



COLEGIO DE POSTGRADUADOS

INSTITUCIÓN DE ENSEÑANZA E INVESTIGACIÓN EN CIENCIAS AGRÍCOLAS

CAMPUS MONTECILLO

POSTGRADO FORESTAL

**ESTIMACIÓN DE VARIABLES
DASOMÉTRICAS MEDIANTE TECNOLOGÍA
LiDAR**

ALMA DELIA ORTIZ REYES

T E S I S
PRESENTADA COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE:

MAESTRA EN CIENCIAS

MONTECILLO, TEXCOCO, EDO. DE MEXICO

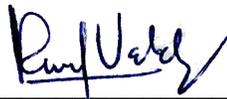
2014

La presente tesis titulada: “**Estimación de variables dasométricas mediante tecnología LiDAR**” realizada por la alumna: **Alma Delia Ortiz Reyes**, bajo la dirección del Consejo Particular indicado, ha sido aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRA EN CIENCIAS
POSTGRADO EN CIENCIAS FORESTALES

CONSEJO PARTICULAR

CONSEJERO



DR. JOSÉ RENÉ VALDEZ LAZALDE

ASESOR



DR. TOMÁS MARTÍNEZ TRINIDAD

ASESOR



DR. HUMBERTO VAQUERA HUERTA

Montecillo, Texcoco, Estado de México, marzo de 2014.

Esta investigación fue patrocinada por la Oficina de Programas Internacionales del Servicio Forestal del Departamento de Agricultura de EEUU a través del Northern Research Station y el Programa de Paisajes Sustentables de la Agencia para el Desarrollo Internacional de EEUU.

Asimismo se agradece al Proyecto "Fortalecimiento REDD+ y Cooperación Sur-Sur, México-Noruega" quienes financiaron parte del trabajo de campo.

AGRADECIMIENTOS

Al Consejo Nacional de Ciencia y Tecnología y al Colegio de Postgraduados, por la oportunidad de continuar con mi formación académica.

A los integrantes de mi consejo académico: **Dr. José René Valdez Lazalde**, **Dr. Tomas Martínez Trinidad** y **Dr. Humberto Vaquera Huerta** por el apoyo e interés para llevar a cabo este trabajo. Así mismo al **Dr. Gregorio Ángeles Pérez**, por su disponibilidad y confianza durante todo este proceso y al **Dr. Héctor Manuel de los Santos Posadas**, mi sincero agradecimiento por la asesoría en el análisis estadístico de los datos.

A l@s chic@s que con su trabajo apoyaron la toma de datos en campo, **Benjamin Mendez**, **Odettee Cadena**, **Oscar López**, **Ramiro Puc**, **Ángeles Soriano** y **Teresa Martínez**, porque todo fue más rápido y divertido.

A mis **amig@s** y **compañer@s**, por su ayuda, apoyo, compañía, asesorías y cada momento que compartimos, con ustedes todo fue más fácil, más comprensible, más alegre y menos solitario.

CONTENIDO

ÍNDICE DE CUADROS	iii
ÍNDICE DE FIGURAS	iv
RESUMEN	v
ABSTRACT	vi
1. INTRODUCCIÓN	1
2. OBJETIVOS DEL ESTUDIO	2
2.1 Objetivo general	2
2.2 Objetivos específicos	2
3. REVISIÓN DE LITERATURA	3
3.1 Sensores Remotos	3
3.2 El sensor LiDAR	4
3.3. Funcionamiento de la tecnología LiDAR.	5
3.4 Componentes del sistema LiDAR aerotransportado.	6
3.4.1 El vehículo	7
3.4.2 El sensor láser	7
3.4.2.1 Propiedades espectrales	9
3.4.2.2 Intensidad	9
3.5 Georeferenciación directa	11
3.6 Tipos de sistema LiDAR	12
3.7 Procesamiento de datos	13
3.7.1 Almacenamiento de datos.	14
3.7.2. Software de procesamiento	15
3.8 Productos finales de LiDAR	15
3.9 Aplicaciones de LiDAR	16
3.10 Aplicaciones en el campo forestal	17
3.10.1 Caracterización de la estructura del bosque	18
3.10.2 Inventarios forestales	20
3.10.3 Biomasa	21
3.11 Integración de sensores	22
4. MATERIALES Y MÉTODOS	24
4.1 Área de estudio	24
4.2 Diagrama metodológico	26

4.3 Obtención de los datos de campo.....	27
4.4. Cálculo de variables dasométricas.....	30
4.4.1 Área basal	30
4.4.2 Volumen y Biomasa.....	30
4.4.3 Cobertura arbórea	31
4.5 Obtención de datos LiDAR.....	31
4.6 Análisis de datos LiDAR.....	32
4.6.1 Creación de parcelas de LiDAR.....	33
4.6.2 Obtención de métricas LiDAR por parcela.....	33
4.7 Cálculo de las variables dasométricas mediante regresión lineal múltiple	35
4.7.1 Análisis de correlación.....	35
4.7.2 Modelos de regresión	35
4.8 Cálculo de las variables dasométricas mediante el uso de estimadores de razón y regresión empleando las métricas de LiDAR.....	37
4.9 Estimación de las variables dasométricas mediante muestreo estratificado.....	38
4.10 Generación de cartografía para las variables de interés.....	40
5. RESULTADOS Y DISCUSIÓN	41
5.1 Relación entre las variables forestales y métricas de LiDAR	41
5.2 Estimación de las variables dasométricas mediante regresión lineal múltiple ...	46
5.3 Estimación de las variables dasométricas mediante regresión no lineal.....	52
5.4 Estimación de las variables dasométricas mediante estimadores de razón y regresión	59
5.5 Comparación de las estimaciones obtenidas por regresión lineal, no lineal, estimadores de razón versus el inventario tradicional.....	62
5.6 Relaciones esperadas entre las variables dasométricas y las métricas de LiDAR.....	68
6. CONCLUSIONES Y COMENTARIOS FINALES.....	70
7. BIBLIOGRAFÍA	72
8. ANEXOS	81

ÍNDICE DE CUADROS

Cuadro 1. Contribuciones de la tecnología LiDAR en aplicaciones forestales.....	20
Cuadro 2. Valores de R^2 ajustada relacionando las imágenes de los diferentes sensores y los atributos estructurales: área basal y biomasa aérea.....	23
Cuadro 3. Funciones para estimar volumen y biomasa en diferentes tipos de vegetación.	30
Cuadro 4. Características del sensor LiDAR utilizado.....	32
Cuadro 5. Descripción de las métricas LiDAR obtenidas para cada parcela.	34
Cuadro 6. Estratos y su correspondiente superficie en la zona de estudio.	40
Cuadro 7. Coeficientes de correlación de Pearson entre las variables forestales: área basal ($m^2/sitio$), volumen ($m^3/sitio$), biomasa ($kg/sitio$) y cobertura arbórea ($m^2/sitio$) con las métricas de LiDAR.	42
Cuadro 8. Modelos de regresión lineal múltiple y variables seleccionadas para la estimación de variables forestales: área basal ($m^2/sitio$), biomasa ($kg/sitio$), cobertura arbórea ($m^2/sitio$) y volumen ($m^3/sitio$).....	44
Cuadro 9. Estimación promedio por hectárea y total de los parámetros forestales área basal (m^2), biomasa (Mg), cobertura arbórea (m^2 y %) y volumen (m^3) mediante regresión lineal múltiple.	47
Cuadro 10. Modelos de regresión no lineal y variables seleccionadas para la estimación de variables forestales: área basal ($m^2/sitio$), biomasa ($kg/sitio$), cobertura arbórea ($m^2/sitio$) y volumen ($m^3/sitio$).....	52
Cuadro 11. Estimación promedio por hectárea y total de los parámetros forestales área basal (m^2), biomasa (Mg), cobertura arbórea (m^2 y %) y volumen (m^3) mediante los estimadores de razón.....	61
Cuadro 12. Estimación promedio por hectárea y total de los parámetros forestales área basal (m^2), biomasa (Mg), cobertura arbórea (m^2 y %) y volumen (m^3) mediante los estimadores de regresión.....	61
Cuadro 13. Estimación promedio por hectárea y total de los parámetros forestales área basal (m^2), biomasa (Mg), cobertura arbórea (m^2 y %) y volumen (m^3) mediante muestreo simple aleatorio.....	63
Cuadro 14. Estimación promedio por hectárea y total de los parámetros forestales área basal (m^2), biomasa (Mg), cobertura arbórea (m^2 y %) y volumen (m^3) mediante muestreo estratificado.....	63
Cuadro 15. Comparación del inventario tradicional versus los diferentes métodos para la estimación total de área basal (m^2), biomasa (Mg), cobertura arbórea (%) y volumen (m^3).....	64

ÍNDICE DE FIGURAS

Figura 1. Diferencia de respuesta entre sensores pasivos y activos.....	3
Figura 2. Dispositivos principales del sistema LiDAR aerotransportado.	7
Figura 3. Mecanismos de escaneo y patrones sobre la superficie.....	9
Figura 4. Diagrama de LiDAR a) retorno discreto, b) retorno continuo	12
Figura 5. Ubicación de la zona de estudio en el Municipio de Zacualtipán, Hidalgo....	25
Figura 6. Proceso metodológico implementado en la investigación.....	26
Figura 7. Arreglo del conglomerado de muestreo.	28
Figura 8. Distribución de conglomerados de muestreo en el área de estudio.....	29
Figura 9. Gráficas de a) área basal ($m^2/sitio$), b) biomasa total ($kg/sitio$), c) cobertura arbórea ($m^2/sitio$) y d) volumen ($m^3/sitio$).....	46
Figura 10. Representación cartográfica del área basal (m^2ha^{-1}) en la zona de estudio.	48
Figura 11. Representación cartográfica de la biomasa total ($Mg ha^{-1}$) en la zona de estudio.....	49
Figura 12. Representación cartográfica de la cobertura arbórea (%) en la zona de estudio.....	50
Figura 13. Representación cartográfica del volumen ($m^3 ha^{-1}$) en la zona de estudio. .	51
Figura 14. Representación cartográfica del área basal ($m^2 ha^{-1}$) en la zona de estudio, utilizando el modelo no lineal.....	54
Figura 15. Representación cartográfica de la biomasa aérea ($Mg ha^{-1}$) en la zona de estudio, utilizando el modelo no lineal.	55
Figura 16. Representación cartográfica de la cobertura arbórea (%) en la zona de estudio, utilizando el modelo no lineal.	56
Figura 17. Representación cartográfica del volumen total ($m^3 ha^{-1}$) en la zona de estudio, utilizando el modelo no lineal.	57
Figura 18. Gráficas de a) área basal ($m^2/sitio$), b) biomasa total ($kg/sitio$), c) cobertura arbórea ($m^2/sitio$) y d) volumen ($m^3/sitio$).....	58
Figura 19. Correlaciones mayores de área basal, biomasa total, cobertura arbórea y volumen.....	60
Figura 20. Comparación de las variables forestales estimadas a través del inventario tradicional y los métodos que emplean las métricas de LiDAR..	65

ESTIMACIÓN DE VARIABLES DASOMÉTRICAS MEDIANTE TECNOLOGÍA LiDAR

Alma Delia Ortiz Reyes, M. C.

Colegio de Postgraduados, 2014.

La técnica más común para estimar variables dasométricas a escalas grandes o pequeñas son los inventarios forestales que se basan en un muestreo en campo. En la actualidad la teledetección ofrece un abanico de posibilidades para contrubuir a esa tarea, tal es el caso de los datos LiDAR (Light Detection And Ranging) que permiten obtener una nube de puntos georreferenciados que dibuja tridimensionalmente el bosque. En este trabajo se estudió la relación entre datos derivados de LiDAR y datos medidos en campo para estimar variables dasométricas como: área basal (AB), biomasa total (BT), cobertura arbórea (COB) y volumen (VOL), mediante cuatro métodos: 1) regresión lineal múltiple, 2) regresión no lineal, 3) estimadores de razón y regresión e 4) inventario forestal tradicional. Las estimaciones totales derivadas de los tres primeros enfoques se encuentran dentro del intervalo de confianza al 95 % calculado mediante el inventario tradicional, siendo los valores estimados mediante estimadores de razón y regresión los más cercanos y precisos con $AB=20,818.97 \text{ m}^2$, $BT=104,083.31 \text{ MG}$, $COB=108.59 \%$ y $VOL=157,993.14 \text{ m}^3$, seguidos de las estimaciones mediante modelos lineales. Las estimaciones de los modelos no lineales fueron los más optimistas con respecto al inventario tradicional. Los resultados indican una buena relación ($R^2 > 0.50$) entre las métricas de LiDAR y datos de campo, principalmente los percentiles de altura y las tasas de retorno sobre una altura definida. A partir de los modelos lineales se generó la cartografía de cada una de las variables de interés. Este estudio ratifica que el uso de los datos LiDAR es una herramienta que apoya el cálculo de inventarios forestales y puede ser usado a una escala regional.

Palabras claves: Inventario forestal, LiDAR, FUSION, biomasa total, volumen.

ESTIMATING DASOMETRIC VARIABLES THROUGH LiDAR TECHNOLOGY

Alma Delia Ortiz Reyes, M. C.

Colegio de Postgraduados, 2014.

The most common technique to estimate dasometric variables at large or small scales are field sampling-based forest inventories. At present remote sensing offers a range of possibilities to achieve that task, as is the case of LiDAR (Light Detection And Ranging) data, which through a georeferenced point cloud allows drawing the forest in three dimensions. In this paper the relationship between LiDAR data and data measured in the field was studied to estimate dasometrics variables as: basal área (BA), total biomass (TB), tree cover (TC) and timber volumen (TV) by four methods: 1) Multiple linear regression, 2) non-linear regression, 3) Ratio and regression estimators and 4) Traditional forest inventory. Total estimates derived from the first three approaches are within the 95 % confidence interval calculated by traditional inventory, being the estimated values through ratio and regression estimators the most nearby and precise with $BA=20,818.97 \text{ m}^2$, $TB=104,083.31 \text{ MG}$, $TC=108.59 \%$ y $TV=157,993.14 \text{ m}^3$, followed by estimations thorough linear models. Estimates thorough non-linear models were the most optimistic compared with traditional inventory. Results indicate a good relationship ($R^2 > 0.50$) among LiDAR derived metrics and field data, particularly height percentiles and rates of return at a defined height. From linear models a map was generated of each of the variables of interest. This study confirms that the use of LiDAR data is a tool that supports the calculation of forest inventories and can be used at a regional scale.

Key words: Forest inventory, LiDAR, FUSION, total biomass, volume.

1. INTRODUCCIÓN

La medición de variables dasométricas útiles para el manejo forestal se realiza tradicionalmente a través de muestreos en campo que sirven de base para dimensionar un inventario forestal definitivo, considerando un nivel de error permitido y un nivel de incertidumbre (Cruz *et al.*, 2010). Esta situación implica tiempo y costos considerables para la obtención de los parámetros biofísicos del bosque como el área basal, el volumen maderable, la biomasa total o la densidad (Hawbaker *et al.*, 2010).

La teledetección permite obtener información relevante para los inventarios forestales de forma más eficiente. Una de las principales ventajas de esta tecnología es la capacidad de obtener datos espacialmente explícitos en grandes áreas de manera oportuna y económica (Aguirre *et al.*, 2014). Por ello se ha utilizado en diferentes tipos de bosques como un medio para obtener estimaciones espacialmente continuas de las variables estructurales, tal es el caso de los sensores ópticos pasivos como las imágenes Landsat TM (Wulder, 1998).

El bajo costo de adquisición de datos mediante sensores ópticos, ha provocado que la investigación digital de teledetección para la estimación de parámetros biofísicos del bosque se haya centrado en utilizar este tipo de sensores. Sin embargo, la capacidad de éstos es limitada, en parte porque proporcionan información en dos dimensiones, siendo necesario estudiar las variables estructurales de forma tridimensional (Hall *et al.*, 2005). Además de la imposibilidad de los sensores ópticos para medir directamente indicadores importantes de la estructura de la vegetación como el área basal, la altura del dosel o estimaciones de cambios en la biomasa, los cuales permiten realizar un diagnóstico del estado actual del ecosistema o predecir a largo plazo los cambios en su composición y función (Antonarakis *et al.*, 2011).

En la actualidad existe otro tipo de tecnología de teledetección que permite obtener información tridimensional del bosque. Tal es el caso de LiDAR (Light Detection And Ranging) y Radar (Radio Detection and Ranging), las cuales detectan la respuesta reflejada de los objetos que son iluminados a partir de fuentes de energía generada de manera artificial, y que ofrecen mejores alternativas para estudiar este tipo de variables (Dubayah and Drake, 2000).

Dentro de las cualidades que ofrece LiDAR, se encuentra su alta resolución espacial y buena penetración en el dosel para obtener variables dasométricas tales como altura de los árboles, área basal, área de la copa, densidad y la clasificación de grupos de especies (Van Aardt *et al.*, 2008; Valdez y Aguirre, 2013), características que son valiosas en evaluaciones ambientales para definir a través del uso de modelos la cantidad de biomasa o el volumen de madera en los bosques (Popescu, 2007; Navarro *et al.*, 2010).

A pesar de que las variables dasométricas son relativamente simples de obtener, los conocimientos y técnicas para el procesamiento de datos con LiDAR en estudios del sector forestal de México, no están suficientemente desarrollados para su aplicación directa. La literatura apenas reporta estudios de obtención de variables dasométricas a partir de datos LiDAR en zonas específicas de México, lo que justifica realizar un estudio con el propósito de estimar variables dasométricas empleando esta tecnología en una zona de interés.

En este trabajo se evaluó la precisión con que se pueden estimar variables dasométricas (área basal, biomasa total, cobertura arbórea y volumen maderable) a partir de datos LiDAR. Los resultados de las estimaciones se compararon con los resultados obtenidos mediante un inventario forestal tradicional y se generó la cartografía de cada variable.

2. OBJETIVOS DEL ESTUDIO

2.1 Objetivo general

- Estimar variables dasométricas de un bosque templado mediante la aplicación de tecnología LiDAR en la zona de Zacualtipán de los Ángeles, Hidalgo.

2.2 Objetivos específicos

- Comparar la precisión de los resultados obtenidos mediante el uso de tecnología LiDAR contra un inventario tradicional.
- Generar la cartografía de cada una de las variables estimadas en la zona de estudio.

3. REVISIÓN DE LITERATURA

3.1 Sensores Remotos

Existen dos tipos de sistemas de sensores remotos: activos y pasivos. Un sistema pasivo usa el sol como fuente de radiación electromagnética. La radiación emitida por el sol interactúa con la superficie mediante los procesos de reflexión, dispersión y absorción, y los detectores a bordo de plataformas del sensor miden la cantidad de energía que se refleja (Gibson, 2000). La mayoría de los sensores empleados para la observación de la tierra son pasivos, los cuales generalmente registran energía electromagnética en el rango visible del espectro electromagnético, (400 a 700 nanómetros); ejemplos de ellos son los sistemas fotográficos, sensores multiespectrales e hiperspectrales.

Un sensor remoto activo emite su propio recurso de radiación electromagnética. Esta radiación es dirigida a la superficie y la energía que se dispersa de la superficie se registra. Los sistemas activos pueden operar a cualquier hora del día e incluso penetrar las nubes (INEGI, 2013). El sistema RADAR es un sistema remoto activo común que produce radiación electromagnética que opera en frecuencias de radio o de microondas (300 MHz y 300 GHz). Otro sistema activo que ha sido usado en percepción remota son los láseres como LiDAR y dispositivos SONAR (Gibson, 2000).

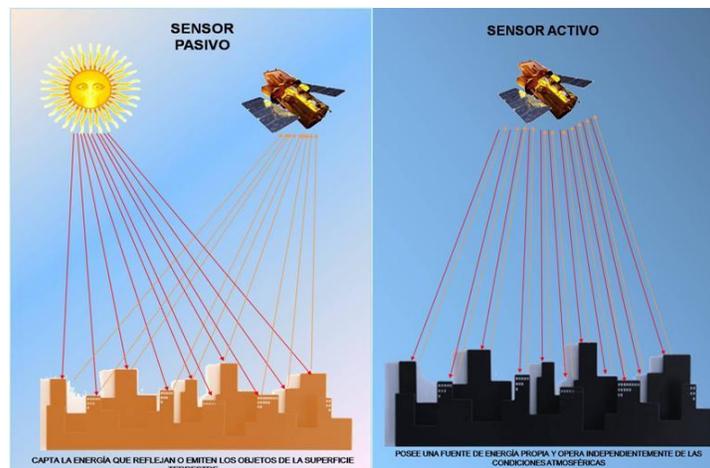


Figura 1. Diferencia de respuesta entre sensores pasivos y activos (INEGI, 2013).

3.2 El sensor LiDAR

Durante la década de 1960 se iniciaron trabajos y estudios que emplearon sistemas láser con el fin de obtener información altimétrica (Raber and Cannistra, 2005). Posteriormente, en la siguiente década la NASA (National Aeronautics and Space Administration) comenzó a trabajar con prototipos aéreos que buscaban el despliegue de sensores aerotransportados, estos trabajos se enfocaron en mediciones de la atmósfera (Flood, 2001), el agua de los océanos, análisis volumétrico y de composición de materiales, estudios sobre las capas de hielo y el dosel del bosque.

Para la década de 1980, la Universidad de Stuttgart realizó estudios que demostraban la alta precisión geométrica de un sistema láser, sin embargo, resultó complicado hacer uso de esta tecnología ya que no se contaba con los sistemas de geoposicionamiento global y de navegación inercial como los desarrollados actualmente (National Oceanic and Atmospheric Administration, 2008).

Fue hasta la década de 1990 que el láser se empleó en levantamientos topográficos y en percepción remota como sensor activo; a mediados de ese periodo, los fabricantes de escáneres láser lanzaron al mercado sensores capaces de emitir de 2,000 a 25,000 pulsos por segundo. En ese momento, esta tecnología resultó de interés para usuarios de datos geospaciales, teledetección y fotogrametría ya que se consideró robusta y que proporcionaba alta densidad de datos que no se lograba con otros medios. En este punto, los proyectos se enfocaron en obtener información de elevación para estudios fotogramétricos, el mapeo del suelo desnudo y la caracterización del bosque (Schuckman y Renslow, 2012).

En la primera década del siglo XXI los sensores LiDAR alcanzaron su mayor nivel de diversificación y progreso ya que se desarrollaron escáneres más robustos y estables que, dependiendo del dispositivo pueden emitir más de 250,000 pulsos por segundo (Lemmens, 2011). Así mismo, el perfeccionamiento en los sistemas de geoposicionamiento global y de medición inercial para captura de los parámetros de orientación del sensor, permiten mediciones más confiables y consistentes. Esto permitió que los sectores comerciales y privados ofrecieran nuevos programas de computo (softwares) y servicios para el procesamiento y elaboración de productos

finales, mientras que el sector académico apostó al uso de esta tecnología en sus líneas de investigación (Lichti *et al.*, 2008).

Debido a la gran cantidad de fabricantes de sensores, creadores de software y usuarios de LiDAR, se hizo necesario contar con especificaciones técnicas y normas de precisión, por lo que la American Society for Photogrammetry and Remote Sensing (ASPRS) desarrolló el formato LiDAR Archive Standard (LAS) para el intercambio de datos binarios, el cual ha sido ampliamente aceptado (Cerrillo, 2010).

Actualmente existen más de 200 sistemas LiDAR operando en el mundo y su uso se ha extendido rápidamente debido a que los usuarios conocen las ventajas y beneficios que este tipo de datos y productos derivados proporciona a las aplicaciones geoespaciales.

Los sistemas modernos son capaces de manejar múltiples pulsos en un momento específico, capturar múltiples retornos de pulsos individuales o incluso digitalizar el retorno completo de la onda (Næsset, 1997).

3.3. Funcionamiento de la tecnología LiDAR.

LiDAR por su acrónimo en inglés significa **L**ight **D**etection **A**nd **R**anging es decir, detección y medida de luz. También se le conoce como **L**aser **I**maging **D**etection **A**nd **R**anging; es un método directo y activo que puede coleccionar valores de elevación de manera densa y precisa (Wehr and Lohr, 1999). Es capaz de producir una rápida colección de puntos sobre un área extensa; este grupo de datos proporciona grandes ventajas sobre otras técnicas como: su alta resolución espacial, precisiones próximas a centímetros, buena penetración en el bosque, mínima dependencia de condiciones atmosféricas y menor tiempo de producción tanto en la obtención de datos como en el procesamiento de productos finales (National Oceanic and Atmospheric Administration, 2008).

De acuerdo con Baltsavias (1999), el sistema LiDAR funciona bajo el principio de medir el tiempo de viaje entre el pulso emitido (por el sensor) y el pulso que recibe (del objetivo), la medición de la distancia (*R*-rango) se da al multiplicar este intervalo de tiempo por la velocidad de la luz y dividirlo entre dos como se ilustra en la siguiente ecuación:

$$R = c \frac{t}{2}$$

Donde t es el intervalo de tiempo relativo a un punto específico sobre el pulso y c es la velocidad de la luz, aproximadamente 300,000 km/segundo. Si sólo se multiplicara, se obtendría la distancia recorrida del sensor al objeto de interés, y de regreso, conocido como “viaje redondo”.

3.4 Componentes del sistema LiDAR aerotransportado.

El sistema LiDAR aerotransportado (Airborne Laser Scanning - ALS) también conocido como Airborne LiDAR Topographic (ALT), Airborne LiDAR Terrain Mapping System (ALTMS) y Airborne Laser Swath Mapping (ALSM); consiste en un sensor instalado en una plataforma móvil que emite pulsos láser mediante un barrido horizontal de la superficie reflectante y mide el tiempo en que dichos pulsos llegan a la superficie y retornan al sensor, obteniendo una nube de puntos de coordenadas precisas (García, 2009).

El equipo LiDAR está compuesto por un sensor láser, un sistema inercial de navegación (INS) y un receptor GPS en una plataforma (Figura 2). En el terreno es necesario contar con una red de GPS que trabaja conjuntamente con el instalado en la plataforma y el número mínimo de satélites GPS para realizar el levantamiento de datos deben ser cuatro.

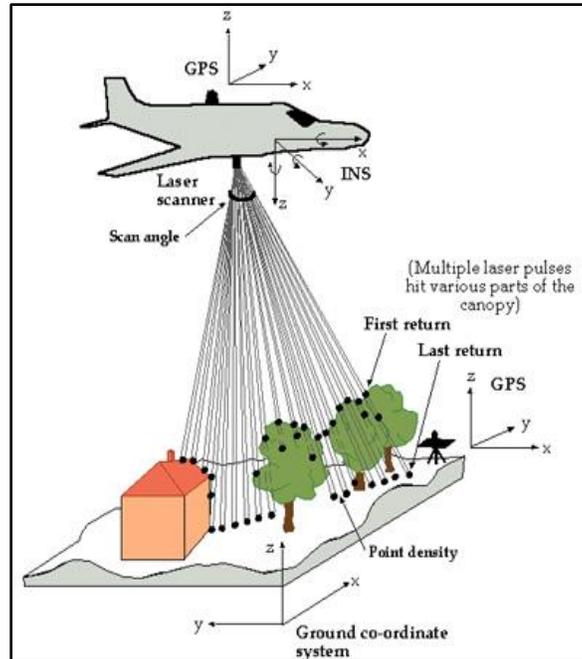


Figura 2. Dispositivos principales del sistema LiDAR aerotransportado (Dowman, 2007).

3.4.1 El vehículo

El sensor LiDAR aerotransportado se instala comúnmente en aviones tripulados, en helicópteros e incluso en vehículos aéreos no tripulados o globos dirigibles (Baltsavias, 2008). Tanto el sensor como el GPS y los sistemas inerciales son montados en el fuselaje del avión, en el ala o se instalan en dispositivos especiales sobre una parte externa de la aeronave.

Dependiendo de los objetivos y alcances del proyecto, así como del área a escanear, se elegirá el tipo de vehículo aéreo; por ejemplo, los sensores montados en un helicóptero permitirán una captura de mayor densidad de datos, aunque su procesamiento digital será mayor que los datos capturados por un avión.

3.4.2 El sensor láser

El sensor láser es el componente principal en esta tecnología, en él se encuentra la fuente de láser, el detector láser, el mecanismo de digitalización, el sistema electrónico para cronometrar los pulsos y retornos y la computadora que procesará y registrará los datos en tiempo real (Schuckman y Renslow, 2012).

Las configuraciones del sensor láser se pueden dividir de la siguiente manera: primero dependiendo del modo de trabajo del láser empleado, el cual puede ser de onda continua (que se interpreta como la potencia de emisión expresada por una senoide), o de pulso (refiriéndose al envío de pulsos en intervalos regulares de tiempo). El funcionamiento del sensor láser también se precisa por la trayectoria que realiza la señal reflejada en el terreno debido a la óptica de salida del sensor láser (Figura 3) utilizando ya sea un espejo oscilante, un polígono rotatorio, el escáner de Palmer o de fibra óptica rotatoria (Wehr & Lohr, 1999).

Los patrones de barrido de acuerdo con Baltsavias (2008), se enlistan a continuación:

- Zigzag: Un espejo oscilatorio junto con un galvanómetro direcciona el pulso láser haciendo más uniforme el barrido. Este es el patrón más utilizado por los sensores comerciales.
- Sinusoidal: También conocido como de tipo meandro, utiliza un espejo parecido al patrón zigzag, que es muy utilizado por los sensores comerciales.
- Líneas paralelas: Usa un espejo poligonal que direcciona el pulso láser a lo largo de líneas paralelas del barrido. Una de las ventajas es la uniformidad de los puntos a lo largo del barrido.
- Elípticas: Este patrón es generado a través de un espejo rotatorio o un espejo nutatorio (Escáner Palmer) que gira sobre su propio eje junto con la inclinación del avión. Ejemplos de espejos rotatorios están: poligonal, piramidal, de prisma, inclinado y de un lado.
- TopoSys: Este patrón fue desarrollado por la empresa alemana TopoSys. Este sensor, a diferencia de los anteriores, emite los impulsos y recibe los retornos a través de fibra óptica. La ventaja del TopoSys es que los pulsos lineales y sinusoidales son paralelos, uniformes y espaciados durante el escaneo.

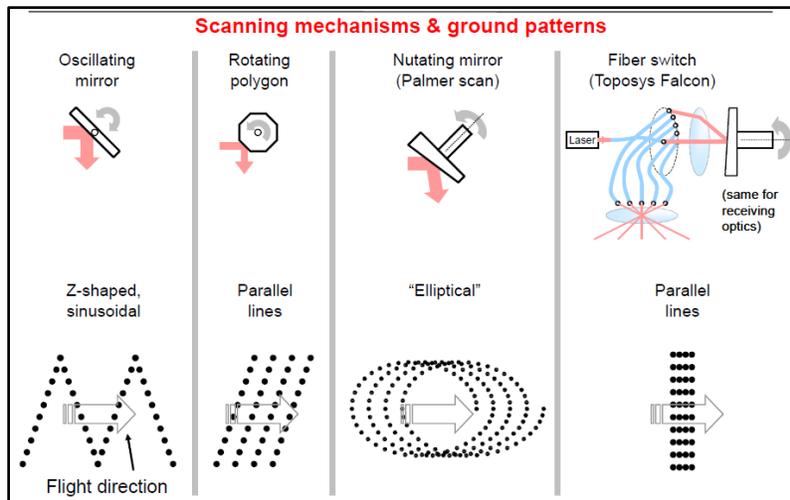


Figura 3. Mecanismos de escaneo y patrones sobre la superficie (Baltsavias, 2008).

Todos los patrones de barrido y densidad de puntos son afectados en cierta medida por la geometría misma del patrón, causando distorsiones para la obtención de la nube de puntos, los cuales deben ser corregidos por diferentes procedimientos tanto técnicos como computacionales.

3.4.2.1 Propiedades espectrales

La longitud de onda en la cual trabajan la mayoría de los láseres es de 1064 nanómetros (nm), ubicada en la banda del infrarrojo cercano del espectro electromagnético, aunque existen algunos sistemas que trabajan en 810, 900 nm (ScaLAR, FLI-MAP) ó en 1540 nm (TopoSys y Riegl). El LiDAR topográfico sólo emite en una longitud de onda, pero en el caso de LiDAR batimétrico, emiten en dos longitudes de onda, usualmente en 1064 y 532 nm. La longitud de onda infrarroja es reflejada sobre el agua de la superficie mientras que el verde penetra en el agua y es reflejada por la superficie inferior y otros objetos en el agua (Baltsavias, 2008).

3.4.2.2 Intensidad

La mayoría de los sistemas LiDAR registran la intensidad o magnitud del pulso de retorno, es decir, además de medir el tiempo de retorno de un pulso miden la fuerza de éste. Los valores de intensidad varían dependiendo de la altura de vuelo, condiciones

atmosféricas, propiedades direccionales de reflectancia, la reflectividad del objetivo y los parámetros del láser (Baltasvias, 1999).

Hudak *et al.* (2009) indica que una vez calculada la altura, cobertura y otras mediciones de la vegetación a determinada resolución de celda se puede obtener una capa ráster. Estas salidas ráster son análogas a las bandas en una imagen multiespectral, pero la salida de LiDAR indica características estructurales en lugar de espectrales, por ejemplo, la distribución de valores de altura del dosel en determinada celda es en realidad una “firma estructural” análoga a la “firma espectral” de un píxel de la imagen hiperespectral, pero en cada una de las firmas se caracterizan propiedades de la vegetación muy diferentes. Una firma estructural es más consistente para la clasificación, por ejemplo, del potencial de crecimiento maduro (potential old-growth), mientras que una firma espectral debe ser más sensible, por ejemplo a condiciones de salud de la vegetación.

Bajo esta consideración, la salida ráster de LiDAR no se puede analizar de la misma forma que se analiza la reflectancia en una imagen obtenida por un sensor óptico pasivo; sin embargo, contar con una imagen de intensidad de datos LiDAR es de gran ayuda para interpretar y clasificar los retornos, además es posible crear pares estereoscópicos para apoyar la extracción de datos, a este proceso se le denomina Lidargrametría (Schuckman and Renslow, 2012). Hay un enorme potencial de complementariedad entre las firmas estructurales y espectrales en la investigación futura de integración de datos de sensores remotos.

En este sentido, existen investigaciones que han examinado el potencial de aplicación para describir las características del bosque empleando la intensidad de datos LiDAR como el que realizó Kim *et al.* (2008) en donde buscaban comprobar si la intensidad puede ser usada en la diferenciación y clasificación por grupos de especies en áreas boscosas. Encontraron que los datos de intensidad fueron capaces de distinguir entre las especies caducifolias de las especies de coníferas, sin embargo, esta diferenciación también está relacionada con características del bosque como apertura del dosel, espaciamiento y tipo de follaje de las copas de los árboles.

Cabe señalar que una característica fundamental de LiDAR es que es una herramienta de muestreo y no una imagen. Incluso en el caso de la exploración o “imágenes” obtenidas mediante los sistemas de retorno discreto, la unidad de muestreo fundamental, o el pulso láser mejor conocido como “huella”, rara vez se distribuye tan densamente como para proporcionar una cobertura espacial continua, como sucede en los píxeles de la imagen. Además, se distribuye verticalmente de forma discontinua en tercera dimensión, lo cual es la principal razón porque la densidad de puntos LiDAR varían en proporción a la complejidad de la superficie a través del paisaje, mientras que la densidad del pixel de la imagen son espacialmente continuos (Hudak *et al.*, 2009).

3.5 Georeferenciación directa

La georeferenciación directa se refiere a la medición de la posición del sensor en las coordenadas X, Y, Z y en su orientación con respecto al aleo y cabeceo del avión. Para realizar la georeferenciación directa es necesario contar con un sistema de posicionamiento global (GPS) auxiliado por un sistema de navegación inercial (Schuckman y Renslow, 2012).

La tecnología GPS se emplea para derivar la posición precisa del sensor en X, Y, Z en un espacio tridimensional mientras que está montado en la plataforma móvil. Para alcanzar las máximas precisiones se sitúa en el avión un receptor GPS de doble frecuencia, mientras que en tierra se establece una red que realiza una observación simultánea con el medio móvil (Ibañez, 2008).

El GPS permite posicionar en tiempo real al instrumento, para saber en cada momento donde se encuentra. Después de realizar el vuelo se combinan los datos del GPS de la plataforma con los del GPS diferencial en tierra, para obtener precisiones de hasta 5 cm en la posición del instrumento (García, 2009).

El sistema de navegación inercial orienta a la plataforma tomando como punto fijo la antena del GPS. El componente principal que realiza esta función es la unidad de medición inercial. La unidad mide la rotación en los tres ejes espaciales (giro, inclinación y cabeceo) con una precisión de 0.001 grados de forma que se pueden compensar dichos movimientos; así como las velocidades y aceleraciones en las tres dimensiones, utilizando la combinación de giroscopios y acelerómetros. Las mediciones

del sistema de navegación y del GPS son utilizadas por el procesador para calcular con precisión la posición, velocidad y orientación del transporte aéreo (García, 2009).

3.6 Tipos de sistema LiDAR.

Existen dos grandes categorías en los que se clasifica LiDAR: 1) de retorno discreto de la onda o huella pequeña y 2) de retorno continuo de la onda o huella grande (Figura 4). Los dispositivos de retorno discreto miden un pequeño número de alturas para identificar en la señal retornada, los picos principales que representan objetos discretos en el camino de la iluminación láser (Lefsky *et al.* 2002). Este tipo de LiDAR emite un pequeño haz de luz (centímetros de diámetro) y graba las posiciones a la cual la energía retornada es más grande que un determinado umbral.

Los dispositivos de huella grande graban la forma de onda y registran la intensidad variable en el tiempo de la energía retornada de cada pulso láser, proporcionando un registro de distribución de altura de las superficies iluminadas por el pulso. LiDAR de retorno continuo se caracteriza por la emisión de un haz amplio de luz (decenas de metros de diámetro), la energía devuelta se almacena como un perfil de altura de la intensidad dentro de ese haz (Mallet y Bretar, 2009).

Los sensores típicos de esta categoría son: SLICER (Scanning Lidar Imager of Canopies by Echo Recovery), LVIS (Laser Vegetation Imaging Sensor) y ICESat (Ice, Cloud, and land Elevation Satellite).

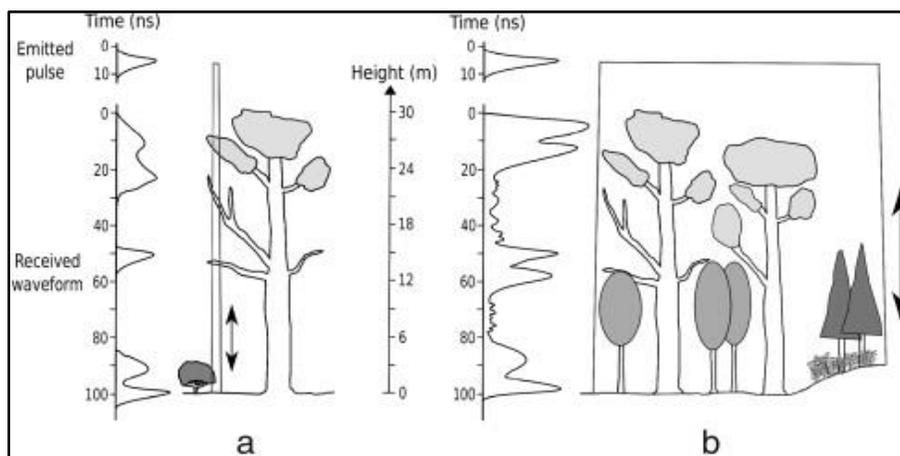


Figura 4. Diagrama de LiDAR a) retorno discreto, b) retorno continuo (Mallet y Bretar, 2009).

LiDAR de huella grande es típicamente desarrollada dentro de programas experimentales y los vendedores comerciales no los ofrecen (Andersen, 2005). A diferencia de LiDAR de retorno discreto que se distribuye ampliamente en los sensores comerciales como: Optech ALTM 1020, DATISII (3Di/EagleScan Inc.), AeroScan (EarthData Inc.) Leica-Geosystems ALS40 por mencionar algunos.

Los sistemas de retorno discreto identifican al recibir la señal de retorno, los tiempos de retención y altura de los picos principales; los sistemas que graban la forma de onda, capturan la señal entera para su posterior procesamiento y registra las posiciones de la cual la energía devuelta es mayor que un determinado umbral.

3.7 Procesamiento de datos

Una vez que se tienen los datos de los escaneos aéreos auxiliado por los sistemas inerciales de navegación, los receptores GPS del avión y puntos de control en el campo, se corrige la posición y se procesan los datos para así obtener los puntos escaneados de forma vectorial y tridimensional georreferidos, a este nuevo modelo se le conoce como la nube de puntos. Posteriormente, con la ayuda de software especializados y equipo de cómputo muy rápido y de gran capacidad de almacenamiento se generan varios productos de salida (Evans *et al.*, 2009).

Para el procesamiento de los datos LiDAR es necesario separar los puntos que pertenecen al terreno de los puntos que pertenecen a la vegetación o a construcciones. Para esta labor se han desarrollado diferentes procedimientos y algoritmos de filtrado (Wehr y Lohr, 1999). Sin embargo, a pesar de los esfuerzos de diversos autores la técnica no está completamente desarrollada. El filtrado se realiza utilizando los datos crudos o una cuadrícula regular interpolada, sin embargo en el último caso se presenta una desventaja por los errores de interpolación.

La visualización de datos y la edición manual es necesaria en diferentes etapas del procesamiento. Los grandes avances se han logrado principalmente en la mejora de los programas de post procesamiento de datos y menos en el hardware del escáner láser.

Generalmente el proveedor de datos realiza correcciones para la conversión de datos crudos a través de una geo-corrección de los retornos, usando la estación base del GPS y los datos del sistema de navegación inercial, así como la proyección y transformaciones del datum, las correcciones de los sensores y el formato de los datos.

Así mismo es necesario realizar correcciones geodésicas que permitan una adecuada precisión y exactitud, obteniendo una máxima precisión (Root Mean Square Error) vertical de 10 cm y horizontal de 5 cm, dependiendo del sensor GPS. En caso que se requiera de mayor precisión y exactitud topográfica, los datos LiDAR tiene que complementarse con un modelo de la misma zona obtenido mediante un sensor LiDAR terrestre (Lohani, 2008).

Para obtener un modelo digital que se acerque lo más posible al terreno es necesario hacer una corrección geométrica, la cual busca la relación correcta entre un punto LiDAR y su correspondiente coordenada geodésica. Aunque algunos sensores integran la proyección geodésica UTM al momento del escaneo por el GPS, hay sensores que manejan sus propias referencias geográficas que tienen que ser reproyectadas a UTM. Sin importar que los sensores integren UTM, es necesario verificar la proyección mediante el ángulo del sensor, sistema de navegación inercial, puntos de control de campo, modelos digitales de elevación u ortofotos (vuelos fotogramétricos y satelitales) para buscar áreas de coincidencias geodésicas.

3.7.1 Almacenamiento de datos.

Una vez realizadas las correcciones, se obtiene una nube de puntos digital completa o en partes (mosaicos de nubes de puntos) que permite un sencillo manejo digital y procesamiento sólo de algunas partes del modelo. En la actualidad existen dos problemas con la operación digital de los modelos de nubes de puntos (Real, 2011):

- 1) Algunos modelos están compuestos de millones de puntos (en algunos casos pueden pesar más de 1 terabyte TB), necesitando gran espacio digital para su procesamiento. En general, los datos brutos LiDAR son más pesados que los productos finales post-procesados.

2) No existe un software único que permita realizar todos los procesos (desde la captura, post-procesamiento, correcciones, análisis u obtención de productos finales), por ello es necesario la utilización de varias herramientas en cada paso, lo cual resalta la importancia de la interoperabilidad entre los datos digitales. Este problema de interoperabilidad se debe en parte al rápido desarrollo de software comercial y académico, cada uno de éstos con sus propios formatos.

3.7.2. Software de procesamiento

De acuerdo con Fernández *et al.* (2007), el software de procesamiento LiDAR puede clasificarse en tres categorías:

- I. Captura: cuando se captura el pulso-retorno, un software lo almacena digitalmente en el sensor y permite que dichos datos se exporten a otras herramientas. Algunas veces este mismo software permite observar los datos captados (2D o 3D) o importar datos de otros sensores.
- II. Proceso: Permiten trabajar directamente los datos con las siguientes funciones: corregir, cortar, transformar, exportar o reducir tamaño digital.
- III. Análisis: obtener información cuantitativa de los datos (segmentar, clasificar, filtrar, fusionar) que permitan obtener los modelos digitales que pueden enviarse a otros programas con fines ilustrativos, demostrativos, aplicativos, entre otros.

3.8 Productos finales de LiDAR

Posterior al procesamiento de datos LiDAR con la ayuda de un software especializado, se obtiene finalmente el modelo de la nube de puntos que representa el área escaneada.

Estos productos se pueden clasificar en los siguientes modelos digitales (INEGI, 2011):

Modelos digitales de elevación (MDE) a partir de la nube de puntos completa, los cuales son una representación visual y matemática de los datos de relieve que caracterizan las formas del terreno, representa todo lo que existe en cierta área, ya sean accidentes topográficos, vegetación, cuerpos de agua, construcciones, caminos, asentamientos humanos, campos de cultivo, etc.

Modelos digitales de superficie (MDS) que contienen todos los detalles y elementos existentes sobre el terreno, como las características de la vegetación o construcciones.

Modelos digitales del terreno (MDT), los cuales sólo representan la forma del terreno que se obtiene mediante procesos de filtrado del modelo digital de superficie.

La información del modelo se almacena en estructuras ráster o vectoriales (Felicísimo, 1999). Los modelos más usados en LiDAR son los ráster por la simplicidad computacional que aportan.

3.9 Aplicaciones de LiDAR.

Flood (1999) indica las siguientes aplicaciones en las que la tecnología LiDAR ofrece ventajas sobre otras técnicas empleadas con el mismo propósito:

- a) Modelado urbano: Los modelos digitales precisos de las zonas urbanas se utilizan para una amplia gama de aplicaciones como las telecomunicaciones, el modelado del microclima, las comunicaciones inalámbricas, la detección de construcciones ilegales, la planificación de catástrofes o planes de emergencia, aplicaciones de ingeniería entre otras. Es uno de los campos de mayor interés en la cartografía por la necesidad de contar con información actualizada y precisa.
- b) Cartografía de riesgos de avenidas e inundaciones: LiDAR ofrece un método rentable que permite obtener datos topográficos que funcionan como variables de entrada en varios programas de modelado de riesgos de avenidas e inundaciones. El empleo de estos sistemas permiten la generación de cartografía precisa de las zonas susceptibles a sufrir inundaciones, aspecto básico para la planificación, la valoración de riesgos, e incluso para la valoración en caso de una catástrofe.
- c) Cartografía de elementos lineales: El sistema láser aerotransportado ofrece MDE de corredores lineales en un bajo tiempo de producción y bastante efectivo. Este tipo de cartografía es muy frecuente para el diseño y ejecución de vías de comunicación, trasvases o conducciones de gas.

- d) Humedales y áreas de acceso restringido. Existen zonas de interés ambiental de las cuales es necesario contar con información precisa, sin embargo, su acceso puede ser difícil como pantanos, humedales y manglares. En estos casos la aplicación de sistemas LiDAR presenta importantes ventajas sobre técnicas fotogramétricas o topográficas. Esta tecnología también puede ser aplicada a zonas en las que existen depósitos de residuos tóxicos o industriales.
- e) Cartografía de zonas costeras: La aplicación a las zonas costeras proporciona importantes ventajas con respecto a las técnicas fotogramétricas, en particular, para el control y la monitorización de zonas especialmente dinámicas y de escasa textura de imagen, por ejemplo, las zonas de playa y dunas. Con series temporales de vuelos LiDAR se puede evaluar la evolución de la línea de costa, o las dunas.
- f) Manejo de recursos forestales: Es uno de los primeros campos en los que se investigó la aplicación de LiDAR. Es posible obtener de forma precisa la topografía tanto del terreno como de las copas de los árboles, esta información en muchos casos es difícil de obtener mediante técnicas convencionales. El post procesamiento de los datos permite separar los retornos clasificados como vegetación o terreno. Así mismo, existen técnicas desarrolladas por el sector de investigación en los que usan la forma completa de la onda para estudiar la estructura completa del dosel. Esto lo hace una técnica bastante efectiva comparada con la fotogrametría para estudios de grandes superficies.

3.10 Aplicaciones en el campo forestal

Los datos generados mediante la tecnología LiDAR proporcionan una alta resolución y gran detalle de bosques, cuencas hidrográficas, caminos y otros recursos valiosos para informar y mejorar las decisiones de manejo de recursos naturales. LiDAR permite obtener caracterizaciones de atributos del suelo y vegetación que son consistentemente precisas, lo que destaca su potencial para aplicaciones a gran escala (Hudak *et al.*, 2009). Se identifican al menos tres grandes rubros de las aplicaciones de LiDAR en el manejo de recursos naturales: caracterización de la estructura del bosque, aplicaciones de recursos que incluye inventarios forestales, fuego y combustibles,

ecología y fauna, geología, geomorfología e hidrología superficial y por último la integración de sensores.

3.10.1 Caracterización de la estructura del bosque

La altura de la vegetación a diferentes niveles sobre el suelo es uno de los atributos más comúnmente usados para describir la estructura del bosque. Variables como: número de estratos del dosel, diámetro de copa del árbol, altura total del árbol, densidad de tallos, biomasa, área basal y volumen pueden ser modeladas fácilmente con mediciones de altura generadas a partir de datos LiDAR (Hudak *et al.*, 2009).

Uno de los primeros trabajos para obtener variables forestales con tecnología LiDAR fue el descrito por Næsset (1997), cuyo objetivo fue evaluar la exactitud con que se determinaba la altura media de los árboles en bosques noruegos empleando un sistema de retorno discreto. En la investigación encontró una subestimación entre las alturas obtenidas con el sensor y los datos registrados en campo de 4.1 a 5.5 m y una desviación estándar de 1.3 -1.6 m. Sin embargo dichas estimaciones disminuyeron cuando utilizó un enfoque de ponderación en las alturas que se obtuvieron mediante el sistema láser. El sesgo de las estimaciones de LiDAR estuvo en el intervalo -0.4 m a 1.9 m. La desviación estándar de las diferencias entre la altura medida del láser y la del terreno fue de 1.1 a 1.6 m.

Otro estudio preliminar que evaluó las principales características estructurales (altura, área basal y volumen) obtenidos a partir de la tecnología láser fue el descrito por Means *et al.* (2000). Estos autores encontraron que al correlacionar las variables obtenidas en campo (variables predictoras) con las variables obtenidas mediante LiDAR a través de la técnica de regresión Stepwise, la altura se predijo con bastante exactitud con una R^2 de 0.93. En el caso del área basal se ajustaron regresiones con logaritmo natural, debido a que presentaba heterocedasticidad con las variables predictoras y esto también provocó una correlación bastante alta de 0.95, el mismo caso sucedió con el volumen que se correlacionó con un valor de R^2 de 0.97.

Por otro lado, Drake *et al.* (2002) realizaron un estudio usando el sensor LVIS (Laser Vegetation Imaging Sensor) el cual es un sistema de huella grande con 25 m de diámetro, para estimar características estructurales de un bosque tropical en Costa

Rica. Los autores emplearon la técnica de regresión Stepwise para predecir el diámetro medio cuadrático del fuste, área basal y biomasa aérea a nivel de parcela obteniendo altas correlaciones; el valor de R^2 y RMSE fue de 0.93 (2.00 cm), 0.72 (3.00 m²/ha) y 0.93 (18.39 Mg/ha) respectivamente. Lo que indicó que LiDAR de huella completa es un sistema prometedor para estimar atributos estructurales del bosque que permiten calcular biomasa en bosques tropicales.

Popescu *et al.* (2003) estudiaron el diámetro de copa por árbol en bosques mixtos de coníferas y caducifolios al Sur de E.U.A. El diámetro de copa fue considerado importante para estimar otras características como volumen del árbol y biomasa. Las mediciones derivadas de LiDAR se usaron en modelos de regresión y validación cruzada para estimar a nivel de parcela el diámetro de copa. Los resultados de la estimación del diámetro de copa fueron similares para coníferas y caducifolios con valores de $R^2=0.62$, 0.63 y RMSE de 1.36 a 1.41 m y para la estimación de volumen y biomasa la correlación fue por arriba de $R^2=0.25$ con un RMSE de 8 m³/ha para volumen y 7 Mg/ha.

Otro estudio que parte de la medición de variables estructurales para posteriormente realizar estimaciones derivadas se realizó por Hall *et al.* (2005), en donde emplearon LiDAR de retorno discreto para estimar variables como altura del rodal, biomasa aérea total, biomasa foliar, área basal, densidad de árboles, altura base del dosel y densidad aparente del dosel, las cuales sirvieron como variables de entrada en modelos predictivos de comportamiento de fuego. Usaron el criterio de información Akaike, para clasificar los modelos de regresión y seleccionar el mejor modelo que estimara cada variable estructural. Encontraron correlaciones entre los valores obtenidos en campo y los de LiDAR con una R^2 de 0.57 para el caso de altura media del rodal, 0.74 para la biomasa aérea total, biomasa foliar de 0.79, área basal de 0.78, densidad del arboles de 0.67, altura base del dosel de 0.79 y densidad aparente del dosel de 0.82, lo cual apoya los resultados de investigaciones similares e indica que las mediciones son bastante útiles para estimar otras características de interés.

3.10.2 Inventarios forestales

El volumen de los árboles en el bosque es una de las estadísticas más importantes utilizadas en el manejo forestal. El volumen de un árbol es considerado usualmente como una función de diámetro normal, de altura y de una expresión de la forma del árbol, pero la mayoría de los profesionales prefieren usar ecuaciones de volumen que involucra sólo el diámetro normal y la altura del árbol.

Con la tecnología LiDAR se puede localizar la posición del tronco de cada árbol individual, obtener la altura media del rodal, estudiar la calidad de la madera, realizar cálculos del índice de área foliar (LAI), biomasa, volumen de madera, entre otros datos de interés. Todas estas variables son de especial importancia a la hora de realizar un inventario forestal y actualmente se obtienen mediante estimaciones realizadas con trabajo de campo de manera tradicional. De acuerdo con Means *et al.* (2000) se pueden obtener variables de interés forestal ya sea por mediciones directas o derivadas de modelos de regresión como se enlista en el cuadro 1.

Cuadro 1. Contribuciones de la tecnología LiDAR en aplicaciones forestales.

Características Forestales	Derivación de LiDAR
Altura del dosel	Medición directa
Topografía del subdosel	Medición directa
Distribución vertical de superficies interceptadas	Medición directa
Biomasa aérea	Modelado
Área basal	Modelado
Diámetro medio del tronco	Modelado
Perfiles verticales foliares	Modelado
Volumen del dosel	Modelado
Densidad de árboles grandes	Modelado
Cobertura del dosel, Índice de área foliar	Fusión con otros sensores
Diversidad de forma de vida	Fusión con otros sensores

Andersen *et al.* (2005) realizaron un estudio en donde a través de análisis de regresión lineal desarrollaron modelos predictivos para relacionar distintas mediciones obtenidas a partir de LiDAR con parámetros de combustible forestal estimados a partir de datos de campo de inventario al oeste del Estado de Washington. La investigación indica que existen fuertes correlaciones entre las estimaciones de LiDAR y campo para todos los parámetros evaluados: peso del combustible de copa $R^2=0.86$, densidad aparente de la

copa $R^2=0.84$, altura base del dosel $R^2=0.77$ y altura del dosel $R^2=0.98$. Para validar los modelos emplearon un procedimiento de validación cruzada. Finalmente, los autores indican que los modelos de predicción de combustibles basados en datos LiDAR se pueden emplear para desarrollar mapas de los parámetros críticos de combustible en áreas boscosas al noroeste del Pacífico de Estados Unidos.

Peterson *et al.* (2005) utilizaron LiDAR de retorno continuo para estimar la densidad aparente del dosel y la altura base, dos características que se emplearon como variables de entrada en un sistema (FARSITE) para modelar el comportamiento del fuego. Los resultados indican que las mediciones de LiDAR son predictores significativos de la densidad aparente del dosel ($R^2=0.71$) y de la altura base del dosel ($R^2=0.59$). Los autores indican que LiDAR ya no tiene que ser considerada una técnica experimental sino que es bastante aceptable como un recurso de precisión para los inventarios forestales.

3.10.3 Biomasa

La biomasa forestal es la materia orgánica resultante de la producción primaria a través de la fotosíntesis menos el consumo a través de la respiración y la cosecha (FAO, 2012). La estimación de la biomasa proporciona información sobre la estructura y atributos del bosque.

El desarrollo de los modelos para estimar la estructura forestal y biomasa a partir de datos LiDAR se basa en el supuesto de que la distribución vertical de los retornos del láser está relacionada con la distribución vertical de la vegetación. Los sistemas de retorno discreto o huella pequeña se han empleado exitosamente para estimar biomasa aérea tanto a nivel de árbol como del rodal e incluso se han combinado con imágenes satelitales y datos de RaDAR (Popescu, 2007).

Diversos estudios se han realizado para estimaciones de biomasa empleando datos LiDAR como el que reporta Lefsky *et al.* (2001) donde compararon las relaciones entre la estructura del dosel medido con LiDAR y en campo en tres diferentes biomas: bosques caducifolio, coníferas de zonas templadas y coníferas de zonas boreales. El objetivo del trabajo fue encontrar un método simplificado para estimar biomasa de los tres sitios que pudiera replicarse a escalas mayores reduciendo el trabajo de campo y

los costos. Encontraron que mediante una ecuación simple se puede explicar el 84 % de la varianza de la biomasa aérea, sin sesgo estadísticamente significativo en las predicciones a nivel de sitio.

La necesidad de evaluar de forma más precisa biomasa aérea y sus componentes ha llevado a otros autores como Popescu *et al.* (2007) a desarrollar métodos que sean capaces de estimar con mayor precisión el diámetro normal de árboles individuales a partir de dos características fáciles de obtener mediante LiDAR (altura del árbol y diámetro de copa) y haciendo uso de técnicas de regresión lineal y no lineal. Encontraron que los modelos de regresión lineal utilizando las variables obtenidas con LiDAR fueron capaces de explicar el 93 % de la variabilidad asociada con la biomasa por árbol, 90 % para el diámetro normal y del 79 al 80 % para los componentes de biomasa como follaje, raíces gruesas, el fuste y su corteza.

Swatantran *et al.* (2011) exploraron la combinación de dos fuentes de información para estimar y mapear biomasa así como el nivel de estrés en un área de la Sierra Nevada en E.U.A. Emplearon el sensor LVIS (Laser Vegetation Imaging Sensor) para datos LiDAR e imágenes del sensor AVIRIS (Airborne Visible Infrared Imaging Spectrometer). Los resultados reportados para la estimación de biomasa indican que la mejor variable predictora para LiDAR fue la altura y que el mejor modelo a nivel rodal tuvo una correlación de $R^2= 0.77$, esta situación mejoró cuando se combinaron los datos de las imágenes de AVIRIS después de realizar el procedimiento de clasificación de la vegetación con LiDAR con una $R^2=0.84$. Se reporta además que la predicción empleando sólo variables derivadas de LiDAR muestra una mejora estadísticamente significativa sobre el modelo que si se emplearan sólo las variables de las imágenes de AVIRIS.

3.11 Integración de sensores

Los esfuerzos para modelar y mapear la altura de los árboles y otros atributos relacionados utilizando sólo imágenes satelitales, generalmente ha sido demasiado impreciso para los manejadores forestales ya que la altura por sí sola está fuertemente relacionada a otros atributos estructurales de interés, tales como área basal y biomasa (Hudak *et al.*, 2006).

Se ha comparado la utilidad de varios sensores remotos para determinar con precisión características estructurales del bosque. Lefsky *et al.* (2001a) realizaron un estudio para evaluar la eficacia de varios tipos de información obtenida a través de diferentes sensores remotos con el objetivo de mapear la estructura del bosque y atributos relacionados a una escala regional. Los sensores evaluados incluyeron: i) Landsat Thematic Mapper (TM), ii) Multitemporal Landsat TM, iii) Airborne Data Acquisition and Registration (ADAR) un sensor con alta resolución espacial, iv) Airborne Visible-Infrared Imaging Spectrometer (AVIRIS) un sensor con alta resolución espectral y v) Scanning Lidar Imager of Canopies by Echo Recovery (SLICER) un sensor LiDAR que mide directamente la altura y estructura del dosel. Los atributos estructurales del rodal incluían edad, área basal, biomasa aérea, diámetro normal de árboles dominantes y codominantes, media y diámetro normal de todos los fustes. El estudio reveló que SLICER se desempeñó mejor que cualquiera de las otras cuatro técnicas ya que ofrece mejoras sustanciales con respecto a los otros sensores, en la exactitud de las predicciones de atributos estructurales del bosque (Cuadro 2).

Cuadro 2. Valores de R^2 ajustada relacionando las imágenes de los diferentes sensores y los atributos estructurales: área basal y biomasa aérea.

Sensor	Área basal	Biomasa aérea
SLICER	0.84	0.86
TM multitemporal	0.62	0.60
ADAR	0.39	0.47
AVIRIS	0.36	0.38
Landsat TM	0.25	0.31

Así mismo, Hudak *et al.* (2006) compararon la utilidad de los datos de LiDAR de retorno discreto y datos obtenidos a partir de imágenes satelitales ALI (Advanced Land Imager), el cual es un satélite diseñado para mejorar la tecnología de los satélites Landsat. La integración de estos dos grupos de datos se empleó para modelar y mapear el área basal y densidad de árboles en dos bosques de coníferas. De forma general, las variables de LiDAR tuvieron mayor utilidad que las de ALI para predecir las variables de respuesta, especialmente área basal. Los modelos que integraron las

variables provenientes de los dos sensores fueron los que explicaron mejor la varianza de las variables de respuesta con un 90 %.

4. MATERIALES Y MÉTODOS

4.1 Área de estudio

Este estudio forma parte de los trabajos de investigación que se desarrollan en el Sitio Intensivo de Monitoreo de Flujos de CO₂ a largo plazo en bosques bajo manejo en el centro de México (Ángeles *et al.*, 2011). Comprende un área de 900 ha (3 x 3 km), conformada en su mayoría por porciones de cuatro ejidos del municipio de Zacualtipán de los Ángeles, Hidalgo: La Mojonera, Atopixco, El Reparó y Tzincoatlán, así como pequeñas áreas de los ejidos Santo Domingo, Zahuastipán y de propiedad privada los cuales están localizados en la Sierra Madre Oriental entre las coordenadas 20°35'00" y 20°38'30" N y 98°34'00" y 98°38'00" W (Figura 5). La región presenta topografía variable; desde zonas elevadas con pendientes suaves, hasta terrenos con pendientes pronunciadas (Martínez, 2004).

Zacualtipán colinda al norte con Tianguistengo, al sur con Metzquititlán, al este con Veracruz, y al oeste con Metztlán y Xochicoatlán. Su fisiografía comprende la Sierra Madre Oriental, conocida como Sierra Alta Hidalguense y una parte del Eje Neovolcánico, subprovincia Carso Huasteco. Está conformado por pendientes, mesetas y cañones (Instituto para el Federalismo y el Desarrollo Municipal, 2010).

El municipio cuenta con tres ríos principales: el Pánuco, el Zoyatla y el Miniahuaco, además de la laguna Chapultepec. Su sustrato geológico data del periodo Cenozoico (terciario superior) y está conformado por rocas ígneas extrusivas del tipo toba ácida (Ts - Ta, al norte) y basalto (Ts - B, al sur). El sustrato edáfico está representado por suelos acrisol órtico (Ao), luvisol crómico (Lc) y feozem háplico (Hh) (Instituto para el Federalismo y el Desarrollo Municipal, 2010). El clima existente es C(fm)w"b(e)g, templado-húmedo con una estación marcada de lluvias entre junio y octubre. La precipitación media anual oscila (temporalmente) entre 700 y 2050 mm, la precipitación del mes más seco menor de 40 mm; lluvias de verano y porcentaje de lluvia invernal

del 5% al 10.2% del total anual. Debido a que el sitio se localiza en una de las partes más altas de la Sierra Madre Oriental (2000 a 2200 m s.n.m.) es común observar un gran número de días con neblinas. Por tanto, la mayor parte del año la humedad relativa permanece alta (Ángeles *et al.*, 2011).

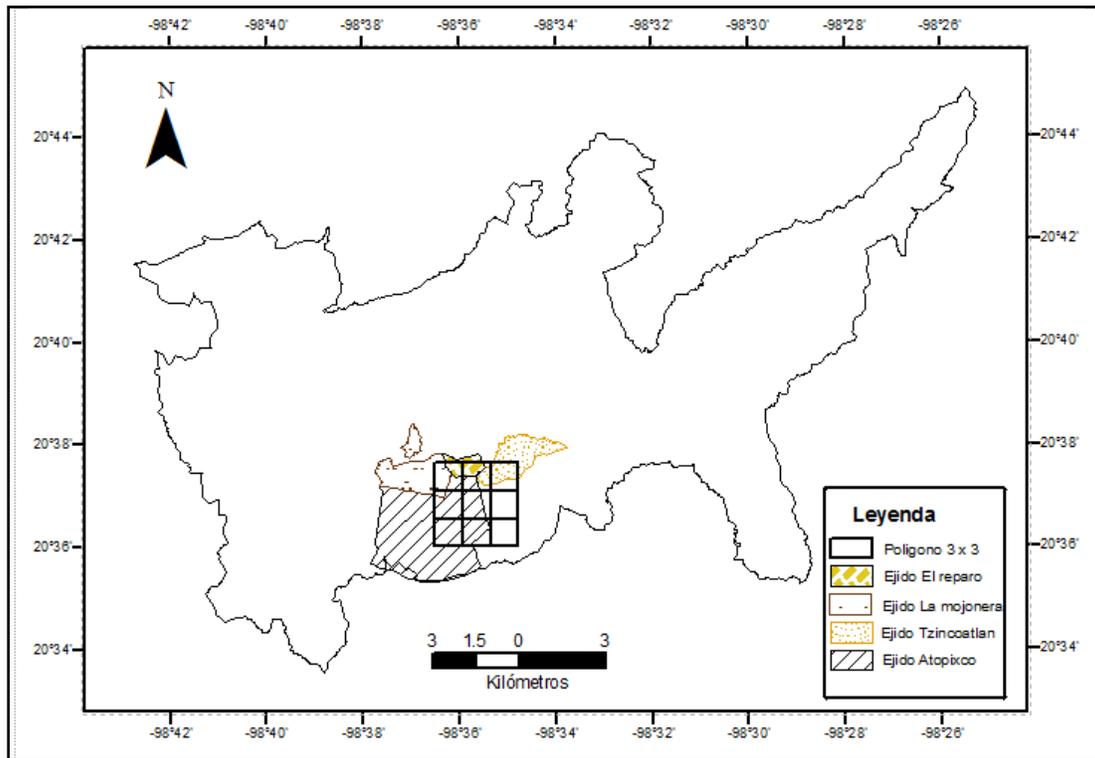


Figura 5. Ubicación de la zona de estudio en el Municipio de Zacualtipán, Hidalgo. Elaboración propia.

Los tipos de vegetación predominantes son: bosque mesófilo de montaña, bosque de pino y bosque de pino-encino. Entre las especies arbóreas dominantes se encuentran *Pinus patula*, *Quercus crassifolia*, *Q. affinis*, *Q. laurina*, *Q. sartori*, *Q. excelsa*, *Q. xalapensis*, *Clethra mexicana*, *C. pringlei*, *Magnolia schiedeana*, *Cornus disciflora*, *Viburnum spp.*, *Cleyera theaoides*, *Arbutus xalapensis*, *Prunus serotina*, *Vaccinium leucanthum*, *Liquidambar styraciflua*, *Fagus grandifolia* subsp. *mexicana*, *Podocarpus reichei*, *Cercis canadensis*, entre otras (Ángeles *et al.*, 2011).

4.2 Diagrama metodológico

La Figura 6 ilustra de forma resumida la secuencia de pasos relevantes para el desarrollo del trabajo de investigación.

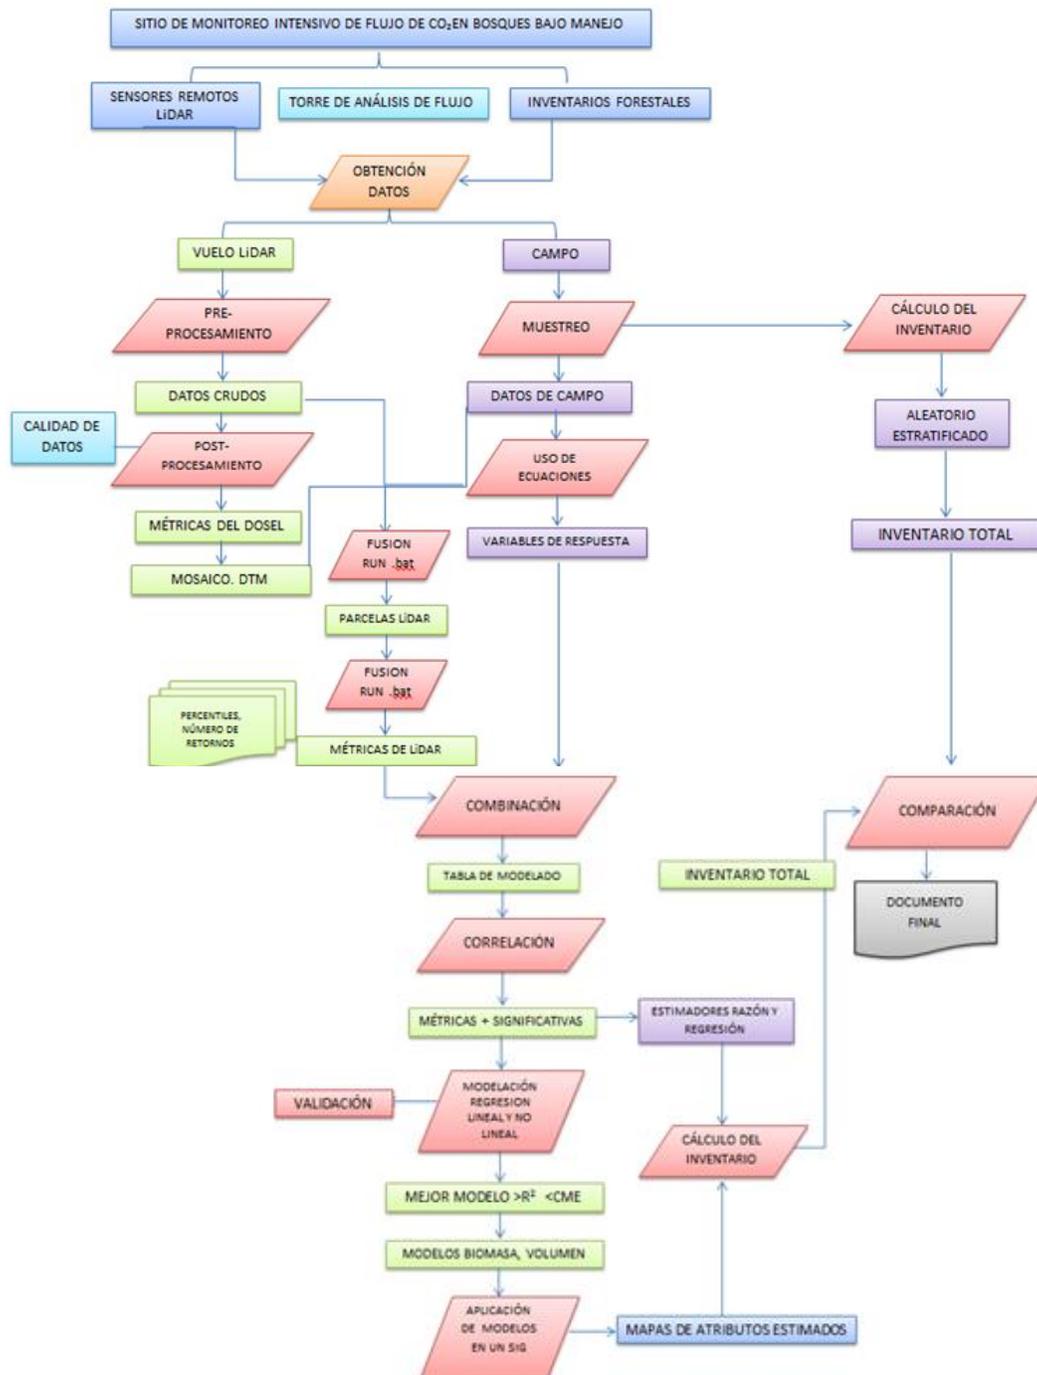


Figura 6. Proceso metodológico implementado en la investigación.

Partiendo del hecho que este estudio forma parte de un proyecto de mayor envergadura, se consideró obtener la información del bosque por medio de dos fuentes: 1) a través de un inventario forestal tradicional y 2) a partir de los datos generados por el sensor LiDAR. A continuación se describe el proceso para obtener las variables dasométricas en campo.

4.3 Obtención de los datos de campo

En el mes de abril de 2013 se realizó un muestreo en campo para la toma de datos en el área de estudio. Para ello fue necesario tomar en cuenta algunas consideraciones para la colecta y preparación de los datos en campo (Laes *et al.*, 2011). Las características son las siguientes:

- **Localización:** Las parcelas deberán ser georreferidas con una precisión de un metro o menos.
- **Sincronización:** Los datos de las parcelas deberán ser medidos dentro de una temporada de crecimiento a la toma de datos LiDAR. Los errores en la sincronización, tal como una discrepancia de temporización, pueden resultar en intentar relacionar dos condiciones diferentes.
- **Tamaño:** Las parcelas deben ser lo suficientemente grandes ($>$ a 1/10 de acre ó 400 m^2) para minimizar el efecto de límite y poder caracterizar a la vegetación. Además las parcelas deberán tener un radio fijo en lugar de un radio variable.
- **Biomasa:** Toda la biomasa contribuye a los retornos de pulsos de LiDAR, por lo cual tiene que ser medida toda la biomasa: arbustos, hierbas, no sólo los árboles grandes.
- **Muestras:** Es necesario contar con las parcelas suficientes para una validez estadística, además que deben cubrir el rango completo de variabilidad para la medición de interés.
- **Consistencia:** Además de un tamaño uniforme y relativamente grande, las parcelas deben representar condiciones individuales y coleccionar los mismos datos de campo para cada parcela.

Las variables que se midieron en campo para alimentar los modelos de cálculo de área basal, biomasa, cobertura arbórea y volumen fueron el diámetro normal (DN), la altura total de los árboles (H), la altura del fuste limpio (h) y el diámetro de copa (DC).

La información obtenida en campo resultó de implementar el diseño de muestreo sistemático por conglomerado de la CONAFOR, esto con la finalidad de que la información obtenida en este estudio sirva para mejorar las estimaciones de acumulación de carbono, y permita su escalamiento regional al ligarlos con los datos obtenidos en sitios similares levantados por el Inventario Nacional Forestal y de Suelos (INFyS).

El tipo del conglomerado corresponde a una “Y invertida”, integrado por 4 unidades circulares de registro o sitios equidistantes del centro a cada 45.14 m (CONAFOR, 2010) cuya distribución se observa en la Figura 7.

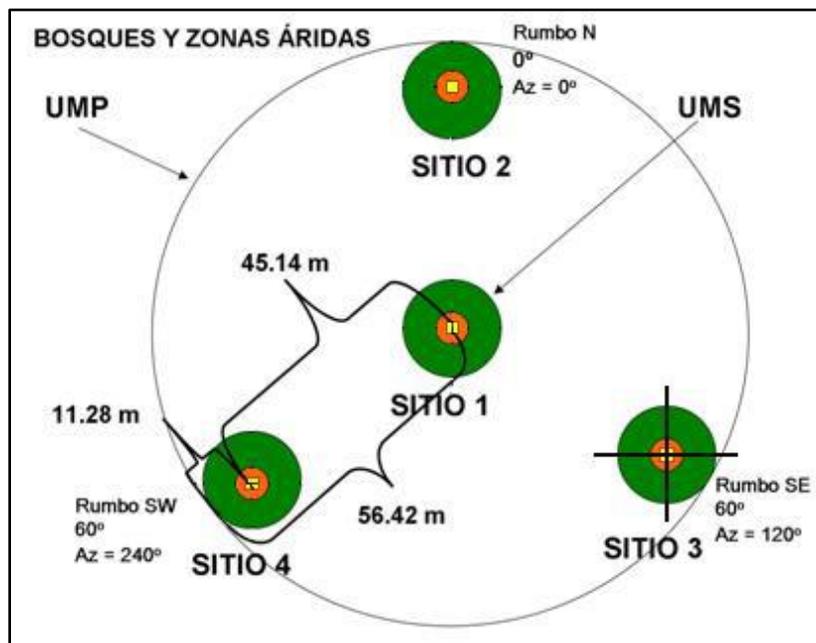


Figura 7. Arreglo del conglomerado de muestreo (CONAFOR, 2010).

En total se obtuvieron datos en 40 conglomerados de forma circular, abarcando una superficie de 1 ha con un radio de 56.42 m. Las cuatro unidades de muestreo secundario o sitios son de 400 m² con radio de 11.28 m. La distribución de los 160 sitios en la cuadrícula de 3 por 3 km se presenta en la Figura 8.

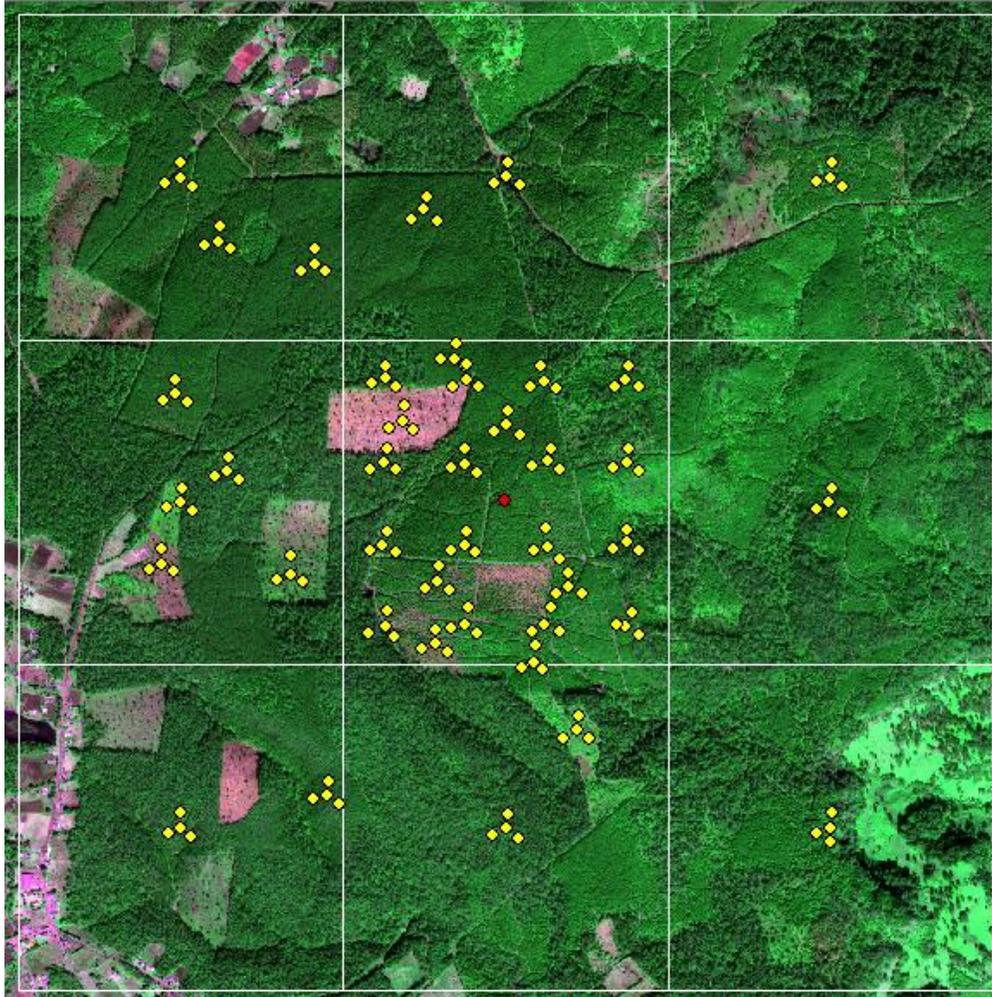


Figura 8. Distribución de conglomerados de muestreo en el área de estudio. El punto rojo indica la ubicación de la torre de flujo.

La ubicación del centro de cada sitio fue georreferenciada usando un GPS Garmin GPSMAP® 62S, con el cual se obtuvieron promedios de mediciones para obtener una lectura lo más precisa posible, además se conectó la antena del instrumento y con la ayuda de un estadal se subió hasta una altura de 4 metros.

Como se observa en la figura anterior, la mayor concentración de sitios está en el cuadro central, en donde también se localiza la Torre Eddy-covariance con la instrumentación para mediciones micro-meteorológicas y de flujo de CO₂, la cual mide el intercambio de carbono, agua y energía entre el bosque y la atmósfera (Ángeles *et al.*, 2011).

En los 160 sitios se midieron los árboles con un diámetro normal mayor a 2.5 cm, su altura total con la ayuda del clinómetro Suunto y el diámetro de copa en sus dos ejes (norte - sur y este – oeste) con una cinta.

4.4. Cálculo de variables dasométricas

4.4.1 Área basal

El área basal (AB) para cada árbol se calculó con el diámetro normal empleando la siguiente fórmula

$$AB = \frac{\pi}{40,000} \times DN^2$$

Donde: AB en m², DN: Diámetro normal, π valor del número pi.

4.4.2 Volumen y Biomasa

Para el cálculo de volumen y biomasa, se utilizaron los modelos desarrollados previamente en la zona de estudio y áreas aledañas (Cuadro 3).

Cuadro 3. Funciones para estimar volumen y biomasa en diferentes tipos de vegetación.

Tipo de vegetación	Fórmula	Fuente	Zona de estudio
Latifoliadas	$V = 0.000082 * DN^{(1.785782)} * H^{(0.915827)}$	Cruz, 2007	Ejido Atopixco
	$B_T = 4.042193 + 0.027336 * DN^2 * H$	Ángeles, 2013 (en preparación)	Área cercana
<i>Pinus patula</i>	$V = e^{-9.7688} * (DN^2 * H)^{0.9451}$	Carrillo <i>et al.</i> , 2004	Área cercana
	$B_T = 5.339 + 0.018635 * DN^2 * H$	Figueroa, 2011	Ejido La Mojonera

Donde: V: Volumen en m³, B_T=Biomasa total en kg, H= Altura en m, lo demás ya se ha definido.

4.4.3 Cobertura arbórea

En el caso de la cobertura arbórea de cada individuo se calculó mediante la fórmula:

$$COB = DC^2 \times \frac{\pi}{4}$$

Donde: *COB*= Cobertura arbórea estimada (m²), *DC*= Diámetro de copa (m), lo demás ya se ha definido.

Las variables forestales de interés se calcularon primero a nivel de árbol individual, enseguida se sumaron todos los valores para obtener el área basal, volumen, biomasa total y la cobertura arbórea por sitio (400 m²). Finalmente estos resultados se combinaron con las métricas de LiDAR calculadas para cada sitio.

4.5 Obtención de datos LiDAR

El vuelo para obtener los datos LiDAR se llevó a cabo durante el mes de mayo de 2012. El proveedor de la información utilizó un sistema LiDAR Riegl-VQ480 (Cuadro 4), equipado con un receptor GPS/IMU NovAtel, además colocaron dos estaciones GPS L1/L2 (L1/L2: frecuencias duales esenciales para eliminar el error causado por la refracción ionosférica) al momento de la adquisición de datos.

El proveedor usó además información de tres estaciones fijas de la Red Geodésica Nacional Activa establecida por el Instituto Nacional de Estadística Geografía e Informática (INEGI) como referencia absoluta para el cálculo y ajuste de las trayectorias. Las estaciones están localizadas en Puebla (ICEP), Tampico (TAMP) y Toluca (TOL2).

Cuadro 4. Características del sensor LiDAR utilizado.

Sensor LiDAR	Riegl VQ-480
Frecuencia del pulso	200 Khz
Ángulo de barrido	+ - 15°
Densidad de puntos por pasada	5 ptos/m ² sin embargo como la sobreposición de 50 % tenemos una densidad real de 10 ptos/m ²
Altitud de vuelo	397 m (1,300 ft)
Velocidad de vuelo	80-90 nudos
Sobreposición de las líneas de vuelo	50 %
Radio del pulso	30 cm
Precisión absoluta de la medición vertical	+ - 0.15 m en áreas abiertas planas y 0.5 m en zonas boscosas o pendientes mayores de 20 %
Precisión absoluta de la medición horizontal	+ - 0.5 m en áreas planas y 0.75 m. en áreas con pendiente.

Los proveedores realizaron un pre-procesamiento de los datos crudos de LiDAR empleando el software E3De de Excelis y DTMaster de la compañía Inpho. El área que cubrió el sensor fue de 9 km² (3 x 3 km) teniendo al centro la torre de medición de flujos de carbono del sitio intensivo de monitoreo.

4.6 Análisis de datos LiDAR

Para el análisis de los datos LiDAR fue necesario realizar una serie de pasos que permitieron en primera instancia validar la calidad de los datos que el proveedor ofreció, obtener el modelo digital de elevación para contar con una referencia con respecto al nivel del mar; así mismo ejecutar los diversos procesos para obtener las métricas a nivel de parcela y del conjunto entero de los datos LiDAR.

El software que se utilizó en el manejo de los datos LiDAR fue FUSION/LVD versión 3.21 (McGaughey, 2012) Es un software libre desarrollado por el “USDA Forest Service Remote Sensing Applications Center” (RSAC) del Departamento Forestal de Estados Unidos. FUSION permite procesar datos vectoriales de LiDAR por medio de algoritmos orientados a mediciones forestales.

Una consideración al realizar evaluaciones con datos LiDAR, es que dependiendo del tipo de estudio es necesario contar con una densidad mínima de puntos, así para productos topográficos y mediciones del dosel de primer orden como: altura del rodal, cobertura del dosel o densidad. Es recomendable una densidad de 1 a 3 pulsos por metro cuadrado en promedio y si la intención es modelar parámetros de inventarios forestales como biomasa, área basal, volumen, etc. correlacionándolos con la información obtenida de las parcelas de campo, se recomienda una densidad de 4 pulsos por metro cuadrado o mayor (Laes *et al.*, 2011).

Teniendo en cuenta lo anterior, la calidad de los datos brutos de LiDAR se evaluó de forma independiente a través de un proceso específico que ofrece el software FUSION. En este paso se obtuvo un grupo de reportes que describen características importantes del grupo de datos LiDAR como la densidad total y los primeros retornos del láser, así como la densidad mínima, máxima y promedio de los retornos.

4.6.1 Creación de parcelas de LiDAR

Para extraer las métricas de los datos LiDAR correspondientes a la ubicación de las parcelas en campo, se usó el comando ClipData de FUSION. Se emplearon cuatro recursos de entrada para completar el proceso: las coordenadas y el radio de las parcelas, el modelo digital del terreno (MDT) del área de estudio generado a través de los datos LiDAR y los datos LiDAR crudos (.las files). El proceso produjo datos de salida separados (nube de puntos) para cada parcela.

4.6.2 Obtención de métricas LiDAR por parcela

Una vez que se extrajeron los datos LiDAR correspondientes a las parcelas de campo, se obtuvieron las métricas de LiDAR, las cuales fueron calculadas para cada nube de puntos usando el comando CloudMetrics FUSION. Las métricas resultantes son las variables predictoras. Cada registro en la tabla de salida tiene un grupo de variables, que juntas describen la distribución vertical de los puntos LiDAR representativa del arbolado dentro de la parcela.

Las métricas de LiDAR son una variedad de parámetros estadísticos que describen el grupo de datos. Las métricas son procesadas usando los puntos de elevación y valores de intensidad (cuando están disponibles). Se dividen en tres grupos: descriptivos,

valores de percentiles de altura y las métricas relacionadas al dosel. En el Cuadro 5 se enlistan las métricas más importantes:

Cuadro 5. Descripción de las métricas LiDAR obtenidas para cada parcela.

Categoría	Variabes de salida
Descriptivas	Número total de retornos
	Conteo de retorno por número de retorno
	Mínimo
	Máximo
	Media
	Mediana (salida como percentil 50)
	Moda
	Desviación estándar
	Varianza
	Coefficiente de variación
	Distancia intercuantil
	Coefficiente de asimetría
	Coefficiente de curtosis
Valores de percentiles de altura	Desviación absoluta promedio
	L-momentos (L1, L2, L3, L4)
Métricas relacionadas al dosel (tasas de retorno, sobre una altura de corte)	1, 5, 10, 20, 25, 30, 40, 50, 60, 70, 75, 80, 90, 95 y 99
	Porcentaje de primeros retornos sobre una altura específica (cobertura del dosel estimada)
	Porcentaje de primeros retornos sobre la altura media/elevación
	Porcentaje de primeros retornos sobre la altura moda/elevación
	Porcentaje de todos los retornos sobre una altura específica
	Porcentaje de todos los retornos sobre la altura media/elevación
	Porcentaje de todos los retornos sobre la altura moda/elevación
	Número de retornos sobre una altura específica/total de primeros retornos * 100
	Número de retornos sobre la altura media/total de primeros retornos * 100

4.7 Cálculo de las variables dasométricas mediante regresión lineal múltiple

4.7.1 Análisis de correlación

Una vez que se contó con las variables de campo y las métricas de LiDAR (por sitio) combinadas, se estudiaron las relaciones entre las variables de respuesta (área basal, biomasa, cobertura arbórea y volumen) con cada una de las variables predictoras (métricas de LiDAR) a fin de conocer su comportamiento. De los 160 sitios de muestreo se eliminaron del análisis tres sitios; dos de ellos debido a que no había correspondencia entre las estimaciones hechas en campo y lo captado por LiDAR, a causa del aprovechamiento maderable días antes del muestreo en campo y una parcela más se eliminó porque estaba dentro del área de influencia de otra parcela que se muestreo previamente.

Con los 157 sitios finales, se escogieron al azar, con fines de validación, los sitios número 3 de cada conglomerado (en total 38), estos quedaron excluidos del proceso de ajuste de modelos, empleando finalmente sólo 119 sitios.

A continuación, se realizó un análisis de correlación de Pearson empleando el paquete estadístico SAS 9.0 (SAS, Institute Inc. 2002), este fue un primer filtro de variables explicativas, desechando aquellas que no aportaban información o que su correlación resultó muy baja. Este proceso se hizo para cada una de las variables: área basal, biomasa total, cobertura arbórea y volumen.

4.7.2 Modelos de regresión

Una vez que las variables LiDAR de mayor correlación con las variables dasométricas de interés fueron identificadas, se probaron modelos lineales simples con la siguiente estructura:

$$Y = \beta_0 + \beta_1 X_1 + \varepsilon_i$$

Donde: Y = variable forestal de interés; X_1 : métricas de LiDAR; β_0 , β_1 : Coeficientes de regresión, ε_i = error

Así mismo, se utilizó el procedimiento de regresión Stepwise para definir el mejor modelo que estimara las variables forestales por sitio con la siguiente estructura:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon_i$$

Donde: Y = variable forestal de interés; X_k : métricas de LiDAR; β_k : Coeficientes de regresión, ε_i = error.

También se analizaron “regresiones forzadas” incorporando a los modelos variables que definen por sí solas una característica notoria que describe la estructura tanto vertical como horizontal del dosel y que comprensiblemente pudiera modelar el área basal o la misma cobertura, como la elevación media o la tasa de proporción del dosel (Canopy_relief_ratio). Esto con el propósito de estudiar la capacidad predictiva de dichas variables.

Como indicadores de bondad de ajuste de los modelos, se utilizó el coeficiente de determinación (R^2) y un valor de probabilidad de rechazo (P) menor al 0.05 para cada uno de los parámetros de los modelos, la R^2 se calculó con la siguiente fórmula:

$$R^2 = \frac{SCR}{SCT} = 1 - \frac{SCE}{SCT}$$

Donde: SCR =Suma de cuadrados de regresión, SCE =Suma de cuadrados del error, SCT =Suma de cuadrados corregidos por la media.

Para cada uno de los parámetros se estimaron los límites de confianza al 95 % mediante la expresión:

$$IC = Y'_i \pm t_{n-(k+1)(1-\frac{\alpha}{2})} s'_R \sqrt{1 + h_{ii}}$$

Donde: IC =Intervalo de confianza, Y'_i =Valor predicho, t = Valor t de Student con $n-(k+1)$ grados de libertad y un nivel de significancia $(1-\alpha/2)$, s'_R = Cuadrado medio del error,

$h_{ii} = \overrightarrow{X'_i} (X'X)^{-1} \overrightarrow{X'_i}$ Varianza del valor estimado de Y'_i .

Con la finalidad de validar los modelos generados, las estimaciones obtenidas a través de los modelos, se compararon con los valores medidos en campo para cada una de las variables de interés. El ajuste de modelos lineales a los datos predichos y

observados es una forma de medir su capacidad predictiva, es decir, de medir cuanto las estimaciones predichas se asemejan a las estimaciones observadas en campo.

4.8 Cálculo de las variables dasométricas mediante el uso de estimadores de razón y regresión empleando las métricas de LiDAR.

En los trabajos de muestreo es común usar información adicional para mejorar la precisión de las estimaciones, como el caso de los métodos que utilizan estimadores de razón y regresión. Estos requieren medir una variable auxiliar X que esté altamente correlacionada con la variable de interés Y . Generalmente la variable X es fácil de medir, mientras que la variable Y implica lo contrario. En trabajos que incluyen muestreo de variables a alto costo, es común usar información adicional proveniente de una variable fácil de medir para mejorar la precisión de las estimaciones a un bajo costo. Para este estudio, el estimador de razón utiliza un valor estimado de la proporción entre una variable auxiliar (métrica de LiDAR fácil de medir) y las variables dasométricas. Esta proporción (Scheaffer *et al.*, 1986) se expresa como sigue:

$$\hat{R} = \frac{\sum_{i=1}^n VD}{\sum_{i=1}^n VL}$$

Donde: VD =Variable dasométrica de interés medida en campo en la i -ésima unidad muestral, VL =Variable LiDAR con alta correlación con las variable dasométrica en la i -ésima unidad muestral.

Para la estimación de la media poblacional del estimador de razón la expresión es:

$$\overline{VD}_{\hat{R}} = \hat{R} x \bar{X}$$

Siendo \bar{X} la media poblacional de la variable LiDAR que se calculó mediante la ecuación:

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N VL$$

Donde: N =tamaño de la población, lo demás ya se ha definido.

La precisión se expresa como: $2\sqrt{\hat{V}_R/\hat{R}}$; Donde \hat{V}_R es la varianza estimada de \hat{R}

En el caso del estimador de regresión, la estimación de las variables dasométricas promedio es (Scheaffer *et al.*, 1986):

$$\overline{VD}_R = \overline{VD} + b\left(\frac{1}{N} \sum_{i=1}^N VL - \frac{1}{n} \sum_{i=1}^n VL\right)$$

Donde: b = tasa de cambio de la variable dasométrica respecto a la métrica de LiDAR de alta correlación (VL), \overline{VD} = promedio de la variable dasométrica medida en campo, n =tamaño de la muestra, lo demás ya se ha definido.

4.9 Estimación de las variables dasométricas mediante muestreo estratificado.

Tradicionalmente un inventario forestal se realiza empleando los estimadores del muestreo aleatorio estratificado (Scheaffer *et al.*, 1986), en el cual se realiza una zonificación del bosque con el objetivo de conseguir estratos más homogéneos, por ejemplo estratos de bajo, medio y alto volumen por ha o por área de la misma edad, como el caso de este estudio.

Una de las principales ventajas de este muestreo es que ofrece una mayor precisión de los estimadores y se ve reducida la varianza del estimador de la media poblacional debido al diseño de los estratos.

A continuación se expresan los estimadores a nivel de estrato; para el caso de la estimación de la media se define como (Scheaffer *et al.*, 1986):

$$\bar{Y}_h = \frac{\sum_{i=1}^{n_h} Y_{ih}}{n_h}$$

Donde: Y_{ih} = valor obtenido en la i -ésima unidad del h -ésimo estrato; n_h =número de unidades muestrales en el h -ésimo estrato.

Para el caso de la varianza muestral se expresa como sigue:

$$S^2_h = \frac{\sum (Y_{ih} - \bar{Y}_n)^2}{n_h - 1}$$

El cálculo de la varianza de la media se expresa como:

$$S^2_{\bar{Y}_n} = \frac{S^2_h}{n_h} \left(1 - \frac{n_h}{N_h} \right)$$

Donde: N_h =número de elementos en el h-ésimo estrato de la población, la otras variables se han expresado líneas arriba.

De tal forma que el estimador poblacional se expresa como:

$$\bar{Y}_{ST} = \sum_{h=1}^L \left(\frac{N_h}{N} \right) \bar{Y}_h$$

Donde N =tamaño de la población; L =número de estratos, lo demás ya se ha definido.

Y para el caso de la varianza del estimador se describe como:

$$S^2_{\bar{Y}_{ST}} = \sum_{h=1}^L \left(\frac{n_h}{N} \right)^2 S^2_{\bar{Y}_h}$$

El cálculo de la precisión se define como:

$$2\sqrt{S^2_{\bar{Y}_{ST}} / \bar{Y}_{ST}}$$

Y finalmente para el cálculo del inventario global:

$$\hat{T} = \bar{Y}_{ST} N$$

Los estratos corresponden a la edad de los rodales presentes en el área de estudio (Cuadro 6). Cabe aclarar que una condición en este tipo de muestreo es que n_h debe ser ≥ 3 por lo que se agruparon algunas edades (anualidades de corta), debido a que en algunos casos sólo se contaba con un sitio por estrato; esta agrupación tomó en cuenta una diferencia de edades no mayor a 2 años, además de que fueran áreas cercanas.

Cuadro 6. Estratos y su correspondiente superficie en la zona de estudio.

Anualidad (estratos)	Superficie ha.	No. de sitios
1933 (bosque natural)	374.8	12
1982-1984	29.1	5
1983	14.7	5
1985	18.9	7
1986	11.8	4
1987	12.3	4
1988	12.2	6
1991-1992	10.2	3
1993	20.3	8
1994	13.4	11
1995	20.1	7
1996	22.0	10
1997	8.8	5
1998	109.8	19
1999	8.2	10
2001	16.1	4
2004	13.2	4
2005	21.6	5
2006	19.4	6
2007-2008	30.9	6
2009	26.5	7
2010-2011	18.1	4
2012-2013	15.8	5

4.10 Generación de cartografía para las variables de interés.

Una vez identificadas las métricas LiDAR relevantes (significativas) para explicar las variables de interés mediante modelos de regresión, estas se extrajeron mediante el comando GridMetrics de FUSION para cada celda que conforma el área de estudio. Finalmente, estas métricas se utilizaron para alimentar los modelos resultantes con mejor ajuste (previa transformación de formato ascii a ráster), generando así la

cartografía de área basal, biomasa, cobertura arbórea y volumen mediante álgebra de mapas simple en el software ArcGIS 9.

5. RESULTADOS Y DISCUSIÓN

5.1 Relación entre las variables forestales y métricas de LiDAR

Se encontraron correlaciones positivas entre las métricas de LiDAR y las variables forestales área basal, volumen, biomasa y cobertura arbórea. Por simplicidad, no todas las métricas se presentan en el Cuadro 7. Estos resultados coinciden con el trabajo reportado por Means, (2000) y Persson *et al.*, (2002), quienes indican que existe una fuerte correlación entre el área basal y la altura derivada por el sensor láser, situación similar sucede con la biomasa total estimada en un bosque de coníferas.

Lo anterior es apoyado por varios estudios que indican que la altura media del arbolado, el área basal y el volumen maderable pueden ser relacionados empíricamente a la distribución de altura del dosel, derivado de las mediciones del sensor láser y también a la proporción de los retornos láser reflejados en la vegetación a partir del total de pulsos emitidos (Means *et al.*, 2000; Næsset, 2002; Holmgren, 2004; Maltamo *et al.*, 2006; Hawbaker *et al.*, 2010).

Cuadro 7. Coeficientes de correlación de Pearson entre las variables forestales: área basal (m²/sitio), volumen (m³/sitio), biomasa (kg/sitio) y cobertura arbórea (m²/sitio) con las métricas de LiDAR.

Métricas de LiDAR	Área basal* m ²	Volumen* m ³	Biomasa* kg	Cobertura arbórea* m ²
Conteo total de retornos sobre 1	0.71	0.65	0.65	0.58
Conteo del retorno 1 sobre la altura de 1	0.71	0.60	0.59	0.62
Conteo del retorno 2 sobre la altura de 1	0.66	0.65	0.66	0.49
Elevación del percentil 70	0.64	0.76	0.75	
Elevación del percentil 75	0.64	0.76	0.75	
Porcentaje de primeros retornos sobre 3	0.85	0.76	0.75	0.66
Porcentaje de todos los retornos sobre 3	0.83	0.74	0.75	0.69
Porcentaje de todos los retornos sobre la altura media	0.85	0.78	0.75	0.59
(Todos los retornos sobre la altura media) / (Total de primeros retornos) * 100	0.83	0.79	0.77	0.55
Índice de penetración del láser	0.78	0.67	0.68	0.71

* Significancia <0.0001

A partir de esta información y después de realizar los procesos de regresión lineal múltiple, Stepwise y de regresión forzada, se eligieron las métricas de LiDAR que mejor predicen a las variables forestales área basal, biomasa total, cobertura arbórea y volumen en el área de estudio (Cuadro 8). El criterio para la selección de los modelos fue el coeficiente de determinación (R²) y la significancia de los parámetros asociados a cada una de las variables involucradas.

Para el caso del área basal las métricas seleccionadas fueron la elevación media de los retornos, la elevación del percentil 70 correspondiente a la altura del arbolado y el porcentaje de todos los retornos sobre la media de los retornos, estas variables se encuentran dentro del grupo con los coeficientes de correlación más altos, 0.61, 0.64 y 0.85 respectivamente.

Para la variable biomasa aérea las métricas seleccionadas fue una tasa de retorno definida como “Todos los retornos sobre una altura de tres metros / Total de los primeros retornos * 100”, la cual corresponde a la categoría de métricas relacionadas a

la copa, así mismo fue seleccionada la elevación del percentil 50 y el coeficiente de variación de intensidad, las dos primeras métricas son consistentes con los valores de coeficientes de correlación más altos 0.77 y 0.74, situación que no se repite con el coeficiente de variación de intensidad que fue de 0.28.

En cuanto a la cobertura arbórea se seleccionaron sólo dos variables, una corresponde a la métrica con mayor valor de correlación, el índice de penetración láser con un valor de 0.71 y la desviación absoluta de la mediana con un coeficiente de correlación de 0.43.

El volumen seleccionó tres métricas que cuenta con similitudes a las elegidas para el área basal, la primera coincide con la métrica de mayor correlación “Todos los retornos sobre la altura media / Total de primeros retornos * 100”, su coeficiente corresponde a un valor de 0.79, la siguiente métrica es la elevación media cuadrática, 0.73 y el coeficiente de variación de intensidad que es la misma variable seleccionada para el área basal, sin embargo su coeficiente de correlación es mucho menor, 0.30.

Cuadro 8. Modelos de regresión lineal múltiple y variables seleccionadas para la estimación de variables forestales: área basal (m²/sitio), biomasa (kg/sitio), cobertura arbórea (m²/sitio) y volumen (m³/sitio).

Modelo	R ² ajustada	RMSE	Param	Estimación	P
AB= A0+A1*Elevación media +A2*Elevación del percentil 70+A3*Porcentaje de todos los retornos sobre la media	0.77	0.21	A0	-0.16455	0.0069**
			A1	0.066837	0.0011**
			A2	-0.03704	0.0231*
			A3	0.022009	<.0001**
BIOM=A0+A1*((Todos los retornos sobre tres) / (Total de primeros retornos) * 100))+A2*Elevación del percentil 50+A3* Coeficiente de variación de intensidad	0.76	1340.08	A0	2832.088	0.0004**
			A1	39.51389	<.0001**
			A2	224.1344	<.0001**
			A3	-10921.2	<.0001**
COB=A0+A1*índice de penetración láser+ A2*Desviación absoluta de la mediana	0.53	139.71	A0	-89.5733	0.0558*
			A1	911.8164	<.0001**
			A2	22.47737	0.0136*
VOL=A0+A1*((Todos los retornos sobre la altura media) / (Total de primeros retornos) * 100))+A2* Elevación media cuadrática+A3*Coeficiente de variación de intensidad	0.79	2.07	A0	2.812044	0.0027**
			A1	0.109815	<.0001**
			A2	0.404383	<.0001**
			A3	-16.6025	<.0001**

*≤0.05 Significativo, **≤0.01 Muy significativo, Param: Parámetros.

En general, para los modelos de área basal, biomasa total y volumen, las variables predictoras relevantes son aquellas que describen la estructura vertical del dosel, específicamente el valor de algún percentil de altura del arbolado (0-99) (Næsset, 2004; Mora *et al.*, 2013).

Holmgren (2004), estimó el área basal y el volumen maderable empleando el percentil de altura 90 y una proporción de la vegetación (una métrica relacionada a la cobertura del dosel) para ambos parámetros, en un bosque de *Picea abies* (L.) Karst y *Pinus sylvestris* L. al suroeste de Suecia.

La elevación media de los retornos correspondientes a la vegetación, resultó una variable adecuada para predecir el área basal, lo cual coincide con estudios previos

para bosques de coníferas maduros y viejos en un bosque experimental en Oregon, USA, donde encontraron un modelo que emplea la altura media para predecir área basal con una R^2 de 0.88 (Means *et al.*, 1999).

La predicción generalmente mejora cuando se incluye en los modelos una métrica relacionada con los retornos provenientes del dosel, debido a que es una medida de la cantidad de follaje. Lo anterior, ayuda a identificar las parcelas con mayor cantidad de área basal lo que concuerda con las aseveraciones de Popescu (2007). Dicha tendencia se encontró en el modelo de área basal de este estudio, al incluir una métrica relacionada a las tasas de retorno del dosel.

Así mismo Næsset (2004), desarrolló un modelo para predecir el área basal con una R^2 de 0.74 en bosques maduros de *Picea abies* (L.) Karst. y *Pinus sylvestris* L. al sureste de Noruega; en el cual empleaba el valor del logaritmo natural del percentil 70 (correspondiente a la altura del arbolado), métrica que también se presenta en nuestro modelo y con un valor de la R^2 ligeramente mayor de 0.77.

El modelo de biomasa generado incluye tres métricas, una de ellas corresponde la métrica de elevación del percentil 50 (P50, correspondiente a los retornos del arbolado), misma situación fue reportado en modelos ajustados para biomasa aérea total y por componentes en los trabajos de Lim y Treitz (2004) en bosques de *Acer saccharum* Marsh y *Betula alleghaniensis* Britton, la variabilidad (R^2) que lograron explicar mediante los modelos oscilaron de 0.86 a 0.89 y en el caso de biomasa total por Bortolot y Wynne (2005), con valores de R^2 de 0.50 a 0.53 cuando aplicaron el modelo durante el proceso de validación utilizando sólo esta variable (P50), en plantaciones de *Pinus taeda* en Virginia, Estados Unidos. El modelo generado en este trabajo explica la variabilidad con un valor de $R^2=0.76$.

Con la finalidad de validar los modelos generados, las estimaciones obtenidas a través de éstos se compararon con los valores medidos en campo para cada una de las variables de interés (Figura 9). El ajuste de modelos lineales a los datos predichos y observados indica factores de ajuste (pseudo R^2) de 0.84 para área basal, de 0.85 para biomasa aérea y volumen y de 0.57 para la cobertura arbórea, dicho factor nos indica cuanto las estimaciones predichas se asemejan a las estimaciones medidas en campo.

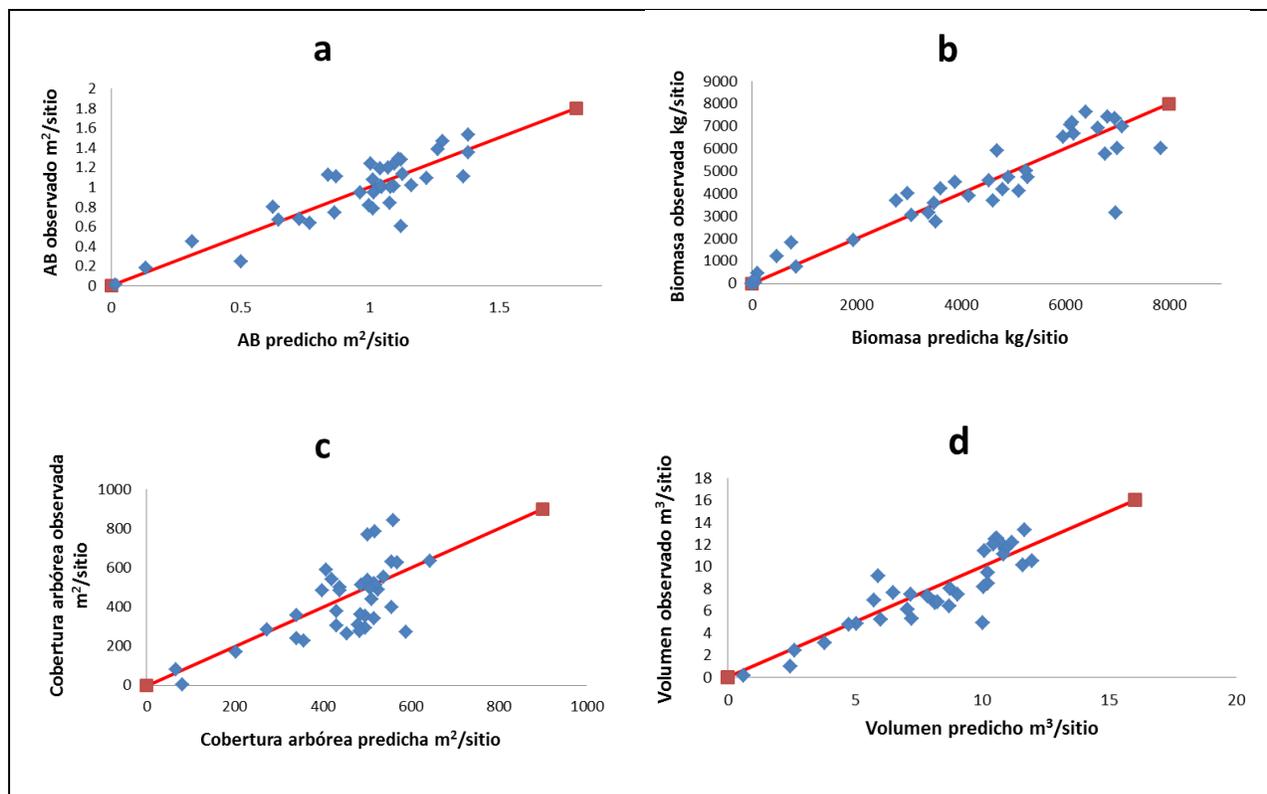


Figura 9. Gráficas de a) área basal ($m^2/sitio$), b) biomasa total ($kg/sitio$), c) cobertura arbórea ($m^2/sitio$) y d) volumen ($m^3/sitio$). La línea roja muestra la relación 1 a 1. La pseudo r^2 es de 0.84, 0.85, 0.57 y 0.85 respectivamente.

5.2 Estimación de las variables dasométricas mediante regresión lineal múltiple

Con las ecuaciones de regresión ajustadas para cada variable de interés, se estimaron valores para cada grid (celda por celda) a partir de sus correspondientes datos láser almacenados en las métricas generadas a nivel de grid. Con esta información se generaron mapas que describen la variabilidad espacial de las variables (Figuras 10, 11, 12 y 13).

Así mismo se estimó el inventario total para los parámetros área basal, biomasa total, cobertura arbórea y volumen. Los resultados se presentan en el Cuadro 9 para el área completa de estudio.

Cuadro 9. Estimación promedio por hectárea y total de los parámetros forestales área basal (m²), biomasa (Mg), cobertura arbórea (m² y %) y volumen (m³) mediante regresión lineal múltiple.

	Área basal m ²		Biomasa Mg		Cobertura arbórea		Volumen m ³	
	ha	Total	ha	Total	m ² ha ⁻¹	%	ha	Total
Media	23.41	21,068.26	127.62	114,862.48	11,170.95	111.70	202.11	181,747.45
IC+	25.38	22,838.15	139.51	125,563.27	12,350.13	123.50	219.99	197,992.23
IC-	21.54	19,386.81	116.39	104,753.88	10,052.52	100.52	185.07	166,566.62
Precisión %	8.0		8.8		10.0		8.4	

IC: Intervalo de confianza al 95 %

En este procedimiento se decidió obtener los intervalos de confianza \pm al 95 % para cada uno de los píxeles, de esta forma se puede estimar un intervalo de confianza a nivel poblacional al promediar los intervalos superior e inferior en todos los píxeles estimados. Los intervalos reportados pueden considerarse como los intervalos reales de la estimación, sin embargo, se observa que no son totalmente simétricos debido a que para cada píxel entra una combinación de métricas que son únicas para esa celda.

En otras palabras, cuando se calculó la precisión de los intervalos superiores e inferiores con una confiabilidad al 95 % se notó que no son exactamente iguales. Esto se realizó obteniendo la diferencia de los intervalos \pm con respecto a la media y el valor resultante dividido entre la media y multiplicarlo por 100 para obtenerlo en %.

Cabe aclarar que estos resultados tienen menos incertidumbre, a diferencia de los calculados mediante los otros métodos utilizados. En este caso, los intervalos de confianza funcionan como un indicador de la precisión total del modelo.

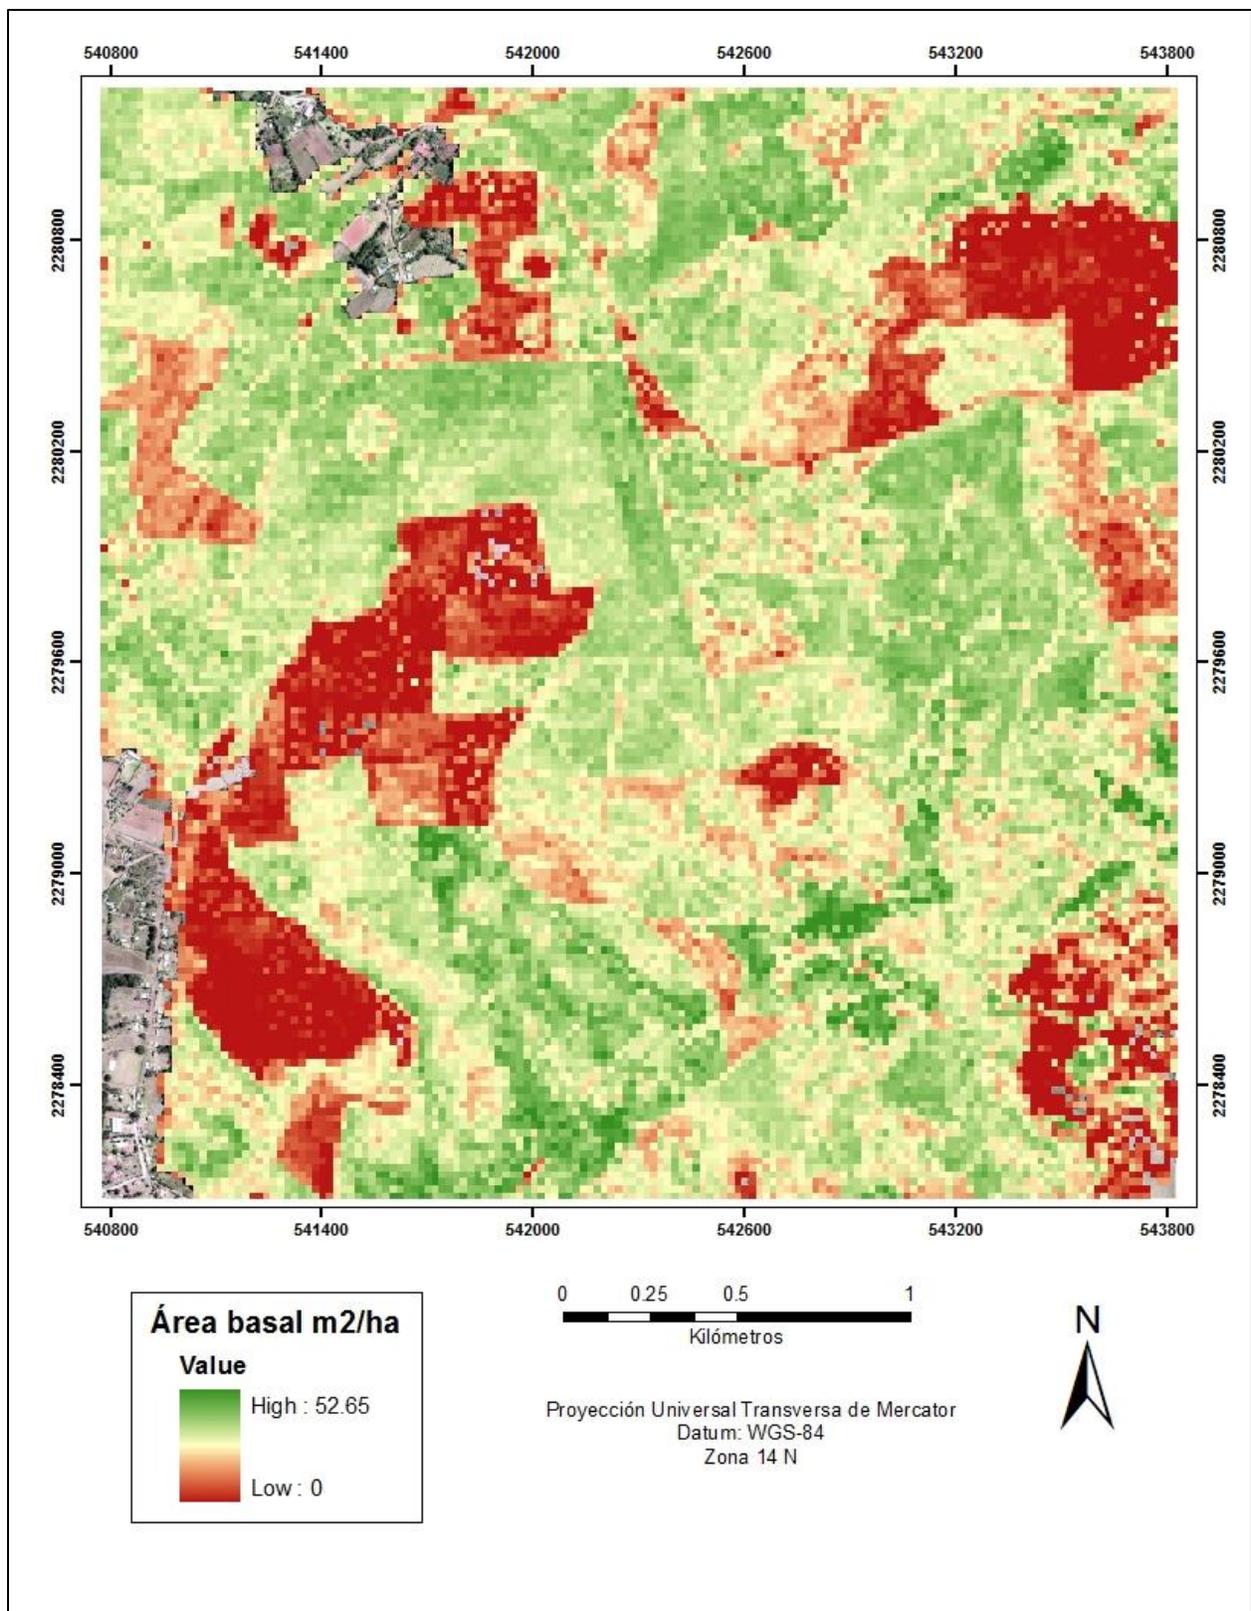


Figura 10. Representación cartográfica del área basal (m^2ha^{-1}) en la zona de estudio.

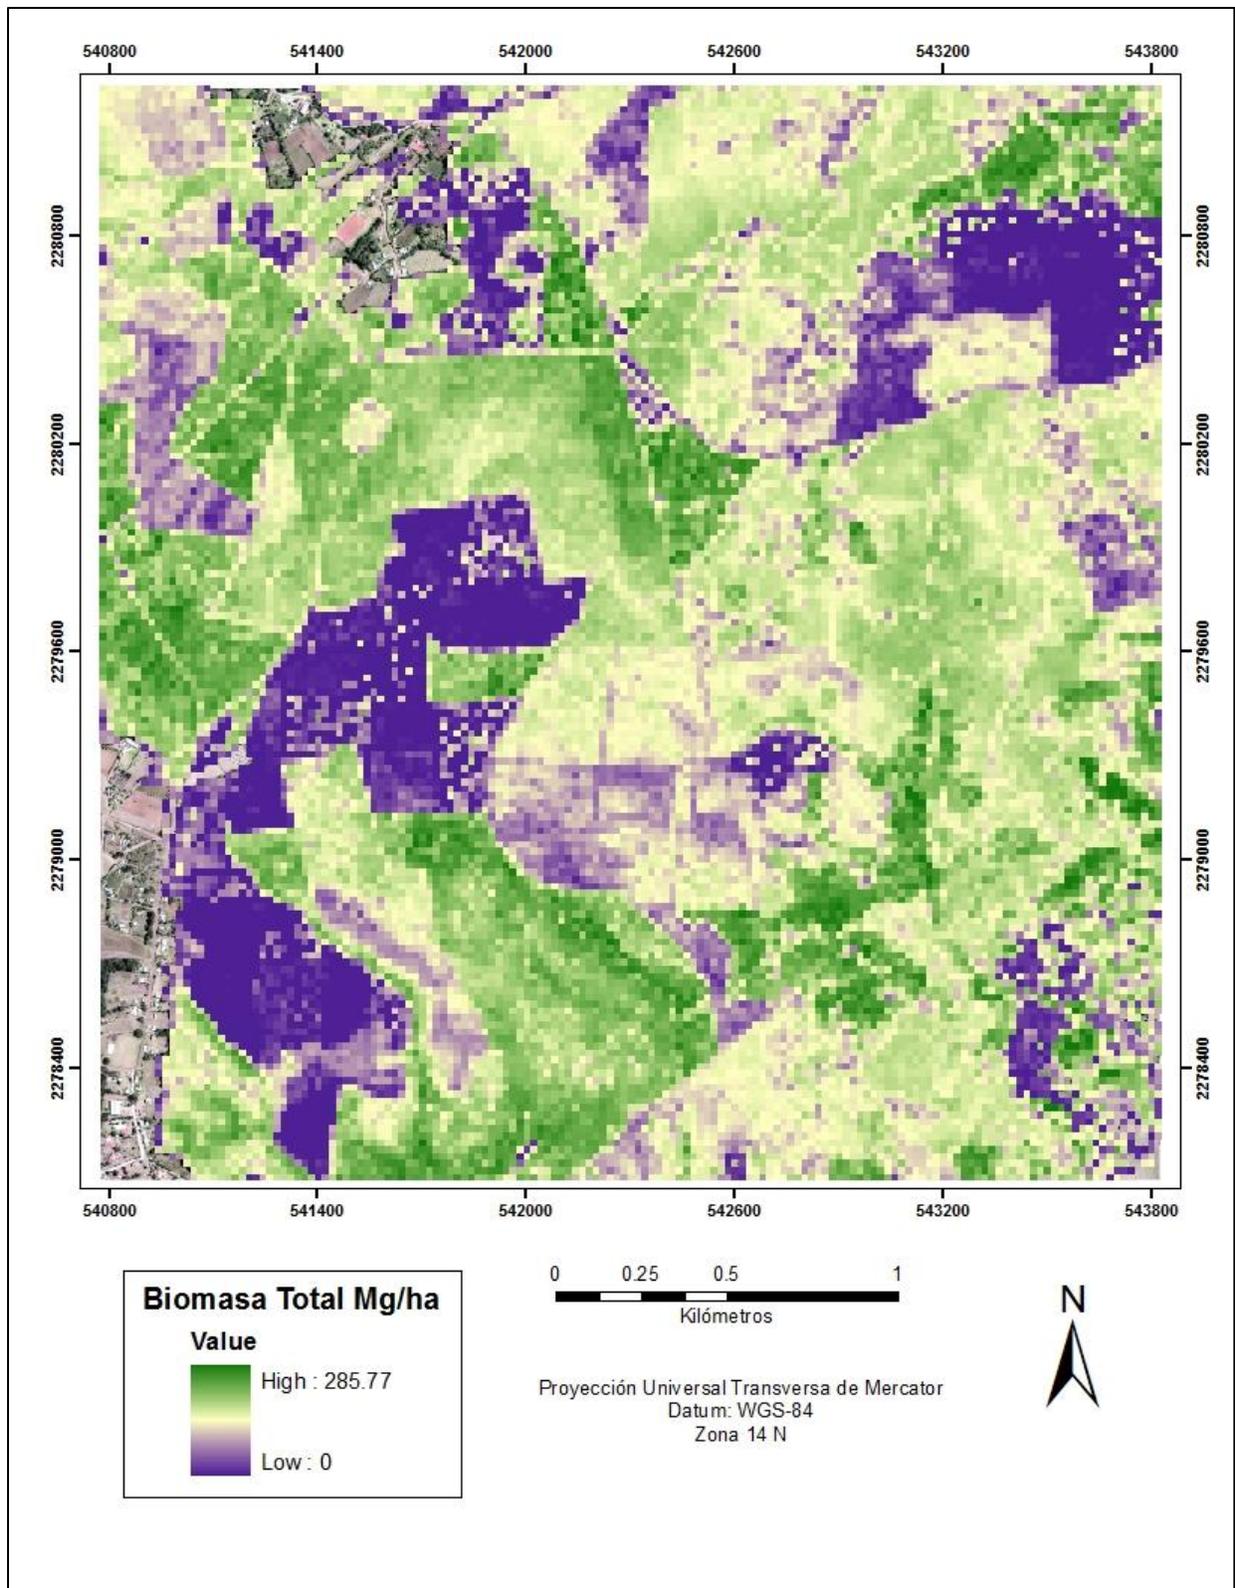


Figura 11. Representación cartográfica de la biomasa total (Mg ha^{-1}) en la zona de estudio.

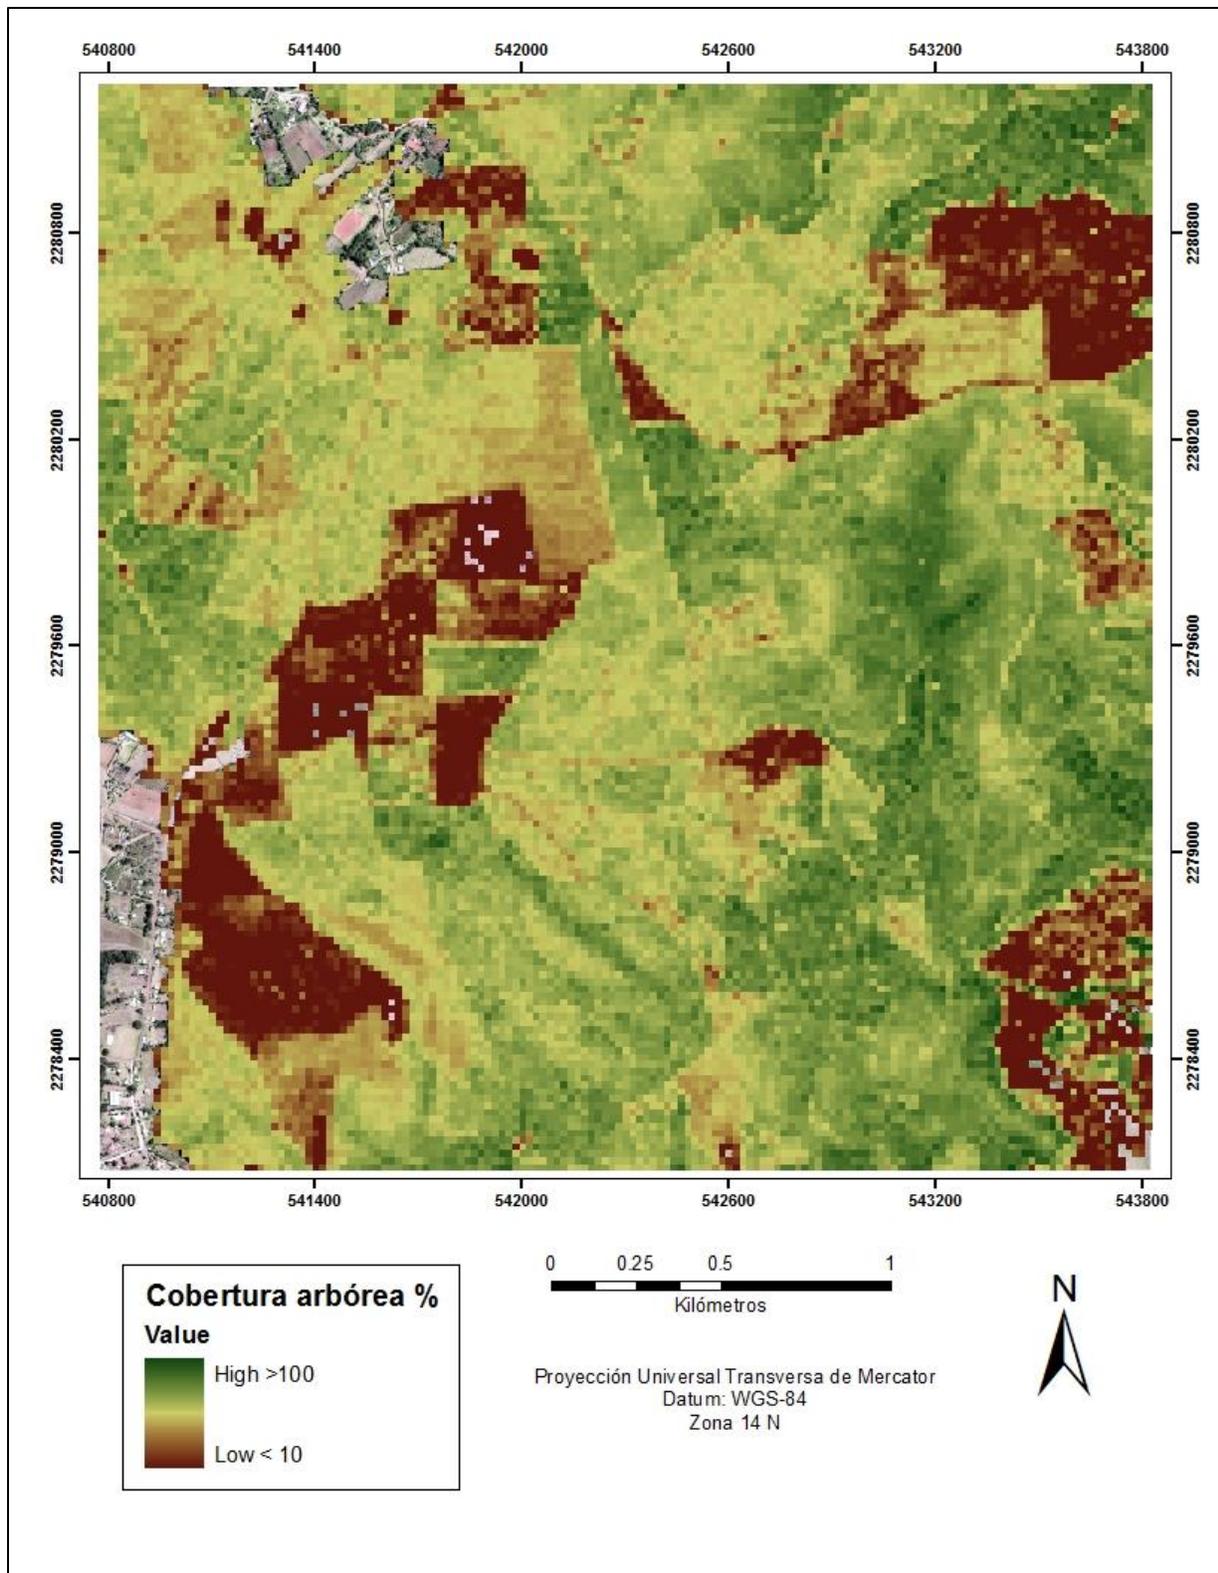


Figura 12. Representación cartográfica de la cobertura arbórea (%) en la zona de estudio.

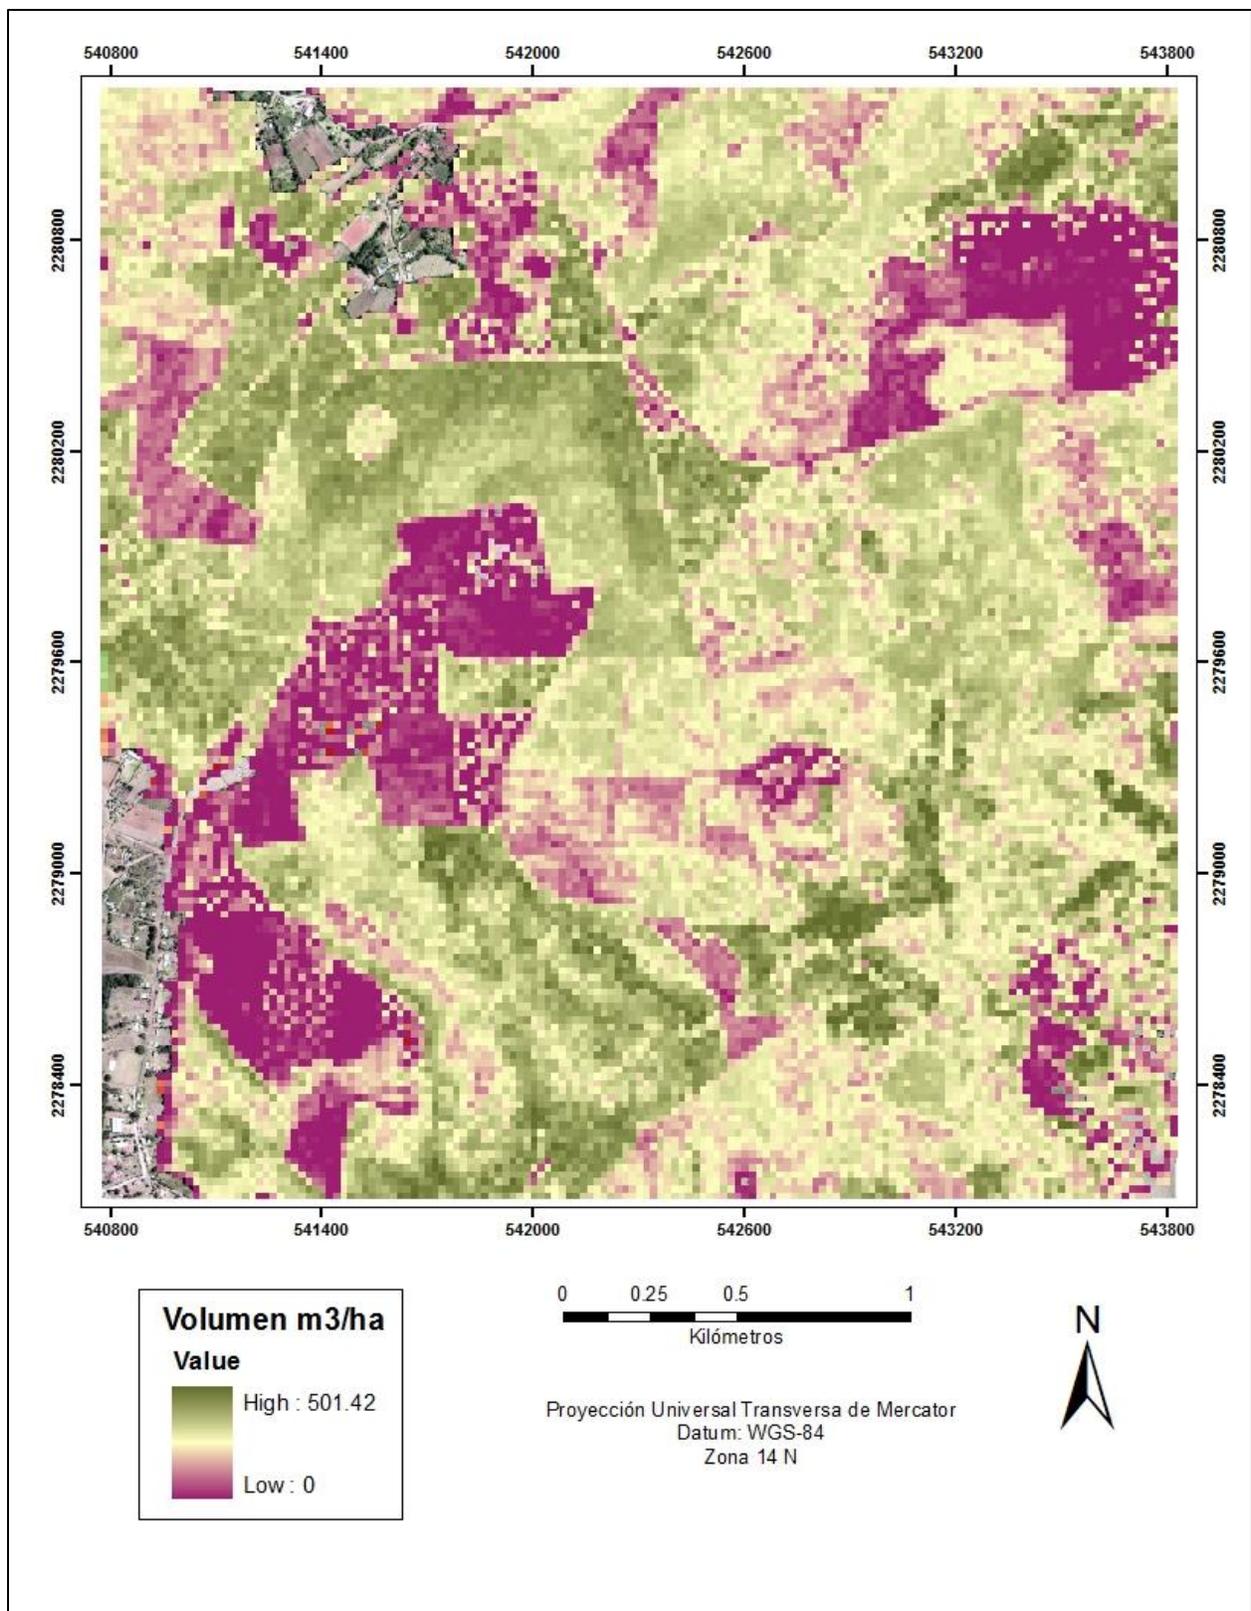


Figura 13. Representación cartográfica del volumen ($\text{m}^3 \text{ha}^{-1}$) en la zona de estudio.

5.3 Estimación de las variables dasométricas mediante regresión no lineal.

Al aplicar los modelos resultantes en el cálculo de las variables de interés, se observó que se obtenían algunas estimaciones negativas; una desventaja de las predicciones de la regresión lineal que generalmente coinciden con áreas recientemente cosechadas. Los valores obtenidos se pueden generalizar a cero, dado que resulta ilógica la presencia negativa de biomasa, área basal o volumen en términos cuantitativos (Aguirre, 2011).

Para eliminar tal desventaja los modelos iniciales se ajustaron como modelos no lineales (Cuadro 10) bajo la estructura del modelo Cobb-Webb, de esta manera aseguramos que el valor de la R^2 es el valor real del parámetro de interés. Los modelos resultantes fueron:

Cuadro 10. Modelos de regresión no lineal y variables seleccionadas para la estimación de variables forestales: área basal ($m^2/sitio$), biomasa ($kg/sitio$), cobertura arbórea ($m^2/sitio$) y volumen ($m^3/sitio$).

Modelo	R^2 ajustada	RMSE	Param.	Estimación	P
AB= $\exp^{(A0)}$ *Elevación media ($A1$) * Elevación del percentil 70($A2$) * Porcentaje de todos los retornos sobre la media($A3$)	0.78	0.20	A0	-4.06942	<.0001**
			A1	1.062955	<.0001**
			A2	-0.68133	0.0088**
			A3	0.882647	<.0001**
BIOM= $\exp^{(A0)}$ * ((Todos los retornos sobre tres) / (Total de primeros retornos) * 100))($A1$) * Elevación del percentil 50($A2$) * Coeficiente de variación de intensidad($A3$)	0.81	1182.19	A0	2.166776	0.0002**
			A1	0.719721	<.0001**
			A2	0.883867	<.0001**
			A3	-0.9	0.0001**
COB= $\exp^{(A0)}$ * índice de penetración láser($A1$) * Desviación absoluta de la mediana($A2$)	0.51	139.73	A0	6.811036	<.0001**
			A1	1.306306	<.0001**
			A2	0.140579	0.0122*
VOL= $\exp^{(A0)}$ * (Todos los retornos sobre la altura media) / (Total de primeros retornos) * 100))($A1$) * Elevación media cuadrática($A2$) * Coeficiente de variación de intensidad($A3$)	0.84	1.83	A0	-4.37924	<.0001**
			A1	0.816008	<.0001**
			A2	0.915251	<.0001**
			A3	-0.84315	<.0001**

*≤0.05 Significativo, **≤0.01 Muy significativo. exp=exponencial. Param: Parámetros. Ejemplificando el modelo de área basal quedaría como:

$$AB = e^{(-4.06942)} * EM^{(1.062955)} * EP70^{(-0.68133)} * PTRSM^{(0.882647)}$$

Los modelos de regresión no lineal ajustados para estimar el área basal y la cobertura arbórea no mejoraron sustancialmente la explicación de la variabilidad en comparación con los modelos lineales. Los valores de R^2 pasaron de 0.77 a 0.78 para el caso del área basal y para cobertura arbórea la R^2 disminuyó de 0.53 a 0.51. La ventaja de estos modelos es que no calculan valores negativos a diferencia de los modelos iniciales; sin embargo, sería necesario explorar otras estructuras que se ajusten mejor a la distribución de los datos, e incluso otras relaciones con las métricas LiDAR que predigan con mejores resultados a las variables de área basal y cobertura. A partir de estas nuevas estructuras se generó la cartografía correspondiente para el área completa de estudio (Figuras 14 y 16).

En cuanto a biomasa total, el modelo no lineal mejoró notablemente el valor de la R^2 (de 0.76 a 0.81), eliminando además la estimación de valores negativos. A pesar del incremento en la R^2 , se notó una falta de ajuste al graficar los residuales del modelo (gráfica no mostrada), por lo que particularmente para la biomasa se sugiere probar algunos modelos de crecimiento como la ecuación exponencial de Chapman-Richards o el modelo de Schumacher. Este tipo de ecuaciones son especiales para modelar fenómenos biológicos, dada su naturaleza asintótica (Aguirre, 2011). En general, el modelo lineal ajustado inicialmente se comportó mejor, ya que su poder de predicción es bastante aceptable, salvo por aquellos valores negativos que se obtienen; posteriormente se obtuvo el mapa correspondiente (Figura 15).

El modelo no lineal para estimar volumen explicó la variabilidad en un 84 % (la R^2 aumentó de 0.79 a 0.84), en este modelo se observó que las variables son más o menos complementarias, esto quiere decir que no existe alta colinealidad. Este modelo fue el único que funcionó mejor en comparación con su contraparte lineal, ya que no presentó falta de ajuste y eliminó la estimación de valores negativos para las variables dasométricas de interés. De igual manera y con base en estos resultados, se obtuvo el mapa correspondiente (Figura 17).

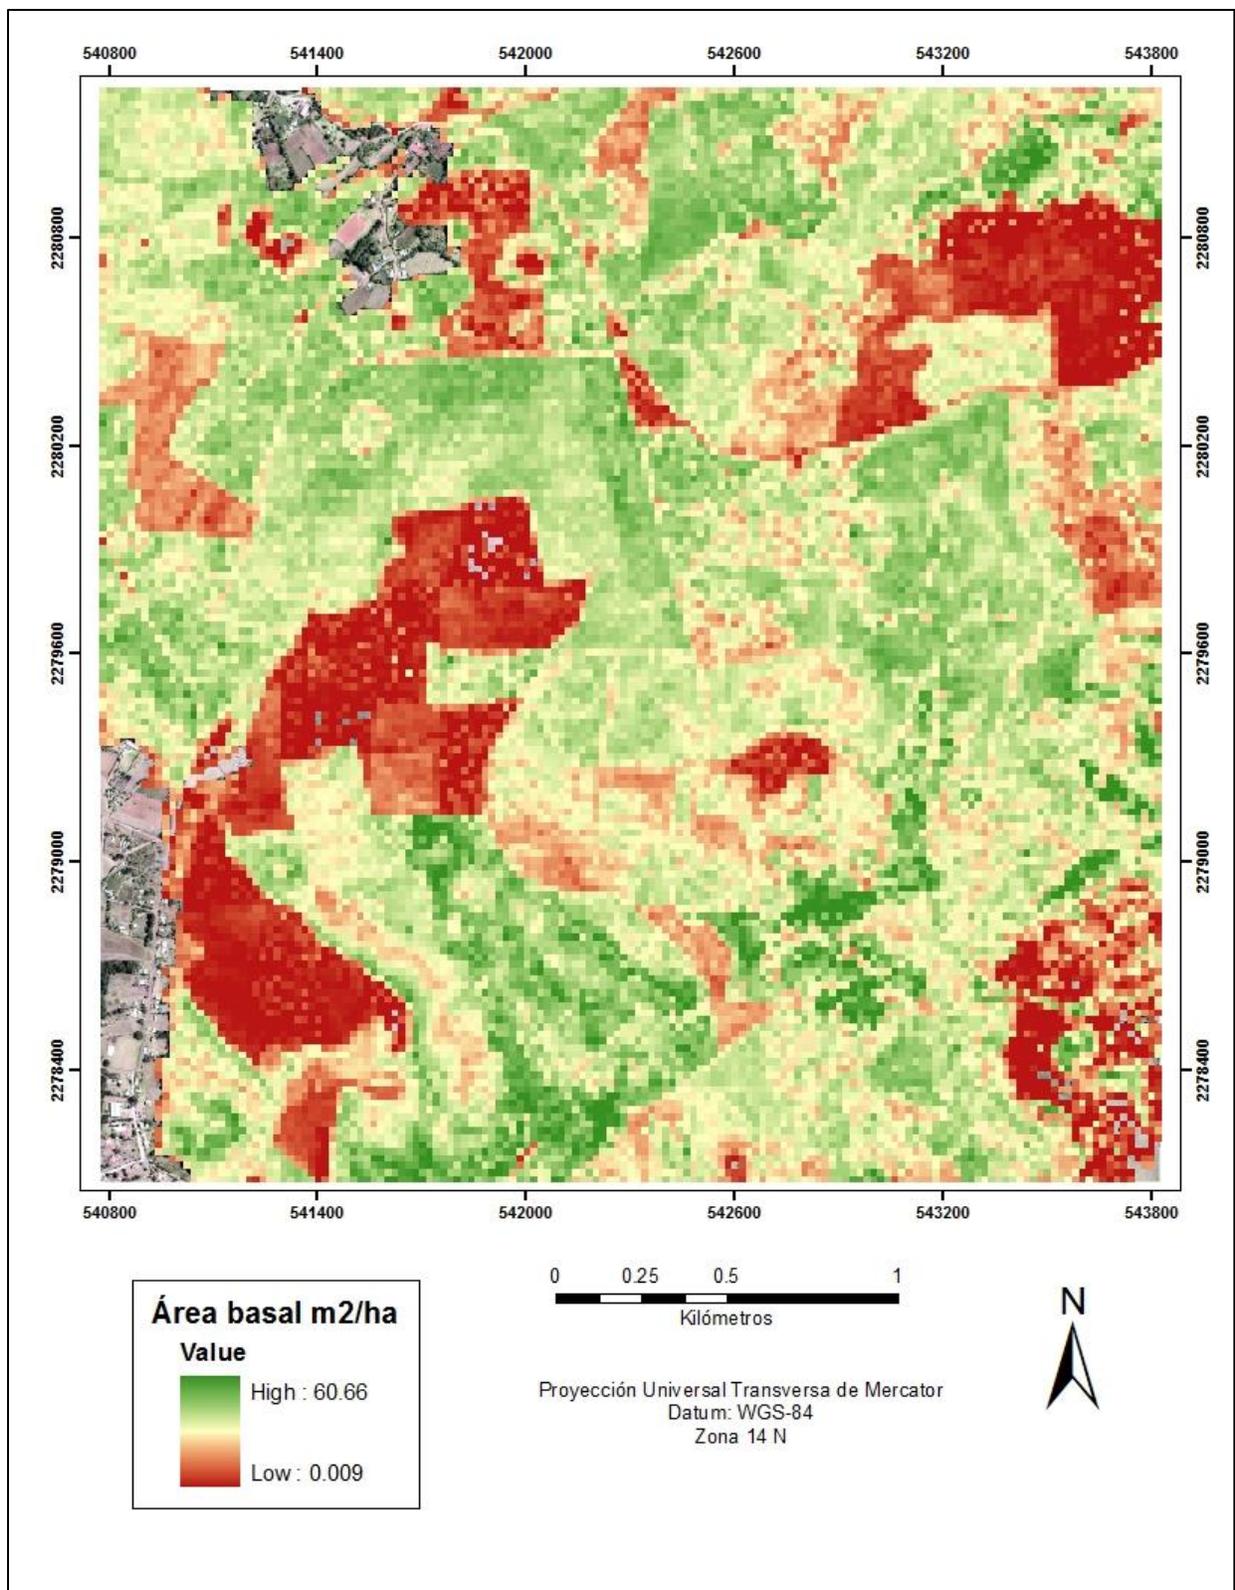


Figura 14. Representación cartográfica del área basal ($\text{m}^2 \text{ha}^{-1}$) en la zona de estudio, utilizando el modelo no lineal.

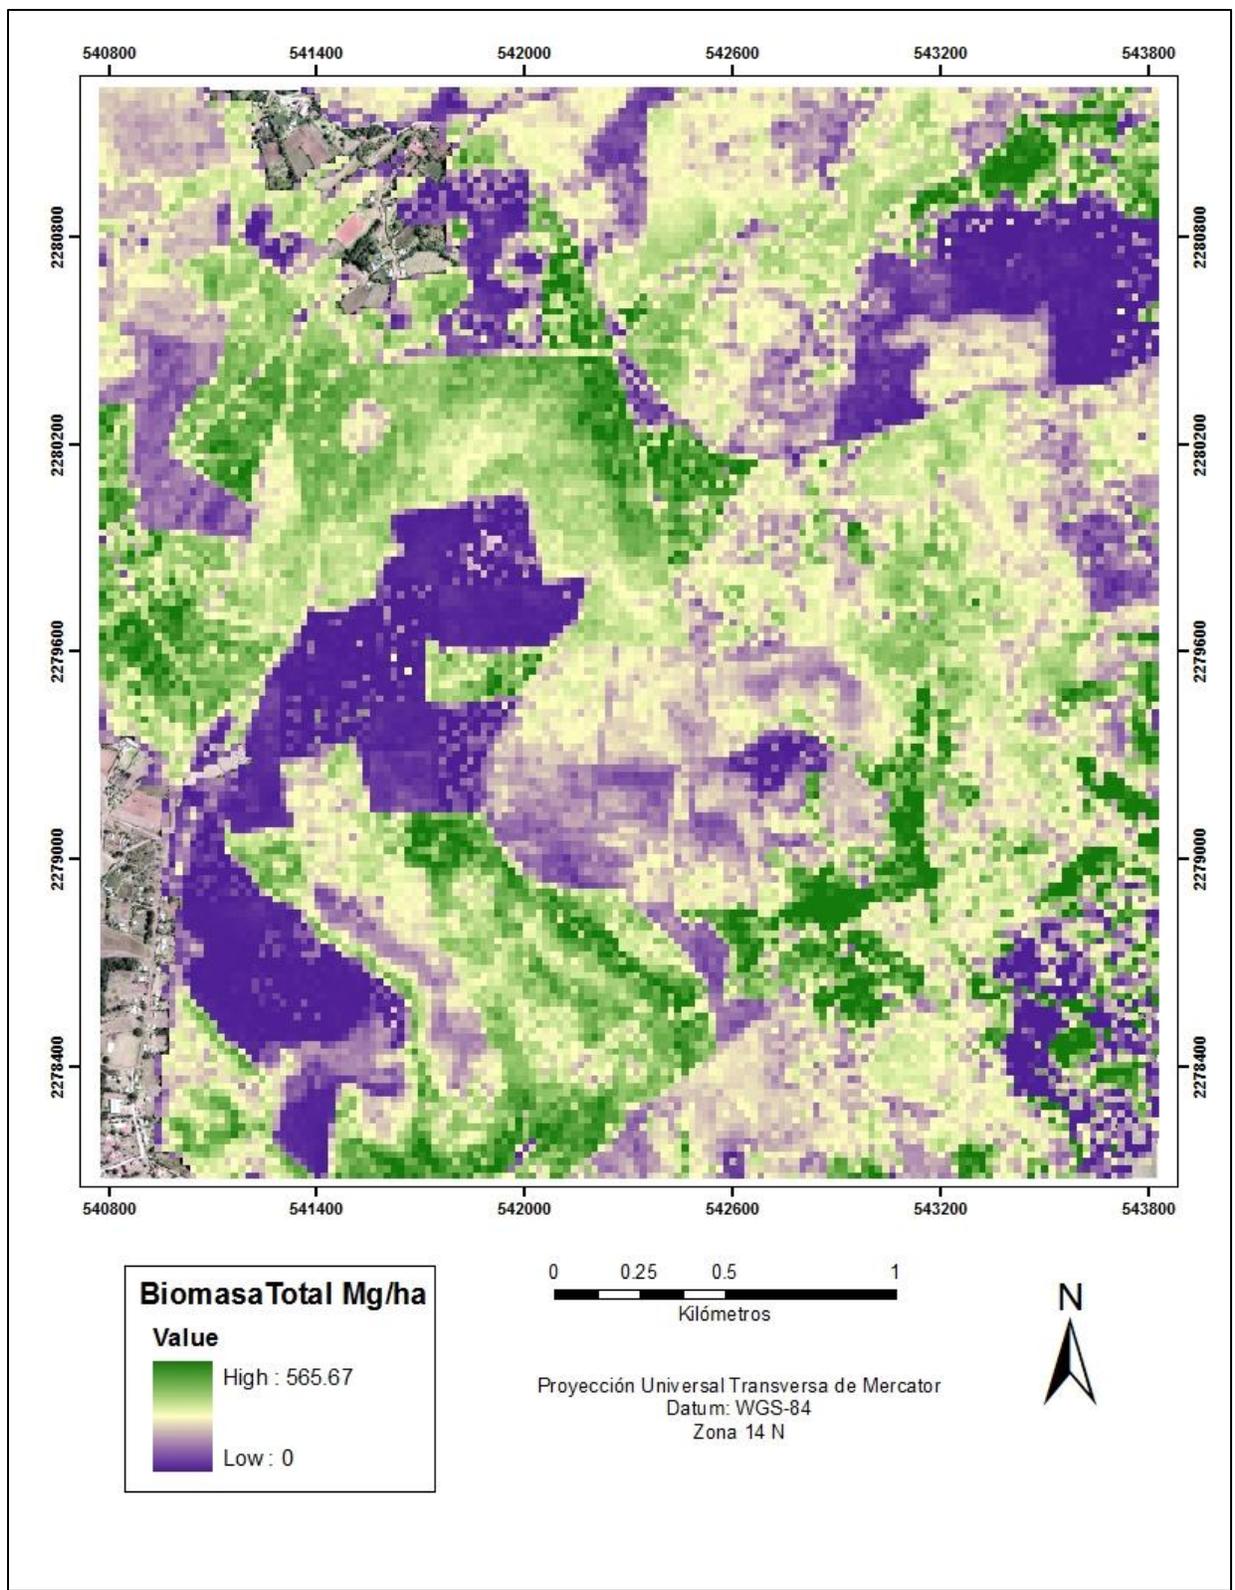


Figura 15. Representación cartográfica de la biomasa aérea (Mg ha^{-1}) en la zona de estudio, utilizando el modelo no lineal.

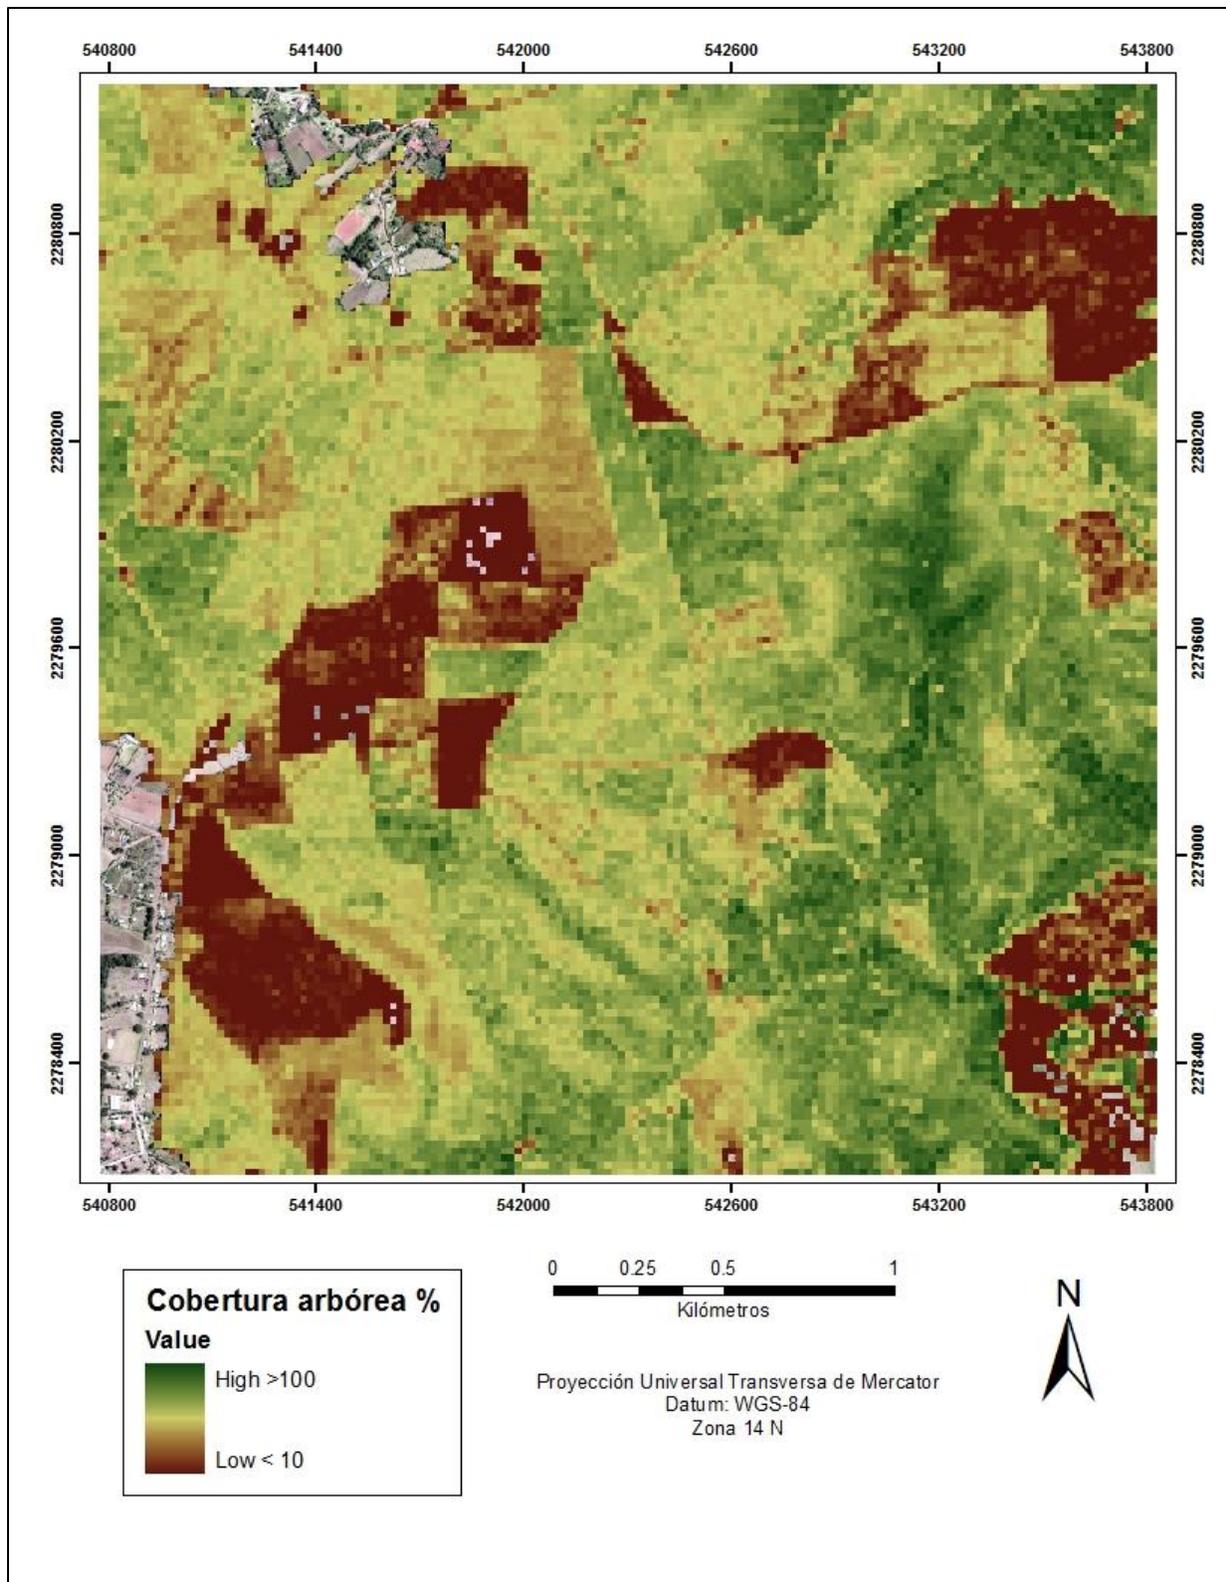


Figura 16. Representación cartográfica de la cobertura arbórea (%) en la zona de estudio, utilizando el modelo no lineal.

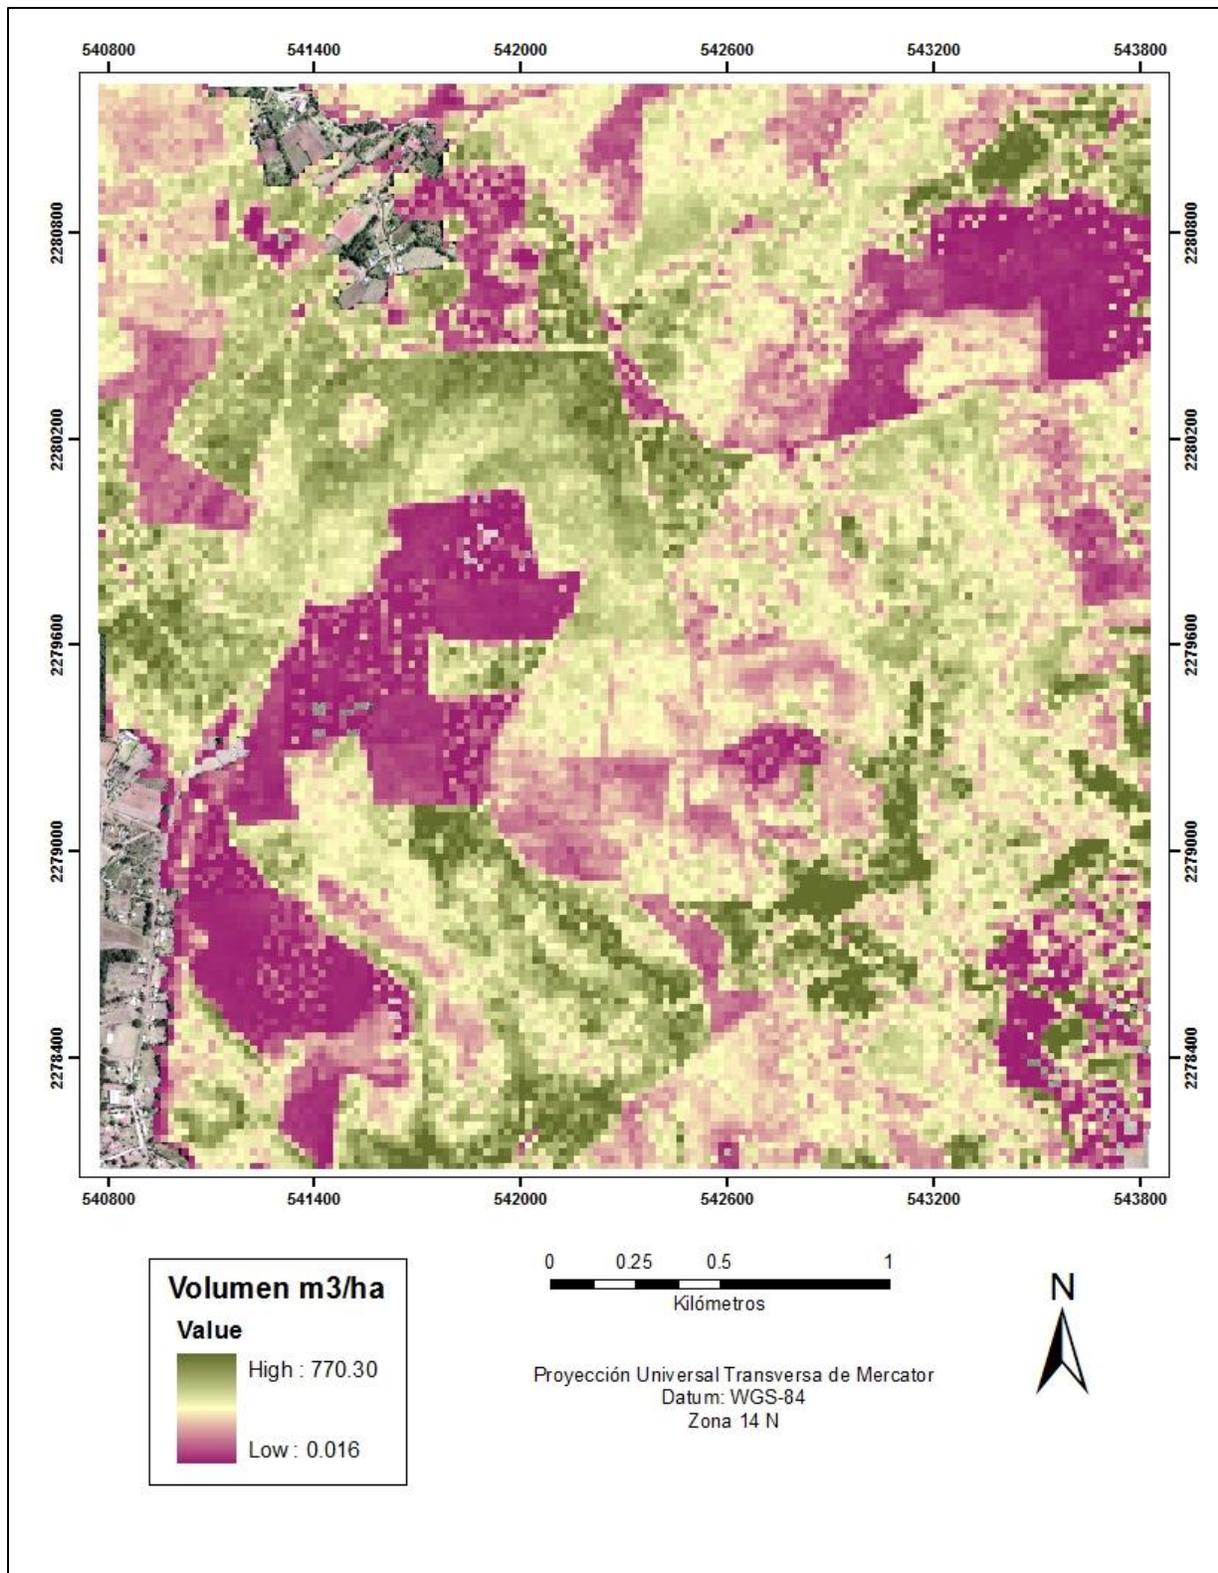


Figura 17. Representación cartográfica del volumen total ($\text{m}^3 \text{ha}^{-1}$) en la zona de estudio, utilizando el modelo no lineal.

Cuando se probó el modelo en aquellos sitios que quedaron fuera del proceso de validación, el factor de ajuste entre los valores observados y predichos no aumentó, para el caso de área basal y biomasa permaneció exactamente igual, en la variable cobertura arbórea disminuyó a 0.53 y para el volumen aumentó a 0.86 (Figura 18), lo que podría interpretarse como que los modelos lineales planteados inicialmente son bastante aceptables, con la excepción de que generan valores por debajo de cero para las cuatro variables de interés. Así mismo se da la pauta para mejorar la predicción de estos modelos, empleando otras estructuras como relaciones logísticas que sean capaces de ajustarse mejor a la dispersión de los datos, o incluso investigar aún más aquellas métricas que describan características específicas del dosel y de las cuales se tenga conocimiento de mejor funcionamiento en el desarrollo de los modelos.

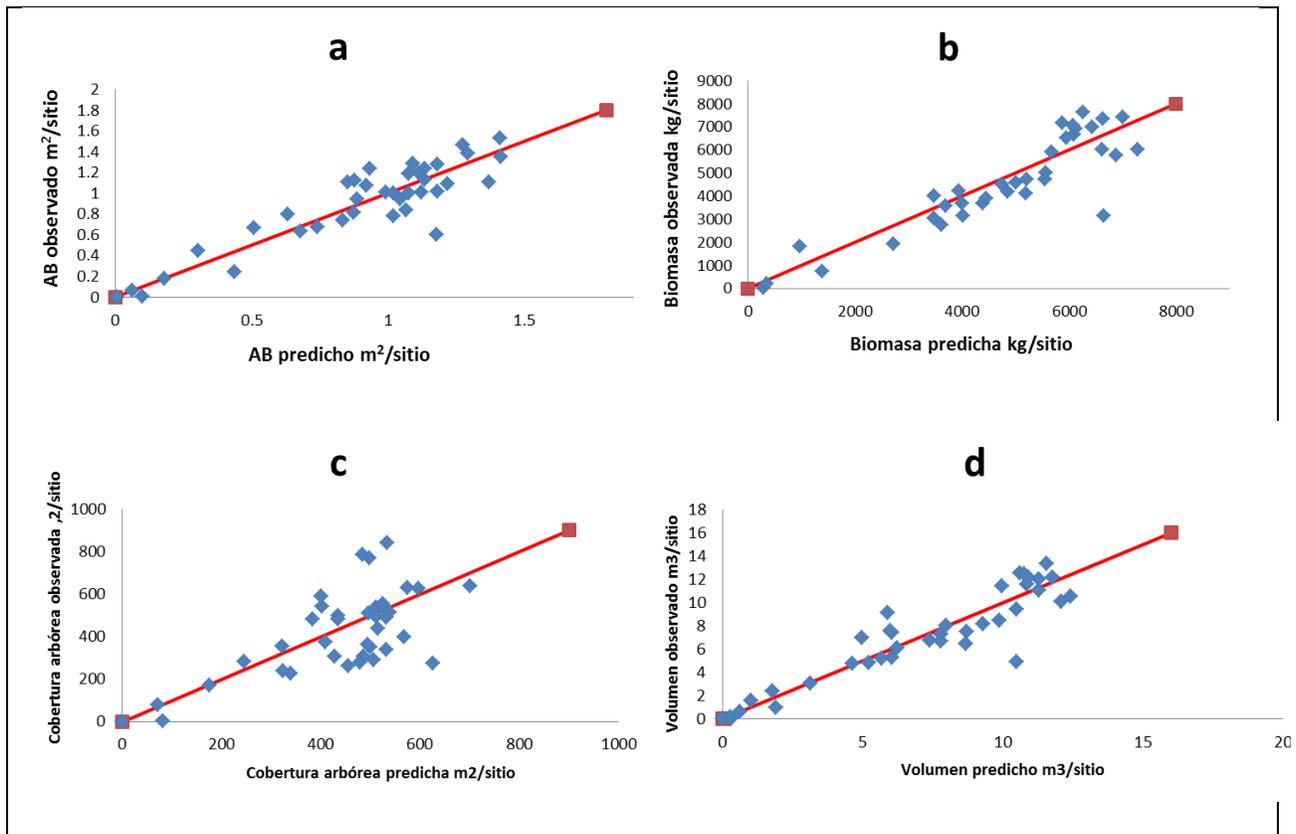


Figura 18. Gráficas de a) área basal (m²/sitio), b) biomasa total (kg/sitio), c) cobertura arbórea (m²/sitio) y d) volumen (m³/sitio). La línea roja muestra la relación 1 a 1. La pseudo R² es de 0.84, 0.85, 0.53 y 0.86 respectivamente.

En general, los modelos generados explican la mayor variabilidad en volumen como lo reportado por Howbaker *et al.* (2010), en donde los modelos que explicaron mejor la variabilidad fue para aquellos que estimaban el volumen de madera aserrada y para pulpa. Así mismo, nuestros modelos también predicen bastante bien para el área basal, biomasa total y cobertura arbórea.

5.4 Estimación de las variables dasométricas mediante estimadores de razón y regresión

Durante el proceso de análisis de correlación de Pearson, se encontró que existen métricas LiDAR que presentaron el mayor valor de correlación para cada una de las variables de interés (Cuadro 5). Se utilizaron como variables auxiliares para determinar un estimador de razón y uno de regresión como una forma alternativa de calcular el inventario total de cada variable en el área de estudio.

Para el caso del área basal se utilizó el Porcentaje de primeros retornos sobre tres (Percfirst_retabthree), el coeficiente de correlación de Pearson fue de 0.85, para la biomasa aérea el valor fue de 0.77 con la métrica Todos los retornos sobre la tres/Total de primeros retornos * 100 (Allretab3_Tot1stret100), el volumen utilizó la métrica Todos los retornos sobre la media/Total de primeros retornos * 100 (Allretabmean_Tot1stret100) el valor de su correlación fue 0.79 y el menor valor de correlación se presentó con la cobertura arbórea y el índice de penetración láser con un valor de 0.71 (Figura 19).

En todos los casos las métricas que presentan el mayor valor de correlación son aquellas que describen alguna tasa o proporción de los retornos provenientes del dosel.

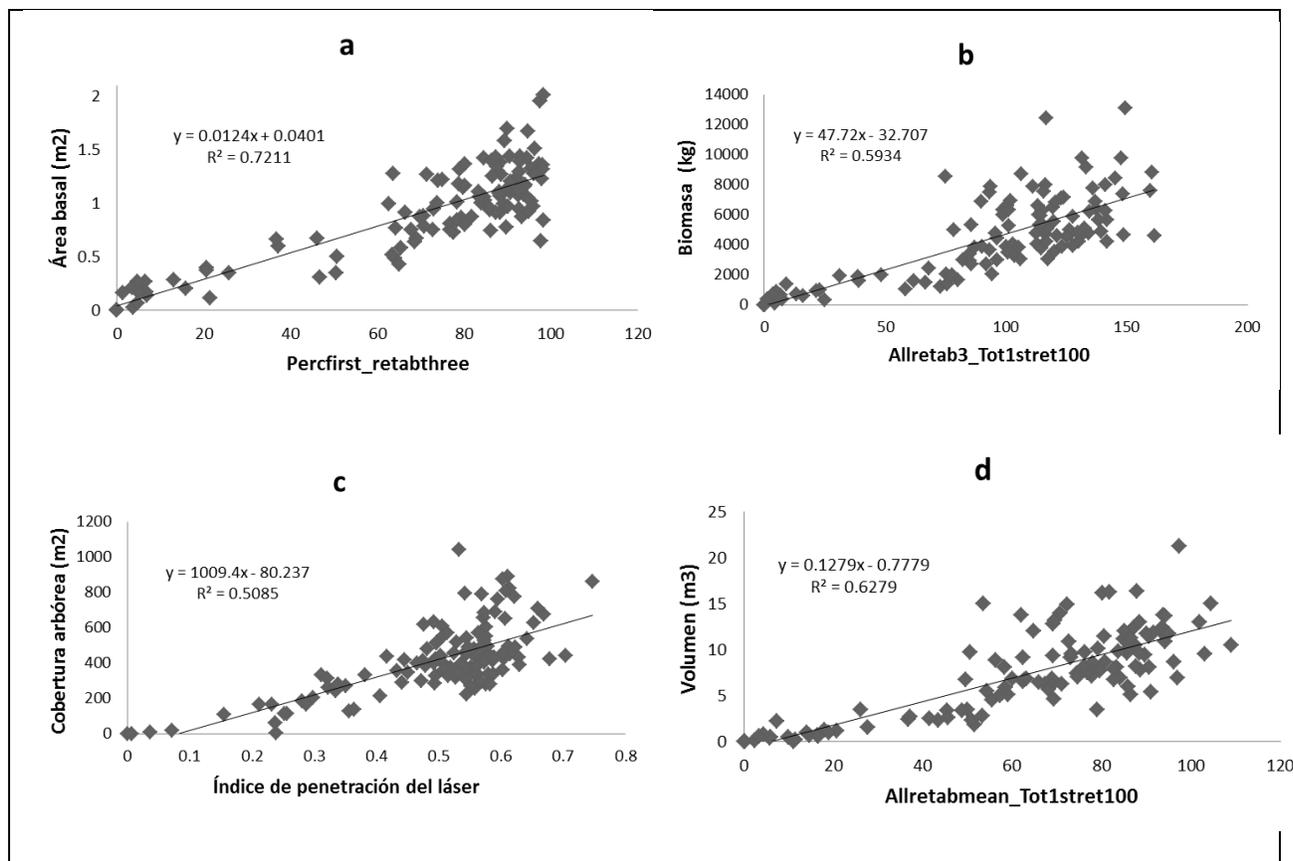


Figura 19. Correlaciones mayores de a) área basal y Percfirst_retabthree: Porcentaje de primeros retornos sobre tres; b) biomasa y Allretab3_Tot1stret100: Todos los retornos sobre la tres/Total de primeros retornos * 100; c) cobertura e índice de penetración láser y d) volumen y Allretabmean_Tot1stret100: Todos los retornos sobre la media/Total de primeros retornos * 100.

Las métricas anteriores se utilizaron como variables auxiliares y se realizó el cálculo del inventario total mediante los estimadores de razón y regresión, los cuales se presentan en los Cuadros 11 y 12 respectivamente.

Cuadro 11. Estimación promedio por hectárea y total de los parámetros forestales área basal (m²), biomasa (Mg), cobertura arbórea (m² y %) y volumen (m³) mediante los estimadores de razón.

	Área basal m ²		Biomasa Mg		Cobertura arbórea		Volumen m ³	
	ha	Total	ha	Total	m ² ha ⁻¹	%	ha	Total
Media	23.13	20,818.97	115.65	104,083.31	10,859.50	108.59	175.55	157,993.14
IC+	24.05	21,647.97	122.60	110,341.24	11,518.77	115.18	186.66	167,995.66
IC-	22.21	19,989.97	108.69	97,825.38	10,200.24	102.00	164.43	147,990.61
Precisión %	4.6		6.9		6.3		7.3	

IC: Intervalo de confianza al 95 %

Cuadro 12. Estimación promedio por hectárea y total de los parámetros forestales área basal (m²), biomasa (Mg), cobertura arbórea (m² y %) y volumen (m³) mediante los estimadores de regresión.

	Área basal m ²		Biomasa Mg		Cobertura arbórea		Volumen m ³	
	ha	Total	ha	Total	m ² ha ⁻¹	%	ha	Total
Media	23.12	20,806.71	115.68	104,110.22	10,487.75	104.87	174.53	157,072.50
IC+	24.18	21,763.73	123.73	111,353.89	11,060.80	110.60	187.29	168,563.91
IC-	22.06	19,849.70	107.63	96,866.55	9,914.71	99.15	161.76	145,581.10
Precisión %	4.6		7.0		6.2		7.3	

IC: Intervalo de confianza al 95 %

Se considera que este tipo de estimaciones debieran ser más precisas; por abajo del 10 % ya se puede considerar una ganancia en la precisión. Por otro lado, se observaron similitudes en los dos métodos, con respecto a las medias estimadas para cada variable y al porcentaje de precisión, por lo que una característica a tomar en cuenta para la elección del método más preciso es con base en el patrón de los datos; se elige emplear a los estimadores de razón cuando la dispersión de los datos pasen cerca del origen, en caso contrario sería más confiable hacer uso de los estimadores de regresión. Tomando en cuenta lo anterior y como se observa en la Figura 19, se eligieron a los estimadores de razón para la comparación de resultados.

Por otro lado y de acuerdo con el trabajo de Maltamo (2006), los resultados obtenidos por LiDAR puede mejorar considerablemente la precisión de un inventario. Los retornos sobre la superficie o retornos clasificados como vegetación, son usados para construir los modelos de superficie del dosel y la idea básica detrás de los inventarios forestales basados en LiDAR, es que el volumen debajo de la superficie del dosel está directamente relacionado a la biomasa total y por lo tanto, con el volumen maderable.

Con base en lo anterior, es coincidente que las métricas con mayor correlación de Pearson (y que se utilizaron como variables auxiliares en los estimadores de razón y regresión), fueran aquellas que se describen como índices y que para su construcción hacen uso de otras métricas que representan la variabilidad espacial del dosel, reflejado en el número de retornos que penetran en la superficie de la vegetación, así como en las ramas más bajas, las hojas y el suelo, o el porcentaje de retornos que regresan del dosel (Hawbaker *et al.*, 2010).

En la estimación del inventario total a través de ambos métodos se nota claramente la mejora en la precisión de la estimación, en comparación con la precisión calculada para el inventario mediante el muestreo aleatorio simple y estratificado (Cuadros 13 y 14) e incluso sobre el inventario total calculado con los modelos de regresión lineal múltiple.

5.5 Comparación de las estimaciones obtenidas por regresión lineal, no lineal, estimadores de razón versus el inventario tradicional.

A partir de la información medida en campo se calculó el inventario forestal para el área completa de estudio, haciendo uso de los estimadores del muestreo simple aleatorio (Cuadro 13) y estratificado (Cuadro 14), empleando a las anualidades como elemento de estratificación. A pesar de que se ha reportado que las estimaciones mediante el muestreo estratificado son mejores, sobre todo porque mejora las estimaciones en comparación con el muestreo aleatorio simple (Shiver and Borders, 1996; Aguirre, 2007 y Muñoz, 2012) en este trabajo no sucedió así.

En primera instancia se observó que la precisión de los parámetros en el muestreo aleatorio simple fueron mejores que el muestreo aleatorio estratificado, esto pudiera deberse a que el estrato que abarcó mayor superficie -en este caso el bosque natural- no tuvo un número adecuado de sitios de muestreo, afectando la ponderación de la media y en consecuencia la varianza de la media. Por lo que se recomienda que para futuros trabajos se añada más unidades de muestreo en esta zona, ya que abarca más de 45 % de la superficie total inventariada; sin embargo, como tradicionalmente se hace uso de este método para calcular el inventario total, fueron los estimadores del muestreo estratificado los empleados para hacer las comparaciones con las estimaciones de regresión lineal, no lineal y estimadores de razón.

Cuadro 13. Estimación promedio por hectárea y total de los parámetros forestales área basal (m^2), biomasa (Mg), cobertura arbórea (m^2 y %) y volumen (m^3) mediante muestreo simple aleatorio.

	Área basal m^2		Biomasa Mg		Cobertura arbórea		Volumen m^3	
	ha	Total	ha	Total	m^2ha^{-1}	%	ha	Total
Media	22.54	20,283.25	109.06	92,497.80	10,414.02	104.14	181.44	153,886.36
IC+	24.24	21,813.00	119.46	101,316.76	11,213.44	112.13	198.82	168,628.23
IC-	20.84	18,753.51	98.66	83,678.83	9,614.60	96.14	164.06	139,144.49
Precisión %	7.5		9.5		7.7		9.6	

IC: Intervalo de confianza al 95 %

El inventario tradicional mediante el muestreo estratificado estima un total del 20,491.95 m^2 de área basal, la biomasa aérea total estimada es de 104,664.06 Mg; la cobertura arbórea promedio está por arriba del 100 % y finalmente el volumen total estimado es de 161,214.50 m^3 .

Cuadro 14. Estimación promedio por hectárea y total de los parámetros forestales área basal (m^2), biomasa (Mg), cobertura arbórea (m^2 y %) y volumen (m^3) mediante muestreo estratificado.

	Área basal m^2		Biomasa Mg		Cobertura arbórea		Volumen m^3	
	ha	Total	ha	Total	m^2ha^{-1}	%	ha	Total
Media	25.04	20,491.95	127.90	104,664.06	13,132.47	131.32	197.01	161,214.50
IC+	27.39	22,414.49	144.82	118,502.65	14,157.04	141.57	217.53	178,008.70
IC-	22.69	18,569.40	110.99	90,825.46	12,107.91	121.07	176.49	144,420.30
Precisión %	9.5		13.4		7.9		10.5	

IC: Intervalo de confianza al 95 %

En el Cuadro 15 se concentran las estimaciones totales de área basal, biomasa total, cobertura arbórea y volumen mediante el inventario tradicional y los métodos de regresión lineal y no lineal, así mismo se presentan las estimaciones totales generadas a partir del estimador de razón (este método es el que finalmente se presenta ya que como se explicó anteriormente, se ajustó mejor a la dispersión de los datos).

Cuadro 15. Comparación del inventario tradicional versus los diferentes métodos para la estimación total de área basal (m²), biomasa (Mg), cobertura arbórea (%) y volumen (m³).

	Inventario tradicional I	Regresión lineal II	Regresión no lineal III	Estimador de razón IV	Tasa de cambio entre el inventario tradicional y los otros métodos		
					I vs II	I vs III	I vs IV
IC-	18,569.40	19,386.81		19,989.97			
Área basal m ²	20,491.95	21,068.26	21,600.11	20,818.97	2.81	5.41	1.60
IC+	22,414.49	22,838.15		21,647.97			
IC-	90,825.46	104,753.88		97,825.38			
Biomasa aérea Mg	104,664.06	114,862.48	115,711.56	104,083.31	9.74	10.56	-0.55
IC+	118,502.65	125,563.27		110,341.24			
IC-	121.07	100.52		102.00			
Cob arbórea %	131.32	111.70	112.01	108.59	-6.44	-6.19	-9.05
IC+	141.57	123.50		115.18			
IC-	144,420.30	166,566.62		147,990.61			
Volumen m ³	161,214.50	181,901.25	187,383.66	157,993.14	12.83	16.23	-2.00
IC+	178,008.70	197,992.23		167,995.66			

IC: Intervalo de confianza al 95 %. Cob: cobertura

Las estimaciones totales por medio de los métodos de regresión lineal y no lineal tienden a ser optimistas respecto a las estimaciones mediante el inventario tradicional. Usando el inventario tradicional como referencia, se tiene que en el caso del estimador de razón las estimaciones son conservadoras para la biomasa y el volumen, mientras que para el área basal son ligeramente optimistas. Mención aparte son las estimaciones de cobertura arbórea, ya que en todos los casos los resultados fueron muy conservadores con respecto al inventario tradicional (Figura 20).

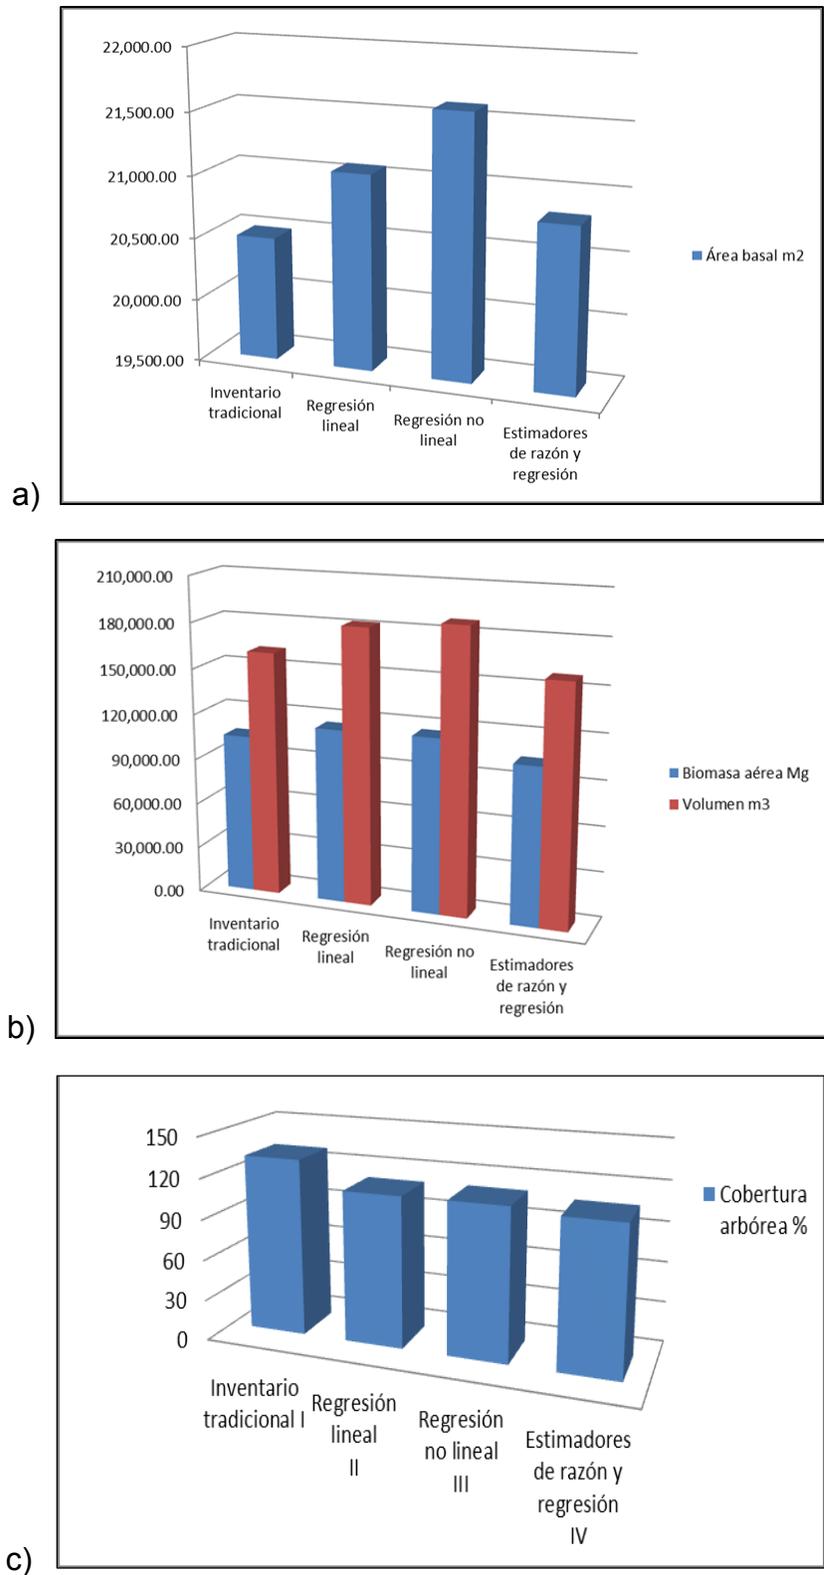


Figura 20. Comparación de las variables forestales estimadas a través del inventario tradicional y los métodos que emplean las métricas de LiDAR. a) Área basal (m²), b) Volumen (m³) y Biomasa total (Mg) c) cobertura arbórea (%).

Las estimaciones realizadas a través del estimador de razón fueron las más similares a los resultados de los estimadores puntuales (Cuadro 15). Estas difieren mínimamente de lo estimado por el inventario tradicional: +1.60 % para el área basal (20,818.97 m²), -0.55 % (104,083.31 Mg) y -2.0 % (157,993.14 m³) para biomasa total y volumen maderable respectivamente. Para la cobertura arbórea se tiene un -9.05 %, la mayor diferencia porcentual entre los estimadores probados para esta variable.

El método de regresión lineal fue el segundo más similar al inventario tradicional con +2.81 % para el área basal (21,068.26 m²), +9.74 % (114,862.48 Mg) para la biomasa aérea total y +12.83 % (181,901.25 m³) para el volumen. Contrariamente para la cobertura arbórea se tiene - 6.44 %.

Por otro lado, el método de regresión no lineal produjo las estimaciones más distantes con respecto al inventario tradicional: +5.41 % en el área basal, de +10.56 % para la biomasa total y +16.23 % para el volumen total; para la cobertura arbórea, al igual que los anteriores estimadores este método fue conservador en un 6.19 %.

Cabe resaltar que con independencia del método, las estimaciones de cobertura arbórea sobrepasaron el 95 %, indicando que estos bosques son muy densos y que siendo manejados para producción de madera de aserrío, tal vez requieren un manejo más agresivo de su densidad. Los resultados son similares a lo reportado por Aguirre (2011), quién indica que para los rodales más viejos y algunos jóvenes (8 a 11 años) la cobertura sobrepasa el 80 %, concluyendo que la falta de aclareos en edades jóvenes y en rodales no intervenidos produce estos valores extremos de cobertura.

Por otro lado, los estimadores de razón y regresión estimaron más parecidamente y de manera conservadora al inventario tradicional, lo que sería una gran ventaja aún sobre los métodos de regresión lineal y no lineal para calcular las existencias totales en una forma más sencilla, ya que sólo se requiere contar con las métricas con mayor correlación y a partir de esto, obtener los parámetros de interés.

Esta situación cambia al momento de evaluar y seleccionar los modelos de regresión que cumplan en principio, con los fundamentos básicos de la regresión lineal, además de continuar en la búsqueda de modelos que predigan mejor las variables de interés. Lo anterior, tomando en cuenta que no exista falta de ajuste o que el modelo sea capaz

de calcular eficazmente en aquellas zonas donde, por ejemplo, se haya realizado una corta reciente.

El hecho de contar con una estimación total del inventario con estos valores de precisión (menores al 8 %) y en un tiempo reducido, a través de un método que concentra toda la información del área de estudio a partir de una métrica de LiDAR, - como el caso de los estimadores de razón y regresión-, es satisfactoriamente deseable para fines de planificación del manejo forestal, donde es mejor contar con estimaciones precisas y rápidas y que sean plenamente justificables a fin de contar con información oportuna y confiable para enfrentar los nuevos retos como los que conlleva el sistema de Monitoreo, Reporte y Verificación de la iniciativa REDD+.

Los resultados de este trabajo indican que los datos LiDAR se pueden utilizar para hacer estimaciones con elevada precisión de las variables forestales área basal, biomasa total, cobertura arbórea y volumen.

Se comprobó la existencia de una buena correlación ($R^2 > 0.50$) entre la distribución de alturas medida por el sensor y las variables forestales que se midieron en campo. Los resultados obtenidos por los procedimientos de ajuste de modelos de regresión lineal y no lineal reflejan que los modelos poseen una elevada precisión en las predicciones obtenidas para el área completa de estudio, no obstante, es necesario seguir explorando nuevas estructuras y aumentar la cantidad de datos para evitar estimaciones negativas o la falta de ajuste de algunos modelos.

Si se comparan entre sí los modelos obtenidos, se comprueba que la precisión con que se estiman las variables área basal, biomasa total y volumen es netamente mejor que la de cobertura arbórea, esto puede deberse al hecho de que los árboles de menor tamaño pueden pasar desapercibidos en la nube de puntos y en campo fueron medidos cada uno de los individuos presentes en la parcela, por lo tanto, estos tienen elevada influencia en la cobertura arbórea calculada mediante el inventario convencional y pudo no haber una buena correlación entre lo observado en campo y lo que captó LiDAR.

Algunos estudios han reportado mejores ajuste para los modelos de bosques heterogéneos, debido a una mayor filtración de los pulsos láser a lo largo de la estructura vertical del dosel a diferencia de los resultados en bosques homogéneos en

donde influye el tipo de hoja, la altura y densidad de árboles (Salvador *et al.*, 1997 y Zalmo *et al.*, 2010). Lo anterior, puede ser una explicación para tratar de evaluar los resultados en este estudio, debido a que como se indicó anteriormente, la densidad del arbolado sobrepasa el 95 %; se muestrearon varios sitios totalmente cerrados en donde el pulso láser no logró penetrar en las partes intermedias y más bajas del dosel. El tipo de bosque que se está analizando está bajo manejo, por lo tanto se considera homogéneo y esto repercute en la penetración del pulso láser y los retornos que dibujen la estructura vertical del dosel.

Otros estudios coinciden en la dificultad de extraer las métricas derivadas de LiDAR en aquellos doseles cerrados debido a que los retornos del pulso láser tienden a distribuirse preferentemente hacia el exterior de la copa del árbol y pocos pulsos penetran más allá de la altura en la que el dosel empieza a estar cerrado (Lovell *et al.*, 2003; Maltamo *et al.*, 2004).

5.6 Relaciones esperadas entre las variables dasométricas y las métricas de LiDAR.

Como se ha discutido anteriormente se encontró una buena correlación entre las variables dasométricas y las métricas de LiDAR, sobre todo con los percentiles de altura (aquella altura desde el suelo a la que un determinado porcentaje de los retornos están por debajo) y las métricas que están relacionadas con alguna proporción o tasa de los retornos que corresponden al dosel; sin embargo, y aunque se realizaron regresiones forzadas con aquellas métricas que por sí solas describían una característica notoria y que podría funcionar en la predicción de las variables de interés, no siempre fue así y es que para el caso de la métrica: tasa de los retornos provenientes del dosel (canopy relief ratio) se esperaba una mejor correlación con la cobertura arbórea o el área basal.

En la mayoría de los estudios para estimar alguna variable del bosque, se emplean enfoques estadísticos para relacionar la distribución de los retornos del láser con la estructura de la vegetación. Chasmer *et al.* (2006) indica que estos métodos no toman en cuenta la influencia del rayo láser y la vegetación en los retornos que regresan al sensor. Por lo tanto, se requiere una mejor comprensión de las propiedades de

reflexión y distribución física de los retornos del dosel para que las ecuaciones alométricas y relaciones físicas entre la distribución de los retornos láser con las variables dasométricas (por ejemplo biomasa) puedan ser evaluados.

Así mismo, Goetz and Dubayah (2011) subrayan que a pesar de los avances en el análisis de la vegetación con datos LiDAR, aún existen relaciones en torno a los retornos del dosel que no se entiende muy bien. En algunos casos, los errores en la estimación de las métricas no son cuantificadas porque el muestreo de la estructura del dosel se queda sólo en términos de la altura del árbol, la base de la copa viva o el índice de área foliar y no va más allá, por ejemplo a nivel de las ramas.

Por otro lado, los mecanismos exactos que explican por qué las métricas LiDAR relacionadas a la altura son tan buenos predictores de la biomasa (u otra variable de interés) a nivel de parcela sigue siendo un tema de investigación (Chen *et al.*, 2007). La altura del dosel no es necesariamente un buen indicador de la biomasa de la copa, sino un indicador más sensible de la biomasa total por rodal. Es por ello que, otras métricas relacionadas a la altura se han utilizado con éxito para mejorar las predicciones de biomasa. Estas métricas proporcionan información acerca de que tan abierto o cerrado está el dosel, la fuerza del retorno de la superficie y la distribución vertical de la vegetación (Goetz and Dubayah, 2011).

Si bien se han publicado infinidad de estudios que encontraron buenas relaciones entre las variables del bosque y las métricas de LiDAR, no existe una lista de métricas generalizadas que funcionen para cualquier tipo de bosque; los modelos resultantes se deben calibrar con datos de campo locales y por lo tanto se puede decir que se carece de modelos fiables que se puedan utilizar independientemente de la ubicación o el tipo de vegetación.

Así mismo, Muss *et al.* (2011) indica que un inconveniente de los estudios forestales basados en datos LiDAR, es la agrupación de los cuantiles de altura para crear variables predictoras que se utilizan en los modelos lineales. Estos predictores basados en cuantiles hacen que sea difícil formular hipótesis a priori con respecto a la importancia de las variables del modelo, o una explicación a posteriori para la derivación de estos modelos que se basan en la estructura física del bosque. Así

mismo, los análisis basados en la frecuencia de los datos de LIDAR de retorno discreto, suelen ignorar un elemento potencialmente importante de los datos -la intensidad del retorno- que, si se utiliza, podría mejorar la robustez de los modelos.

Por otro lado, existen diversas explicaciones para entender las diferencias entre las estimaciones, aparte de lo que ya se ha comentado; un aspecto importante y del cual hay que hacer hincapié es la georreferenciación de las parcelas con una precisión menor a 1 m., como lo indica Laes *et al.* (2011) y lo reportado por Howbaker (2010) donde la precisión en la georreferenciación fue de 0.57 m; ya que de esto dependerá que se relacionen adecuadamente y de forma más estrecha las características estructurales de campo y lo captado por el sensor.

Los resultados demuestran que es muy satisfactorio contar con una alta densidad de datos LiDAR para monitorear los atributos estructurales de un bosque bajo manejo, sin embargo, algunos autores indican que una alta densidad de puntos no precisamente es necesaria para realizar inventarios forestales a gran escala.

Con la adquisición de nuevos datos LiDAR, año tras año, se puede dar seguimiento a la evolución del bosque en términos de crecimiento y esto será posible con la información disponible a través de diversos satélites que serán lanzados en los próximos años, sin embargo, estos datos serán de menor densidad, por lo que habrá que ajustar modelos con base en esta nueva información disponible, pero la metodología para la elaboración de los nuevos modelos podrían ser los presentados en este trabajo.

Finalmente, la metodología desarrollada demuestra el potencial de emplear nuevas tecnologías, como lo es LiDAR, para la estimación del inventario total de los bosques templados bajo manejo.

6. CONCLUSIONES Y COMENTARIOS FINALES

Los resultados demuestran que la estimación de variables dasométricas como el área basal, la biomasa total, la cobertura arbórea y el volumen se pueden generar a partir de datos LiDAR con buena precisión y con la ventaja de crear mapas que exponen la variabilidad espacial para cada una de las variables.

La mayoría de las correlaciones entre las métricas obtenidas a partir de LiDAR y las variables forestales estuvieron por encima de 0.50, siendo la variable área basal la que presentó mayor correlación con la métrica relacionada al dosel: Porcentaje de primeros retornos sobre tres ($R^2=0.72$).

Los percentiles de altura y las métricas relacionadas al dosel (tasas de retorno sobre una altura de corte) fueron las que mejor describieron a las variables forestales área basal, biomasa total, cobertura arbórea y volumen, por lo que se enfatiza su uso para seguir explorando nuevos modelos y para determinar el inventario total en investigaciones futuras.

Las estimaciones totales obtenidas mediante los métodos de regresión lineal y no lineal, así como mediante los estimadores de razón y regresión se consideran buenas y aceptables, ya que los valores se encuentran dentro del intervalo de confianza estimado mediante la metodología asociada a un inventario forestal tradicional; sin embargo, es importante dejar claro que los modelos definidos mediante la regresión lineal pueden generar estimaciones negativas, lo que repercute en una disminución de las estimaciones totales. De hecho, mediante modelos no lineales es posible hacer frente a este problema.

Las estimaciones obtenidas a partir de estimadores de razón y regresión son las que más se aproximan a las estimaciones obtenidas mediante un inventario forestal tradicional, pero el inconveniente inmediato es no poder plasmar la variabilidad de la variable de interés en un mapa.

La información generada a partir de los datos LiDAR son una opción más para el monitoreo de los recursos forestales a una escala espacial pequeña y en un periodo de tiempo corto, a fin de medir y cuantificar el estado y desarrollo de los bosques, así como la cantidad de madera y biomasa existente.

A medida que estén disponibles más datos de sensores activos como LiDAR, será posible generar y mejorar las estimaciones de las variables dasométricas más comunes, e incluso hacer trabajos para obtener otras variables como índices de área foliar o incluso realizar la clasificación de especies. Lo anterior se prevé para el corto plazo ya que se estima que para el 2016 se contará con satélites como el ICESat-II, de

la NASA que permitirá llevar un registro continuo como el caso de las imágenes satelitales, todo con el fin de cartografiar y monitorear la dinámica de la estructura de los bosques. Aunque la densidad de pulsos de los datos LiDAR será mínima, esto no implicará problema, puesto que estudios previos evidencian que la baja densidad de puntos por m² son empleados con gran precisión para calcular los inventarios en áreas forestales extensas.

Los resultados obtenidos aportan información valiosa que puede ser empleada en el desarrollo de nuevos modelos, con mejorada precisión para la estimación de los parámetros forestales de interés en una escala a nivel regional, aprovechando el potencial de los datos LiDAR y conjugándolo incluso con información en 2D como las imágenes satelitales para mejorar aún más la precisión en las estimaciones.

7. BIBLIOGRAFÍA

- Aguirre, S. C. A., J. R. Valdez L., G. Ángeles P., H. M. De los Santos P. y A. I. Aguirre S. 2011. Mapeo de índice de área foliar y cobertura arbórea mediante fotografía hemisférica y datos SPOT HRG: Regresión y k-nn. *Agrociencia* 45: 105-119.
- Aguirre, S. C. A., E. J. Treviño G., O. A. Aguirre C., J. Jiménez P., M. A. González T., J. R. Valdez L., G. Sánchez D., R. Haapanen, A. I. Aguirre S., L. Miranda A. 2014. Mapping aboveground biomass by integrating geospatial and forest inventory data through a k-nearest neighbor strategy in North Central Mexico. *Journal of Arid Land* 6 (1): 80–96.
- Andersen H. E., R. J. McGaughey, and S. T. Reutebuch. 2005. Estimating forest canopy fuel parameters using LIDAR data. *Remote Sensing of Environment* 94: 441–449.
- Ángeles P. G., C. Wayson, R. Birdsey, R. Valdez L., H. De los Santos P., y O. Plascencia E. 2011. Sitio intensivo de monitoreo de flujos de CO₂ a largo plazo en bosques bajo manejo en el centro de México. En: *Memorias III Simposio Internacional del Carbono en México*. 12 al 14 de octubre. México, Resumen No. 5.4.

- Antonarakis A. S., S. S. Saatch, R. L. Chazdon y P. R. Moorcroft. 2011. Using LiDAR and Radar measurements to constrain predictions of forest ecosystem structure and function. *Ecological Applications* 21: 1120-1137.
- Baltsavias E. P. 1999. Airborne laser scanning: basic relations and formulas. *Journal of Photogrammetry and Remote Sensing* 54: 199-214.
- Baltsavias, E. P. School on LiDAR Technology. [En línea]. Abril de 2008. [ref. de 10 de junio de 2012]. Disponible en web: <http://home.iitk.ac.in/~blohani/LiDARSchool2008/Downloads/Kanpur-Baltsavias.pdf>
- Bortolot J., Z. and R. H. Wynne. 2005. Estimating forest biomass using small footprint LiDAR data: An individual tree-based approach that incorporates training data. *Journal of Photogrammetry & Remote Sensing* 59: 342-360.
- Carrillo A. F., M. Acosta M. y G. Tenorio G. 2004. Tabla de volumen para *Pinus patula* Schl. et Cham. en el Estado de Hidalgo. Folleto Técnico No. 2. INIFAP SAGARPA. 16 p.
- Cerrillo L. Formato LAS, el estándar de datos LiDAR. [En línea]. 18 de noviembre de 2010. [ref. de 24 de junio de 2012]. Disponible en web: <http://lidar.com.es/2010/11/18/formato-las-el-estandar-de-datos-lidar/>
- Chasmer, L., C. Hopkinson and P. Treitz. 2006. Investigating laser pulse penetration through a conifer canopy by integrating airborne and terrestrial lidar. *Canadian Journal of Remote Sensing* 32 (2): 116-125.
- Chen Q, P. Gong, D. Baldocchi, Q and Y. Tian. 2007. Estimating basal area and stem volume for individual trees from LiDAR. *Photogrammetric Engineering Remote Sensing* 73 (12): 1355-1365.
- CONAFOR, 2010. Inventario Nacional Forestal y de Suelos, manual y procedimientos para el muestreo de campo, remuestreo 2010. Zapopan, Jalisco, México. 140 p.
- Cruz M., Z. 2007. Sistema de ecuaciones para estimación y partición de biomasa aérea en Atopixco, Zacualtipán, Hidalgo, México. Tesis de Maestría en Ciencias.

- División de Ciencias Forestales. Universidad Autónoma Chapingo. Texcoco, México. 39 p.
- Cruz, L. I., J. R. Valdez L. G. Ángeles P. y H. M. De los Santos P. 2010. Modelación espacial de área basal y volumen de madera en bosques manejados de *Pinus patula* y *P. teocote* en el ejido Atopixco, Hidalgo. *Madera y bosques* 16 (3): 75-97.
- Dowman, I. *Fundamentals of Airborne Lidar*. [En línea]. Noviembre de 2007. [ref. de 24 de octubre de 2011] Disponible en web: <http://www.docstoc.com/docs/87344410/Slide-1---UCL>
- Drake B. J., R. O. Dubayah, D. B. Clark, R. G. Knox, J. B. Blair, M. A. Hofton, R. L. Chazdon, J. F. Weishampel, and S. D. Prince. 2002. Estimation of tropical forest structural characteristics using large-footprint lidar. *Remote Sensing of Environment* 79: 305–319.
- Dubayah R. O. and J. B. Drake. 2000. Lidar remote sensing for forestry. *Journal of Forestry* 98 (6): 44-46.
- Evans J. S., A. T. Hudak, and A. M. S. Smith. 2009. Discrete return lidar in natural resources: recommendations for project planning, data processing, and deliverables. *Remote Sensing* 1: 776-794.
- FAO. *Las funciones de los bosques en el cambio climático*. [En línea]. 15 de junio de 2012. [ref. de 24 de junio de 2012]. Disponible en web: <http://www.fao.org/forestry/climatechange/53459/es/>
- Felicísimo A. M. 1999. *Modelos Digitales del Terreno*. [En línea]. Departamento de Ingeniería de los Recursos Naturales y Medio Ambiente. Universidad de Vigo. [ref. de 24 de junio de 2012]. Disponible en web: <http://www6.uniovi.es/~feli/pdf/libromdt.pdf>
- Fernández J. C., A. Singhanian, J. Caceres, K. C. Slatton, M. Starek and R. Kumar. 2007. An overview of LiDAR point cloud processing software. *Geosensing engineering and mapping*. Civil and coastal engineering department. University of Florida. 27 p.

- Figuerola, N. C. M., G. Ángeles P., A. Velázquez M., y H. M. De los Santos P. 2011. Estimación de la biomasa en un bosque bajo manejo de *Pinus patula* Schltdl. et Cham. en Zacualtipán, Hidalgo. *Revista Mexicana de Ciencias Forestales* 1(1): 105-112.
- Flood M. 1999. Review of airborne laser technology. *EARSel Newsletter* 38: 20-23.
- Flood M. 2001. Lidar activities and research priorities in the commercial sector. *International Archives of Photogrammetry and Remote Sensing* 34 (3): 3-6.
- García J. C. 2009. Servicio de Sistemas de Información Geográfica y Teledetección Universidad de Girona. [En línea]. 12 de marzo de 2009. [ref. de 18 de octubre de 2011]. Disponible en web: <http://dugi-doc.udg.edu/bitstream/10256/1413/1/C17.pdf>
- Goetz, S. and R. Dubayah. 2011. Advances in remote sensing technology and implications for measuring and monitoring forest carbon stocks and change. *Carbon Management*. 2 (3): 231-244.
- Gibson P. J. 2000. *Introductory remote sensing, principles and concepts*. Routledge. London. pp: 12-65.
- Hall S. A., I. C. Burke, D. O. Box, M. R. Kaufmann, and J. M. Stoker. 2005. Estimating stand structure using discrete-return lidar: an example from low density, fire prone ponderosa pine forests. *Forest Ecology and Management* 208: 189-209.
- Hawbaker T. J., T. Gobakken, A. Lesak, E. Tromborg, K. Contrucci and V. Radeloff. 2010. Light Detection and Ranging-based measures of mixed hardwood forest structure. *Forest Science* 56 (3): 313-326.
- Holmgren, J. 2004. Prediction of tree height, basal area and stem volume in forest stands using airborne laser scanning. *Scandinavian Journal of Forest Research* 19 (6): 543-553.
- Hudak A. T., N. L. Crookston, J. S. Evans, M. J. Falkowsky, A. M. S. Smith, P. E. Gessler, and P. Morgan. 2006. Regression modeling and mapping of coniferous forest basal area and tree density from discrete-return lidar and multispectral satellite data. *Canadian Journal of Remote Sensing* 32 (2): 126-138.

- Hudak A. T., J. S. Evans, and A. M. S. Smith. 2009. LiDAR Utility for natural resource managers. *Journal Remote Sensing* 1:934-951.
- Ibañez, E. 2008. Validación de modelos digitales del terreno de precisión a partir de datos láser escáner aerotransportado; aplicación a la marisma del parque nacional de Doñana. Tesina. Departamento de Ingeniería del Terreno, Cartografía y Geofísica. Universidad Politécnica de Catalunya. Barcelona, España. 70 p.
- INEGI. 2011. Gestión de datos LiDAR a través de SIG y base de datos geospacial. [En línea]. 2011 [ref. de 24 de junio de 2012]. Disponible en web: http://www.inegi.org.mx/eventos/2011/conf_ibero/doc/ET1_25_ARELLANO.pdf
- INEGI 2013. Imágenes de satélite, elementos de percepción remota. . [En línea]. 2013 [ref. de 10 de noviembre de 2013]. Disponible en web: <http://www.inegi.org.mx/geo/contenidos/imgpercepcion/imgsatelite/elementos.aspx>
- Instituto para el Federalismo y el Desarrollo Municipal (INAFED). 2010. Secretaría de Gobernación. Enciclopedia de los municipios de México, EMM. Estado de Hidalgo: Zacualtipán de los Ángeles.
- Kim S., R. J. McGaughey, and H. E. Andersen. 2008. Individual tree species identification using lidar intensity data. In: ASPRS 2008 Annual Conference Portland, Oregon April 28 - May 2, 2008.
- Laes D., S. T. Reutebunch, R. McGaughey, B. Mitchell. 2011. Guidelines to estimate forest inventory parameters from LiDAR and field plot data. Forest Service. Pacific Northwest Research Station. United States Department of Agriculture. 21 p.
- Lefsky M. A., W. B. Cohen, D. J. Harding, G. G. Parker, S. A. Acker, and S. T. Gower. 2001. Lidar remote sensing of aboveground biomass in three biomes. *International Archives of Photogrammetry and Remote Sensing* 34: 155-160.

- Lefsky M. A., W. B. Cohen, and T. A. Spies. 2001a. An evaluation of alternate remote sensing products for forest inventory, monitoring, and mapping of Douglas-fir forests in western Oregon. *Canadian Journal of Forest Research* 31: 78-87.
- Lefsky M. A., W. B. Cohen, G. G. Parker, and D. J. Harding. 2002. Lidar remote sensing for ecosystem studies. *BioScience* 52 (1): 19-30.
- Lemmens M. 2011. Geo-information: technologies, applications and the environment. Vol. 5 of geotechnologies and the environment series. Springer. London. 315 p.
- Lichti D., N. Pfeifer, and H. Maas. 2008. Terrestrial Laser Scanning. *ISPRS Journal of Photogrammetry and Remote Sensing* 63 (1): 1-3.
- Lim K., and P. Treitz. 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 (6): 558-570.
- Lohani, B. 2008. Airborne Altimetric LiDAR: principle, data collection, processing and applications. [En línea]. 18 de agosto de 2010. [ref. de 24 de junio de 2012]. Disponible en web: http://home.iitk.ac.in/~blohani/LiDAR_Tutorial/Airborne_AltimetricLidar_Tutorial.htm
- Lovell, J. L., D. Jupp, D. Culvenor and N. Coops. 2003. Using airborne and ground-based ranging LiDAR to measure canopy structure in Australian forests. *Canadian Journal of Remote Sensing*. 29 (5): 607-622.
- Mallet C. and F. Bretar. 2009. Full-waveform topographic lidar: State-of-the-art. *Journal of Photogrammetry and Remote Sensing* 64: 1-16.
- Maltamo, M., K. Mustonen, J. Hyypä, J. Pitkanen and X. Yu, 2004. The accuracy of estimating individual tree variables with airborne laser scanning in a boreal nature reserve. *Canadian Journal of Forest Research*. 34 (9): 1791-1801.
- Maltamo M., K. Eerikäinen, P. Packalén and J. Hyypä. 2006. Estimation of stem volume using laser scanning-based canopy height metrics. *Forestry* 79 (2): 217-229.

- M. M., M. A. 2004. Nuevos registros de aves en el bosque mesófilo de montaña del noreste de Hidalgo, México. *Huitzil* 5(2):12-19.
- McGaughey, R. J. 2012. FUSION/LDV: Software for LIDAR data analysis and visualization. Forest Service. Pacific Northwest Research Station. United States Department of Agriculture. 171 p.
- Means, J. E., S. A. Acker, D. J. Harding, J. B. Blair, M. A. Lefsky, W. B. Cohen, M. E. Harmon, and W. A. McKee. 1999. Use of large-footprint scanning airborne LiDAR to estimate forest stand characteristics in the western Cascades of Oregon, *Remote Sensing of Environment* 67: 298-308.
- Means J. E., S. A. Acker, B. J. Fitt, M. Renslow, L. Emerson and C. J. Hendrix. 2000. Predicting forest stand characteristics with airborne scanning LiDAR. *Photogrammetric Engineering and Remote Sensing* 66 (11): 1367-1371.
- Mora B., M. A. Wulder, J. C. White and G. Hobart. 2013. Modeling stand height, volume, and biomass from very high spatial resolution satellite imagery and samples of airborne LiDAR. *Remote Sensing* 5: 2308-2326.
- Muñoz R., M. A. 2012. Estimación de variables dasométricas del bosque templado de Hidalgo, México mediante datos espectrales y del inventario nacional forestal. Tesis de Maestría en Ciencias. Colegio de Postgraduados. Postgrado Forestal. México. 75 p.
- Næsset, E. 1997. Determination of mean tree height of forest stands using airborne laser scanner data. *Journal of Photogrammetry & Remote Sensing* 52: 49-56.
- 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. Practical large-scale forest stand inventory using a small-footprint airborne scanning laser. *Scandinavian Journal of Forest Research* 19 (2): 164-179.
- Navarro C. R. M., M. Sánchez, J. Gómez, A. García, R. Hernández, S. Lanjeri. 2010. Aplicación de imágenes LIDAR para la estimación del índice de superficie foliar

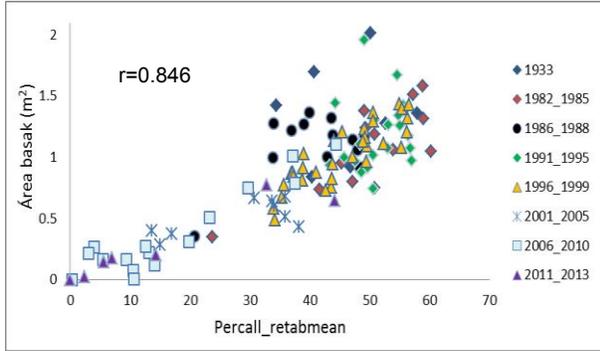
- (LAI) en encinas [*Quercus ilex* L. subsp. *ballota* (Desf.) Samp.]. *Forest Systems* 19 (1) 61-69.
- National Oceanic and Atmospheric Administration (NOAA) Coastal Services Center. 2008. *Lidar 101: An introduction LiDAR technology, data, and applications*. Charleston, SC: NOAA Coastal Services Center. 68 p.
- Persson A., J. Holmgren, U. Söerman. 2002. Detecting and measuring individual trees using an airborne laser scanner. *Photogrammetric Engineering & Remote Sensing* 68 (9): 925–32.
- Peterson B., R. Dubayah, P. Hyde, M. Hofton, J. Blair, and J. Fites-Kaufman. 2005. Use of LIDAR for forest inventory and forest management application In: *Proceedings of the seventh annual forest inventory and analysis symposium*. Portland, Maine, USA. 03-06 October 2005. 193-202.
- Popescu C. S., R. H. Wynne, and R. F. Nelson. 2003. Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass. *Canadian Journal Remote Sensing* 29: 564-577.
- Popescu S. C. 2007. Estimating biomass of individual pine trees using airborne LiDAR. *Biomass and Bioenergy* 31: 646-655.
- Raber, B. R., and J. Cannistra. 2005. *LiDAR guidebook: concepts project design and practical applications*. The urban and regional information systems association (URISA). Illinois. 64 p.
- Real, S., E. 2011. *El modelado geomático del LiDAR: de la fusión SVM a la noción de prosdetección*. Tesis de Maestro en Geomática. Centro de Investigación en Geografía y Geomática Ing. Jorge L. Tamayo A.C. CentroGeo. Centro Público de Investigación CONACYT. México, D.F. 74 p.
- Salvador, R., X. Pons, y X. Baulies. 1997. Análisis de imágenes multiespectrales aerotransportadas para estimar variables estructurales de bosques mediterráneos de *Quercus ilex* L. *Orsis*: 12: 127-139.
- SAS, Institute Inc. 2002. *SAS/IML Users guide, Version 9.0*. Cary, N.C. SAS Institute Inc. 1031 p.

- Scheaffer, L. R., W. Mendenhall and L. Ott. 1986. Elementary survey sampling. PWS Publishers. U.S.A. 320 p.
- Shiver B. D. and B. E. Borders. 1996. Sampling techniques for forest resource inventory. New York: John Wiley and Sons, pp. 126-128.
- Schuckman K., and M. Renslow. Lidar technology and applications. [En línea]. College of Earth and Mineral Sciences. The Pennsylvania State University. Julio de 2008 [ref. de 31 de mayo de 2012]. Disponible en web: <https://www.e-education.psu.edu/lidar/l1.html>
- Swatantran A., R. Dubayah, D. Roberts, M. Hofton, and J. B. Blair. 2011. Mapping biomass and stress in the Sierra Nevada using LiDAR and hyperspectral data fusion. *Remote Sensing of Environment* 115: 2917–2930.
- Valdez, L. J. R. y C. A. Aguirre S. 2013. Active microwave remote sensing for forest resources management: current use in the world and potential use in Mexico. En: *Aplicaciones de geomática en la región central de México*. Coords. M. J. Escalona Maurice et al. Colegio de Postgraduados. pp. 155-178.
- Van Aardt, J., R. Wynne, and J. Scrivani. 2008. Lidar-based mapping of forest volume and biomass by taxonomic group using structurally homogenous segments. *Photogrammetric Engineering & Remote Sensing* 74: 1033–1044.
- Wehr, A. and Lohr, U. 1999: Airborne laser scanning – an introduction and overview. *ISPRS Journal of Photogrammetry and Remote Sensing* 54: 68–82.
- Wulder, M. 1998. Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters. *Progress in Physical Geography*. 22: 449-476.
- Zaldo, V. G. Moré y X. Pons. 2010. Estimación y cartografía de parámetros ecológicos y forestales en tres especies (*Quercus ilex* L. subsp *ilex*, *Fagus sylvatica* L. y *Pinus halepensis* L.) con datos LiDAR. *Revista de Teledetección*. 34: 55-68.

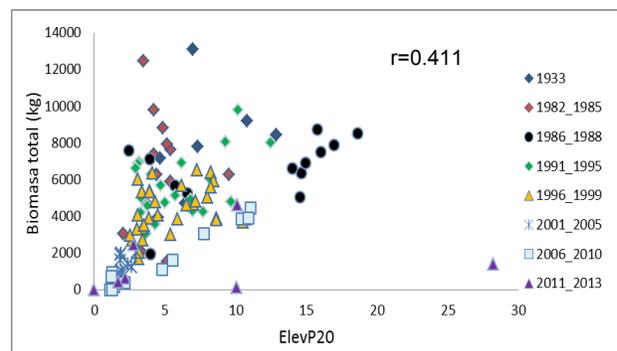
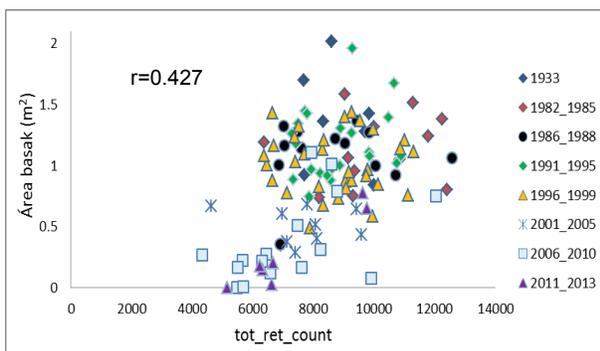
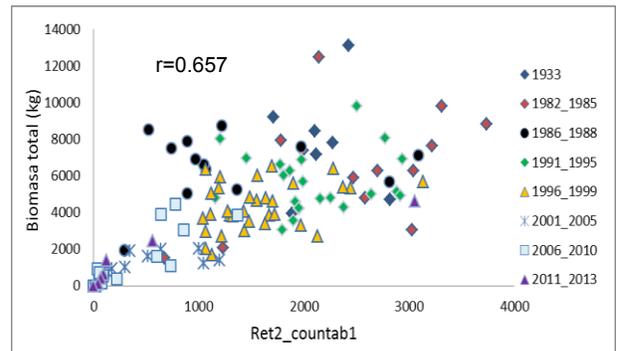
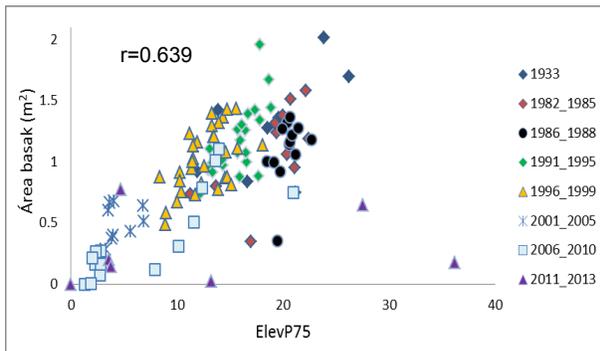
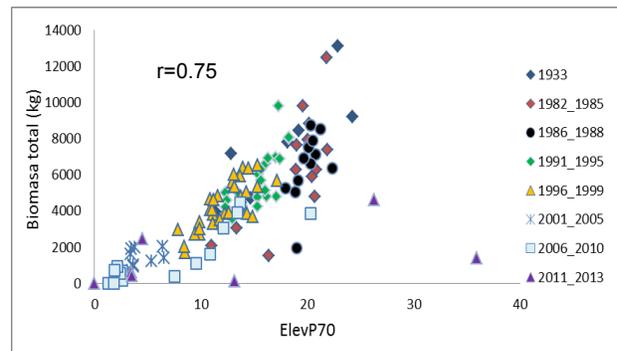
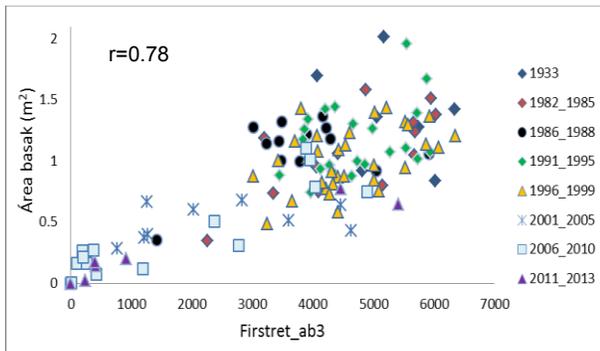
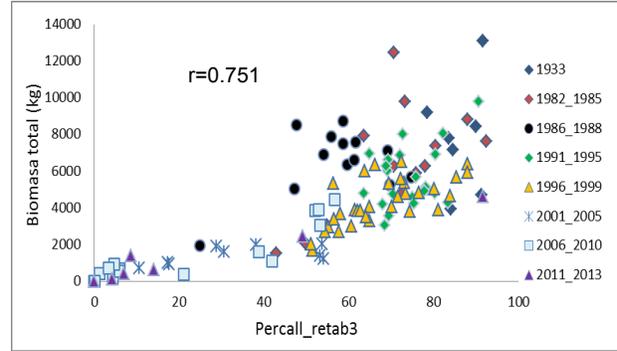
8. ANEXOS

Correlaciones entre las métricas de LiDAR vs

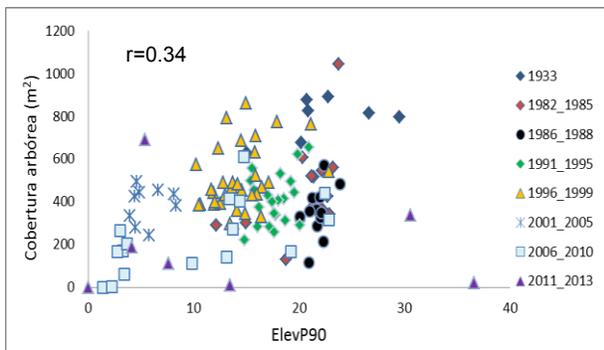
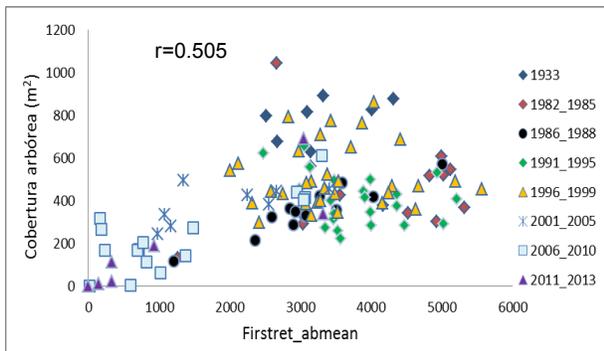
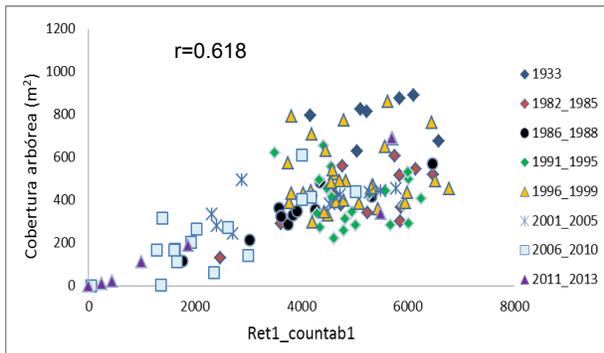
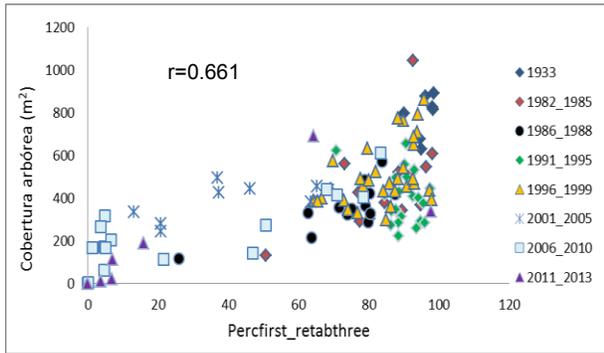
Área basal



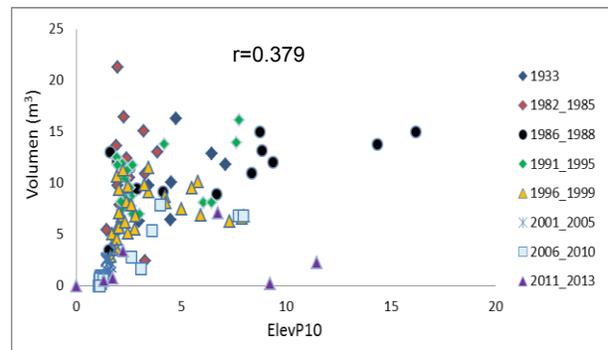
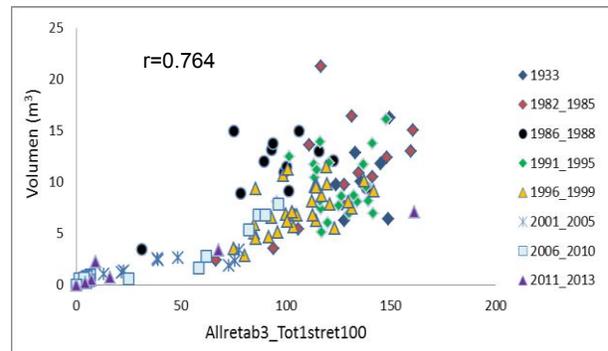
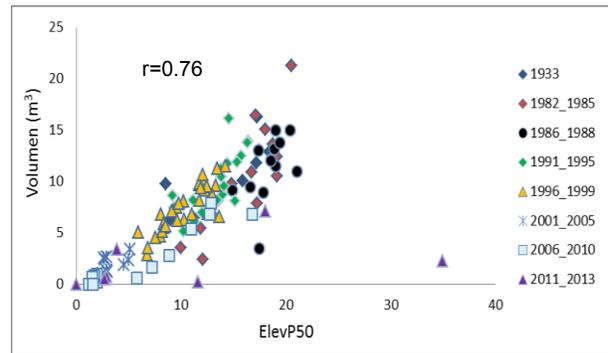
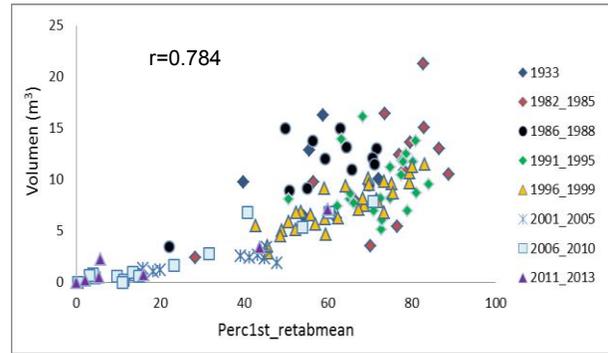
Biomasa aérea



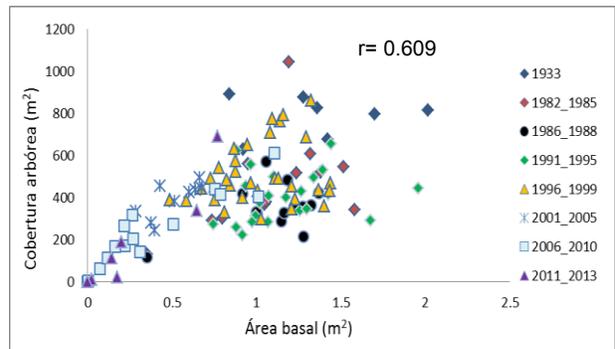
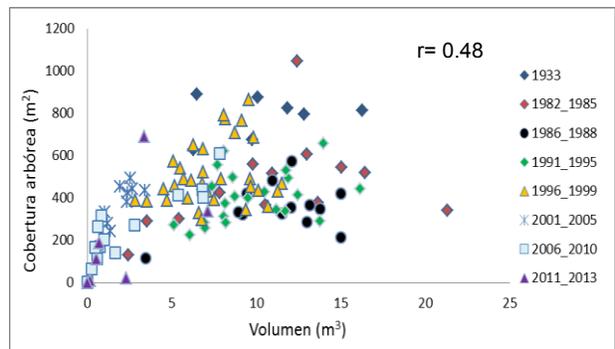
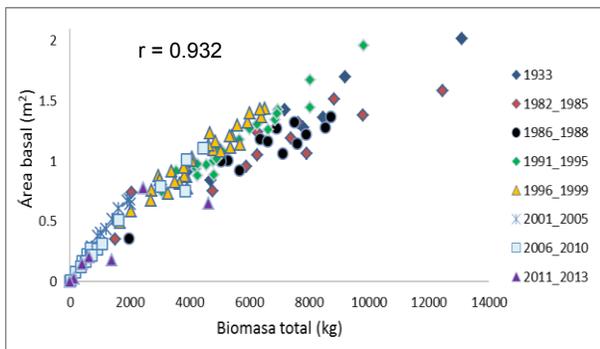
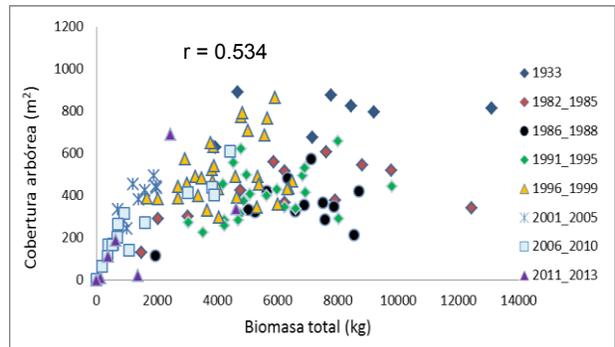
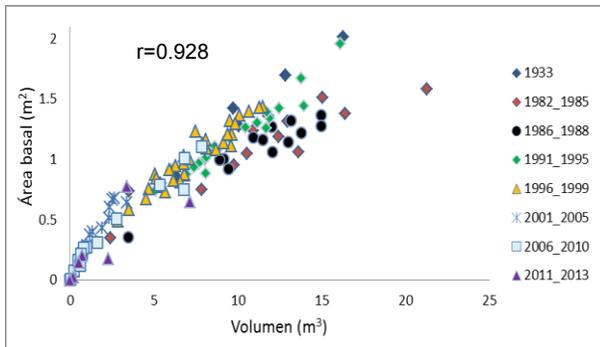
Cobertura arbórea



Volumen



Gráficas de correlaciones entre pares de variables biofísicas.



Métricas derivadas del software FUSION

Nombre completo	Nombre corto	Descripción
Total return count	tot_ret_count	Conteo total de retornos LiDAR para una parcela
Total return count above 2.00	Totret_countab2	Conteo total de retornos LiDAR por encima de 2 m
Return 1 count above 2.00	Ret1_countab2	Conteo de los primeros retornos por encima de 2 m
Return 2 count above 2.00	Ret2_countab2	Conteo de los segundos retornos por encima de 2 m
Return 3 count above 2.00	Ret3_countab2	Conteo de los terceros retornos por encima de 2 m
Return 4 count above 2.00	Ret4_countab2	Conteo de los cuartos retornos por encima de 2 m
Return 5 count above 2.00	Ret5_countab2	Conteo de los quintos retornos por encima de 2 m
Return 6 count above 2.00	Ret6_countab2	Conteo de los sextos retornos por encima de 2 m
Return 7 count above 2.00	Ret7_countab2	Conteo de los séptimos retornos por encima de 2 m
Return 8 count above 2.00	Ret8_countab2	Conteo de los octavos retornos por encima de 2 m
Return 9 count above 2.00	Ret9_countab2	Conteo de los novenos retornos por encima de 2 m
Other return count above 2.00	Otherret_countab2	Conteo de otros retornos por encima de 2 m
Elev minimum	Elev_min	Altura mínima de todos los retornos para una parcela.
Elev maximum	Elev_max	Altura máxima de todos los retornos para una parcela.
Elev mean	Elev_mean	Altura media sobre el terreno de todos los retornos para una parcela.
Elev mode	Elev_mode	Altura moda sobre el terreno de todos los retornos para una parcela.

Elev stddev	Elev_stddev	Desviación estándar de las alturas sobre el terreno de todos los retornos para una parcela.
Elev variance	Elev_variance	Varianza de las alturas sobre el terreno de todos los retornos para una parcela.
Elev CV	Elev_CV	Coficiente de variación de las alturas sobre el terreno de todos los retornos para una parcela.
Elev IQ	Elev_IQ	Distancia intercuantil de las alturas sobre el terreno de todos los retornos para una parcela.
Elev skewness	Elev_skewness	Asimetría de las alturas sobre el terreno de todos los retornos para una parcela.
Elev kurtosis	Elev_kurtosis	Curtosis de las alturas sobre el terreno de todos los retornos para una parcela.
Elev AAD	Elev_AAD	Desviación absoluta media de las alturas sobre el terreno de todos los retornos para una parcela.
Elev MAD median	Elev_MAD_median	Desviación absoluta mediana de las alturas sobre el terreno de todos los retornos para una parcela.
Elev MAD mode	Elev_MAD_mode	Desviación absoluta moda de las alturas sobre el terreno de todos los retornos para una parcela.
Elev L1	ElevL1	Primer momento de las alturas sobre el terreno de todos los retornos para una parcela
Elev L2	ElevL2	Segundo momento de las alturas sobre el terreno de todos los retornos para una parcela
Elev L3	ElevL3	Tercer momento de las alturas sobre el terreno de todos los retornos para una parcela
Elev L4	ElevL4	Cuarto momento de las alturas sobre el terreno de todos los

		retornos para una parcela
Elev L CV	ElevLCV	Momento coeficiente de variación de las alturas sobre el terreno de todos los retornos para una parcela
Elev L skewness	ElevL_skewness	Momento simetría de las alturas sobre el terreno de todos los retornos para una parcela
Elev L kurtosis	ElevL_kurtosis	Momento curtosis de las alturas sobre el terreno de todos los retornos para una parcela
Elev P01	ElevP01	Altura desde el suelo a la que un determinado porcentaje de los retornos están por debajo (01-99)
Elev P05	ElevP05	
Elev P10	ElevP10	
Elev P20	ElevP20	
Elev P25	ElevP25	
Elev P30	ElevP30	
Elev P40	ElevP40	
Elev P50	ElevP50	
Elev P60	ElevP60	
Elev P70	ElevP70	
Elev P75	ElevP75	
Elev P80	ElevP80	
Elev P90	ElevP90	
Elev P95	ElevP95	
Elev P99	ElevP99	
Canopy relief ratio	Canopy_relief_ratio	Tasa de los retornos provenientes del dosel
Elev SQRT mean SQ	Elev_SQRT_mean_SQ	Media cuadrática de las alturas sobre el terreno de todos los retornos para una parcela
Elev CURT mean CUBE	Elev_CURT_mean	Media cúbica de las alturas sobre el terreno de todos los

	_CUBE	retornos para una parcela
Int minimum	Int_min	Intensidad mínima de todos los retornos para una parcela.
Int maximum	Int_max	Intensidad máxima de todos los retornos para una parcela.
Int mean	Int_mean	Intensidad media de todos los retornos para una parcela.
Int mode	Int_mode	Intensidad moda de todos los retornos para una parcela.
Int stddev	Int_stddev	Desviación estándar de la intensidad de todos los retornos para una parcela.
Int variance	Int_variance	Varianza de la intensidad de todos los retornos para una parcela.
Int CV	Int_CV	Coficiente de variación de la intensidad de todos los retornos para una parcela.
Int IQ	Int_IQ	Distancia intercuantil de la intensidad de todos los retornos para una parcela.
Int skewness	Int_skewness	Asimetría de la intensidad de todos los retornos para una parcela.
Int kurtosis	Int_kurtosis	Curtosis de la intensidad de todos los retornos para una parcela.
Int AAD	Int_AAD	Desviación absoluta media de la intensidad de todos los retornos para una parcela.
Int L1	Int_L1	Primer momento de la intensidad de todos los retornos para una parcela
Int L2	Int_L2	Segundo momento de la intensidad de todos los retornos para una parcela
Int L3	Int_L3	Tercer momento de la intensidad de todos los retornos para una parcela

Int L4	Int_L4	Cuarto momento de la intensidad de todos los retornos para una parcela
Int L CV	IntL_CV	Momento coeficiente de variación de la intensidad de todos los retornos para una parcela
Int L skewness	IntL_skewness	Momento simetría de la intensidad de todos los retornos para una parcela
Int L kurtosis	IntL_kurtosis	Momento curtosis de la intensidad de todos los retornos para una parcela
Percentage first returns above 3.00	Percfirst_retabthre e	Porcentaje de todos los primeros retornos por encima de 3 m
Percentage all returns above 3.00	Percall_retab3	Porcentaje de todos los retornos por encima de 3 m
(All returns above 3.00) / (Total first returns) * 100	Allretab3_Tot1stret 100	(Todos los retornos por encima de 3 m) / (Total de todos los primeros retornos) *100
First returns above 3.00	Firstret_ab3	Todos los primeros retornos por encima de 3 m.
All returns above 3.00	Allret_above3	Todos los retornos por encima de 3 m.
Percentage first returns above mean	Perc1st_retabmea n	Porcentaje de todos los primeros retornos por encima de la altura media de los retornos
Percentage first returns above mode	Perc1st_retabmod e	Porcentaje de todos los primeros retornos por encima de la altura moda de los retornos
Percentage all returns above mean	Percall_retabmean	Porcentaje de todos los retornos por encima de la altura media de los retornos
Percentage all returns above mode	Percall_retabmode	Porcentaje de todos los retornos por encima de la altura moda de los retornos
(All returns above mean) / (Total first returns) * 100	Allretabmean_Tot1 stret100	(Todos los retornos por encima de la altura media de los retornos) / (Total de todos los primeros retornos) *100

(All returns above mode) / (Total first returns) * 100	Allretabmode_Tot1stret100	(Todos los retornos por encima de la altura moda de los retornos) / (Total de todos los primeros retornos) *100
First returns above mean	Firstret_abmean	Todos los primeros retornos por encima de la altura media de los retornos
First returns above mode	Firstret_abmode	Todos los primeros retornos por encima de la altura moda de los retornos
All returns above mean	Allret_abmean	Todos los retornos por encima de la altura media de los retornos
All returns above mode	Allret_abmode	Todos los retornos por encima de la altura moda de los retornos
Total first returns	Total1st_returns	El total de los primeros retornos
Total all returns	Totalall_returns	El total de todos los retornos

El componente de intensidad indica la fuerza del retorno LiDAR. Este valor de intensidad es influenciado por la reflectancia del material golpeado por el pulso láser, por el ángulo de escaneo. La intensidad del retorno LiDAR está directamente relacionada con la reflectancia en el infrarrojo cercano del material objetivo.