



COLEGIO DE POSTGRADUADOS

**INSTITUCIÓN DE ENSEÑANZA E INVESTIGACIÓN EN CIENCIAS
AGRÍCOLAS**

CAMPUS MONTECILLO

POSTGRADO EN CIENCIAS FORESTALES

ESTIMACIÓN DE VARIABLES DEL BOSQUE MEDIANTE SENSORES REMOTOS EN EL ESTADO DE HIDALGO

JUAN ESTEBAN TORRES VIVAR

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

MAESTRO EN CIENCIAS

MONTECILLO, TEXCOCO, EDO. DE MÉXICO


2016

La presente tesis titulada: **ESTIMACIÓN DE VARIABLES DEL BOSQUE MEDIANTE SENSORES REMOTOS EN EL ESTADO DE HIDALGO** realizada por el alumno: **Juan Esteban Torres Vivar** bajo la dirección del Consejo Particular indicado, ha sido aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

MAESTRO EN CIENCIAS FORESTALES

POSTGRADO EN CIENCIAS FORESTALES

CONSEJO PARTICULAR



CONSEJERO

Dr. José René Valdez Lazalde

ASESOR



Dr. Gregorio Ángeles Pérez

ASESOR



Dr. Carlos Arturo Aguirre Salado

Montecillo, Texcoco, Estado de México, diciembre de 2016

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

ESTIMACIÓN DE VARIABLES DEL BOSQUE MEDIANTE SENSORES REMOTOS EN EL ESTADO DE HIDALGO

Juan Esteban Torres Vivar, M. C.
Colegio de Postgraduados: Postgrado en Ciencias Forestales, 2016

RESUMEN

Se analizaron las relaciones existentes entre datos espectrales derivados del sensor SPOT 6, de métricas LiDAR, y de la combinación de datos de estos dos sensores con datos dasométricos medidos en campo para estimar el inventario de las variables dasométricas: área basal (Ab), biomasa total (Bt), cobertura de copa (Cob), volumen (Vol) e índice de área foliar (IAF), mediante tres métodos: (1) modelos de regresión lineal múltiple, (2) muestreo con estimadores de razón y regresión e (3) inventario tradicional en un bosque de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo, México. La hipótesis nula fue que los datos derivados del sensor LiDAR son mejores que los derivados de SPOT 6 y que la combinación de los dos sensores es ventajosa para la estimación del inventario de las variables dasométricas. Las estimaciones de campo provienen de mediciones realizadas en 157 sitios de 400 m² distribuidos sistemáticamente bajo un diseño por conglomerados en una superficie de 900 hectáreas. En términos generales las métricas LiDAR presentaron mayor correlación con las variables de campo que las variables espectrales derivadas del sensor SPOT 6. Los modelos construidos solo con métricas LiDAR presentaron coeficientes de determinación (R^2) que oscilan de 0.55 a 0.92. Contrariamente, los modelos construidos solo con variables espectrales del sensor SPOT 6 arrojaron valores de R^2 de 0.27 a 0.66. Los modelos de regresión ajustados utilizando como variables predictivas a una combinación de métricas LiDAR y variables espectrales resultando en una ganancia mínima en su capacidad predictiva valores de R^2 de 0.56 y 0.94. Dentro de los inventarios realizados con métricas LiDAR el estimador de regresión resultó ser la mejor estrategia, con precisiones que oscilan entre 3.16 a 5.65 %. La mejor precisión lograda con variables espectrales se obtuvo también con el estimador de regresión, presentando una precisión de 4.80 a 6.90 %.

Palabras clave: SPOT 6, LiDAR, inventario, mapeo.

ESTIMATION OF VARIABLES OF THE FOREST BY REMOTE SENSORS IN THE STATE OF HIDALGO

Juan Esteban Torres Vivar, M. C.
Colegio de Postgraduados: Postgrado en Ciencias Forestales, 2016

ABSTRACT

The objective of this research was to know the relation between data obtained of SPOT 6 sensor, LIDAR metrics, data combined from these two sensors and data of the field inventory. With this information the inventory of forest variables was estimated: basal area (A_b), total biomass (B_t), canopy cover (C_{ob}), volume (V_{ol}) and leaf area index (LAI), using three methods: (1) multiple linear regression models, (2) sampling with ratio and regression estimators and (3) traditional inventory in a forest of *Pinus patula* under management in Zacualtipan, Hidalgo, Mexico. The null hypothesis was that data derived from LiDAR sensor are better than derivatives of SPOT 6 and the combination of the two sensors are good for the inventory of dasometric variables. A total of 157 sites with a size of 400 m² per site, distributed through a systematic sampling under a cluster design on an area of 900 hectares were used. Overall the LiDAR metrics have a higher correlation with the field variables than spectral variables derived from SPOT 6 sensor. The models constructed only with LiDAR metrics showed determination coefficients (R^2) ranging from 0.55 to 0.92. Conversely, the models constructed only with spectral variables of SPOT 6 sensor returned values of R^2 from 0.27 to 0.66. Adjusted regression models using as variables predictors a combination of metrics LiDAR and spectral variables result in a minimal gain in its predictive capacity; R^2 values ranging from 0.56 and 0.94. Among the inventories carried out with LiDAR metrics, regression estimator proved to be the best strategy, with accuracies ranging from 3.16 to 5.65%. The best accuracy in spectral variables was also achieved with the regression estimator with an accuracy of 4.80 to 6.90%.

Keywords: SPOT 6, LiDAR, combination, inventory.

DEDICATORIAS

A mi padre Juan Torres Hernández, por los consejos que me ha brindado, los cuales me han servido para ser una mejor persona y poder lograr mis metas propuestas en la vida.

A mi abuelita Agrícola Hernández Osorio por ser una inspiración de mujer a lo largo de toda mi vida, por ser la figura femenina que más he admiro y respeto en la vida.

A mis hermanos Diego Cesar, Gustavo Armando y José Javier por brindarme su apoyo en todo el transcurso de mi formación profesional.

“Puedo aceptar el fracaso pero no puedo aceptar no intentarlo”

Autor: Michael Jordan (1963-a la fecha) Jugador de la NBA Estadounidense.

AGRADECIMIENTOS

Al Dr. José René Valdez Lazalde por la paciencia, apoyo, sugerencias, comentarios y conocimiento compartido para la finalización del presente trabajo de investigación.

A los Drs. Gregorio Ángeles Pérez, Héctor Manuel de los Santos Posada y Carlos Arturo Aguirre Salado por formar parte del Consejo Particular y por compartir sus conocimientos a lo largo la maestría. Por brindarme tiempo valioso en la revisión del presente proyecto de investigación.

Al Colegio de Postgraduados y a cada una de las personas que conforman el Postgrado en Ciencias forestales, por su conocimiento compartido.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT), por brindarme el apoyo económico para lograr terminar los estudios de maestría.

Al Servicio Forestal del Departamento de Agricultura de EE. UU. por el financiamiento a través del Northern Research Station y el Programa de Paisajes Sustentables de la Agencia para el Desarrollo Internacional de EE. UU.

A la Dra. Antonia Macedo Cruz, gestora de las imágenes satelitales del sensor SPOT 6 ante la Estación de Recepción México Nueva Generación y ASTRIUM.

A todos mis amigos con los cuales compartí excelente momentos durante la maestría: Adrián Hernández, Leonardo Beltrán, Luis Martínez, Jonathan Hernández, Rodrigo Huerta, Vicente Vázquez, Fráncico Montoya y Ramiro Puc Kaulil.

“Si no conozco una cosa, la investigaré”

Autor: Louis Pasteur (1822-1895) Químico y microbiólogo francés.

CONTENIDO

LISTA DE CUADROS.....	xi
LISTA DE FIGURAS.....	xiii
CAPÍTULO I	1
1.- INTRODUCCIÓN GENERAL.....	1
1.1 GENERALIDADES DE LA PERCEPCIÓN REMOTA	1
1.2 ESPECTRO ELECTROMAGNÉTICO.....	2
1.3 SENSORES REMOTOS.....	3
1.4 EL SENSOR LIDAR	4
1.4.1 Componentes de LiDAR.....	4
1.5 EL SENSOR SPOT 6.....	5
1.6 PROCESAMIENTO DE IMÁGENES SATELITALES	7
1.6.1 Pre-procesamiento de imágenes.....	7
1.6.2 Análisis de los datos de campo vs. datos espectrales.....	8
1.6.3 Estimación de las variables dasométricas de interés mediante un método estadístico	8
1.6.4 Estimación de error y “validación” de los resultados	9
1.7 LITERATURA CITADA.....	9
1.8 OBJETIVOS.....	12
1.8.1 General.....	12
1.8.2 Específicos	12
CAPÍTULO II.....	13
2. INVENTARIO Y MAPEO DE UN BOSQUE DE <i>Pinus patula</i> BAJO MANEJO FORESTAL MEDIANTE EL SENSOR SPOT 6	13
2.1 RESUMEN.....	13
2.3 INTRODUCCIÓN	15
2.4 MATERIALES Y MÉTODOS	15

2.4.1	Área de estudio	15
2.4.2	Muestreo en campo	17
2.4.3	Estimación de las variables del bosque.....	17
2.4.4	Pre-procesamiento de la imagen SPOT 6	19
2.4.4.1	Obtención de variables espectrales.....	20
2.4.5	Análisis estadístico.....	20
2.4.5.1	Análisis de correlación	20
2.4.5.2	Modelos de regresión.....	20
2.4.6	Cálculo del inventario tradicional.....	21
2.4.7	Estimadores de razón y regresión	21
2.4.8	Generación de cartografía	22
2.5	RESULTADOS Y DISCUSIÓN.....	22
2.5.1	Relación entre variables de campo y variables espectrales	22
2.5.2	Estimaciones de variables mediante modelos de regresión	23
2.5.3	Estimación del inventario tradicional	27
2.5.4	Estimación del inventario total mediante los estimadores de razón y regresión	29
2.5.5	Análisis comparativo de metodos de la estimación del inventario	29
2.5.6	Distribución espacial de las variables en el área de estudio	29
2.6	CONCLUSIONES	34
2.7	LITERATURA CITADA.....	35
CAPÍTULO III.....		38
3. DATOS LiDAR Y SPOT 6 PARA INVENTARIO DE BOSQUES TEMPLADOS BAJO MANEJO.....		38
3.1	RESUMEN.....	38
3.3	INTRODUCCIÓN	40
3.4	MATERIALES Y MÉTODOS	41

3.4.1 Área de estudio	41
3.4.2 Muestreo en campo	42
3.4.3 Estimación de las variables dasométricas a nivel bosque	43
3.4.4 Captura y pre-procesamiento de los datos LiDAR	45
3.4.5 Análisis de datos LiDAR	45
3.4.6 Pre-procesamiento de la imagen SPOT 6	46
3.4.7 Obtención de variables espectrales	47
3.4.8 Análisis estadístico: correlación, ajuste de modelos de regresión	47
3.4.9 Estimación del inventario total de manera tradicional.....	48
3.4.10 Estimación del inventario total mediante los estimadores de razón y regresión	48
3.5 RESULTADOS Y DISCUSIÓN.....	49
3.5.1 Correlación de las variables de campo vs métricas LiDAR y variables espectrales .	49
3.5.2 Estimación de variables mediante modelos de regresión	53
3.5.3 Estimación del inventario total mediante los estimadores de razón y regresión auxiliados con métricas LiDAR y variables espectrales.....	61
3.5.4 Análisis comparativo de métodos de la estimación del inventario total	63
3.6 CONCLUSIONES	65
3.7 LITERATURA CITADA.....	66
CAPÍTULO IV.....	69
4. CONCLUSIONES GENERALES	69

LISTA DE CUADROS

Capítulo I.

Cuadro 1.1. Características de las imágenes satelitales del sensor SPOT 6. 6

Capítulo II.

Cuadro 2.1. Modelos para estimar Biomasa total (Bt), Volumen (Vol) de *Pinus patula* y latifoliadas en Zacualtipán de Ángeles, Hidalgo. 18

Cuadro 2.2. Modelos utilizados para la estimación del Índice de área foliar de *Pinus patula* en Zacualtipán de Ángeles, Hidalgo. 19

Cuadro 2.3. Matriz de correlación de las variables de campo vs. variables espectrales. 22

Cuadro 2.4. Modelos de regresión lineal múltiple para las variables de campo (VC), en Zacualtipán de Ángeles, Hidalgo. 24

Cuadro 2.5. Estimación del inventario total para el bosque de *Pinus patula* bajo manejo en Zacualtipán de Ángeles, Hidalgo, mediante diferentes estrategias de análisis. 27

Capítulo III.

Cuadro 3.1. Modelos para estimar Biomasa total (Bt) y Volumen (Vol) de *Pinus patula* y latifoliadas en Zacualtipán de Ángeles, Hidalgo. 43

Cuadro 3.2. Modelos utilizados para la estimación del Índice de Área Foliar de *Pinus patula* en Zacualtipán de Ángeles, Hidalgo. 45

Cuadro 3.3. Matriz de correlación de las variables de campo vs. métricas LiDAR y variables espectrales. 50

Cuadro 3.4. Modelos de regresión lineal múltiple ajustados con métricas LiDAR para la estimación de las variables de campo (VC), en un bosque de *Pinus patula* bajo manejo en Zacualtipán de Ángeles, Hidalgo. 54

Cuadro 3.5. Modelos de regresión lineal múltiple ajustados únicamente con variables espectrales del sensor SPOT 6 para la estimación de las variables de campo (VC), en un bosque de <i>Pinus patula</i> bajo manejo en Zacualtipán de Ángeles, Hidalgo.	55
Cuadro 3.6. Modelos de regresión lineal múltiple ajustados con métricas LiDAR y variables espectrales para estimación de las variables de campo (VC), en un bosque de <i>Pinus patula</i> bajo manejo en Zacualtipán de Ángeles, Hidalgo.	57
Cuadro 3.7. Comparación de parámetros de ajuste de los modelos de regresión lineal múltiple que utilizan únicamente métricas LiDAR, únicamente variables espectrales del sensor SPOT 6 y la combinación de variables de los dos sensores.	59
Cuadro 3.8. Estimaciones del inventario total (900 ha) mediante la forma tradicional, métricas LiDAR y variables espectrales derivadas del sensor SPOT 6 para el bosque de <i>Pinus patula</i> bajo manejo en Zacualtipán de Ángeles, Hidalgo.	62

LISTA DE FIGURAS

Capítulo I.

- Figura 1.1. Diagrama de los elementos del proceso de percepción remota (tomado de INEGI, 2015). 2
- Figura 1.2. Espectro electromagnético y luz visible (tomado de Camber, 2013). 3
- Figura 1.3. Tipos de sensores remotos (tomado de INEGI, 2015). 4

Capítulo II.

- Figura 2.1. Ubicación del bosque de *Pinus patula* en Zacualtipán de Ángeles, Hidalgo. 16
- Figura 2.2 Diagrama de dispersión de observados vs. predichos de área basal (Ab), biomasa total (Bt), cobertura de copa (Cob), volumen (Vol) e índice de área foliar (IAF). 26
- Figura 2.3. Área basal estimada mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo. 30
- Figura 2.4. Biomasa total estimada mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo. 31
- Figura 2.5. Cobertura de copa estimada mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo. 32
- Figura 2.6. Volumen estimado mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo. 33
- Figura 2.7. Índice de área foliar estimado mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo. 34

Capítulo III.

- Figura 3.1. Ubicación del área de estudio en Zacualtipán de Ángeles, Hidalgo. Bosque de *Pinus patula* bajo manejo con fines de producción maderable. 42

Figura 3.2. Correlación de las variables de campo vs. métricas LiDAR (gráfica en columna izquierda) y variables espectrales (gráfica en columna derecha) para un bosque de <i>Pinus patula</i> bajo manejo en Zacualtipán de Ángeles, Hidalgo.....	52
Figura 3.3. Diagrama de dispersión de valores observados vs. valores predichos de área basal (Ab), biomasa total (Bt), cobertura de copa (Cob), volumen (Vol) e índice de área foliar (IAF). Estimaciones en base a datos LiDAR se presentan en las gráficas de área foliar (IAF).....	61

CAPÍTULO I

1.- INTRODUCCIÓN GENERAL

1.1 GENERALIDADES DE LA PERCEPCIÓN REMOTA

La percepción remota se define como el proceso de adquirir información acerca de un objeto, área o fenómeno desde la distancia, en esta amplia definición se cubre prácticamente todo, desde los ojos hasta los radiotelescopios (Hay *et al.*, 2006).

Otra definición más concreta de la percepción remota dice que es la ciencia que permite observar, medir, obtener y registrar información de la energía electromagnética reflejada en nuestro planeta desde el espacio y relacionar estas mediciones con su naturaleza y su distribución (INEGI, 2015 y SEMAR, 2015).

INEGI (2015) hace referencia a los elementos de la percepción remota los cuales son los siguientes (Figura 1.1):

- a) Fuente de energía que provea energía electromagnética al objeto de interés.
- b) Atmósfera, ya que la energía interactúa con este elemento al viajar del sensor al objeto y viceversa.
- c) Objetos, dependiendo de sus propiedades es la interacción o respuesta a la energía recibida y reflejada.
- d) Sensor remoto que recoge y graba la radiación electromagnética reflejada o emitida por el objeto y la atmósfera. Este instrumento se monta en una plataforma llamada satélite.
- e) Transmisión, recepción y procesamiento. La energía grabada por el sensor se transmite a una estación receptora, en donde los datos se procesan y son convertidos a imágenes digitales.
- f) Interpretación y análisis, consiste en interpretar la imagen para extraer la información de los objetos captados.
- g) Usuario final que le da una aplicación a la información extraída de las imágenes para un mejor conocimiento de los objetos de interés.

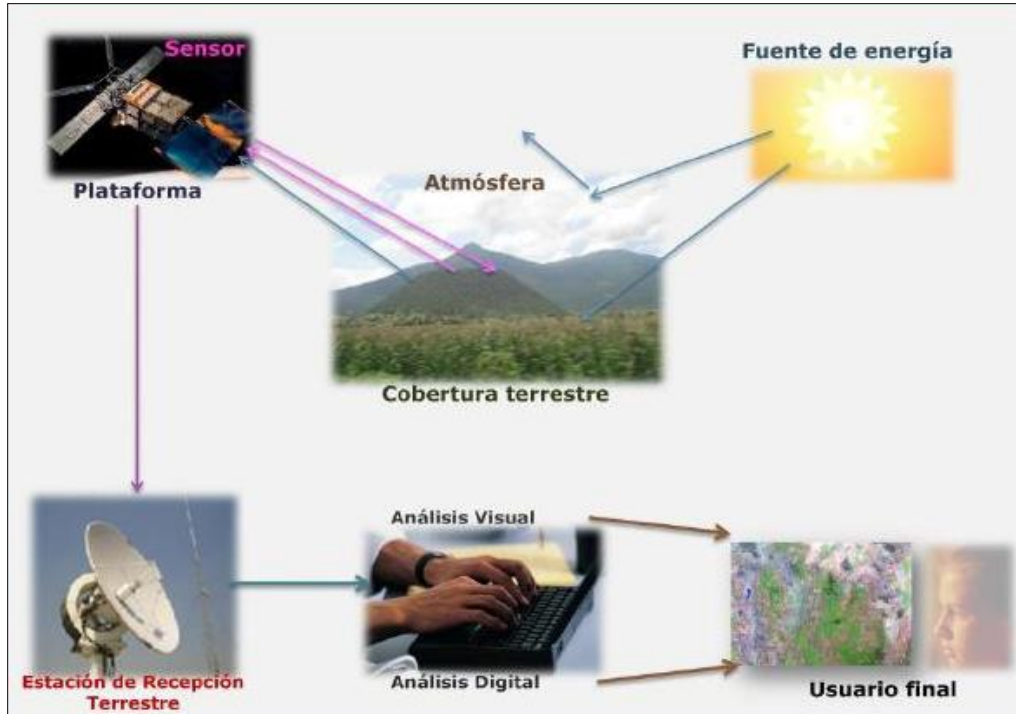


Figura 1.1. Diagrama de los elementos del proceso de percepción remota (tomado de INEGI, 2015).

1.2 ESPECTRO ELECTROMAGNÉTICO

El espectro electromagnético es el conjunto de ondas electromagnéticas que emiten (espectro de emisión) o absorben (espectro de absorción) una sustancia. El conjunto de ondas de menor longitud son los rayos cósmicos, los rayos gama y los rayos X, pasando por la luz ultravioleta, la luz visible y los rayos infrarrojos, hasta llegar a las ondas electromagnéticas de mayor longitud, como son las ondas de radio (SEMAR, 2015, Figura 1.2).

El espectro visible es la única radiación electromagnética que nuestros ojos pueden percibir, siendo el azul (0.4 a 0.5 μm), el verde (0.5 a 0.6 μm) y el rojo (0.6 a 0.7 μm) en razón de los colores elementales asociados a la longitudes de onda del espectro electromagnético (Chuvieco, 1995).

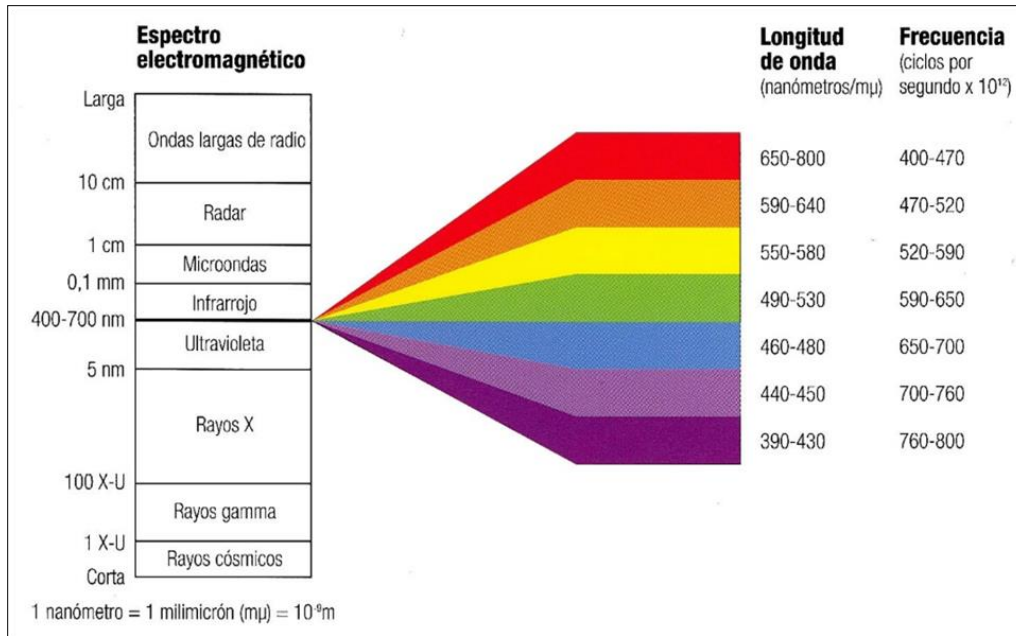


Figura 1.2. Espectro electromagnético y luz visible (tomado de Camber, 2013).

1.3 SENSORES REMOTOS

Los sensores remotos son dispositivos instalados en plataformas satelitales destinados a captar la energía electromagnética reflejada o emitida por los objetos observados en la superficie terrestre. Existen dos tipos de sensores remotos: los activos y los pasivos. El sensor pasivo usa el sol como fuente de radiación electromagnética, mientras que un sensor activo emite su propio recurso de radiación electromagnética (INEGI, 2015, Figura 1.3).




Figura 1.3. Tipos de sensores remotos (tomado de INEGI, 2015).

1.4 EL SENSOR LIDAR

El sensor LiDAR (acrónimo de Light Detection and Ranging en inglés, decir, detección y medición por luz) es una tecnología de teledetección que permite estimar la distancia desde un emisor laser a un objeto o superficie, utilizando un pulso de energía electromagnética de la banda del infrarrojo cercano, comúnmente 1064 nanómetros. La distancia a un objeto se determina midiendo el retardo de tiempo entre la transmisión de un pulso y la detección de la señal reflejada (Sangam, 2012; Ortiz-Reyes *et al.*, 2015).

1.4.1 Componentes de LiDAR

El equipo LiDAR está compuesto por un sensor laser, un sistema de navegación inercial y un receptor GPS.

a) El vehículo

El vehículo que transporta el laser LiDAR aerotransportado es instalado en aviones tripulados o no tripulados, en helicópteros o globos dirigibles (Baltsavias, 2008). El GPS y los sistemas

inerciales son montados en el fuselaje del avión o en dispositivos especiales sobre una parte externa de la del vehículo que realizara el vuelo.

b) El sensor laser

En el sensor láser se encuentra la fuente 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 dos maneras: de onda continua o de pulso (refiriéndose al envío de pulsos en intervalos regulares de tiempo). El funcionamiento del sensor láser depende de la trayectoria que realiza la señal reflejada en el terreno debido a la óptica de salida del sensor láser utilizando ya sea un espejo oscilante, un polígono rotatorio, el escáner de Palmer o de fibra óptica rotatoria (Wehr & Lohr, 1999).

c) Propiedades espectrales

La longitud de onda donde trabaja la mayoría de los laser es de 1064 nanómetros (nm), ubicada en la banda del infrarrojo cercano del espectro electromagnético. El LiDAR topográfico sólo en una longitud de onda, mientras LiDAR batimétrico, trabaja en dos longitudes de onda, usualmente en 1064 y 532 nm. La longitud de onda infrarroja es reflejada en el agua de la superficie y que el verde penetra en el agua y es reflejada por los objetos localizados en el cuerpo de agua (Baltsavias, 2008).

d) Intensidad

Los sistemas LiDAR registran la intensidad o magnitud del pulso de retorno, además de medir el tiempo de retorno de un pulso miden la fuerza de éste. Los valores de intensidad varían de acuerdo a la altitud del vuelo, condiciones atmosféricas, propiedades direccionales de reflectancia, la reflectividad del objetivo y los parámetros del láser (Baltsavias, 1999).

1.5 EL SENSOR SPOT 6

La Estación de Recepción México Nueva Generación (ERMEX NG), es un proyecto compartido entre la Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación (SAGARPA) y la Secretaría de la Defensa Nacional (SEDENA) que tiene como

función la de gestión de imágenes satelitales del territorio nacional. La ERMEX NG fue inaugurada el 19 de febrero del 2013 y recibe telemetría de la constelación de Satélites para la Observación de la Tierra (SPOT). Entre las principales aplicaciones se encuentran la agricultura, cartografía, geología ingeniería civil, planeamiento urbano, estudios ambientales y forestales, exploración de gas y petróleo (Martínez y Díaz 2005; SIAP, 2016).

Cuadro 1.1. Características de las imágenes satelitales del sensor SPOT 6.

Características	Valores	
Número de satélites	2	
Altitud	694 km.	
Ángulos de observación	Estándar: +/- 30°.	
	Ampliado +/- 45°.	
Ancho del barrido	60 km siguiendo un eje Norte-Sur;	
	Hasta 600 km de longitud.	
Resolución espectral	Banda pancromática	0.450-0.745 μm .
	Banda azul	0.455-0.525 μm .
	Banda verde	0.530-0.590 μm .
	Banda rojo	0.625-0.695 μm .
	Banda del infrarrojo cercano	0.760-0.890 μm .
Resolución espacial	Pancromática 1.5 m.	
	Multiespectral 6 m.	

Donde μm : micrómetros; m: metros.

1.6 PROCESAMIENTO DE IMÁGENES SATELITALES

El procesamiento de las imágenes satelitales se pueden agrupar en 5 etapas las cuales son: inventario de campo, pre-procesamiento de las imágenes de satélite, análisis de correlación de los datos de campo *vs.* datos espectrales, estimación de las variables dasométricas de interés mediante algún método estadístico seleccionado y validación de los resultados (Chirici *et al.*, 2008).

1.6.1 Pre-procesamiento de imágenes

Las imágenes satelitales tomadas por cualquier sensor óptico no toman en cuenta las deformaciones del terreno y solo las proyectan en un plano cartesiano, donde las unidades de medida son los pixeles y los valores obtenidos son números digitales que miden la variación espacial de la radiancia reflejada por los objetos. A este tipo de imágenes se les conoce como imágenes crudas por no tener ningún proceso de corrección, las correcciones que comúnmente se hacen antes de realizar un proceso con ellas son: corrección geométrica y corrección radiométrica (Aguirre, 2013).

a) Corrección geométrica

La corrección geométrica consiste en hacer coincidir los pixeles de la imagen con un sistema de coordenadas de referencia espacial definido (por ej. El sistema de coordenadas Universal Transversa de Mercator –UTM). El sistema de referencia provee puntos de control de los cuales se conocen las coordenadas de ubicación en campo. Posteriormente se ajustan un par de modelos de regresión lineal múltiple entre las coordenadas de origen (imagen) y las coordenadas destino (ej. Sistema –UTM), los cuales sirven para proyectar todos los pixeles al sistema de coordenadas de referencia (Aguirre, 2013).

b) Corrección radiométrica

Los valores de brillo digital (números digitales) registrados por los sensores remotos son afectados por varios factores: la topografía, el ángulo solar, el posicionamiento del sensor (ángulo del sensor) y por la condición atmosférica presentes en el área. Estas características condicionan la iluminación de la imagen, lo que se refleja en la calidad de los datos espectrales

captados (Aguirre, 2013). Para aminorar estos efectos, las imágenes se calibraran mediante la conversión de los niveles o números digitales de las imágenes (valores de 0 a 255, en imágenes de 8 bits) a valores adimensionales (reflectancia) que sean numéricamente comparables entre imágenes, fechas y entre sensores (Schaepman-Strub *et al.*, 2006).

1.6.2 Análisis de los datos de campo vs. datos espectrales

En el caso de las variables continuas la manera de ver su comportamiento comparado con la reflectancia registrada en las imágenes, es mediante una gráfica de dispersión de los datos y un análisis de correlación, esto se realiza para conocer el grado de asociación y el signo de la correlación existente entre las variables de interés y los datos espectrales para una realizar una estimación adecuada (McRoberts *et al.*, 2008).

En caso de tener variables categóricas (tipos de vegetación o grados de densidad) la relación se investiga mediante la construcción de firmas espectrales mediante la estimación separada de clases y con análisis de matrices de confusión construidas con los datos de los sitios de entrenamiento que son los sitios de muestreo en campo (Aguirre, 2013).

1.6.3 Estimación de las variables dasométricas de interés mediante un método estadístico

Esta fase también es conocida como mapeo de las variables de interés ya sean continua o categórica, el mapeo se realiza a partir del modelo estadístico que se seleccione, entre los métodos más utilizados destacan los siguientes:

a) Análisis de regresión

Este tipo de análisis parte de modelar la correlación existente entre los datos espectrales y las variables de interés. Las variables independientes son las bandas espectrales de las imágenes debido a que cada una de ellas refleja parte de la variabilidad existente en el paisaje que está siendo capturado y detectan aspectos complementarios de las coberturas del suelo (clorofila: rojo e infrarrojo cercano, humedad: infrarrojo de onda corta e infrarrojo lejano y temperatura: infrarrojo térmico) mientras que las variables dependientes son las variables de la densidad forestal que son las variables de interés medidas en campo (Anaya *et al.*, 2009).

b) El vecino más cercano (K-NN)

En variables continuas este método consiste en tomar a una media ponderada de los K vecinos espectrales más cercanos, mientras que en variables categóricas será mediante la moda de los K vecinos espectrales más cercanos. Dicha ponderación se implementa mediante el inverso de la distancia euclidiana (McRoberts *et al.*, 2008).

1.6.4 Estimación de error y “validación” de los resultados

La estimación del error se realiza mediante el cálculo de la diferencia de las estimaciones de las variables de interés obtenidas con los modelos ajustados contra las estimaciones “reales” (las mediciones realizadas en campo). Los intervalos de confianza se generan mediante el procesamiento tradicional de un inventario forestal (Schreuder *et al.*, 2006).

Para saber la confiabilidad de los resultados obtenidos en los mapas (predichos) contra los valores de campo (observados), cuando se trata de variables cuantitativas (área basal, volumen, biomasa, etc.) se realiza mediante el cálculo del error estándar y en variables cualitativas (densidades, tipo de vegetación entre otras) la evaluación se realizará mediante matrices de confusión, contingencia o error (Treitz and Rogan, 2004).

1.7 LITERATURA CITADA

- Aguirre S., C. A. (2013). Modelación geoespacial de variables de densidad forestal. Tesis de Doctorado. Facultad de Ciencias Forestales, Universidad Autónoma de Nuevo León. Linares, Nuevo León. 119p.
- Anaya, J. A., Chuvieco, E., & Palacios-Orueta, A. (2009). Aboveground biomass assessment in Colombia: A remote sensing approach. *Forest Ecology and Management*, 257(4), 1237-1246.
- Baltsavias E. P. 1999. Airborne laser scanning: basic relations and formulas. *Journal of Photogrammetry and Remote Sensing* 54: 199-214.
- Baltsavias, E. P. 2008. Introduction to airborne LiDAR and physical principles of LiDAR technology. In: international school on LiDAR technology IIT Kanpur, India. 31 march- 4 april 2008. 129 pp.

- Camher, D. Consultado el 15 de marzo del 2015. Página web.
<http://fisiqueameciencias2.blogspot.mx/2013/06/tema-2-los-fenomenos-electromagneticos.html>
- Chirici, G., Barbati, A., Corona, P., Marchetti, M., Travaglini, D., Maselli, F. and Bertini, R. 2008. Non-parametric and parametric methods using satellite images for estimating growing stock volume in alpine and Mediterranean forest ecosystems. *Remote Sensing of Environment*. 112: 2686-2700.
- Chuvieco, E. (1995). *Fundamentos de teledetección espacial*. Segunda edición. Ediciones RIALP, S. MADRID. Madrid, España. 449p.
- Cook, B. D., Nelson, R. F., Middleton, E. M., Morton, D. C., McCorkel, J. T., Masek, J. G. & Montesano, P. M. (2013). NASA Goddard's LiDAR, Hyperspectral and Thermal (G-LiHT) Airborne Imager. *Remote Sensing*, 5(8), 4045-4066.
- Hay, S. I., Tatem, A. J., Graham, A. J., Goetz, S. J. and Rogers D. J. (2006). Global environmental data for mapping infectious disease distribution. *Adv. Parasitol.*
- Instituto Nacional de Estadística y Geografía (INEGI). Percepción remota. Consultado el 12 de marzo del 2015. Página web.
<http://www.inegi.org.mx/geo/contenidos/imgpercepcion/imgsatelite/elementos.aspx>
- Martínez M. J. y Díaz P. A. (2005). *Percepción remota: "fundamentos de teledetección espacial"*. Comisión Nacional del Agua. Pp 62.
- McRoberts, R. E. (2008). Using satellite imagery and the k-nearest neighbors technique as a bridge between strategic and management forest inventories. *Remote Sensing of Environment*, 112(5), 2212-2221.
- Merem, C. E. and Twumasi, Y. A. (2008). Using geospatial information technology in natural resources management: the case of urban land management in west Africa. *Sensor*. (8): 607-619.

- Pinedo A., A. (2008). Modelación de atributos de bosques templados con Landsat tm y Spot-HRV e índice de sitio como indicador de productividad. Tesis de Doctorado. Facultad de Manejo de Recursos Naturales, Universidad Autónoma de Chihuahua. Chihuahua, Chihuahua, México. 94p.
- Sangam, S. (2012). Light detection and ranging. SONU SANGAM. Departament of electronics and communication engineering CMR institute of technology. 8p.
- Schaepman-Strub, G., Schaepman, M.E. Painter, T.H. Dangel, S. and Martonchik, J.V. 2006. Reflectance quantities in optical remote sensing definitions and case studies. Remote Sensing of Environment. 103: 27-42.
- Schreuder, H. T., Ernst, R., & Maldonado, H. R. (2006). Técnicas estadísticas para evaluación y monitoreo de recursos naturales. División de Ciencias Forestales. Universidad Autónoma de Chapingo. 151p.
- Schuckman, K., & Renslow, M. (2009). Lidar technology and applications. The Pennsylvania State University, USA.
- Secretaria de Marina Armada de México (SEMAR). Percepción remota. Consultado el 12 de marzo del 2015. Página web. <http://www.semar.gob.mx/s/informacionsector/ciencia/ermexs/percepcion-remota.html>
- Servicio de Información Agroalimentaria y Pesca (SIAP). 2016. Consultado 28 febrero del 2016. Página web: <http://www.siap.gob.mx/ermex-ng/>
- Treitz, P., & Rogan, J. (2004). Remote sensing for mapping and monitoring land-cover and land-use change—an introduction. Progress in planning, 61(4), 269-279.
- Wehr, A. and Lohr, U. 1999. Airborne laser scanning – an introduction and overview. ISPRS Journal of Photogrammetry and Remote Sensing 54: 68–82.

1.8 OBJETIVOS

1.8.1 General

Estimar variables dasométricas de un bosque templado mediante un sensor remoto activo y un sensor pasivo en el estado de Hidalgo, México.

1.8.2 Específicos

- ✓ Cuantificar el área basal, biomasa, cobertura de copa, volumen e índice de área foliar en un bosque templado bajo manejo mediante datos provenientes del sensor LIDAR aerotransportado e imágenes SPOT 6 en un bosque templado bajo manejo en Zacualtipán, Hidalgo, México.
- ✓ Evaluar el potencial del uso combinado de datos LIDAR aerotransportado e imágenes SPOT 6 para mejorar las estimaciones de área basal, biomasa, cobertura de copa, volumen e índice de área foliar en un bosque templado bajo manejo en Zacualtipán, Hidalgo, México.

CAPÍTULO II

2. INVENTARIO Y MAPEO DE UN BOSQUE DE *Pinus patula* BAJO MANEJO FORESTAL MEDIANTE EL SENSOR SPOT 6

2.1 RESUMEN

El objetivo de la investigación fue cuantificar y mapear las variables de densidad forestal área basal (Ab), biomasa total (Bt), cobertura de copa (Cob), volumen (Vol) e índice de área foliar (IAF) en un bosque de *Pinus patula* bajo manejo maderable. Inicialmente se identificaron las correlaciones existentes entre los datos espectrales derivados del sensor satelital SPOT 6 y datos de inventario de campo. El análisis incluyó el uso de modelos de regresión lineal múltiple, estimadores de razón y regresión y el enfoque tradicional de inventario (únicamente con datos de campo) con fines comparativos. Las correlaciones más altas para Ab, Bt, Cob y Vol fueron con la banda del infrarrojo cercano, teniendo valores de 0.74, -0.77, -0.50 y -0.77 respectivamente. Mientras que el IAF presentó la mayor correlación en la banda verde con un valor de -0.65. Los mejores ajustes se lograron para los modelos de regresión que predicen las variables Ab, Bt y Vol, con un R^2_{Adj} de 0.66 para cada una de ellas y valores de raíz del error cuadrático medio (RECM) de 5.82, 32 y 62.3 respectivamente. Contrariamente, la Cob presentó el ajuste más bajo con una R^2_{Adj} de 0.27 y un RECM de 35.03. Las estimaciones de inventario total fueron de 21,022.65 m² en Ab, 80,430.5 Mg en Bt, 102.3 % en promedio de Cob, 156,932.2 m³ en Vol y 3.24 m² m⁻² en IAF. Las estimaciones de inventario calculadas mediante el método de estimadores de razón y de regresión se encuentran dentro de la amplitud del intervalo de confianza del muestreo aleatorio. El estimador de regresión presentó valores de precisión 4.8 %, 6.7 %, 5.8 %, 6.6 %, 6.9 % en la estimación de Ab, Bt, Cob, Vol e IAF respectivamente, siendo este tipo de muestreo el más conservador de todos los inventarios realizados.

Palabras clave: *Pinus patula*, inventario forestal, modelación espacial, variables de densidad.

INVENTORY AND MAPPING OF A FOREST OF *Pinus patula* UNDER MANAGEMENT THROUGH THE SENSOR SPOT 6

2.2 ABSTRACT

The objective of this research was to quantify and map the forest density variables as basal area (Ab), total biomass (Bt), canopy cover (Cob), volume (Vol) and leaf area index (LAI) in a forest of *Pinus patula* under management in Zacualtipán, Hidalgo, México. Initially, the relationships between spectral data derived from SPOT 6 satellite sensor and field inventory data were identify. The analysis included the use of multiple linear regression models, ratio and regression estimators, and the traditional inventory approach (only with field data) for comparative purposes. The highest correlations to Ab, Bt, Cob and Vol were with the band of near infrared (NIR), with values of 0.74, -0.77, -0.50 and -0.77 respectively. Whereas the IAF had the highest correlation in the green band (V) with a value of -0.65. The best settings were obtained for the regression models that predict Ab, Bt and Vol variables, with a R^2_{Adj} of 0.66 each and with a root mean square error (RMSE) of 5.82, 32 and 62.3 respectively. Conversely, Cob has the lowest setting with a R^2_{Adj} of 0.27 and a RMSE of 35.03. The total inventory estimates were of 21,022.65 m² in Ab, 80,430.49 Mg Bt, 102.28% on average of Cob, 156,932.22 m³ in Vol and 3.24 m² in IAF. The inventory estimates calculated by the ratio and regression estimators method are within the range of the confidence interval of the random sampling. The regression estimator had precision values of 4.80%, 6.70%, 5.79%, 6.62%, 6.90% in the estimation of Ab, Bt, Cob, Vol and IAF respectively, being this type of sampling the most conservative of all inventories carried out.

Keywords: *Pinus patula*, forest inventory, spatial modeling, density variables.

2.3 INTRODUCCIÓN

La valoración y gestión de los recursos forestales requieren de su cuantificación a través de inventarios forestales, lo cual se obtiene mediante la realización de muestreos en campo. Este tipo de muestreo incluye la evaluación de diferentes variables como la densidad del bosque, la altura del arbolado, la cobertura de copa, el área basal y el volumen maderable; lo que requiere de esfuerzo y costos considerables (Hawbaker *et al.*, 2010 y Tanaka *et al.*, 2014).

La geomática contiene disciplinas como la percepción remota, los sistemas de información geográfica (SIG) y los sistemas satelitales de navegación global (SSNG) las cuales facilitan la captura de datos e información valiosa y oportuna sobre los recursos naturales, ofreciendo una alternativa para el levantamiento de inventarios forestales. Con estas tecnologías es posible estimar variables forestales a nivel local (Ortiz-Reyes *et al.*, 2015) y en grandes áreas a diferentes niveles de detalle (Merem y Twumasi, 2008; Muñoz-Ruiz *et al.*, 2014).

El avance constante en la informática permite que los sensores remotos montados en plataformas satelitales o aviones capten imágenes a intervalos de tiempo cada vez menores y con mejor resolución espacial y espectral (Ikonos, QuickBird, SPOT 6 y 7, Pléiades), lo cual posibilita la disponibilidad de datos e información oportuna para la planeación y el manejo de los recursos forestales, particularmente para áreas de difícil acceso (Valdez-Lazalde *et al.*, 2006).

En este sentido, la tecnología asociada a la geomática puede ser empleada para la estimación de los inventarios forestales y transformar estos resultados en mapas para la toma de decisiones en la gestión de los recursos forestales. El objetivo de este estudio fue mapear las variables forestales de área basal, biomasa total, volumen, cobertura de copa e índice de área foliar en un bosque de *Pinus patula* bajo manejo forestal mediante datos espectrales provenientes del sensor SPOT 6 en Zacualtipán, Hidalgo, México.

2.4 MATERIALES Y MÉTODOS

2.4.1 Área de estudio

El área de estudio se localiza en el municipio de Zacualtipán de Ángeles, en el Estado de Hidalgo, México, entre las coordenadas 20°36'00" y 20°37'40" N y 98°34'44" y 98°36'32" O

(Figura 1). Su dimensión es de 900 ha (3 x 3 km), conformadas en su mayoría por cuatro ejidos del municipio de Zacualtipán de Ángeles: La Mojonera, Atopixco, El Reparó y Tzincoatlan, así como pequeñas áreas de los ejidos Santo Domingo, Zahuastipán y de pequeñas propiedades privadas (Ortiz-Reyes *et al.*, 2015).

La fisiografía del área comprende parte de la Sierra Alta Hidalguense y del Eje Neovolcánico, subprovincia Carso Huasteco y está conformada por pendientes, mesetas y cañones. El sustrato edáfico está representado por suelos Acrisol órtico (Ao), Luvisol crómico (Lc) y Feozem háplico (Hh). El clima existente es templado-húmedo [C(fm)w”b(e)g] con una estación marcada de lluvias entre junio y octubre. La precipitación oscila alrededor de 2050 mm (INAFED, 2015).

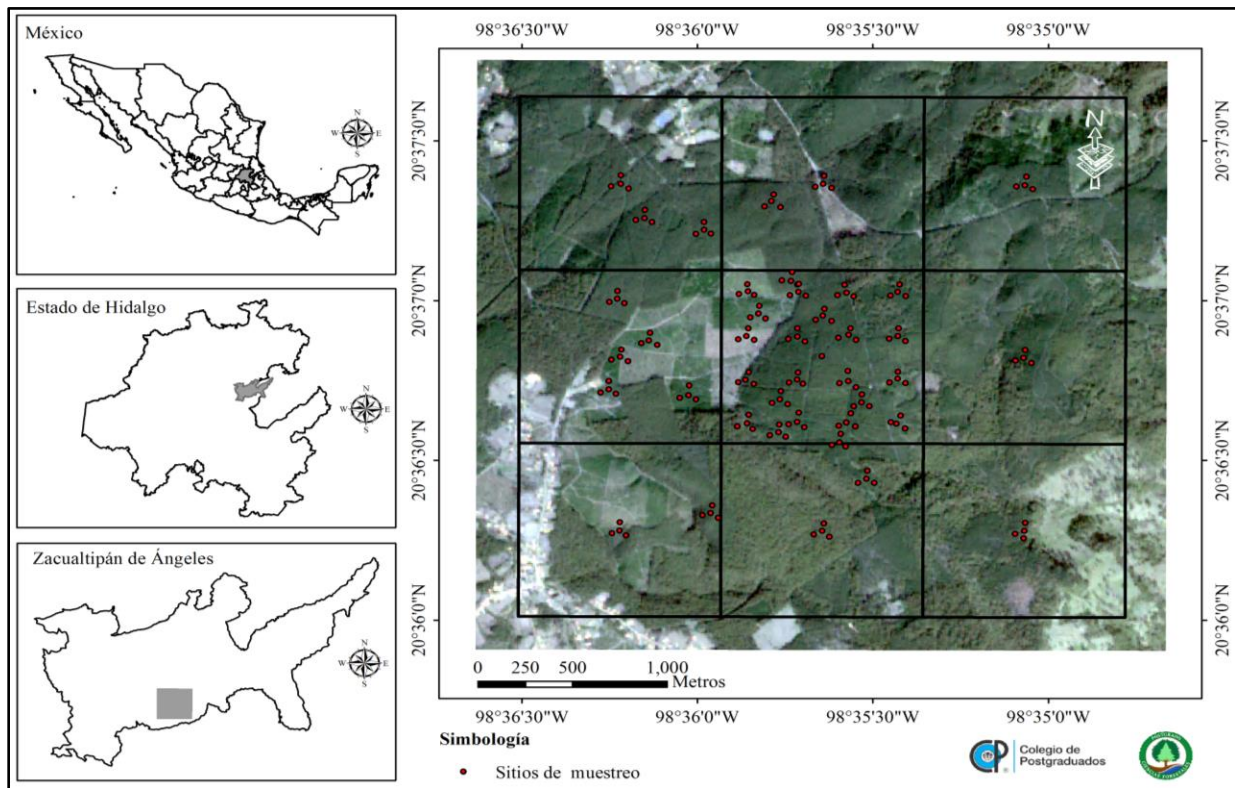


Figura 2.1. Ubicación del bosque de *Pinus patula* en Zacualtipán de Ángeles, Hidalgo.

El área de estudio ha sido manejada en las últimas décadas mediante el denominado Método de Desarrollo Silvícola (MDS), obteniendo rodales de *Pinus patula* mono-específicos, coetáneos, de coberturas y edades variables, que van de 0 hasta 31 años. Existen también rodales sin intervención silvícola (rodales naturales) de aproximadamente 80 años de edad. A pesar de que

los rodales intervenidos se caracterizan técnicamente como mono-específicos, presentan una proporción mínima de otras especies en una distribución variada: *P. teocote*, *Prunus serótina*, *Quercus laurina*, *Q. rugosa*, *Q. excelsa*, *Q. crassifolia*, *Q. affinis*, *Cornus disciflora*, *Viburnum spp.*, *Cleyera theaoides*, *Alnus jorullensis*, *Arbutus xalapensis*, *Symplocus spp.*, *Ternstroemia spp.*, *Vaccinium leucanthum*, principalmente (Figuroa *et al.*, 2010).

2.4.2 Muestreo en campo

Se utilizó un sistema de muestreo sistemático bajo un diseño por conglomerados, similar al propuesto por la Comisión Nacional Forestal (CONAFOR, 2011) para el Inventario Nacional Forestal y de Suelos (INFyS). Cada conglomerado está constituido por cuatro sitios de 400 m², dispuestos en forma de “Y” invertida (Figura 1). La muestra se compone de 157 sitios a los que se les da seguimiento como parte de los trabajos de investigación que se desarrollan en el Sitio Intensivo de Monitoreo de Flujo de CO₂ a largo plazo (Ángeles *et al.*, 2011).

La campaña de campo para el inventario se realizó en mayo del 2013. Se midieron las variables siguientes en todos los árboles presentes en los sitios: diámetro normal (Dn a 1.30 m sobre el nivel del suelo), altura total del árbol (Ht) y diámetro de copa (Dc).

2.4.3 Estimación de las variables del bosque

Las variables medidas en campo sirvieron como base para estimar mediante modelos matemáticos el área basal (Ab), la biomasa total (Bt), la cobertura de copa (Cob), el volumen (Vol) e el índice de área foliar (IAF) para árboles individuales. Las estimaciones a nivel árbol se sumaron para obtener valores por sitio con miras a combinarlos con los datos de una imagen obtenida por el sensor SPOT 6.

El área basal se estimó mediante la siguiente fórmula: $Ab = \frac{\pi}{40,000} \times Dn^2$; donde: Ab en m²/árbol, Dn en cm, π es la constante matemática con valor de 3.1416.

La biomasa total y el volumen se estimaron mediante los modelos ajustados por Cruz (2007) y Soriano *et al.* (2015) para el área de estudio (Cuadro 2.1).

Cuadro 2.1. Modelos para estimar Biomasa total (Bt), Volumen (Vol) de *Pinus patula* y latifoliadas en Zacualtipán de Ángeles, Hidalgo.

Tipo de vegetación	Ecuación de biomasa total y volumen	Fuente
<i>Pinus patula</i>	$Bt = \exp(-4.554805) * (Dn^2 * Ht)^{1.047218}$	Soriano <i>et al.</i> (2015)
	$Vol = \exp(-10.4869) * Dn^{1.7525} * Ht^{1.31936}$	Soriano <i>et al.</i> (2015)
Latifoliadas	$Bt = \exp(-3.109407) * (Dn^2 * Ht)^{0.952688}$	Soriano <i>et al.</i> (2015)
	$Vol = 0.000082 * Dn^{1.785782} * Ht^{0.915827}$	Cruz (2007)

Bt en kg; Vol en m³; Dn: diámetro normal, en cm y Ht: altura total en m.

La Cobertura de copa (Cob) se estimó considerando el diámetro de copa promedio (DC), el cual se obtuvo midiendo el diámetro de copa en dos orientaciones (N-S y E-O), la fórmula utilizada es la siguiente: $Cob = DC^2 \times \frac{\pi}{4}$; donde: Cob en m² y DC en m.

El IAF para *P. patula* se estimó mediante el modelo utilizado por Aguirre-Salado *et al.* (2011):

$$IAF = \frac{\left(\sum_{i=1}^n \left(\frac{AFS}{2} \right) \right)}{A}$$

Dónde: IAF en m²/m², AFS = área foliar superficial en m², A = área del sitio de muestreo (400 m²) e *i* = *i*-ésimo árbol del sitio de muestro.

La estimación del AFS requiere conocer los valores de área foliar específica (AFE) y de biomasa seca foliar (BSF) para cada uno de los árboles que están dentro de cada uno de los sitios de muestreo (Aguirre-Salado *et al.*, 2011). Para ello se utilizaron modelos que se indican en el Cuadro 2.2.

Cuadro 2.2. Modelos utilizados para la estimación del Índice de área foliar de *Pinus patula* en Zacualtipán de Ángeles, Hidalgo.

Variable	Modelo	Fuente
AFS	$AFS = AFE * BSF$	Aguirre-Salado <i>et al.</i> (2011)
AFE	$AFE = 2.64 * (9.5336 - 0.0758 * Dn)$	Cano-Morales <i>et al.</i> (1996)
BSF	$BSF = \exp(-4.750974) * (Dn^2 * Ht)^{0.709796}$	Soriano <i>et al.</i> (2015)

AFS: área foliar superficial en m²; AFE: área foliar específica en m²/kg; BSF: biomasa seca foliar en kg; Dn: diámetro normal en cm y Ht: altura total en m.

2.4.4 Pre-procesamiento de la imagen SPOT 6

La imagen SPOT 6 utilizada fue capturada en enero de 2014. No fue posible obtener una imagen de fecha más cercana al periodo de obtención de los datos de campo debido a que las condiciones atmosféricas no fueron favorables. La escena fue facilitada por La Estación de Recepción México Nueva Generación (ERMEX NG). Esta cuenta con una resolución espacial de 6 m en multiespectral y tiene un proceso Standard Ortho el cual consiste en una ortorectificación utilizando el modelo digital de elevación (MDE) generado por la “Shuttle Radar Topography Mission” (SRTM) de la NASA, con proyección UTM 14 N, datum y elipsoide WGS84 y con corrección radiométrica de 12 bits mediante el método del vecino más cercano (Astrium, 2013).

Los datos espectrales (números digitales) del sensor SPOT 6 fueron convertidos a valores de radiancia y de radiancia a valores de reflectancia utilizando en el paquete ArcMap 10.2® mediante las fórmulas siguientes (Astrium, 2013):

$$L_b(p) = \frac{DC(p)}{GAIN(b)} + BIAS(b) \quad \text{y} \quad P_b(p) = \frac{\pi * L_b(p)}{E_0(b) * \cos(\theta_s)}$$

Donde: $L_b(p)$: radiancia al tope de la atmósfera ($w \text{ sr}^{-1} \text{ m}^{-2} \mu\text{m}^{-1}$), $DC(p)$: número digital, $GAIN(b)$: coeficiente de calibración de la ganancia de cada banda, $BIAS(b)$ = factor multiplicativo de la banda, $P_b(p)$: reflectancia exoatmosférica adimensional, π : valor del número

π (3.1416), $E_0(b)$: radiancia exoatmosférica solar media de cada banda, $\text{Cos}(\theta_s)$ = coseno del ángulo cenital solar de la escena ($90^\circ - \theta_s$). Los valores de los parámetros fueron obtenidos de los metadatos de la imagen SPOT 6.

2.4.4.1 Obtención de variables espectrales

Las variables espectrales utilizadas fueron las cuatro bandas de la imagen SPOT 6: azul (A), verde (V), roja (R) e infrarrojo cercano (NIR) (Astrium, 2013). Adicionalmente se calculó el índice de vegetación de diferencias normalizadas ($\text{NDVI} = \frac{\text{NIR}-\text{R}}{\text{NIR}+\text{R}}$) debido a que este presenta alta correlación con la cobertura de la vegetación (Aguirre-Salado et al., 2011). Estas variables fueron extraídas como el promedio de la reflectancia correspondiente a cada uno de los sitios de muestreo (400 m^2) establecidos en campo, mediante el comando **Zonal Statistics as Table** del programa ArcMap 10.2®.

2.4.5 Análisis estadístico

2.4.5.1 Análisis de correlación

Previo al análisis de correlación, los datos de campo a nivel sitio fueron transformados calculando la raíz cuadrada de su valor original con el fin de minimizar la varianza y obtener una distribución normal. Posteriormente se estimó el coeficiente de correlación de Pearson implementado en SAS 9.0® (SAS, Institute Inc. 2002), para identificar las variables espectrales correlacionadas con las variables de campo.

2.4.5.2 Modelos de regresión

Se utilizó el método de regresión por pasos (STEPWISE) para identificar los modelos de regresión lineal múltiple adecuados para estimar a nivel sitio el área basal, la biomasa total, la cobertura de copa, el volumen y el índice de área foliar. La estructura de los modelos es la siguiente:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon_i$$

Donde: Y: es la variable del bosque de interés, X_n : son las variables espectrales con valores de reflectancia, β_n : son parámetros de regresión, ϵ_i : es el error.

Los indicadores de bondad de ajuste considerados para seleccionar los mejores modelos fueron el coeficiente de determinación ajustado (R^2_{adj}), la Raíz del Error Cuadrático Medio (RECM) y un valor de probabilidad de rechazo (p) menor al 0.05 para cada uno de los parámetros de regresión.

2.4.6 Cálculo del inventario tradicional

El inventario tradicional de las variables Ab, Bt, Cob, Vol e IAF se realizó considerando dos tipos de muestreo: simple aleatorio y estratificado (Scheaffer *et al.*, 1986). El método de muestreo que arrojó la mejor precisión fue utilizado como punto de comparación para las estimaciones realizadas con datos espectrales del sensor SPOT 6.

El criterio para la selección del mejor inventario tradicional e inventario con percepción remota fue la precisión lograda en las estimaciones, mientras que el criterio dentro de los inventarios con percepción remota fue la menor Raíz del Error Cuadrático Medio (RECM).

2.4.7 Estimadores de razón y regresión

Dada la alta correlación que suele existir entre las variables de campo con algunas variables espectrales (Aguirre-Salado *et al.*, 2009; Muñoz-Ruiz *et al.*, 2014), los datos registrados en las imágenes SPOT 6 sirvieron como base para estimar, mediante interpolación, los valores de las variables para toda el área de estudio, a nivel de pixel, a través de estimadores de razón y de regresión (Scheaffer *et al.*, 1986; Valdez-Lazalde *et al.*, 2006).

Los estimadores de razón y regresión se apoyan en una variable auxiliar conocida (X, para nuestro caso variables espectrales) para predecir la variable de interés (Y, para el caso Ab, Vol, Bt, Cob e IAF). Para el estimador de razón se estimó la proporción de Y respecto a X, donde la razón (R) es una constante poblacional definida como $R = \frac{\bar{Y}}{\bar{X}}$. Mientras que el estimador de regresión utiliza una la variable auxiliar de la forma siguiente $\mu_y = \bar{Y} + b (\mu_x - \bar{X})$ para estimar medias totales de Y, donde μ_x es la media poblacional de X; mientras que, \bar{Y} , \bar{X} y b son los parámetros estimados a partir de la muestra (Scheaffer *et al.*, 1986).

2.4.8 Generación de cartografía

Los mejores modelos de regresión ajustados se utilizaron para generar mapas temáticos de las variables de interés (Ab, Bt, Cob, Vol e IAF) mediante algebra de mapas en ArcMap 10.2®.

2.5 RESULTADOS Y DISCUSIÓN

2.5.1 Relación entre variables de campo y variables espectrales

La correlación de las variables de campo y las variables espectrales es negativa, es decir a mayor valor de la variable de campo el valor de la variable espectral es menor (Cuadro 2.3). Las correlaciones oscilan entre -0.36 y -0.77, destacando la Cob es la única variable de campo que presentó correlaciones menores o iguales a -0.50.

Cuadro 2.3. Matriz de correlación de las variables de campo vs. variables espectrales.

Variable Espectral	Variable de Campo				
	Ab	Bt	Cob	Vol	IAF
	(m ² ha ⁻¹)	(Mg ha ⁻¹)	(% ha ⁻¹)	(m ² ha ⁻¹)	(m ² m ⁻²)
A	-0.64	-0.52	-0.44	-0.54	-0.61
V	-0.70	-0.64	-0.48	-0.66	-0.65
R	-0.55	-0.42	-0.36	-0.44	-0.56
NIR	-0.74	-0.77	-0.50	-0.77	-0.63
NDVI	-0.64	-0.71	-0.47	-0.70	-0.54

Ab: área basal; Bt: biomasa total; Cob: cobertura de copa; Vol: volumen; IAF: índice de área foliar; A; banda azul; V: banda verde; R: banda roja; NIR: banda del infrarrojo cercano y NDVI: Índice de vegetacion de diferencia normalizada. Todas las correlaciones fueron altamente significativas (0.001).

La variable espectral con mayor correlación con las variables de campo fue la banda del NIR (Cuadro 2.3), por ello fue considerada para formar parte de los modelos de regresión lineal múltiple. En general el comportamiento de la banda NIR es que los valores altos de reflectancia se presentan en áreas con vegetación densa y vigorosa. Valores bajos de esta variable corresponden a áreas de condiciones de vegetación contrarias a la arriba descrita (poca vegetación o vegetación no vigorosa), además de cuerpos de agua donde la reflectancia es absorbida por estos o en zonas con alto contenido de humedad (Chuvienco, 1995). Las correlaciones más altas para Ab, Bt, Cob y Vol fueron con la banda NIR teniendo valores de -0.74, -0.77, -0.50 y -0.77 respectivamente. Mientras que el IAF presentó la mayor correlación en la banda V con un valor de -0.65.

Este tipo de tendencias negativas son similares a las reportadas por Aguirre-Salado *et al.* (2011) para un bosque de *P. patula* bajo manejo, ubicado en un área aledaña al área que cubre el presente estudio. Estos autores reportaron una correlación entre la banda NIR y el IAF de -0.92 y de -0.93 para Cob, mientras la banda V presento una correlación de -0.40 y -0.39 en IAF y Cob respectivamente.

La baja correlación encontrada en este estudio es debido a dos situaciones presentes en los sitios de muestreo: (1) no se tomaron sitios con suelo desnudo con la finalidad de proporcionar al modelo tantas observaciones con tendencia a cero (Aguirre-Salado *et al.*, 2011) y (2) la alta diversidad de especies que tienen los sitios, ya que la banda NIR capta la estructura de las células y humedad (Jensen, 2007).

Otro caso es el reportado por Muñoz-Ruiz *et al.* (2014) para los bosques templados del estado de Hidalgo, donde la banda V obtuvo correlaciones de -0.43 con Ab, -0.31 con Cob y -0.47 con Vol, mientras que la correlación encontrada en la banda NIR fue muy baja 0.03 con Ab, 0.15 con Cob y 0.03 con Vol, y en los bosques mesófilos la banda V obtuvo -0.46 en Ab, 0.08 en Cob y -0.44 en Vol y en la banda NIR -0.36 en Ab, 0.04 en Cob y -0.33 en Vol.

2.5.2 Estimaciones de variables mediante modelos de regresión

Dada la alta correlación de la banda NIR con las variables de campo, esta fue considerada como variable independiente para ajustar modelos de regresión lineal múltiple. Los mejores

ajustes se lograron para los modelos que predicen las variables Ab, Bt y Vol con una R^2_{Adj} de 0.66 cada una de ellas y con un RECM de 5.82, 32 y 62.3 respectivamente. Contrariamente, la Cob presentó el ajuste mas bajo con una R^2_{Adj} de 0.27 y un RECM de 35.03. El IAF presentó una R^2_{Adj} de 0.51 y un RECM de 2.07 (Cuadro 2.4).

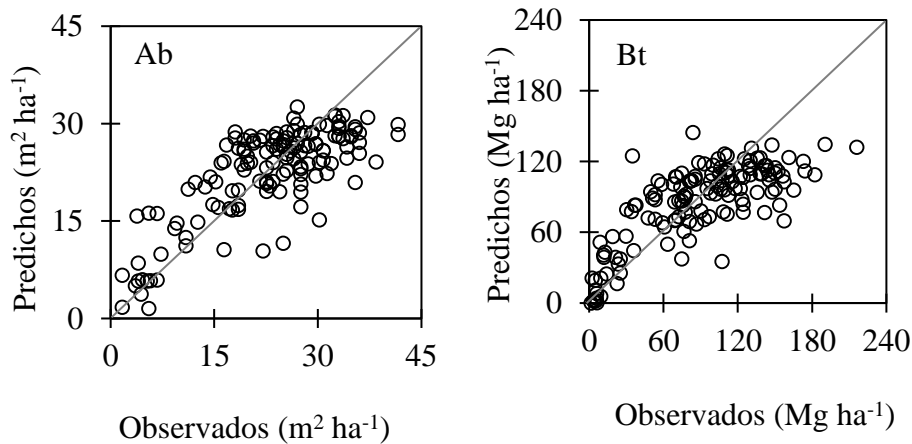
Cuadro 2.4. Modelos de regresión lineal múltiple para las variables de campo (VC), en Zacualtipán de Ángeles, Hidalgo.

VC	R^2_{adj}	REC M	Estructura del modelo (Valor de los parámetros)
Ab	0.66	5.82	$Ab = A_0 + A_1 \times NIR + A_2 \times NDVI + A_3 \times A + A_4 \times R$ $(A_0 = -0.606, A_1 = -15.533, A_2 = 3.483, A_3 = -30.917, A_4 = 55.104)$
Bt	0.66	32	$Bt = A_0 + A_1 \times NIR + A_2 \times NDVI + A_3 \times R + A_4 \times A$ $(A_0 = -5.173, A_1 = -41.816, A_2 = 7.715, A_3 = 207.015, A_4 = -74.645)$
Cob	0.27	35.03	$Cob = A_0 + A_1 \times NIR + A_2 \times A$ $(A_0 = 16.978, A_1 = -30.519, A_2 = -112.236)$
Vol	0.66	62.3	$Vol = A_0 + A_1 \times NIR + A_2 \times NDVI + A_3 \times R + A_4 \times A$ $(A_0 = -5.118, A_1 = -60.095, A_2 = 11.598, A_3 = 241.120, A_4 = -88.301)$
IAF	0.51	2.07	$IAF = A_0 + A_1 \times NIR + A_2 \times NDVI$ $(A_0 = 3.020, A_1 = -39.234, A_2 = 9.712)$

Ab: área basal; Bt: biomasa total; Cob: cobertura de copa; Vol: volumen; IAF: índice de área foliar; A: banda azul; V: banda verde; R: banda roja; NIR: banda del infrarrojo cercano, NDVI: Índice de vegetacion de diferencia normalizada; RECM: raíz del error cuadrático medio y A_0, A_1, A_2, A_3, A_4 : parámetros del modelo. Todos los parámetros fueron significativos (0.05).

Anteriormente Cruz-Leyva *et al.* (2010) ajustaron modelos de regresión para predecir variables similares en bosques de *P. patula* y *P. teocote* bajo manejo en Zacualtipan de Ángeles, Hidalgo, a partir de datos del sensor SPOT 5, logrando buenos ajustes para predecir Ab ($R^2_{Adj} = 0.96$). Lo anterior se explica debido a que en el modelo se incorporaron las variables cartográficas de altitud (msnm) y temperatura media anual, las cuales presentaron buena correlación con las variables espectrales. En otro estudio, Velazco-López *et al.* (2010) estimaron el IAF en bosques de *Abies religiosa* L. en la Reserva de la Biosfera Mariposa Monarca en Michoacan a partir de datos espectrales del sensor SPOT 4, obteniendo un ajuste menor ($R^2_{Adj} = 0.61$ y un RECM = 0.493). Aguirre-Salado *et al.* (2011) reportaron modelos de regresión lineal para predecir IAF y Cob con datos de SPOT 5 HRG en un área mas pequeña pero aledaña al área de estudio, logrando buenos ajustes utilizando únicamente la banda R: $R^2_{Adj} = 0.92$ en IAF y $R^2_{Adj} = 0.93$ en Cob.

Los modelos de regresión lineal múltiple seleccionados mediante STEPWISE presentan un ajuste gráfico adecuado, el comportamiento de los modelos al graficar observados vs. predichos es de una tendencia lineal creciente como se observa en la Figura 2.2 para cada una de las variables de campo.



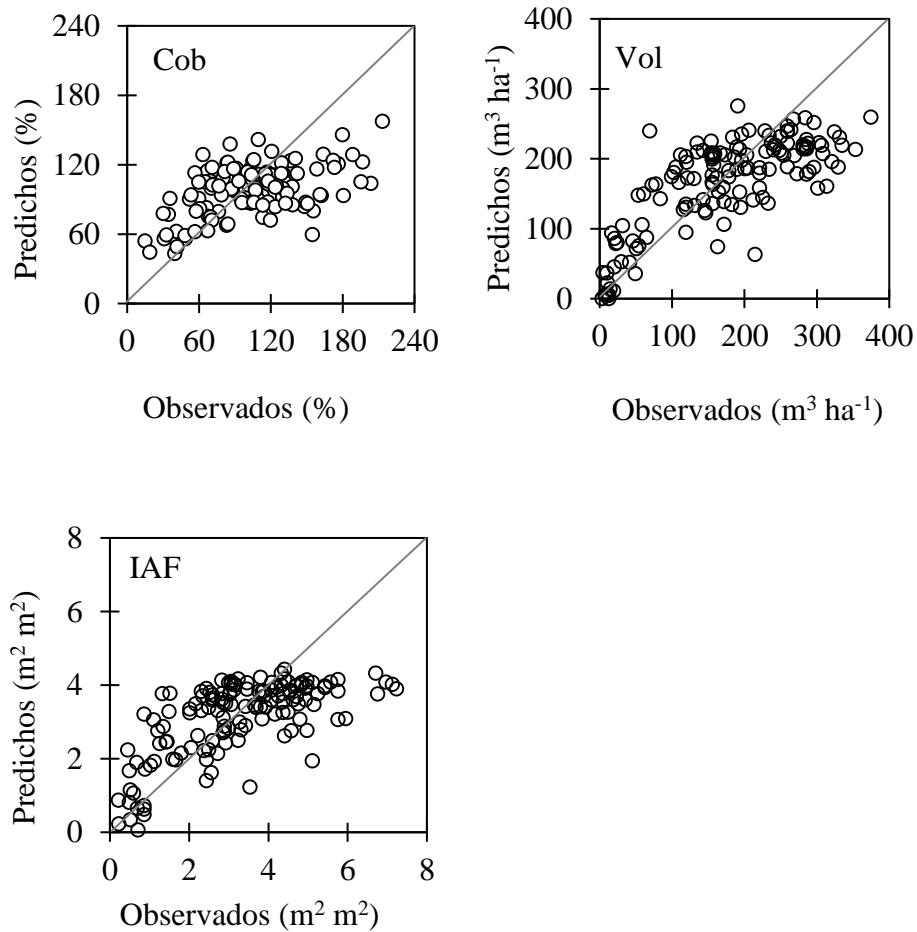


Figura 2.2 Diagrama de dispersión de observados vs. predichos de área basal (Ab), biomasa total (Bt), cobertura de copa (Cob), volumen (Vol) e índice de área foliar (IAF).

La RECM que presentaron los modelos de regresión lineal múltiple fueron de $5.82 \text{ m}^2 \text{ ha}^{-1}$ en Ab, 32 Mg ha^{-1} en Bt, 35.03% en Cob, $62.30 \text{ m}^3 \text{ ha}^{-1}$ en Vol y $2.07 \text{ m}^2 \text{ m}^{-2}$ en el IAF (Cuadro 2.4). Similares a los reportados por Aguirre-Salado *et al.* (2009) de $4.2 \text{ m}^2 \text{ ha}^{-1}$ en Ab y $57.71 \text{ m}^3 \text{ ha}^{-1}$ en Vol con modelos de regresión lineal múltiple para *P. patula* en Hidalgo. Mientras que Velazco-López *et al.* (2010) reportan un error de $0.493 \text{ m}^2 \text{ m}^{-2}$ para IAF con regresiones múltiples en bosques de oyamel en la Reserva de la Biosfera Mariposa Monarca en Michoacán. También Aguirre-Salado *et al.* (2011) reportaron errores de $0.50 \text{ m}^2 \text{ m}^{-2}$ en IAF y 5.71% Cob con modelos de regresión lineal simple para bosques de *P. patula* bajo manejo en Zacualtipán de Ángeles, Hidalgo. Las RECM reportadas con modelos de regresión lineal múltiple por Muñoz-Ruiz *et al.* (2014) fueron de $6.70 \text{ m}^2 \text{ ha}^{-1}$ en Ab, $41.45 \text{ m}^3 \text{ ha}^{-1}$ en Vol y 29.69% en Cob, para

los bosques templados y $8.5 \text{ m}^2 \text{ ha}^{-1}$ en Ab, 29 % en Cob y $79.14 \text{ m}^3 \text{ ha}^{-1}$ en Vol para los bosques mesófilos del estado de Hidalgo.

2.5.3 Estimación del inventario tradicional

El sistema de muestro simple aleatorio arrojó mayor precisión (error menor al 10 %), en las estimaciones de las variables dasométricas, obteniendo inventarios totales de $21,022.65 \text{ m}^2$ en Ab, $80,430.49 \text{ Mg}$ en Bt, 102.28 % en promedio de Cob, $156,932.22 \text{ m}^3$ en Vol y $3.24 \text{ m}^2 \text{ m}^{-2}$ en IAF (Cuadro 2.5).

Estos resultados son similares a los reportados por Ortiz-Reyes *et al.* (2015) para la misma zona de estudio pero estimados a partir de datos LiDAR. Estos autores estimaron el inventario en $20,787.40 \text{ m}^2$ de Ab, $104,037.86 \text{ Mg}$ de Bt, 131.54 % de Cob promedio y $163,436.48 \text{ m}^3$ de Vol en una superficie de 913 hectáreas (misma área que este estudio pero con una ligera variación de 13 ha). Para un área aledaña Aguirre-Salado *et al.* (2011) reportaron un valor promedio de 80 % de Cob y $6 \text{ m}^2 \text{ m}^{-2}$ de IAF en bosques maduros (20 - 24 años) de *P. patula*.

Las diferencias en las estimaciones de Cob y IAF descritas en los párrafos anteriores se deben parcialmente a las intervenciones silvícolas (cosechas totales o parciales en intensidades diferentes) que constantemente ocurren en el bosque sujeto de estudio. Adicionalmente, es importante mencionar que las estimaciones de Bt y Vol reportadas en este estudio se realizaron con modelos de regresión actualizados al 2015 para el área de estudio.

Cuadro 2.5. Estimación del inventario total para el bosque de *Pinus patula* bajo manejo en Zacualtipán de Ángeles, Hidalgo, mediante diferentes estrategias de análisis.

Variabes dasométricas	MSA	ME	MERaz	MEReg
IC -95	19618.05	18669.13	19093.20	19539.27
Ab (m²)	21022.65	21194.43	21022.65	20525.25
IC +95	22427.24	23719.72	22952.09	21511.23
Precisión	6.68%	11.91%	9.18%	4.80%

IC -95	72952.4	75232.61	72838.90	72550.70
Bt (Mg)	80430.49	89563.61	80430.49	77764.82
IC +95	72952.4	103894.60	88022.08	82978.95
Precisión	9.30%	16.00%	9.44%	6.70%
IC -95	95.64	100.04	95.39	94.89
Cob (%)	102.28	116.80	102.28	100.71
IC +95	108.93	133.57	109.17	106.54
Precisión	6.50%	14.35%	6.73%	5.79%
IC -95	142441.47	136472.96	142217.41	141690.38
Vol (m³)	156932.22	156579.84	156932.22	151740.36
IC +95	171422.97	176686.71	171647.03	161790.35
Precisión	9.23%	12.84%	9.38%	6.62%
IC -95	2.97	2.35	2.96	2.94
IAF (m² m²)	3.24	2.60	3.24	3.16
IC +95	3.51	2.85	3.51	3.38
Precisión	8.32%	9.63%	8.49%	6.90%

MSA: muestreo simple aleatorio; ME: muestreo estratificado; MERaz: muestreo con el estimador de razón; MEReg: muestreo con el estimador de regresión; IC+: intervalo de confianza superior; IC-: intervalo de confianza inferior.

2.5.4 Estimación del inventario total mediante los estimadores de razón y regresión

La mejor precisión en las estimaciones del inventario total para las variables de interés se logró mediante la estrategia de análisis denominada estimador de regresión, la cual incorpora variables auxiliares espectrales conocidas en toda el área de estudio; es decir, toma en cuenta la variación existente en campo. Esta precisión es considerablemente mayor que la lograda con el inventario tradicional (Cuadro 2.5).

2.5.5 Análisis comparativo de métodos de la estimación del inventario

Los inventarios totales mediante muestreo con el estimador de razón (MERaz) y muestreo con el estimador de regresión (MEReg) se encuentran dentro de la amplitud del intervalo de confianza del muestreo aleatorio. El MERaz es similar al obtenido mediante el MSA siendo este último el que tiene mayor precisión para la estimación de los inventarios totales de las variables de campo. El MEReg presentó valores de precisión 4.8 %, 6.7 %, 5.8 %, 6.6 %, 6.90% en la estimación de Ab, Bt, Cob, Vol e IAF respectivamente, siendo este tipo de muestreo el más conservador de todos los inventarios realizados (Cuadro 5). Las estimaciones del MEReg no son problema si las decisiones de manejo están basadas en estimaciones conservadoras y con ello la parte de sostenibilidad estaría asegurada (Aguirre-Salado *et al.*, 2009).

Los inventarios totales con mayor precisión son los estimados mediante los estimadores de razón y regresión debido a que utilizan variables auxiliares (en nuestro caso son las variables espectrales con mayor correlación con las variables dasométricas) y estas son conocidas en toda el área de estudio.

2.5.6 Distribución espacial de las variables en el área de estudio

El inventario mediante la regresión lineal múltiple presentó los valores más bajos en la raíz del error cuadrático medio siendo este escogido para el mapeo de las variables de área basal, biomasa total, cobertura de copa, volumen e índice de área foliar (Cuadro 2.4). Los resultados se presentan en las Figuras 2.3, 2.4, 2.5, 2.6, y 2.7. En los mapas generados se excluyeron poblaciones y áreas desprovistas de vegetación debido a que en estas áreas los valores de reflectancia son muy elevados y afectan la escala de las variables dasométricas por tal motivo no se presentan en los mapas.

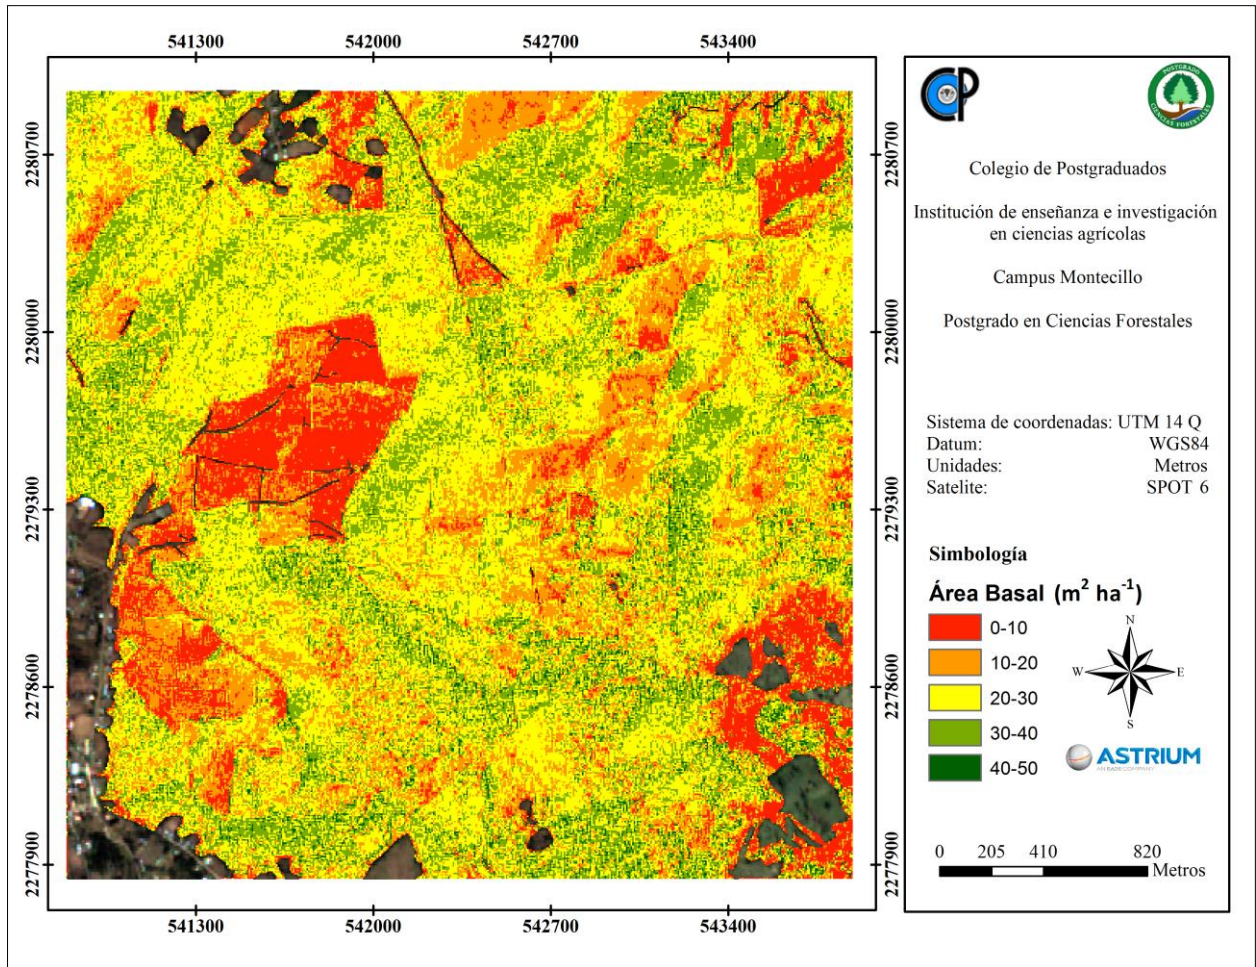


Figura 2.3. Área basal estimada mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo.

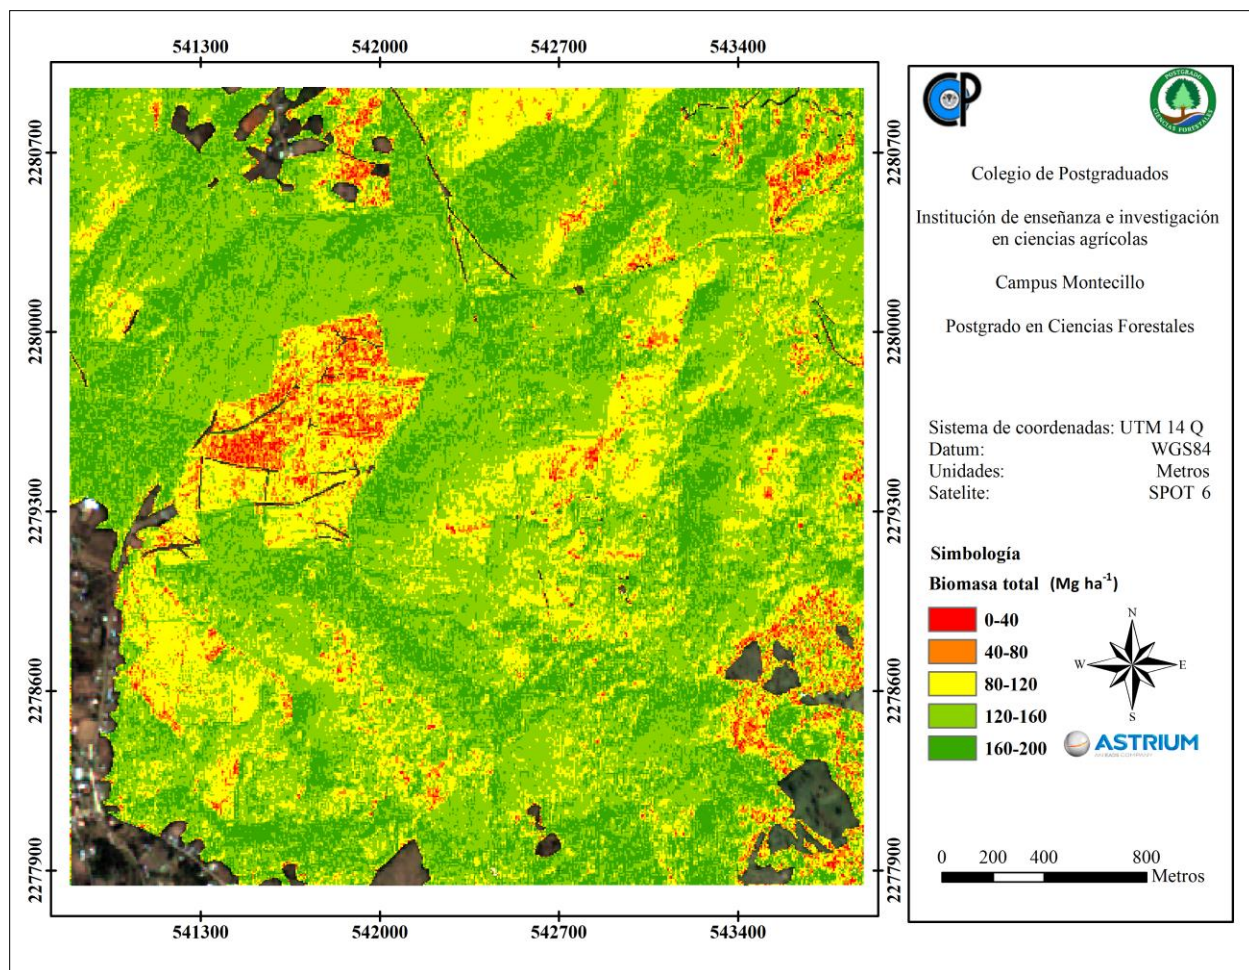


Figura 2.4. Biomasa total estimada mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo.

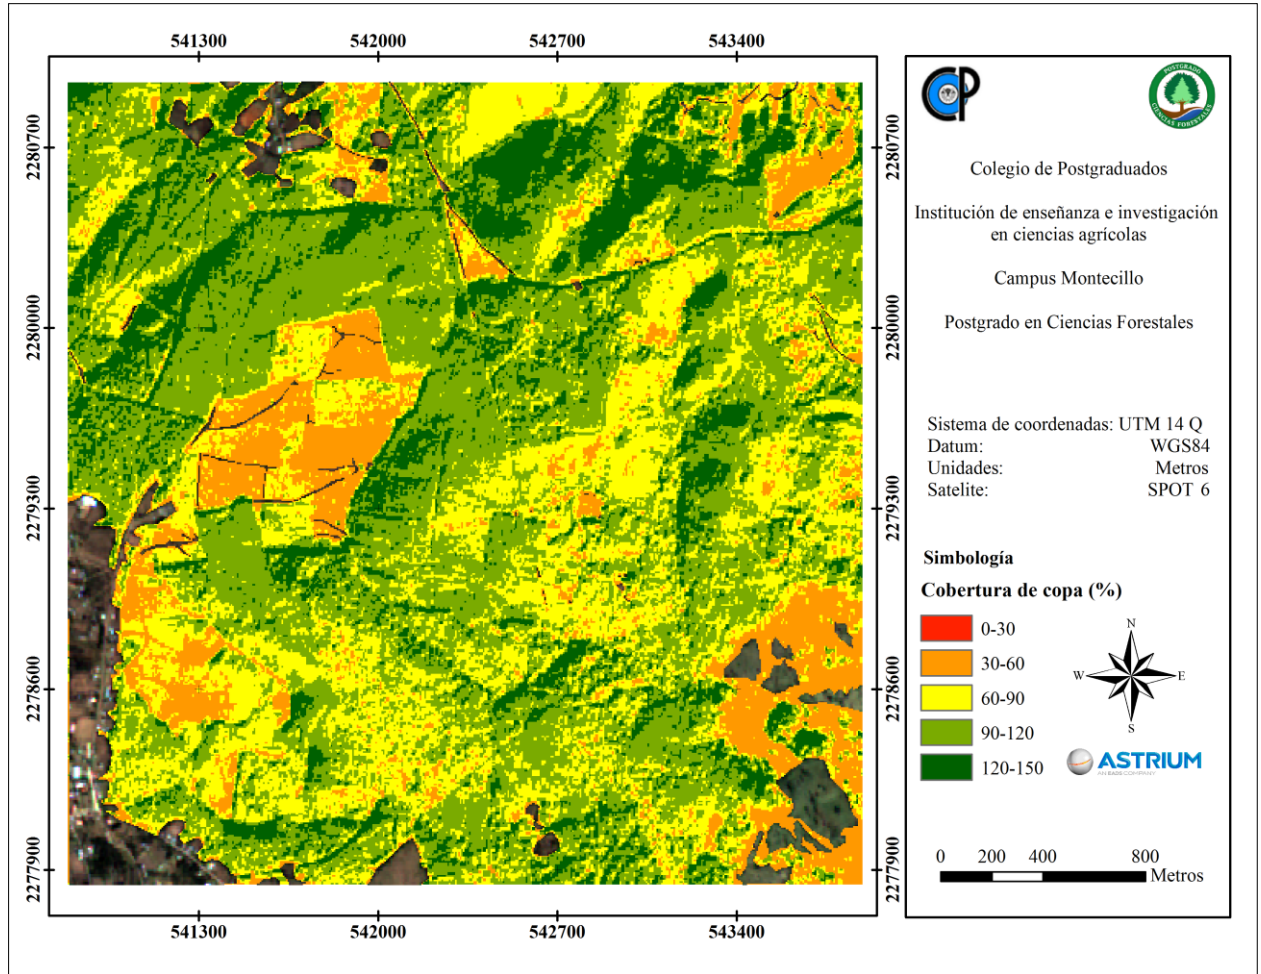


Figura 2.5. Cobertura de copa estimada mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo.

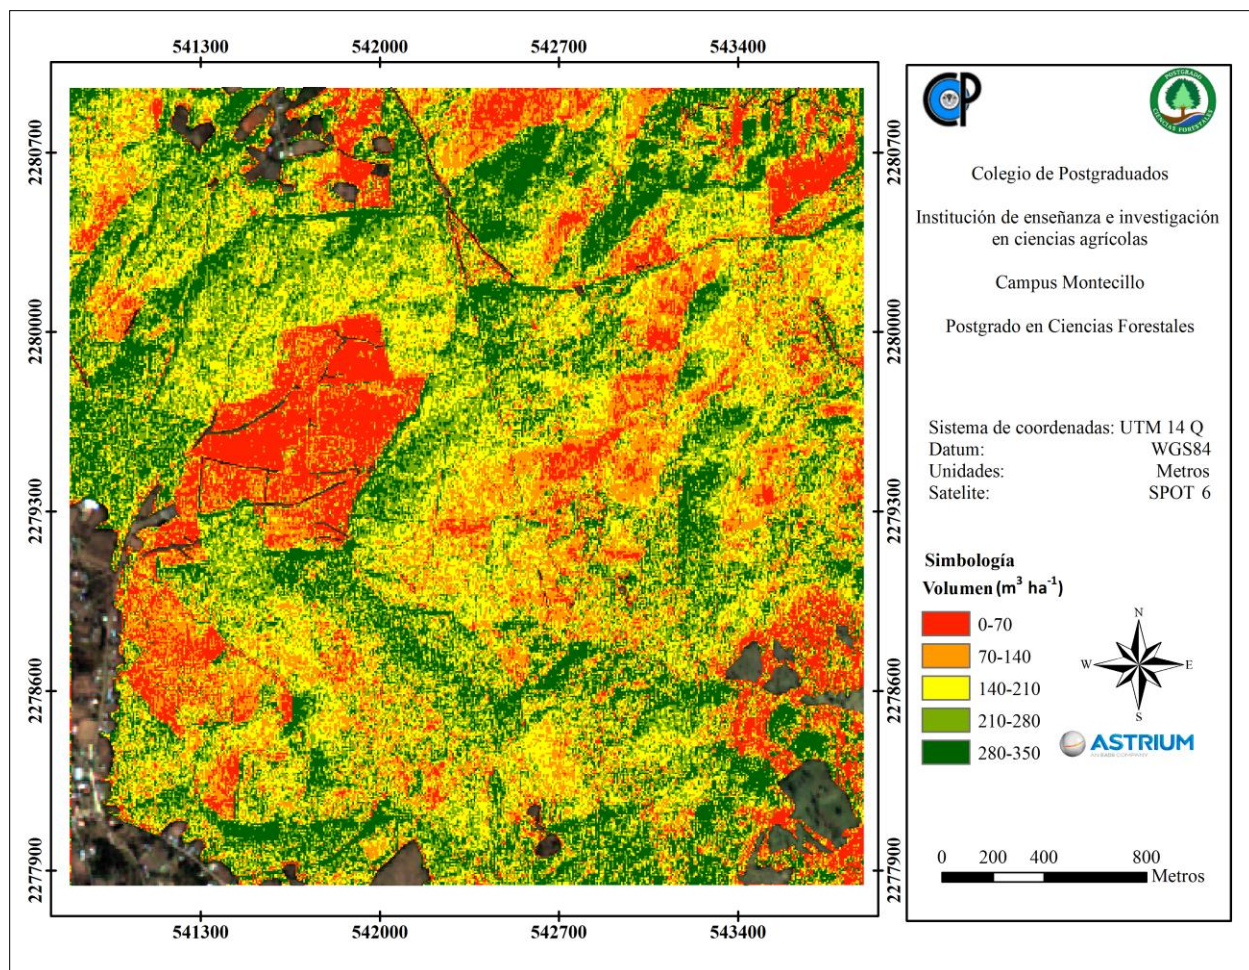


Figura 2.6. Volumen estimado mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo.

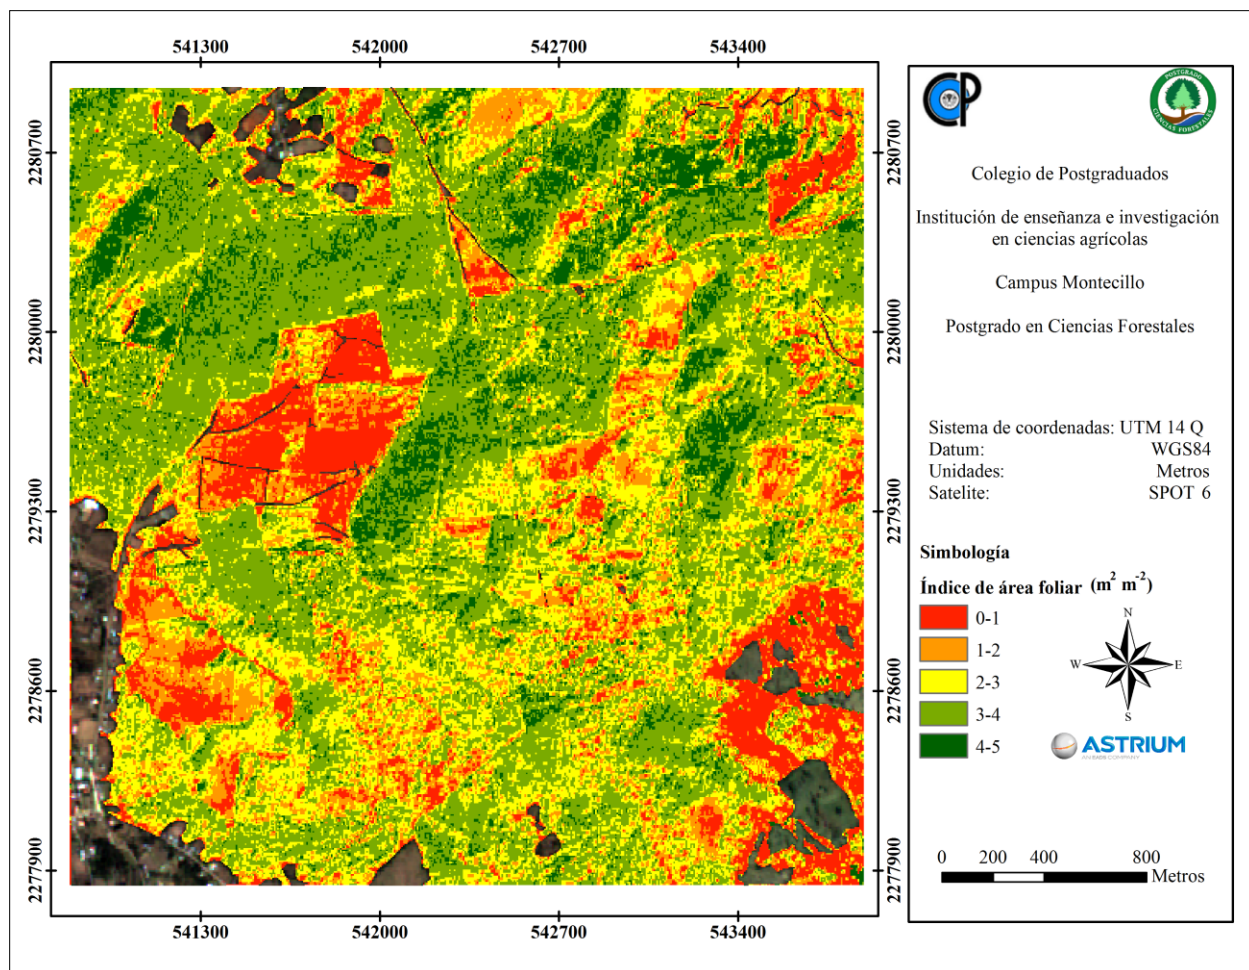


Figura 2.7. Índice de área foliar estimado mediante regresión lineal múltiple de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo.

2.6 CONCLUSIONES

La variable espectral del sensor SPOT 6 con mayor correlación con la mayoría de las variables de interés (área basal, biomasa total, cobertura de copa y volumen) fue la banda del infrarrojo cercano. Esta es una variable independiente constante en los modelos de regresión ajustados para la estimación de las variables anteriormente enunciadas. El índice de área foliar se correlacionó en mayor magnitud con la banda verde.

La cobertura de copa fue la variable con una R^2_{adj} baja. Los inventarios totales realizados con los estimadores de razón y regresión se localizan dentro del intervalo de confianza del inventario tradicional, siendo sus resultados muy confiables con una precisión mayor al inventario

tradicional. El estimador de regresión presentó un rango de precisión entre 4.48 % y 6.07 % en todas las variables de campo.

2.7 LITERATURA CITADA

Aguirre-Salado, C. A., J. R. Valdez-Lazalde, G. Ángeles-Pérez, H. M. de los Santos-Posadas, R. Haapanen, y A. I. Aguirre-Salado. 2009. Mapeo de carbono arbóreo aéreo en bosques manejados de pino patula en Hidalgo, México. *Agrociencia* 43: 209-220.

Aguirre-Salado, C. A., J. R. Valdez-Lazalde, G. Ángeles-Pérez, H. M. de los Santos-Posadas, y A. I. Aguirre-Salado. 2011. Mapeo del índice de área foliar y cobertura arbórea mediante fotografía hemisférica y datos Spot 5 HRG: Regresión y K-nn. *Agrociencia* 45: 105-119.

Ángeles-Pérez, G., J. R. Valdez-Lazalde, H. M. De los Santos-Posadas, P. Hernández-De la Rosa, A. Gómez-Guerrero, and A. Velázquez-Martínez. 2005. Carbon storage in managed *Pinus patula* forest in central Mexico. *The Int. For. Rev.* 7(5): 294.

Ángeles-Pérez G., C. Wayson, R. Birdsey, J. R. Valdez-Lazalde, H. M. de los Santos-Posadas, y F. O. Plascencia-Escalante. 2011. Sitios de monitoreo de flujo 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 Núm. 5.4.

ASTRIUM. 2013. SPOT 6 & SPOT 7 Imagery User Guide. Toulouse, Cedex 4 - France. 120 p.

Cano M., E. E., A. Velázquez M., J. J. Vargas H., C. Rodríguez F. y A. M. Fierros G. 2006. Área foliar específica en *Pinus patula*: efecto del tamaño del árbol, edad del follaje y posición en la copa. *Agrociencia* 30: 117-122.

Chuvieco E. 1995. *Fundamentos de teledetección espacial*. 2da. Ed. Ediciones Rialp, S.A. Madrid. 224 p.

CONAFOR (Comisión Nacional Forestal). 2011. *Inventario nacional forestal y de suelos: Manual y procedimientos para el muestreo de campo, Re-muestreo 2011*. 141 p.

- Cruz-Leyva, I. A., J. R. Valdez-Lazalde, G. Ángeles-Pérez, y H. M. de los Santos-Posadas. 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.
- INAFED (Instituto para el Federalismo y el Desarrollo Municipal). 2015. Secretaría de Gobernación. Enciclopedia de los municipios de México (EMM). Estado de Hidalgo: Zacualtipán de los Ángeles. Consultado el 16 de marzo del 2015. Página web. <http://www.inafed.gob.mx/work/enciclopedia/EMM13hidalgo/index.html>
- Jensen, J. R. 2007. *Remote Sensing of the Environment: An Earth Resource Perspective*. Prentice Hall. Second Edition. New Jersey, USA. 592 p.
- Figuroa N., C. M., G. Ángeles P., A. Velázquez M., y H. M. De los Santos P. 2010. Estimación de Biomasa en un bosque bajo manejo de *Pinus patula* Schltdl. et Cham. en Zacualtipán, Hidalgo. *Rev. Mex. Cien. For.* 1(1): 105-112.
- 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. *For. Sci.* 56(3): 313-326.
- Merem, E. C. and Y. A. Twumasi. 2008. Using geospatial information technology in natural resources management: the case of urban land management in West Africa. *Sensors* 8: 607-619.
- Muñoz-Ruiz, M. A., J. R. Valdez-Lazalde, H. M. de los Santos-Posadas, G. Ángeles-Pérez, y A. I. Monterroso-Rivas. 2014. Inventario y mapeo del bosque templado de Hidalgo, México mediante datos del satélite SPOT y de campo. *Agrociencia* 48: 847-862.
- Ortiz-Reyes, A. D., J. R. Valdez-Lazalde, H. M. de los Santos-Posadas, G. Ángeles-Pérez, F. Paz-Pellat, y T. Martínez-Trinidad. 2015. Inventario y cartografía de variables del bosque con datos derivados de LiDAR: comparación de métodos. *Madera y Bosque* 21(3): 111-128.

- Scheaffer, L.R., W. Mendenhall and L. Ott. 1986. Elementary survey sampling. PWS Publishers. USA. 320 p.
- Soriano-Luna, M. de los A., G. Ángeles-Pérez, T. Martínez-Trinidad, F. O. Plascencia-Escalante, y R. Razo-Zárate. 2015. Estimación de biomasa aérea por componentes estructurales en Zacualtipán, Hidalgo, México. *Agrociencia* 49: 423-438.
- Tanaka, S.; T. Takahashi, T. Nishizono, F. Kitahara, H. Saito, T. Iehara, E. Kodani, and Y. Awaya. 2014. Stand volume estimation using the k-NN technique combined with forest inventory data, satellite image data and additional feature variables. *Rem. Sens.* 7: 378–394.
- Valdez-Lazalde, J. R., M. de J. González-Guillén, y H. M. de los Santos-Posadas. 2006. Estimación de cobertura arbórea mediante imágenes satelitales multiespectrales de alta resolución. *Agrociencia* 40: 383-394.
- Velasco L., S., O. Champo J., Ma. L. España B., y F. Baret. 2010. Estimación del índice de área foliar en la reserva de la biósfera mariposa monarca. *Rev. Fitotec. Mex.* 33 (2): 169-174.

CAPÍTULO III

3. DATOS LiDAR Y SPOT 6 PARA INVENTARIO DE BOSQUES TEMPLADOS BAJO MANEJO

3.1 RESUMEN

El objetivo de esta investigación fue saber la relación de los datos derivados del sensor SPOT 6, sensor LiDAR, la combinación de los datos de estos dos sensores y de los datos del inventario de campo para estimar el inventario de las variables dasométricas área basal (Ab), biomasa total (Bt), cobertura de copa (Cob), volumen (Vol) e índice de área foliar (IAF), mediante tres métodos: (1) modelos de regresión lineal múltiple, (2) muestreo con estimadores de razón y regresión e (3) inventario tradicional en un bosque de *Pinus patula* bajo manejo en Zacualtipán, Hidalgo, México. La hipótesis nula fue que los datos derivados del sensor LiDAR son mejores que los derivados de SPOT6 y la combinación de los dos sensores son buenos para el inventario de las variables dasométricas. Se utilizó un total de 157 sitios con un tamaño de 400 m² por sitio, distribuidos mediante un muestreo sistemático bajo un diseño por conglomerados en una superficie de 900 hectáreas. En términos generales las métricas LiDAR presentaron mayor correlación con las variables de campo que las variables espectrales derivadas del sensor SPOT 6. Los modelos construidos solo con métricas LiDAR presentaron coeficientes de determinación (R²) que oscilan de 0.55 a 0.92. Contrariamente, los modelos construidos solo con variables espectrales del sensor SPOT 6 arrojaron valores de R² de 0.27 a 0.66. Los modelos de regresión ajustados utilizando como variables predictivas a una combinación de métricas LiDAR y variables espectrales resultan en una ganancia mínima en su capacidad predictiva; los valores de R² varían de 0.56 y 0.94. Dentro de los inventarios realizados con métricas LiDAR el estimador de regresión resultó ser la mejor estrategia con precisiones que oscilan de 3.16 a 5.65 %. Mientras que la mejor precisión lograda con variables espectrales también se logró con el estimador de regresión, presentando una precisión 4.80 a 6.90 %. El inventario total mediante el estimador de regresión con métricas LiDAR sobre estima ligeramente al estimado con el muestreo simple aleatorio, siendo lo contrario al realizado con variables espectrales el cual subestima ligeramente.

Palabras clave: SPOT 6, LiDAR, combinación, inventario.

LIDAR AND SPOT 6 DATA FOR TEMPERATE FORESTS INVENTORY UNDER MANAGEMENT

3.3 ABSTRACT

The objective of this research was to know the relation between data obtained of SPOT 6 sensor, LIDAR metrics, data combined from these two sensors and data of the field inventory. With this information the inventory of forest variables was estimated: basal area (A_b), total biomass (B_t), canopy cover (C_{ob}), volume (V_{ol}) and leaf area index (LAI), using three methods: (1) multiple linear regression models, (2) sampling with ratio and regression estimators and (3) traditional inventory in a forest of *Pinus patula* under management in Zacualtipan, Hidalgo, Mexico. The null hypothesis was that data derived from LiDAR sensor are better than derivatives of SPOT 6 and the combination of the two sensors are good for the inventory of dasometric variables. A total of 157 sites with a size of 400 m² per site, distributed through a systematic sampling under a cluster design on an area of 900 hectares were used. Overall the LiDAR metrics have a higher correlation with the field variables than spectral variables derived from SPOT 6 sensor. The models constructed only with LiDAR metrics showed determination coefficients (R^2) ranging from 0.55 to 0.92. Conversely, the models constructed only with spectral variables of SPOT 6 sensor returned values of R^2 from 0.27 to 0.66. Adjusted regression models using as variables predictors a combination of metrics LiDAR and spectral variables result in a minimal gain in its predictive capacity; R^2 values ranging from 0.56 and 0.94. Among the inventories carried out with LiDAR metrics, regression estimator proved to be the best strategy, with accuracies ranging from 3.16 to 5.65%. The best accuracy in spectral variables was also achieved with the regression estimator with an accuracy of 4.80 to 6.90%. The total inventory by regression estimator with metric LiDAR slightly overestimates the estimated simple random sampling, being the opposite to that performed with spectral variables, which slightly underestimates.

Keywords: SPOT 6, LiDAR, combination, inventory.

3.3 INTRODUCCIÓN

La cuantificación de los recursos forestales y el seguimiento de su dinámica, es importante para su adecuada gestión y ordenación. Dicha cuantificación tradicionalmente tiene como base un muestreo en campo, mediante el cual se obtienen estimaciones de variables dasométricas que permiten la cuantificación del recurso. Este proceso requiere de una inversión económica y de tiempo considerable.

La percepción remota, en sinergia con los sistemas de información geográfica ofrecen alternativas metodológicas basadas en el uso de imágenes ópticas y recientemente de sensores activos para lograr estimaciones de las variables dasométricas (Mora *et al.*, 2013; Muñoz-Ruiz *et al.*, 2014). Se ha sugerido la integración de datos multiespectrales o hiperespectrales con datos de sensores activos como LiDAR (Light Detection And Ranging) para estimar inventarios de variables dasométricas y su distribución espacial, así como la variación estructural de los bosques (Popescu *et al.*, 2004; Anderson *et al.*, 2008 y Man *et al.*, 2014).

LiDAR proporciona información sobre la estructura vertical de los bosques, mientras que las imágenes satelitales multiespectrales registran información sobre la estructura horizontal de los mismos; ambos conjuntos de datos son requeridos para la realización de estimaciones precisas de variables de densidad forestal (Man, *et al.*, 2015). Una de las ventajas de LiDAR es su capacidad de capturar información continua sobre la altura de la vegetación, variable imprescindible y de gran valía en la estimación de otras características dasométricas (Cabrera *et al.*, 2014).

El presente estudio tiene como propósito analizar la capacidad predictiva de datos integrados de LiDAR y espectrales del sensor SPOT 6 para estimar el inventario de las variables forestales área basal, biomasa, cobertura de copa, volumen maderable e índice de área foliar en un bosque de *Pinus patula* bajo manejo para la producción de madera, localizado en el municipio de Zacualtipán, Hidalgo, México.

3.4 MATERIALES Y MÉTODOS

3.4.1 Área de estudio

El área de estudio se localiza en el municipio de Zacualtipán de Ángeles, en el Estado de Hidalgo, México, entre las coordenadas 20°36'00" y 20°37'40" de latitud y -98°34'44" y -98°36'32" de longitud (Figura 3.1). Su dimensión es de 900 ha (3 x 3 km), conformadas en su mayoría por terrenos de cuatro ejidos: La Mojonera, Atopixco, El Reparó y Tzincoatlán, así como pequeñas áreas de los ejidos Santo Domingo, Zahuastipán y de pequeñas propiedades privadas (Ortiz-Reyes *et al.*, 2015). El uso principal de los terrenos que conforman el área de estudio es la producción de madera aserrada, leña y carbón bajo un sistema de manejo regular (coetáneo), específicamente utilizan el denominado método de desarrollo silvícola (Ángeles-Pérez, 1995).

La fisiografía del área comprende parte de la Sierra Alta Hidalguense y del Eje Neovolcánico, subprovincia Carso Huasteco y está conformada por pendientes, mesetas y cañones. El sustrato edáfico está representado por suelos Acrisol órtico (Ao), Luvisol crómico (Lc) y Feozem háplico (Hh). El clima existente es templado-húmedo [C(fm)w"b(e)g] con una estación marcada de lluvias entre junio y octubre. La precipitación media anual oscila entre 700 y 2050 mm (INAFED, 2015).

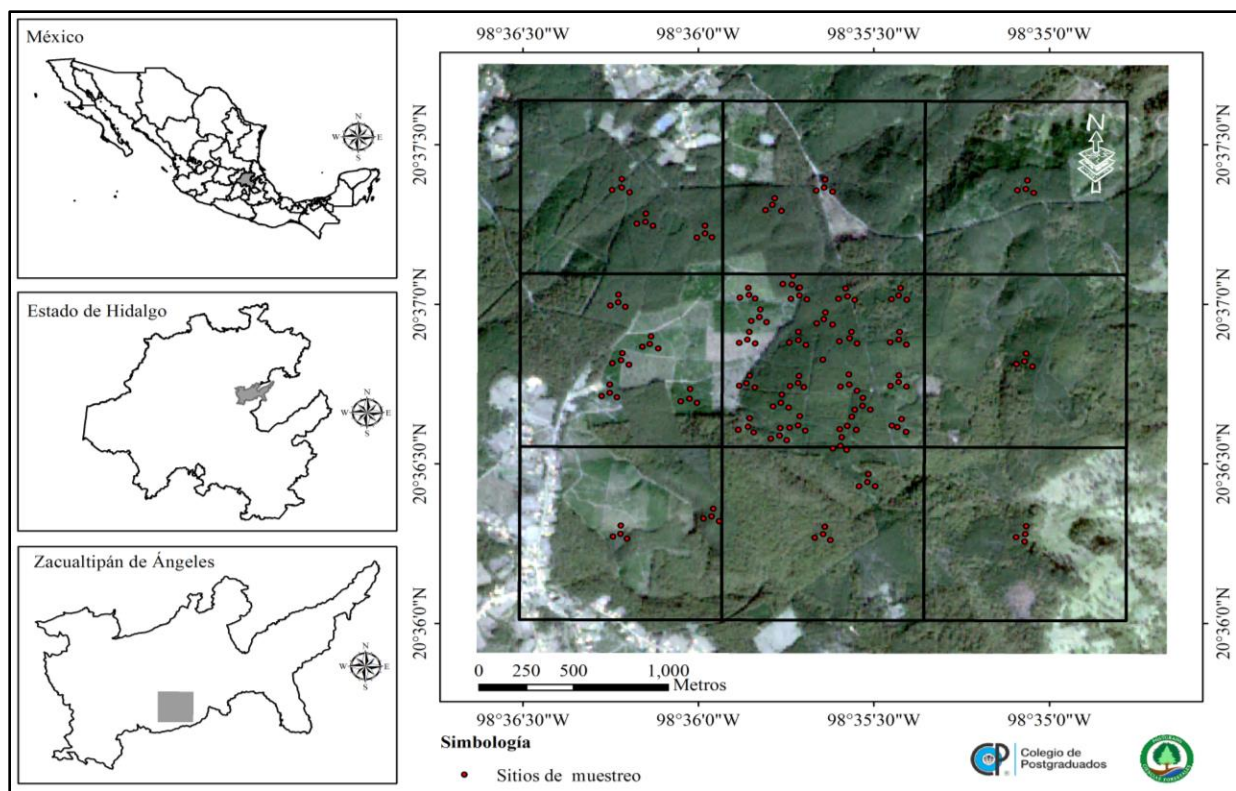


Figura 3.1. Ubicación del área de estudio en Zacualtípán de Ángeles, Hidalgo. Bosque de *Pinus patula* bajo manejo con fines de producción maderable.

El área de estudio ha sido manejada en las últimas décadas mediante el denominado Método de Desarrollo Silvícola (MDS), obteniendo rodales de *Pinus patula* mono-específicos, coetáneos, de coberturas y edades variables (Ángeles-Pérez, 1995), que van de 0 hasta 31 años. Existen también rodales sin intervención silvícola (rodales naturales) de 80 años de edad. A pesar de que los rodales intervenidos se caracterizan técnicamente como mono-específicos, presentan una proporción mínima de otras especies en una distribución variada: *P. teocote*, *Quercus laurina*, *Q. rugosa*, *Q. excelsa*, *Q. crassifolia*, *Q. affinis*, *Cornus disciflora*, *Viburnum spp.*, *Cleyera theaoides*, *Alnus jorullensis*, *Arbutus xalapensis*, *Prunus serotina*, *Symplocus spp.*, *Ternstroemia spp.*, *Vaccinium leucanthum*, principalmente (Ángeles-Pérez, 1995; Figueroa et al., 2010).

3.4.2 Muestreo en campo

Se utilizó un sistema de muestreo sistemático bajo un diseño por conglomerados (cada conglomerado se conforma de cuatro sitios de muestreo Figura 3.1), similar al propuesto por la

Comisión Nacional Forestal (CONAFOR) en el 2011 para el Inventario Nacional Forestal y de Suelos (INFyS), el tamaño de los sitios fue de 400 m², con un total de 157 sitios repartidos en una superficie de 900 hectáreas, ubicadas en un polígono de 3 x 3 km.

La campaña de campo para el inventario se realizó en mayo del 2013. Se midieron las variables siguientes en todos los árboles presentes en los sitios: diámetro normal (Dn a 1.30 metros), altura total del árbol (Ht) y diámetro de copa (Dc).

3.4.3 Estimación de las variables dasométricas a nivel bosque

Las variables medidas en campo sirvieron de base para estimar mediante modelos matemáticos el área basal (Ab), la biomasa total (Bt), la cobertura de copa (Cob), el volumen maderable (Vol) y el índice de área foliar (IAF) para árboles individuales. Las estimaciones a nivel árbol se sumaron para obtener valores por sitio con miras a combinarlos con métricas LiDAR y valores de reflectancia espectral obtenidos de una imagen del sensor SPOT 6.

El área basal (Ab) se estimó mediante la fórmula siguiente:

$$Ab = \frac{\pi}{40,000} \times Dn^2$$

Dónde: Ab en m²/árbol; Dn en cm; π es la constante matemática con valor de 3.1416.

La biomasa total (Bt) y el volumen de madera (Vol) se estimaron mediante los modelos ajustados por Cruz (2007) y Soriano *et al.* (2015) para el área de estudio (Cuadro 3.1).

Cuadro 3.1. Modelos para estimar Biomasa total (Bt) y Volumen (Vol) de *Pinus patula* y latifoliadas en Zacualtipán de Ángeles, Hidalgo.

Tipo de vegetación	Ecuación de biomasa total y volumen	Fuente
<i>Pinus patula</i>	$Bt = \exp(-4.554805) \times (Dn^2 \times Ht)^{1.047218}$	Soriano <i>et al.</i> (2015)
	$Vol = \exp(-10.4869) \times Dn^{1.7525} \times Ht^{1.31936}$	Soriano <i>et al.</i> (2015)

Latifoliadas	$Bt = \exp(-3.109407) \times (Dn^2 \times Ht)^{0.952688}$	Soriano <i>et al.</i> (2015)
	$Vol = 0.000082 \times Dn^{1.785782} \times Ht^{0.915827}$	Cruz, (2007)

Bt: biomasa total en kg; Vol: volumen en m³; Dn: diámetro normal en cm y Ht: altura total en m.

La cobertura de copa (Cob) se estimó considerando el diámetro promedio (DC), el cual resulta de medir el diámetro de copa en dos orientaciones (N-S y E-O), la fórmula utilizada es la siguiente:

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

Dónde: Cob en m² y DC en m.

El índice de área foliar (IAF) para *Pinus patula* se estimó mediante el modelo utilizado por Aguirre-Salado *et al.*, (2011):

$$IAF = \frac{\left(\sum_{i=1}^n \left(\frac{AFS}{2} \right) \right)}{A}$$

Dónde: IAF en m²/m², AFS: área foliar superficial en m²; A: área del sitio de muestreo (400 m²); e *i*: *i*-ésimo árbol del sitio de muestreo.

La estimación del AFS requiere conocer los valores de área foliar específica (AFE) y de biomasa seca foliar (BSF) para cada uno de los árboles que están dentro de cada uno de los sitios de muestreo (Aguirre-Salado *et al.*, 2011). Para ello se utilizaron los modelos que se indican en el Cuadro 3.2.

Cuadro 3.2. Modelos utilizados para la estimación del Índice de Área Foliar de *Pinus patula* en Zacualtipán de Ángeles, Hidalgo.

Variable	Modelo	Fuente
AFS	$AFS = AFE \times BSF$	Aguirre-Salado <i>et al.</i> (2011)
AFE	$AFE = 2.64 \times (9.5336 - 0.0758 \times Dn)$	Cano-Morales <i>et al.</i> (1996)
BSF	$BSF = \exp(-4.750974) \times (Dn^2 \times Ht)^{0.709796}$	Soriano <i>et al.</i> (2015)

AFS: área foliar superficial en m²; AFE: área foliar específica en m²/kg; BSF: biomasa seca foliar en kg; Dn: diámetro normal en cm y Ht: altura total en m.

3.4.4 Captura y pre-procesamiento de los datos LiDAR

Los datos LiDAR fueron capturados en mayo del 2013, con el sistema LiDAR Riegl-VQ480, el vuelo se realizó a una altitud de 397 m, con sobreposición de 50 % entre líneas de vuelo, ángulo de barrido de $\pm 15^\circ$, y frecuencia de pulso de 200 Khz. Con estas características se generó una “nube de puntos” con densidad mínima de 5 puntos por m². Esta fue preprocesada por el proveedor empleando el software E3De de Excelis y DTMaster de la compañía Inpho (Ortiz-Reyes *et al.*, 2015).

3.4.5 Análisis de datos LiDAR

El manejo y procesamiento de la nube de puntos LiDAR se realizó con el programa FUSION/LVD versión 3.21, el cual fue desarrollado por Robert J. McGaughey del Pacific Northwest Research Station del Departamento Forestal de los Estados Unidos (McGaughey, 2012). FUSION procesa datos vectoriales de LiDAR por medio de algoritmos orientados a mediciones forestales. De la nube de puntos LiDAR se obtuvieron 100 estadísticos que la describen, conocidos como métricas LiDAR y se clasifican en tres grupos: descriptivas, valores de percentiles de altura y métricas relacionadas al dosel (McGaughey, 2012, Ortiz-Reyes *et al.*, 2015).

Adicionalmente se agregaron dos variables probadas por Ortiz-Reyes *et al.* (2015) que resultaron de utilidad un propósito similar al de este estudio, y su expresión es la siguiente:

Cob_a (X101) = número total de retornos por encima de 2 metros/número total de retornos.

Cob_b (X1012) = número total de los primeros retornos por encima de 2 metros/número total de retornos.

3.4.6 Pre-procesamiento de la imagen SPOT 6

La imagen SPOT 6 utilizada fue capturada en enero de 2014. No fue posible obtener una imagen de fecha más cercana al periodo de obtención de los datos de campo debido a que las condiciones atmosféricas no fueron favorables. La imagen fue facilitada por la Estación de Recepción México Nueva Generación (ERMEX NG), tiene una resolución espacial de 6 m en multiespectral y tiene un nivel de proceso “Standard Ortho”, el cual consiste en una ortorectificación utilizando el modelo digital de elevación (MDE) generado por la “Shuttle Radar Topography Mission” (SRTM) de la NASA, con proyección y sistema de coordenadas UTM 14 N, datum y elipsoide WGS84 y con corrección radiométrica de 12 bits mediante el método del vecino más cercano (Astrium, 2013).

Los datos espectrales (números digitales) del sensor SPOT 6 fueron convertidos inicialmente a valores de radiancia y posteriormente de radiancia a valores de reflectancia en la aplicación ArcMap 10.2® mediante las fórmulas siguientes (Astrium, 2013):

$$L_b(p) = \frac{DC(p)}{GAIN(b)} + BIAS(b) \quad \text{y} \quad P_b(p) = \frac{\pi \times L_b(p)}{E_0(b) \times \cos(\theta_s)}$$

Dónde: $L_b(p)$: radiancia al tope de la atmosfera ($w sr^{-1} m^{-2} \mu m^{-1}$), $DC(p)$: número digital, $GAIN(b)$: coeficiente de calibración de la ganancia de cada banda, $BIAS(b)$ = factor multiplicativo de la banda, $P_b(p)$: reflectancia exoatmosférica adimensional, π : valor del número pi (3.1416), $E_0(b)$: radiancia exoatmosférica solar media de cada banda, $\cos(\theta_s)$ = coseno del ángulo cenital solar de la escena ($90^\circ - \theta_s$). Los valores de los parámetros fueron obtenidos de los metadatos de la imagen SPOT 6.

3.4.7 Obtención de variables espectrales

Las variables espectrales utilizadas fueron las cuatro bandas de la imagen SPOT 6: azul, verde, roja e infrarrojo cercano (Astrium, 2013). Adicionalmente se calculó el índice de vegetación de diferencias normalizadas (NDVI) debido a que en estudios anteriores ha mostrado tener una alta correlación con la cobertura de la vegetación (Aguirre-Salado *et al.*, 2011).

$$NDVI = \frac{NIR - R}{NIR + R}$$

Dónde: NVDI: índice de vegetación de diferencias normalizada, NIR: banda del infrarrojo cercano y R: la banda del rojo.

Los datos espectrales fueron extraídos como el promedio de la reflectancia correspondiente a cada uno de los sitios de muestreo establecidos en campo, para ello se utilizó el algoritmo denominado **Zonal Statistics as Table** del programa ArcMap 10.2®.

3.4.8 Análisis estadístico: correlación, ajuste de modelos de regresión

Inicialmente se realizó un análisis de correlación de Pearson para identificar las asociaciones entre variables de campo (variables dependientes) y los datos derivados de sensores remotos (SPOT y LiDAR variables predictivas). Una vez identificadas las variables predictivas relevantes se ajustaron modelos de regresión lineal múltiple, mismos que permitieron estimar el inventario de las variables dasométricas de interés a nivel pixel.

La correlación de Pearson se realizó con el paquete estadístico SAS 9.0 (SAS, Institute Inc. 2002®), para identificar las variables espectrales y métricas LiDAR con mayor correlación con las variables de campo (Ab, Bt, Cob, Vol e IAF).

Se utilizó el método de regresión por pasos (STEPWISE) para identificar modelos de regresión lineal múltiple adecuados para estimar, a nivel sitio, el área basal, la biomasa total, la cobertura de copa, el volumen y el índice de área foliar. Los valores de campo a nivel sitio se

transformaron calculando la raíz cuadrada de su valor original con el fin de minimizar la varianza y obtener una distribución normal.

La estructura de los modelos es la siguiente:

$$Y=\beta_0+\beta_1 X_1+\beta_2 X_2+\dots+\beta_n X_n+\varepsilon_i$$

Dónde Y: es la variable del bosque de interés (variable de campo: Ab, Bt, Cob, Vol e IAF); X_n : son las variables espectrales con valores de reflectancia y/o métricas LiDAR; β_n : son parámetros de regresión; ε_i : es el error estadístico.

Los indicadores de bondad de ajuste considerados para seleccionar los mejores modelos fueron el coeficiente de determinación ajustado (R^2_{adj}), la Raíz del Error Cuadrático Medio (RECM) y un valor de probabilidad de rechazo (p) menor al 0.05 para cada uno de los parámetros de regresión.

3.4.9 Estimación del inventario total de manera tradicional

La estimación del inventario de las variables Ab, Bt, Cob, Vol e IAF mediante métodos tradicionales. Se realizó considerando dos tipos de muestreo: el simple aleatorio y el estratificado (Scheaffer *et al.*, 1986). El método de muestreo con mejor precisión fue el utilizado como punto de comparación para los resultados de los inventarios realizados con percepción remota. El criterio para la selección del mejor inventario tradicional e inventario con percepción remota fue la precisión lograda en las estimaciones.

3.4.10 Estimación del inventario total mediante los estimadores de razón y regresión

Dada la alta correlación que existe entre las variables de campo con algunas métricas LiDAR (Ortiz-Reyes *et al.*, 2015), estas sirvieron de base para estimar mediante interpolación los valores de las variables para toda el área de estudio, a nivel de pixel, a través de estimadores de razón y de regresión (Scheaffer *et al.*, 1986; Valdez-Lazalde *et al.*, 2006).

Los estimadores de razón y regresión se apoyan en una variable auxiliar conocida (X, para nuestro caso métricas LiDAR) para predecir la variable de interés (Y, para el caso Ab, Vol, etc.). Para el estimador de razón se estimó la proporción de Y respecto a X, donde la razón (R) es una constante poblacional definida como $R = \frac{\bar{Y}}{\bar{X}}$. Mientras que el estimador de regresión utiliza una la variable auxiliar de la forma siguiente $\mu_y = \bar{Y} + b (\mu_x - \bar{X})$ para estimar medias totales de Y, donde μ_x es la media poblacional de X; mientras que, \bar{Y} , \bar{X} y b son los parámetros estimados a partir de la muestra (Scheaffer *et al.*, 1986).

3.5 RESULTADOS Y DISCUSIÓN

Para facilitar la lectura de los párrafos subsecuentes, a continuación se definen las métricas LiDAR que resultaron relevantes en el análisis realizado. X4 = segundo retorno contado por encima de 3 m, X5 = tercer retorno contado por encima de 3 m, X13 = elevación mínima, X18 = varianza de elevación, X26 = momento L1 en elevación, X36 = P20 percentil 20 en elevación, X40 = P50 percentil 50 en elevación, X63 = momento L2 en intensidad, X68 = kurtosis en el momento de intensidad, X78 = P70 intensidad, X79 = 75 intensidad, X89 = porcentaje de los primeros retornos por encima de la media, X90 = porcentaje de los primeros retornos por encima de la moda, X91 = porcentaje de todos los retornos por encima de la media, X93 = (todos los retornos por encima de la media)/(total de los primeros retornos)*100, X101 = recuento del rendimiento total por encima de 3/recuento del rendimiento total, X102 = número total de los primeros retornos encima de 3/recuento del rendimiento total.

3.5.1 Correlación de las variables de campo vs métricas LiDAR y variables espectrales

La correlación de las variables de campo y las métricas LiDAR es positiva; a mayor valor de la variable de densidad el valor de la métrica LiDAR aumenta, siendo lo contrario para las variables espectrales, las cuales presentaron una tendencia decreciente (Cuadro 3.3). Por razones de espacio solo se presentan las métricas LiDAR con mayor correlación con las variables de campo.

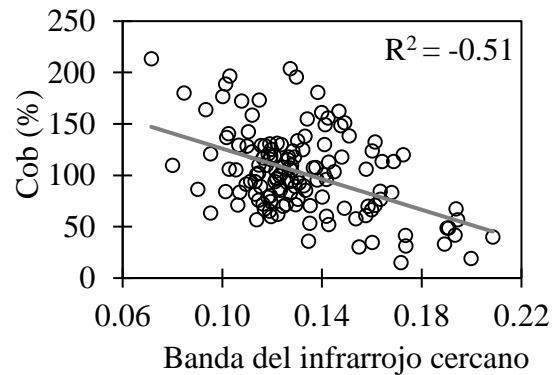

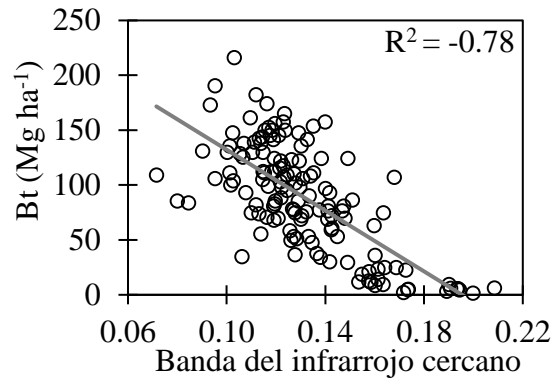



Cuadro 3.3. Matriz de correlación de las variables de campo vs métricas LiDAR y variables espectrales.

Métrica LiDAR y variables espectrales	VARIABLES DE CAMPO				
	Ab (m ² ha ⁻¹)	Bt (Mg ha ⁻¹)	Cob (%)	Vol (m ³ ha ⁻¹)	IAF (m ² m ²)
X89	0.90	0.86	0.55	0.89	0.84
X91	0.92	0.90	0.60	0.92	0.82
X102	0.82	0.73	0.75	0.72	0.67
A	-0.65	-0.53	-0.44	-0.55	-0.61
V	-0.71	-0.65	-0.49	-0.66	-0.65
R	-0.55	-0.42	-0.37	-0.45	-0.56
NIR	-0.74	-0.78	-0.51	-0.78	-0.64
NDVI	-0.65	-0.71	-0.47	-0.71	-0.54

Ab: área basal, Bt: biomasa total, Cob: cobertura de copa, Vol: volumen, IAF: índice de área foliar, X89: porcentaje de los primeros retornos por encima de la media, X91: porcentaje de todos los retornos por encima de la media, X102: número total de los primeros retornos encima de 3 m/recuento del rendimiento total, A: banda azul, V: banda verde, R: banda roja, NIR: banda del infrarrojo cercano y NDVI: Índice de vegetación de diferencia normalizada; todas las correlaciones fueron altamente significativas (0.001).

En términos generales las métricas LiDAR presentaron mayor correlación con las variables de campo que las variables espectrales derivadas del sensor SPOT 6. Específicamente, la métrica X91 resultó estar altamente correlacionada con las variables Ab, Bt y Vol teniendo valores de 0.92, 0.90 y 0.92 respectivamente, mientras que la Cob y el IAF presentaron su correlación más significativa con las métricas X102 y X89 con valores de 0.75 y 0.84 respectivamente (Cuadro 3.3 y Figura 3.2).

Respecto a las variables espectrales, las correlaciones más altas con las variables Ab, Bt, Cob y Vol fueron la banda NIR teniendo valores de -0.74, -0.78, -0.51 y -0.78 respectivamente. Mientras el IAF presentó la mayor correlación en la banda V, con un valor de -0.65 (Cuadro 3.3 y Figura 3.2).



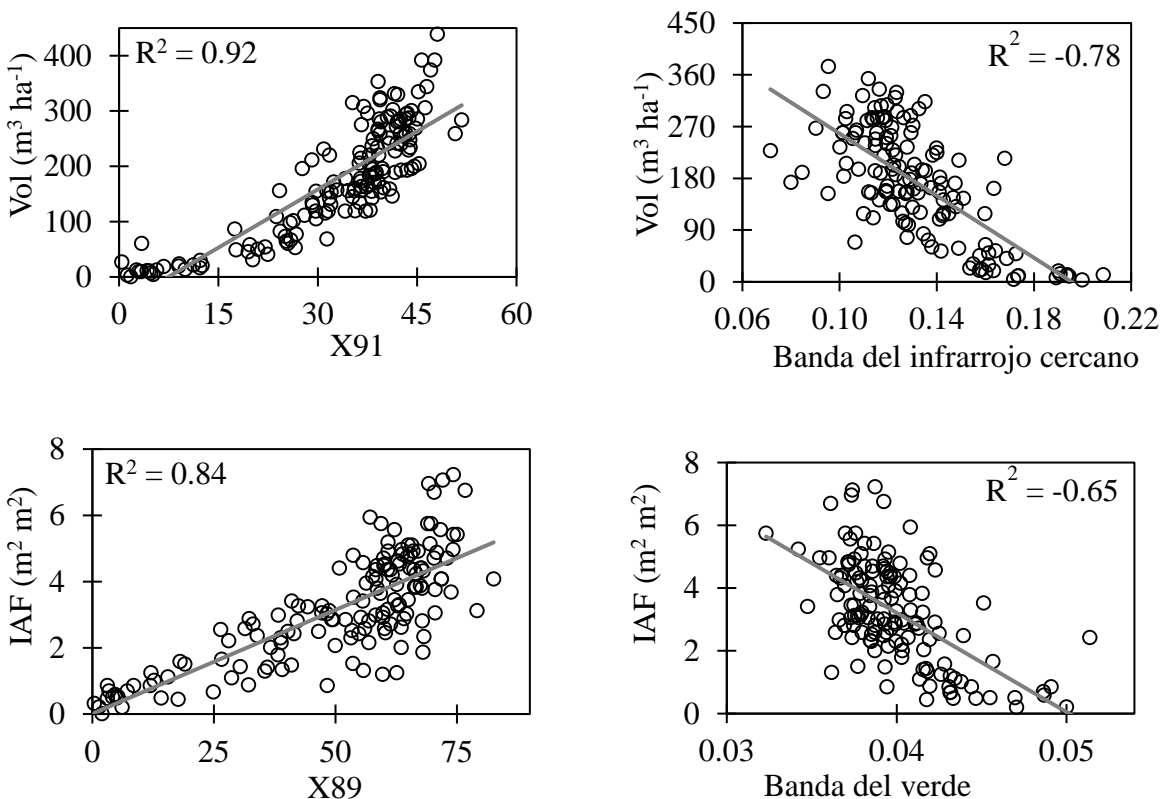


Figura 3.2. Correlación de las variables de campo vs métricas LiDAR (gráfica en columna izquierda) y variables espectrales (gráfica en columna derecha) para un bosque de *Pinus patula* bajo manejo en Zacualtipán de Ángeles, Hidalgo. X89: porcentaje de los primeros retornos por encima de la media, X91: porcentaje de todos los retornos por encima de la media, X102: número total de los primeros retornos encima de 3/recuento del rendimiento total. Ab: área basal; Bt: biomasa total; Cob: cobertura de copa; Vol: volumen; IAF: índice de área foliar.

Las métricas encontradas con mayor correlación respecto a las variables de campo son las mismas que reportó Ortiz-Reyes *et al.* (2015), con valores de 0.89, 0.81 y 0.80 para Ab, Bt y Vol respectivamente con la métrica X91. Mientras la Cob presentó su correlación más significativa con la métrica X102 con un valor de 0.76.

La asociación negativa entre las variables espectrales y las variables dasométricas de interés es similar a las reportadas por Aguirre-Salado *et al.* (2011) para un bosque de *P. patula* bajo manejo, ubicado en un área aledaña al área que cubre el presente estudio. Estos autores

reportaron una correlación entre la banda NIR y el IAF de -0.92 y de -0.93 para la Cob, mientras que la banda V presentó una correlación de -0.40 y -0.39 en IAF y Cob respectivamente.

Otro estudio basado en imágenes SPOT realizado por Muñoz-Ruiz *et al.* (2014) en los bosques templados del estado de Hidalgo reportó que la banda V se correlacionó “mediana” con el Ab (-0.43), con la Cob (-0.31) y con el Vol (-0.47), mientras que la correlación encontrada en la banda NIR fue muy baja: 0.03 con Ab, 0.15 con Cob y 0.03. Estos mismos autores reportaron correlaciones medianas entre la banda V y datos dasométricos correspondientes a bosques mesófilos de montaña; obtuvieron valores del coeficiente de Pearson de -0.46 en Ab, 0.08 en Cob y -0.44 en Vol. La banda NIR se correlacionó como sigue con el Ab, la Cob y el Vol: -0.36, -0.17 y -0.33 respectivamente.

Los valores medianos de correlación entre las variables dasométricas de interés y las variables espectrales, encontrados en este estudio, es debido a dos situaciones presentes en los sitios de muestreo: (1) no se tomaron sitios con suelo desnudo con la finalidad de proporcionar al modelo tantas observaciones con tendencia a cero (Aguirre-Salado *et al.*, 2011) y (2) la alta diversidad de especies que tienen los sitios, ya que la banda NIR capta la estructura de las células y humedad (Jensen, 2007).

3.5.2 Estimación de variables mediante modelos de regresión

La alta correlación que presentaron las métricas LiDAR X89, X91 y X102 sugirió considerarlas para formar parte de los modelos de regresión lineal múltiple para la predicción de las variables de campo. Los modelos construidos solo con métricas LiDAR presentaron coeficientes de determinación (R^2) que oscilan de 0.55 a 0.92 (Cuadro 3.4). Contrariamente, los modelos construidos solo con variables espectrales del sensor SPOT 6 arrojaron valores de R^2 de 0.27 a 0.66 (Cuadro 3.5). Los modelos de regresión ajustados utilizando como variables predictivas a una combinación de métricas LiDAR y variables espectrales resultan en una ganancia mínima en su capacidad predictiva; los valores de R^2 varían de 0.56 y 0.94 (Cuadro 3.6).

Cuadro 3.4. Modelos de regresión lineal múltiple ajustados con métricas LiDAR para la estimación de las variables de campo (VC), en un bosque de *Pinus patula* bajo manejo en Zacualtipán de Ángeles, Hidalgo.

VC	R ² _{adj}	RECM	Valor de los parámetros	Estructura del modelo
Ab (m ² ha ⁻¹)	0.86	4.53	A ₀ =0.283	Ab = A ₀ +A ₁ ×X ₉₁ +A ₂ ×X ₁₀₂
			A ₁ =0.015	
			A ₂ =0.390	
Bt (Mg ha ⁻¹)	0.84	27.54	A ₀ =0.204	Bt = A ₀ +A ₁ ×X ₉₁ +A ₂ ×X ₈₉ +A ₃ ×X ₉₃
			A ₁ =0.082	
			A ₂ =-0.047	
			A ₃ =0.020	
Cob (%)	0.55	33.95	A ₀ =3.791	Cob = A ₀ +A ₁ ×X ₁₀₂
			A ₁ =15.654	
Vol (m ³ ha ⁻¹)	0.92	34.11	A ₀ =11.850	Vol = A ₀ +A ₁ ×X ₁₃ +A ₂ ×X ₄₀ +A ₃ ×X ₁₀₂ +A ₄ ×X ₈₉
			A ₁ =-4.018	
			A ₂ =0.103	
			A ₃ =1.927	
			A ₄ =0.014	
IAF (m ² m ²)	0.82	0.77	A ₀ =2.884	IAF = A ₀ +A ₁ ×X ₈₉ +A ₂ ×X ₇₈ +A ₃ ×X ₄
			A ₁ =0.027	
			A ₂ =-0.000075	
			A ₃ =-0.0002	

Ab: área basal; Bt: biomasa total; Cob: cobertura de copa; Vol: volumen; IAF: índice de área foliar; R²_{adj}: coeficiente de determinación; RECM: raíz del error cuadrático medio; A₀, A₁, A₂, A₃, A₄: parámetros del modelo, todos los parámetros fueron significativos (0.05); X₄, X₁₃, X₄₀, X₇₈, X₈₉, X₉₁, X₉₃, y X₁₀₂ métricas LiDAR.

Cuadro 3.5. Modelos de regresión lineal múltiple ajustados únicamente con variables espectrales del sensor SPOT 6 para la estimación de las variables de campo (VC), en un bosque de *Pinus patula* bajo manejo en Zacualtipán de Ángeles, Hidalgo.

VC	R ² _{adj}	RECM	Valor de los parámetros	Estructura del modelo
Ab (m² ha⁻¹)	0.66	5.82	A ₀ = -0.606 A ₁ = -15.533 A ₂ = 3.483 A ₃ = -30.917 A ₄ = 55.104	Ab = A ₀ +A ₁ ×NIR+A ₂ ×NDVI+A ₃ ×A+A ₄ ×R
Bt (Mg ha⁻¹)	0.66	32	A ₀ = -5.173 A ₁ = -41.816 A ₂ = 7.714 A ₃ = 207.015 A ₄ = -74.645	Bt = A ₀ +A ₁ ×NIR+A ₂ ×NDVI+A ₃ ×R+A ₄ ×A
Cob (%)	0.27	35.03	A ₀ = 16.978 A ₁ = -30.519 A ₂ = -112.236	Cob = A ₀ +A ₁ ×NIR+A ₂ ×A
Vol (m³ ha⁻¹)	0.66	62.3	A ₀ = -5.118 A ₁ = -60.095 A ₂ = 11.598 A ₃ = 241.120 A ₄ = -88.301	Vol = A ₀ +A ₁ ×NIR+A ₂ ×NDVI+A ₃ ×R+A ₄ ×A
IAF (m² m²)	0.51	2.07	A ₀ = 3.020 A ₁ = -39.234 A ₂ = 9.712	IAF = A ₀ +A ₁ ×NIR+A ₂ ×NDVI

Ab: área basal; Bt: biomasa total; Cob: cobertura de copa; Vol: volumen; IAF: índice de área foliar; NDVI: Índice de vegetación de diferencia normalizada; R²_{adj}: coeficiente de determinación; RECM: raíz del error cuadrático medio; A₀, A₁, A₂, A₃, A₄: parámetros del modelo, todos los parámetros fueron significativos (0.05). A: banda azul; V: banda verde; R: banda roja y NIR: banda del infrarrojo cercano.

Dada la alta correlación de la banda NIR con las variables de campo, esta fue considerada como variable independiente para ajustar modelos de regresión lineal múltiple. Los mejores ajustes se lograron para los modelos que predicen las variables Ab, Bt y Vol con una R^2_{Adj} de 0.66 cada una de ellas y con un error de $5.82 \text{ m}^2 \text{ ha}^{-1}$, 32 Mg ha^{-1} y $62.3 \text{ m}^3 \text{ ha}^{-1}$ respectivamente. Contrariamente, la Cob presentó el ajuste mas bajo con una R^2_{Adj} de 0.27 y un error de 35.03 %. El IAF presentó una R^2_{Adj} de 0.51 y un error de $2.07 \text{ m}^2 \text{ m}^2$ (Cuadro 3.5).

Anteriormente Cruz-Leyva *et al.* (2010) ajustaron modelos de regresión para predecir variables similares en bosques de *P. patula* y *P. teocote* bajo manejo en Zacualtipan de Ángeles, Hidalgo, a partir de datos del sensor SPOT 5, logrando buenos ajustes para predecir Ab ($R^2_{Adj} = 0.96$). Lo anterior se explica debido a que en el modelo se incorporaron variables cartográficas, las cuales presentaron buena correlación con las variables espectrales. En otro estudio, Velazco-López *et al.* (2010) estimaron el IAF en bosques de *Abies religiosa* L. en la Reserva de la Biosfera Mariposa Monarca localizada en Michoacan, México a partir de datos espectrales del sensor SPOT 4, obteniendo un ajuste menor ($R^2_{Adj} = 0.61$ y un RECM = 0.493). Aguirre-Salado *et al.* (2011) reportaron modelos de regresión lineal para predecir IAF y Cob con datos de SPOT 5 HRG en un área mas pequeña pero aledaña a la del área de estudio, logrando buenos ajustes utilizando únicamente la banda R: $R^2_{Adj} = 0.92$ en IAF y $R^2_{Adj} = 0.93$ en Cob.

Los modelos generados con una combinación de métricas LiDAR y variables espectrales presentaron buenos ajustes teniendo valores de 0.56 a 0.94 en R^2_{adj} , siendo el modelo para predecir Cob el único que requirió mayor cantidad de variables predictoras y que incorporo una variable espectral diferente (NDVI) respecto a las de mas variables de campo que ocuparon la banda del R (Cuadro 3.6).

Cuadro 3.6. Modelos de regresión lineal múltiple ajustados con métricas LiDAR y variables espectrales para estimación de las variables de campo (VC), en un bosque de *Pinus patula* bajo manejo en Zacualtupán de Ángeles, Hidalgo.

VC	R ² _{adj}	RECM	Valores de los parámetros	Estructura del modelo
Ab (m² ha⁻¹)	0.87	4.78	A ₀ =1.108	Ab = A ₀ +A ₁ ×X ₈₉ +A ₂ ×X ₁₀₂ +A ₃ ×X ₃₆ +A ₄ ×BR
			A ₁ =0.006	
			A ₂ =0.567	
			A ₃ =0.012	
			A ₄ =-14.668	
Bt (Mg ha⁻¹)	0.94	9.83	A ₀ =1.114	Bt = A ₀ +A ₁ ×X ₁₀₁ +A ₂ ×X ₄₀ +A ₃ ×X ₉₀ +A ₄ ×BR
			A ₁ =1.284	
			A ₂ =0.085	
			A ₃ =0.003	
			A ₄ =-22.569	
Cob (%)	0.56	10.04	A ₀ =18.845	Cob = A ₀ +A ₁ ×X ₁₀₂ +A ₂ ×X ₆₃ +A ₃ ×X ₆₈ +A ₄ ×X ₁₈ +A ₅ ×NDVI
			A ₁ =11.389	
			A ₂ =-0.003	
			A ₃ =-20.593	
			A ₄ =0.033	
Vol (m³ ha⁻¹)	0.92	13.06	A ₀ =1.985	Vol = A ₀ +A ₁ ×X ₉₁ +A ₂ ×X ₂₆ +A ₃ ×BR
			A ₁ =0.043	
			A ₂ =0.097	
			A ₃ =-36.585	
			A ₄ =-6.055	
IAF (m² m²)	0.82	1.79	A ₀ =4.424	IAF = A ₀ +A ₁ ×X ₈₉ +A ₂ ×X ₅ +A ₃ ×X ₇₉ +A ₄ ×BR
			A ₁ =0.024	
			A ₂ =-0.0004	
			A ₃ =-0.00007	
			A ₄ =-29.599	

Ab: área basal; Bt: biomasa total; Cob: cobertura de copa; Vol: volumen; IAF: índice de área foliar; R²_{adj}: coeficiente de determinación; RECM: raíz del error cuadrático medio; A₀, A₁, A₂, A₃, A₄ y A₅: parámetros del modelo, todos los parámetros fueron significativos (0.05); X₅, X₁₈, X₂₆, X₃₆, X₄₀, X₆₃, X₆₈, X₇₉, X₈₉, X₉₀, X₉₁, X₁₀₁ y X₁₀₂; R: banda roja; NDVI: Índice de vegetación de diferencia normalizada.

Los valores de R^2 correspondientes a los modelos para predecir las variables de Bt y Vol son elevados en comparación con los obtenidos por Popescu *et al.* (2004) quienes reportaron valores de 0.83 en modelos de volumen con un error de $47.9 \text{ m}^3 \text{ ha}^{-1}$ y un valor de R^2 igual a 0.82 en modelo para predecir biomasa con un error de 29 Mg ha^{-1} en bosques de pino, mientras que en los bosques de hoja caduca obtuvieron ajustes de 0.39 con un error de $52.84 \text{ m}^3 \text{ ha}^{-1}$ en volumen y ajuste de 0.33 y error de 44.41 Mg ha^{-1} en biomasa. Los ajustes fueron obtenidos con la combinación de métricas LiDAR e imágenes ATLAS (NASA's Airborne Terrestrial Land Applications Scanner con resolución de 4 m) en el sureste de la provincia de Piedtmont, Virginia, USA.

Al norte de las regiones rocosas en Idaho, USA, Jensen *at al.* (2008) reportan un ajuste en IAF de 0.79 y un error de $0.69 \text{ m}^2 \text{ m}^2$ en bosques de coníferas. El ajuste fue realizado utilizando métricas LiDAR y variables espectrales derivadas del sensor SPOT 5 (resolución 10 m). Otro ejemplo de la combinación de métricas LiDAR e imágenes SPOT 5 en la estimación de biomasa es el reportado por Qisheng (2012) para bosques de *Picea crassifolia* en las montañas Qilian, provincia Gansu en China Occidental. El ajuste obtenido fue de 0.78 con un error de 17.14 Mg ha^{-1} .

Los ajustes obtenidos en este estudio son similares a los obtenidos por Mora *et al.* (2013) en bosques de coníferas localizados en el territorio de Yukon, Canadá. Estos autores utilizaron métricas LiDAR y variables espectrales derivadas de los sensores QuickBird-2 (0.6 m) y WorldView (0.5 m), teniendo ajustes de 0.92 (R^2) con un error de 22.2 Mg ha^{-1} en biomasa y 0.94 (R^2) con un error de $9.6 \text{ m}^3 \text{ ha}^{-1}$ en volumen.

El ajuste (R^2_{adj}) y el error (RECM) obtenidos para todas las variables de campo motivo del presente estudio fue mejor cuando se utilizaron variables predictivas las métricas LiDAR respecto al uso único de variables espectrales del sensor SPOT 6. El ajuste logrado para los modelos que combinan las métricas LiDAR y las variables espectrales fue similar al obtenido utilizando solo las métricas LiDAR para Ab, Bt, Cob, Vol e IAF. Cabe destacar que el error disminuyó considerablemente para las variables Cob, Vol e IAF, no siendo favorable para la variable de Ab para la cual el error aumentó ligeramente. La Bt es la única variable que mejoró considerablemente su ajuste (en 10 %) pasando de 0.84 a 0.94, al utilizar como variables

predictivas la combinación de métricas LiDAR y variables espectrales. Al igual que las de más variables, la combinación de métricas LiDAR y variables espectrales disminuyó considerablemente el error de los modelos ajustados (Cuadro 3.7). Cabe señalar que en la combinación de métricas LiDAR y variables espectrales el ajuste no mejora en todas las variables pero el error sí es reducido considerablemente.

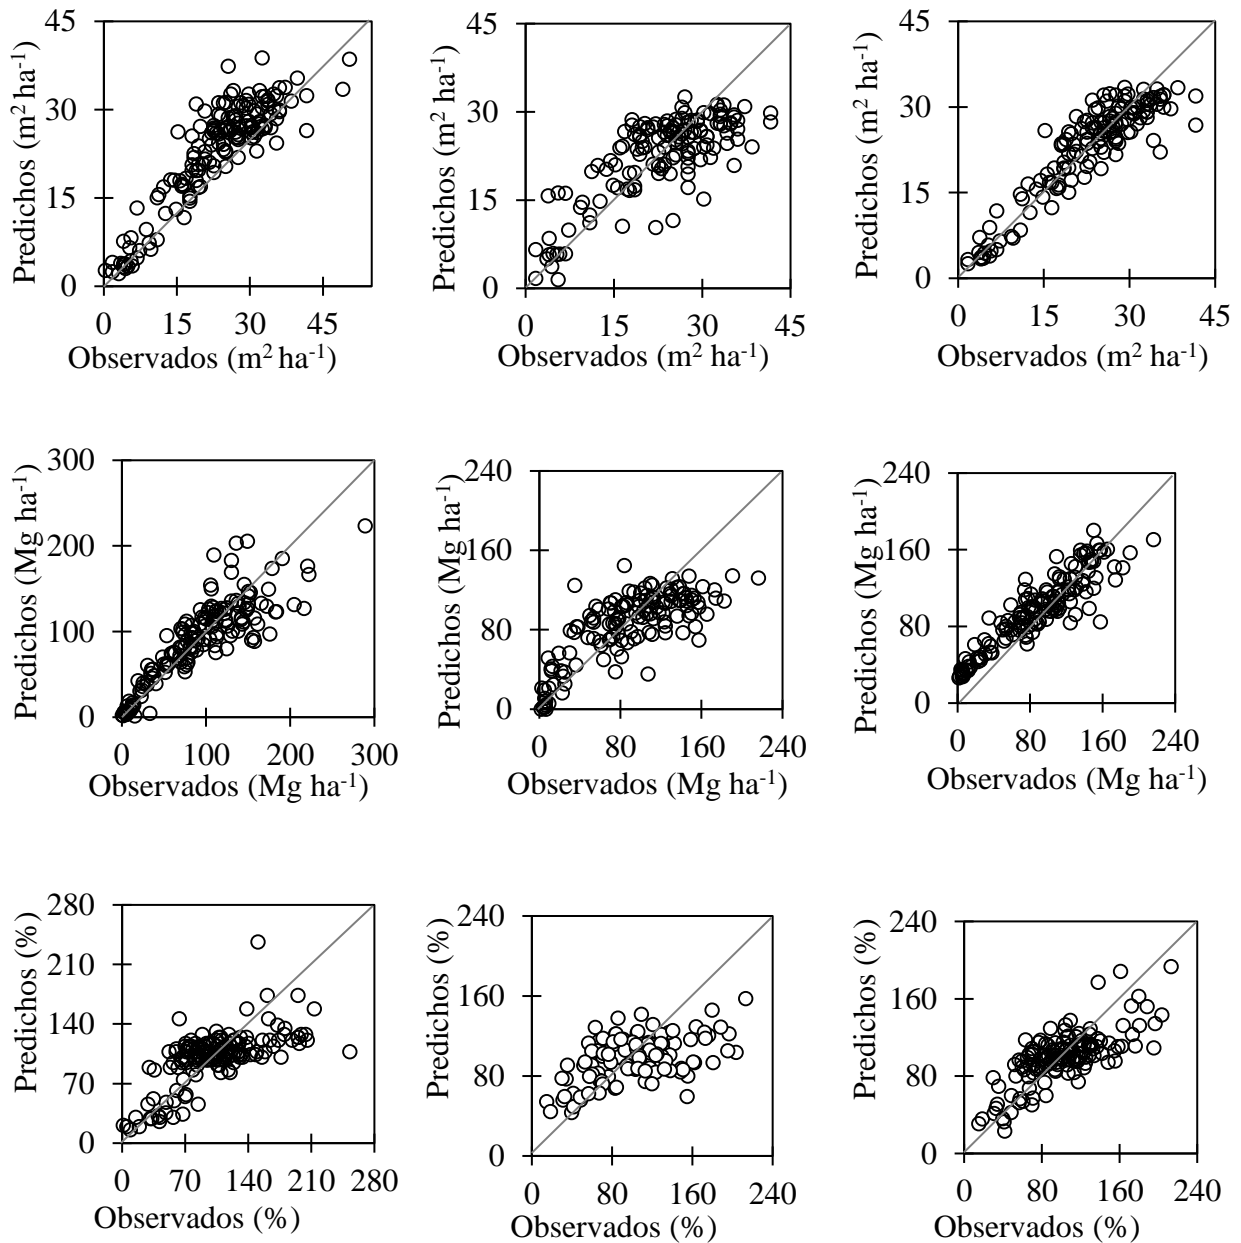
Resultados similares fueron reportados por Jensen *et al.* (2008) para estimar la variable IAF, donde el ajuste con métricas LiDAR fue de 0.75 y un error de 0.75 m² m² y en su combinación de variables el ajuste fue de 0.79 con un error de 0.69 m² m². Otro ejemplo es el obtenido por Qisheng (2012), al intentar predecir la variable a partir de métrica LiDAR obtuvo un ajuste (R²) de 0.74 y un error de 18.64 Mg ha⁻¹; cuando combinó variables LiDAR y variables espectrales derivadas de SPOT 5 el valor del parámetro de ajuste se incremento a 0.78 y el error disminuyó a 17.14 M ha⁻¹.

Cuadro 3.7. Comparación de parámetros de ajuste de los modelos de regresión lineal múltiple que utilizan sólo métricas LiDAR, sólo variables espectrales del sensor SPOT 6 y la combinación de variables de ambos sensores.

Variable de campo	Métricas LiDAR		Variables espectrales SPOT 6		Combinación	
	R ² _{adj}	RECM	R ² _{adj}	RECM	R ² _{adj}	RECM
Ab (m² ha⁻¹)	0.86	4.53	0.66	5.82	0.87	4.78
Bt (Mg ha⁻¹)	0.84	27.54	0.66	32	0.94	9.83
Cob (%)	0.55	33.95	0.27	35.03	0.56	10.04
Vol (m³ ha⁻¹)	0.92	34.11	0.66	62.3	0.92	13.06
IAF (m² m²)	0.82	0.77	0.51	2.07	0.82	1.79

Ab: área basal; Bt: biomasa total; Cob: cobertura de copa; Vol: volumen; IAF: índice de área foliar; R²_{adj}: coeficiente de determinación; RECM: raíz del error cuadrático medio.

Los modelos de regresión lineal múltiple seleccionados mediante STEPWISE presentan un ajuste gráfico adecuado. La figura 3.3 presenta el comportamiento de los modelos al graficar observados vs predichos. Se observa una tendencia lineal creciente para cada una de las variables de campo, mediante las métricas LiDAR, variables espectrales del sensor SPOT 6 y la combinación de estas dos.



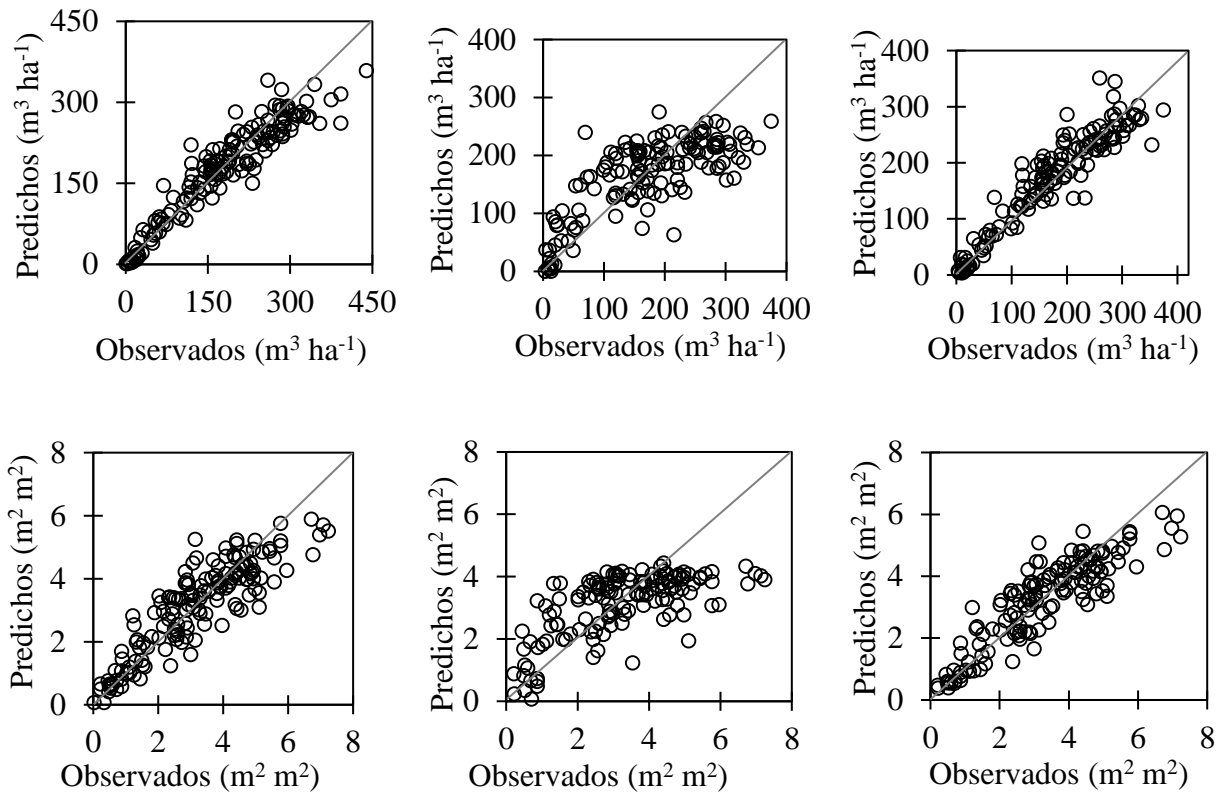


Figura 3.3. Diagrama de dispersión de valores observados vs valores predichos de área basal (Ab), biomasa total (Bt), cobertura de copa (Cob), volumen (Vol) e índice de área foliar (IAF). Las estimaciones obtenidas utilizando datos LiDAR, dato SPOT 6 y la combinación de ambos se encuentran en las columnas de la izquierda, centro y derecha respectivamente.

3.5.3 Estimación del inventario total mediante los estimadores de razón y regresión auxiliados con métricas LiDAR y variables espectrales

El sistema de muestro simple aleatorio arrojó mayor precisión (error menor al 10 %), en las estimaciones de las variables dasométricas, obteniendo inventarios totales de 21,022.65 m² en Ab, 80,430.49 Mg en Bt, 102.28 % en promedio de Cob, 156,932.22 m³ en Vol y 3.24 m² m⁻² en IAF (Cuadro 3.8). Se tomó en cuenta el muestreo simple aleatorio como punto de comparación para las demás estrategias implementadas para la estimación de los inventarios.

Cuadro 3.8. Estimaciones del inventario total (900 ha) mediante la forma tradicional, métricas LiDAR y variables espectrales derivadas del sensor SPOT 6 para el bosque de *Pinus patula* bajo manejo en Zacualtipán de Ángeles, Hidalgo.

Variables	Muestreo tradicional		Métricas LiDAR		Variables espectrales	
	MSA	ME	ML-MERaz	ML-MEReg	VE-MERaz	VE-MEReg
IC-95	19618.05	18669.13	20496.20	20754.17	19093.20	19539.27
Ab	21022.65	21194.43	21173.05	21431.33	21022.65	20525.25
IC+95	22427.24	23719.72	21849.90	22108.48	22952.09	21511.23
Precisión	6.68%	11.91%	3.20%	3.16%	9.18%	4.80%
IC-95	72952.4	75232.61	79209.74	77852.17	72838.90	72550.70
Bt	80430.49	89563.61	84096.83	82512.62	80430.49	77764.82
IC+95	87908.58	103894.60	88983.93	87173.07	88022.08	82978.95
Precisión	9.30%	16.00%	5.81%	5.65%	9.44%	6.70%
IC-95	95.64	100.04	98.18	99.32	95.39	94.89
Cob	102.28	116.80	103.51	104.66	102.28	100.71
IC+95	108.93	133.57	108.85	110.00	109.17	106.54
Precisión	6.50%	14.35%	5.15%	5.10%	6.73%	5.79%
IC-95	142441.47	136472.96	153031.27	153310.23	142217.41	141690.38
Vol	156932.22	156579.84	161162.77	160928.59	156932.22	151740.36
IC+95	171422.97	176686.71	169294.28	168546.96	171647.03	161790.35
Precisión	9.23%	12.84%	5.05%	4.73%	9.38%	6.62%
IC-95	2.97	2.35	3.01	3.11	2.96	2.94
IAF	3.24	2.60	3.17	3.27	3.24	3.16
IC+95	3.51	2.85	3.33	3.42	3.51	3.38
Precisión	8.32%	9.63%	4.98%	4.84%	8.49%	6.90%

Ab: área basal en m²; Bt: biomasa total en Mg; Cob: cobertura de copa %; Vol: volumen en m³; IAF: índice de área foliar en m² m⁻²; MSA: muestreo simple aleatorio; ME: muestreo estratificado; ML-MERaz: muestreo con el estimador de razón, utilizando métricas LiDAR; ML-MEReg: muestreo con el estimador de regresión, utilizando métricas Lidar; VE-MERaz: muestreo con el estimador de razón, utilizando variables espectrales; VE-MEReg: muestreo con el estimador de regresión, utilizando variables espectrales; IC+: intervalo de confianza superior; IC-: intervalo de confianza inferior.

Dentro de los inventarios realizados con métricas LiDAR el estimador de regresión resultó ser la mejor estrategia con precisiones que oscilan de 3.16 a 5.65 % (Cuadro 3.8). Mientras que la mejor precisión lograda con variables espectrales también se logró con el estimador de regresión, presentando una precisión 4.80 a 6.90 %.

El estimador de regresión incorpora todas las variables auxiliares conocidas y de cobertura continua (abarca toda el área de estudio), tomando en cuenta la variación encontrada en campo siendo evidente que con las variables auxiliares (variables espectrales y métricas LiDAR) en la estimación de los inventarios totales la precisión es mucho mayor comparada con el inventario tradicional (Cuadro 3.8) (Aguirre-Salado *et al.*, 2009 y Cruz-Leyva *et al.*, 2010).

3.5.4 Análisis comparativo de métodos de la estimación del inventario total

Las métricas LiDAR se caracterizan por tener variables representativas espacialmente en X, Y y Z; este rasgo agrega información nueva al análisis, de manera que mejora la correlación comparada con el análisis realizado con el uso de información espectral basada en dos dimensiones, y registra rasgos de clorofila, humedad y albedo, en general (Cabrera *et al.*, 2014; Man, *et al.*, 2015).

El inventario total mediante el estimador de razón y regresión auxiliado con métricas LiDAR y variables espectrales se encuentran dentro de la amplitud del intervalo de confianza del muestreo aleatorio. El inventario total mediante el estimador de regresión con métricas LiDAR sobre estima ligeramente al obtenido con el muestreo simple aleatorio, siendo lo contrario al realizado con variables espectrales el cual subestima ligeramente (Cuadro 3.8).

Las estimaciones del inventario total mediante el estimador de regresión con variables espectrales no son problema si las decisiones de manejo están basadas en estimaciones conservadoras, y con ello la parte de sostenibilidad estaría asegurada (Aguirre-Salado, *et al.*, 2009).

El inventario total con mayor precisión es el obtenido con el estimador de regresión auxiliado con métricas LiDAR. Esto es porque las métricas LiDAR tiene una representatividad espacial en X, Y y Z, en la nube de puntos LiDAR generada, con ello teniendo representatividad en la estructura horizontal y vertical de los bosques. En este sentido, el elemento tridimensional obtenido por las métricas LiDAR e incorporado como variable auxiliar representa un aumento en las correlaciones que se obtienen sólo con las variables espectrales (2D).

3.6 CONCLUSIONES

La correlación más alta (positiva) se obtuvo con las métricas LiDAR, siendo la variable X91 (porcentaje de todos los retornos por encima de la media) la más correlacionada con las variables de área basal, biomasa total y volumen. Mientras las variables espectrales presentaron correlaciones altas pero negativas en todas las variables de campo, destacando la banda del infrarrojo cercano como la variable espectral que se correlacionó más con las variables de área basal, biomasa total y volumen.

Las métricas LiDAR son eficaces para la estimación de las variables de campo, teniendo buenos ajustes y errores relativamente bajos. Mientras que las variables espectrales, también presentaron buenos ajustes pero errores ligeramente más elevados respecto a las métricas LiDAR. El uso combinado de métricas LiDAR y variables espectrales presentó ajustes similares a los obtenidos utilizando sólo métricas LiDAR, sin embargo, merece la pena resaltar que el error de estimación se redujo considerablemente.

Dentro de las estrategias implementadas para la estimación del inventario total, el estimador de regresión presentó la mejor precisión para todas las variables, destacando que el uso de variables auxiliares mejora las estimaciones y reduce la amplitud de los intervalos de confianza, esto debido a que la variable auxiliar implementada es conocida en su totalidad y continua en el área de estudio.

De las variables auxiliares implementadas (métricas LiDAR y variables espectrales) en los estimadores de razón y regresión, las métricas LiDAR son las que más aportan precisión a los inventarios totales realizados.

3.7 LITERATURA CITADA

- Aguirre-Salado, C. A., J. R. Valdez-Lazalde, G. Ángeles-Pérez, H. M. de los Santos-Posadas, R. Haapanen, y A. I. Aguirre-Salado. 2009. Mapeo de carbono arbóreo aéreo en bosques manejados de pino *Patula* en Hidalgo, México. *Agrociencia*. 43: 209-220.
- Aguirre-Salado, C. A., J. R. Valdez-Lazalde, G. Ángeles-Pérez, H. M. de los Santos-Posadas, y A. I. Aguirre-Salado. 2011. Mapeo del índice de área foliar y cobertura arbórea mediante fotografía hemisférica y datos Spot 5 HRG: Regresión y K-nn. *Agrociencia*. 45: 105-119.
- Anderson, J. E., L. C. Plourde, M. E. Martin, B. H. Braswell, M. L. Smith, R. O. Dubayah, M. A. Hofton and J. B. Blair. 2008. Integrating waveform lidar with hyperspectral imagery for inventory of a northern temperate forest. *Remote Sensing of Environment*, 112: 1856-1870.
- Ángeles-Pérez, G. 1995. Efecto de la vegetación competidora en el desarrollo inicial de *Pinus patula*. Tesis de Maestría. Postgrado Forestal. Colegio de Postgraduados. Montecillo, Texcoco, Edo. México. 114 p.
- ASTRIUM. 2013. SPOT 6 & SPOT 7 Imagery User Guide. Toulouse, Cedex 4 - France. 120 p.
- Cabrera, J., M. T. Lamelas, A. L. Montealegre y J. de la Riva. 2014. Estimación de variables dasométricas a partir de datos LiDAR PNOA en masas regulares de *Pinus halepensis Mill* in: XVI Congreso Nacional de Tecnología de la Información Geográfica. Alicante. 25, 26 y 27 de junio 2014. pp 7.
- Cano M., E. E., A. Velázquez-Martínez, J. J. Vargas-Hernández, C. Rodríguez-Franco y A. M. Fierros-González. 2006. Área foliar específica en *Pinus patula*: efecto del tamaño del árbol, edad del follaje y posición en la copa. *Agrociencia*. 30: 117-122.
- CONAFOR (Comisión Nacional Forestal). 2011. Inventario Nacional Forestal y de Suelos: Manual y procedimientos para el muestreo de campo, Re-muestreo 2011. 141 p.
- Cruz-Martínez, 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. Chapingo, Texcoco, Edo. de México. 50 p.
- Cruz-Leyva, I. A., J. R. Valdez-Lazalde, G. Ángeles-Pérez, y H. M. de los Santos-Posadas. 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 Bosque*. 16 (3): 75-97.
- Figueroa-Navarro, C. M., G. Ángeles-Pérez, A. Velázquez-Martínez, y H. M. De los Santos-Posadas. 2010. Estimación de Biomasa en un bosque bajo manejo de *Pinus patula* *Schlttdl. et Cham.* en Zacualtipán, Hidalgo. *Revista Mexicana de Ciencias Forestales*. 1(1): 105-112.
- He, Q. 2012. Estimation of coniferous forest above-ground biomass using LiDAR and SPOT-5 data in *Remote Sensing, Environment and Transportation Engineering (RSETE)*, 2012 2nd International Conference on. 4 p.
- INAFED (Instituto para el Federalismo y el Desarrollo Municipal). 2015. Secretaría de Gobernación. Enciclopedia de los municipios de México (EMM). Estado de Hidalgo: Zacualtipán de los Ángeles. Consultado el 16 de marzo del 2015. Página web. <http://www.inafed.gob.mx/work/enciclopedia/EMM13hidalgo/index.html>
- Jensen, R. J. L., K. S. Humes, L. A. Vierling and A. T. Hudak. 2008. Discrete return lidar-based prediction of leaf area index in two conifer forests. *Remote Sensing of Environment*. 112: 3947-3957.
- Jensen, J. R. 2007. *Remote Sensing of the Environment: An Earth Resource Perspective*. Prentice Hall. Second Edition. New Jersey, U.S.A. 592 p.
- Man, Q., P. Dong, H. Guo, Guang Liu and R. Shi. 2014. Light detection and ranging and hyperspectral data for estimation of forest biomass: a review. *Journal of Applied Remote Sensing*. 8(1): 081598-081598.
- McGaughey, R. J. 2015. FUSION/LDV: Software for LIDAR data analysis and visualization. Forest Service. Pacific Northwest Research Station. United States Department of Agriculture. 171 p.

- 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-Ruiz, M. A., J. R. Valdez-Lazalde, H. M. de los Santos-Posadas, G. Ángeles-Pérez, y A. I. Monterroso-Rivas. 2014. Inventario y mapeo del bosque templado de Hidalgo, México mediante datos del satélite SPOT y de campo. *Agrociencia*. 48: 847-862.
- Ortiz-Reyes, A. D., J. R. Valdez-Lazalde, H. M. de los Santos-Posadas, G. Ángeles-Pérez, F. Paz-Pellat y T. Martínez-Trinidad. 2015. Inventario y cartografía de variables del bosque con datos derivados de LiDAR: comparación de métodos. *Madera y Bosques*. (21) 3: 111-128.
- Popescu, S. C., R. H. Wynne and J. A. Scrivani. 2004. Fusion of small-footprint lidar and multispectral data to estimate plot-level volume and biomass in deciduous and pine forests in Virginia, USA. *Forest Science*. 50(4): 551-565.
- Scheaffer, L.R., W. Mendenhall y L. Ott. 1986. *Elementary survey sampling*. PWS Publishers. EUA. 320 p.
- Soriano-Luna, M. de los A., G. Ángeles-Pérez, T. Martínez-Trinidad, F. O. Plascencia-Escalante y R. Razo-Zárate. 2015. Estimación de biomasa aérea por componentes estructurales en Zacualtipán, Hidalgo, México. *Agrociencia*. 49: 423-438.
- Valdez-Lazalde, J. R., M. de J. González-Guillén, y H. M. de los Santos-Posadas. 2006. Estimación de cobertura arbórea mediante imágenes satelitales multiespectrales de alta resolución. *Agrociencia*. 40: 383-394.
- Velasco-López, S., O. Champo-Jiménez, Ma. L. España-Boquera y F. Baret. 2010. Estimación del índice de área foliar en la Reserva de la Biósfera Mariposa Monarca. *Revista Fitotecnia Mexicana*. 33 (2): 169-174.

CAPÍTULO IV

4. CONCLUSIONES GENERALES

Los valores correspondientes (magnitud) a los inventarios totales realizados mediante estimadores de razón y regresión que incorporan como variables auxiliares datos del sensor LiDAR se ubican dentro del intervalo de confianza definido mediante el procesamiento tradicional del inventario (muestreo en campo mediante sitios de dimensiones fijas), siendo los primeros más confiables y de mayor precisión. El estimador de regresión presentó un rango de precisión entre 3.16 % y 6.65 % en todas las variables de campo. La precisión lograda mediante el inventario tradicional vario entre 6.50 % y 9.30 % para las mismas variables.

La correlación más alta (positiva) se presenta con las métricas LiDAR, siendo la variable X91 (porcentaje de todos los retornos por encima de la media) la más correlacionada con las variables de área basal, biomasa total y volumen. Mientras las variables espectrales presentaron correlaciones altas pero negativas en todas las variables de campo, destacando la banda del infrarrojo cercano como la variable espectral que se correlacionó en mayor grado con las variables de área basal, biomasa total y volumen. Esta es una variable independiente constante en los modelos de regresión ajustados para la estimación de las variables anteriormente enunciadas. El índice de área foliar se correlaciono en mayor magnitud con la banda verde.

Las métricas LiDAR son buenas variables predictoras en la estimación de las variables de campo, teniendo buenos ajustes y errores relativamente bajos. En cuanto a las variables espectrales como variables predictivas también presentaron buenos ajustes pero errores más elevados respecto a las métricas LiDAR. El ajuste realizado con la combinación de métricas LiDAR y variables espectrales presentó ajustes similares a los obtenidos solo utilizando métricas LiDAR, sin embargo, es de resaltar que el error de estimación se redujo considerablemente.

Dentro de las estrategias implementadas para la estimación del inventario total, el estimador de regresión presentó la mejor precisión para la estimación de todas las variables, destacando que el uso de variables auxiliares mejora las estimaciones y reduce la amplitud de los intervalos de confianza, debido a que la variable auxiliar implementada fue “medida” en la totalidad del área de estudio.

Comparativamente, las métricas LiDAR aportan mayor precisión a los inventarios totales realizados que las variables espectrales utilizadas del sensor SPOT 6.