelo ajustado con la submuestra de 50 parcelas de *tamaño 3* es el siguiente: $V = 41,4451 + 0,00021379(L_{P_{20}} \cdot L_{FCC})^2$. El ajuste se consigue con un coeficiente de determinación $R^2 = 0,8985$.

En la tabla 3 se presenta el resumen de la variable X obtenida a partir de todos los píxeles en los que se ha rasterizado la nube de puntos LiDAR (primera fase) y a partir de la submuestra de los 50 píxeles correspondientes a las parcelas de campo (segunda fase).

Tabla 3. Resumen de la variable X en la muestra de la primera y la segunda fase

	Fase 1	Fase 2
Número de datos	28948	50
Media	507944.17	537567,68
Desviación típica	410399.14	368809,52
Mínimo	0.00	9846,52
Máximo	2368364.38	1334744,67

A partir de estos datos se obtiene que el valor medio del volumen del monte es 150,0 m³/ha, con un error relativo del 5,1% al 95% de probabilidad.

Si en lugar de mediante un muestreo por regresión en dos fases se hubiese estimado el volumen medio del monte directamente a partir de las 50 parcelas de campo, el volumen medio obtenido hubiese sido 156,4 m³/ha y el error consecuencia del muestreo sistemático aumentaría hasta el 14,9%.

Variación del tamaño de píxel

En la tabla 4 se presentan los valores resumen de la variable X, así como los resultados obtenidos para las diferentes regresiones y los errores de muestreo al considerar los diferentes tamaños de píxel descritos en la tabla 2.

Tabla 4. Resumen de la variable X en la muestra de la primera fase, parámetros ajustados según el modelo $V=a+bX$, coeficiente de determinación R^2 , volumen medio estimado V y error de muestreo para distintos tamaños de pixel

	Tamaño 1	Tamaño 2	Tamaño 3	Tamaño 4	Tamaño 5
Número de datos m	69330	42611	28948	21000	15954
Media X	526125.21	516184.66	507944.17	500683.99	495127.28
Desviación típica X	428730.85	418630.32	410399.14	404233.37	398234.71
a	44.15	38.70	41.45	38.57	38.89
b	0.000192	0.000205	0.000214	0.000206	0.000205
R^2	0.8205	0.8735	0.8985	0.8688	0.8525
V estimado m^3/ha	145.4	144.6	150.0	141.6	140.2
Error de muestreo %	6.9	5.9	5.1	6.2	6.6

A la vista de los resultados se puede decir que el coeficiente de determinación es menor, y el error de muestreo mayor, cuanto más se aleja el tamaño del pixel del de la parcela de muestreo de campo; o lo que es lo mismo se consigue un error de muestreo mínimo para la estimación del volumen cuando la regresión se realiza pixeles de tamaño igual al de la parcela de muestreo en campo.

Variación del número de parcelas de muestreo en campo

En este caso, se ha ajustado el modelo matemático siempre con parcelas de 11 metros de radio y píxeles de *tamaño 3*, pero se ha variado el número de parcelas n de la segunda fase del muestreo. Los resultados se resumen en las figuras 1 a 3 que representan respectivamente el coeficiente de determinación, el volumen estimado y el error relativo del muestreo frente al número de parcelas de campo.

En las dos primeras figuras se observa que los valores del coeficiente de determinación y del volumen del pinar calculados para cada número de parcelas de muestreo, como media de las 100 combinaciones utilizadas, permanece constante e igual al valor obtenido con el total de las 50 parcelas de muestreo. Es decir el coeficiente de determinación medio es siempre 0,8985 y el volumen medio 150,0 m^3/ha .

En estas mismas figuras se observa también que la variabilidad de ambos valores, R^2 y V estimado, es tanto mayor cuanto menor sea el número de parcelas. Así, por ejemplo, cuando el número de parcelas de campo es 20 se obtienen regresiones con coeficientes de determinación entre 0,79 y 0,96, mientras que cuando el número de parcelas de campo es 40 los coeficientes de determinación varían entre 0,87 y 0,93.

En la figura 3 se puede comparar como varía el error de muestreo considerando el doble muestreo por regresión y el que se obtendría en un muestreo de campo con el mismo número de parcelas. Por un lado resulta evidente la mejora conseguida en el doble muestreo por regresión, y por otro queda claro que al disminuir el número de parcelas se aumenta el error de muestreo. Sin embargo es interesante observar como con un número de parcelas pequeño se obtiene un rango de errores bastante amplio, entre un 4.5 y un 11.2%.

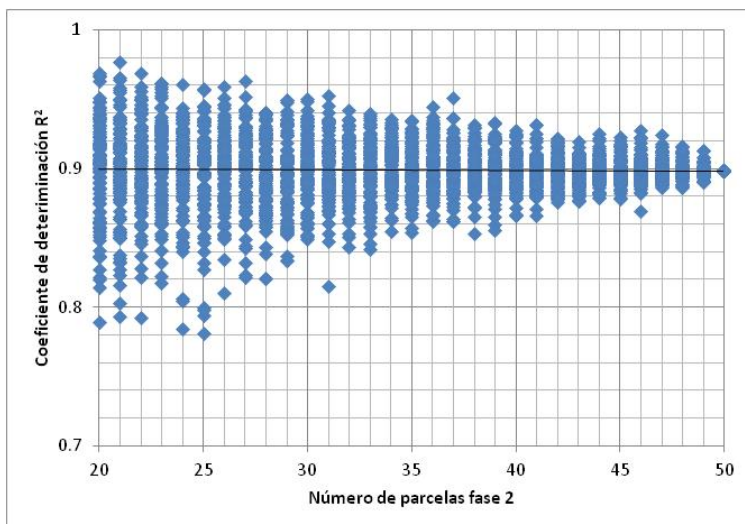


Figura 1. Variación del coeficiente de determinación en función del número de parcelas utilizadas para la regresión




Figura 2. Variación del volumen estimado en función del número de parcelas utilizadas para la regresión

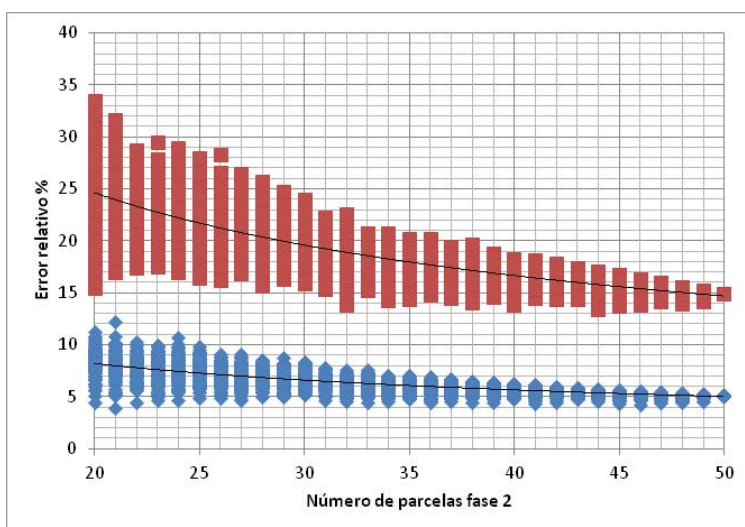


Figura 3. Variación del error de muestreo (regresión en rojo y sistemático en azul) en función del número de parcelas utilizadas para la regresión

Muestreo dirigido

A la vista de los resultados anteriores surge la pregunta de si es posible dirigir el muestreo de campo, de manera que con un número reducido de parcelas se consigan regresiones con coeficientes de determinación elevados y errores de muestreo pequeños.

Uno de los aspectos importantes que deben tenerse en cuenta a la hora de dirigir el muestreo es que las parcelas de campo deben representar la máxima variabilidad de la variable X asegurando así que no se aplica la regresión fuera del rango de construcción. Para ilustrar esto se presentan a modo de ejemplo las figuras 4 y 5 en las que se observa la superficie de pinar que queda fuera del rango (píxeles en rojo) en dos casos particulares cuando se emplean 20 parcelas de muestreo. Los coeficientes de determinación de las regresiones R^2 obtenidos son 0,95 (figura 4) y 0,84 (figura 5). Las superficies que quedan fuera del rango de la regresión son respectivamente 111,5 y 312,9 ha. Se observa como en el caso representado en la figura 5 existen problemas para la estimación del volumen V en rodales enteros, puesto que se observan amplias zonas en las que se aplica la regresión fuera del rango de ajuste de la misma




Figura 4. Píxeles con la variable X fuera del rango de la variable X en las parcelas de campo, para 20 parcelas de campo con R^2 0.95




Figura 5. Píxeles con la variable X fuera del rango de la variable X en las parcelas de campo, para 20 parcelas de campo con R^2 0.84

5. Discusión

En primer lugar hay que hacer notar que aunque los coeficientes de determinación que se han obtenido en las regresiones (aproximadamente 0,90) son del mismo orden que los publicados por otros autores (Means *et al.*, 2000; Næsset, 2002), es posible conseguir mejores ajustes con modelos lineales de regresión múltiple haciendo intervenir un mayor número de variables. Se ha preferido, sin embargo, utilizar un modelo sencillo con el objetivo de calcular el error de muestreo según el procedimiento descrito.

Por otro lado, los resultados obtenidos que indican la importancia de la coherencia entre el tamaño de las parcelas de campo y el de los píxeles en los que se rasteriza la nube de puntos LiDAR, son coherentes con los presentados por otros autores (Magnussen & Boudewyn, 1998). De acuerdo con este mismo autor este tamaño no debe ser demasiado pequeño, sin embargo extender el tamaño de la parcela incrementa el coste del inventario (Næsset, 2002). Algunos artículos demuestran que las precisiones mayores siempre se obtienen con parcelas de campo grandes (Gobakken & Næsset, 2009) y otros se centran en establecer un tamaño óptimo para las parcelas de campo, definido como el mínimo posible que permita obtener regresiones estadísticamente confiables (Frazer *et al.*, 2011).

En cualquier caso la precisión del muestreo, no solo está ligada al tamaño de la parcela, sino también al número de parcelas de muestreo (Zeide, 1980), por lo en este trabajo se centra en disminuir el número de parcelas de muestreo con el mismo objetivo de obtener regresiones confiables y errores de muestreo pequeños.

Los resultados demuestran que en el caso de disminuir el número de parcelas es necesario asegurarse de que estas cubran completamente el rango de variación de las variables en la regresión. Sin embargo este no debe ser el único aspecto a tener en cuenta en el muestreo dirigido, ya que no existe una relación directa entre el rango de variabilidad de la variable X y el coeficiente de determinación obtenido en la regresión. Es decir, es posible obtener coeficientes de determinación pequeños, que se traducen en errores de muestreo elevados, aun cuando el rango de la variable X es amplio, y análogamente se pueden obtener altos coeficientes de determinación aun cuando las parcelas de campo no cubren completamente el rango de variabilidad existente. En este mismo sentido (Maltamo *et al.*, 2011) señalan que el uso *a priori* de la información LiDAR para dirigir el muestreo tiene un gran potencial, si bien es necesario ampliar las investigaciones para poder crear una guía práctica que permita el muestreo dirigido.

6. Conclusiones

Es posible reducir el coste del inventario reduciendo considerablemente el número de parcelas de campo, sin embargo esta reducción va ligada a un aumento del error de muestreo, salvo que se haga un muestreo dirigido. Uno de los aspectos básicos en el muestreo dirigido es elegir las parcelas de modo que se cubra todo el posible rango de variación de la variable auxiliar. De no hacerlo así se podría estar aplicando la regresión, incluso en rodales enteros, fuera del rango de aplicación de la misma. En cualquier caso los errores obtenidos mediante técnicas de doble muestreo son siempre muy inferiores a los que se obtendrían con muestreos sistemáticos con el mismo número de parcelas de campo.

Sin embargo, si lo que se desea es minimizar el tiempo de procesado de la imagen LiDAR aumentando el tamaño del pixel al rasterizar la nube de puntos, es imprescindible que las parcelas de campo tengan el mismo tamaño, lo que aumenta el coste del inventario, ya en caso contrario se aumentan los errores de muestreo.

7. Bibliografía

ANDERSEN, H.; BREIDENBACH, J., 2007. Statistical properties of mean stand biomass estimators in a LIDAR-based double sampling forest survey design. In, Proceedings of the ISPRS Workshop Laser Scanning, pp. 8-13.

BORTOLOTT, Z.J.; WYNNE, R.H.; 2005. Estimating forest biomass using small footprint LiDAR data: An individual tree-based approach that incorporates training data. *ISPRS Journal of Photogrammetry and Remote Sensing* 59: 342-360.

COCHRAN, W.G., 1963. Sampling techniques. In. John Wiley, NY.

DUBAYAH, R.O.; DRAKE, J.B.; 2000. Lidar remote sensing for forestry. *Journal of Forestry* 98: 44-46.

EID, T.; GOBAKKEN, T.; NÆSSET, E.; 2004. Comparing stand inventories for large areas based on photo-interpretation and laser scanning by means of cost-plus-loss analyses. *Scandinavian Journal of Forest Research* 19: 512-523.

FABRA-CRESPO, M.; 2012. Aplicaciones de la tecnología LIDAR al sector forestal y comparación de costes frente a metodologías tradicionales. *Montes: revista de ámbito forestal*: 33-37.

FRAZER, G.; MAGNUSSEN, S.; WULDER, M.; NIEMANN, K.; 2011. Simulated impact of sample plot size and co-registration error on the accuracy and uncertainty of LiDAR-derived estimates of forest stand biomass. *Remote Sensing of Environment* 115: 636-649.

GOBAKKEN, T.G.T.; NÆSSET, E.N.E.; 2009. Assessing effects of positioning errors and sample plot size on biophysical stand properties derived from airborne laser scanner data. *Canadian Journal of Forest Research* 39: 1036-1052.

HOPKINSON, C.; CHASMER, L.; 2009. Testing LiDAR models of fractional cover across multiple forest ecozones. *Remote Sensing of Environment* 113: 275-288.

LIM, K.S.; TREITZ, P.M.; 2004. Estimation of above ground forest biomass from airborne discrete return laser scanner data using canopy-based quantile estimators. *Scandinavian Journal of Forest Research* 19: 558-570.

MAGNUSSEN, S.; BOUDEWYN, P.; 1998. Derivations of stand heights from airborne laser scanner data with canopy-based quantile estimators. *Canadian Journal of Forest Research* 28: 1016-1031.

MALTAMO, M.; BOLLANDSÅS, O.; NÆSSET, E.; GOBAKKEN, T.; PACKALÉN, P.; 2011. Different plot selection strategies for field training data in ALS-assisted forest inventory. *Forestry* 84: 23-31.

MCGAUGHEY, R.J.; CARSON, W.W.; 2003. Fusing LIDAR data, photographs, and other data using 2D and 3D visualization techniques. *Proceedings of Terrain Data: Applications and Visualization—Making the Connection*: 28-30.

MEANS, J.E.; ACKER, S.A.; FITT, B.J.; RENSLOW, M.; EMERSON, L.; HENDRIX, C.J.; 2000. Predicting forest stand characteristics with airborne scanning lidar. *PE & RS-Photogrammetric Engineering & Remote Sensing* 66: 1367-1371.

NÆSSET, E.; 2002. Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data. *Remote Sensing of Environment* 80: 88-99.

NÆSSET, E.; 2004. Accuracy of forest inventory using airborne laser scanning: evaluating the first Nordic full-scale operational project. *Scandinavian Journal of Forest Research* 19: 554-557.

NÆSSET, E.; GOBAKKEN, T.; 2008. Estimation of above-and below-ground biomass across regions of the boreal forest zone using airborne laser. *Remote Sensing of Environment* 112: 3079-3090.

NILSSON, M.; 1996. Estimation of tree heights and stand volume using an airborne lidar system. *Remote Sensing of Environment* 56: 1-7.

PARKER, R.C.; EVANS, D.L.; 2004. An application of LiDAR in a double-sample forest inventory. *Western Journal of Applied Forestry* 19: 95-101.

POPESCU, S.C.; 2007. Estimating biomass of individual pine trees using airborne lidar. *Biomass and Bioenergy* 31: 646-655.

RODRÍGUEZ, F.; BROTO, M.; 2010. *Ecuaciones de volumen comercial para las principales especies maderables de Castilla y León*. Fundación CESEFOR.

ZEIDE, B.; 1980. Plot size optimization. *Forest Science* 26: 251-257.