

Inventario y mapeo de variables forestales mediante **sensores remotos** en el estado de
Quintana Roo, México

Inventory and mapping of forest variables through remote sensors in Quintana Roo state,
México

Jonathan Hernández-Ramos^{1*}, Xavier García-Cuevas¹, Ramiro Pérez-Miranda², Antonio
González-Hernández² y Luis Martínez-Ángel³

¹ Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias. Campo Experimental Chetumal. Chetumal, Quintana Roo, México. garcia.xavier@inifap.gob.mx

² Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias. Centro Nacional de Investigación Disciplinaria en Conservación y Mejoramiento de Ecosistemas Forestales. Ciudad de México, México. miranda.ramiro@inifap.gob.mx, gonzalez.antonio@inifap.gob.mx; luis_90chi@hotmail.com

³ Comisión Nacional Forestal. Gerencia del Sistema Nacional de Monitoreo Forestal. Unidad Técnica Especializada en Monitoreo, Reporte y Verificación. Zapopan, Jalisco, México. lmartinez.ute@conafor.gob.mx

*Autor de correspondencia. forestjonathanhdez@gmail.com

Resumen

Los sensores remotos en combinación con información derivada de los inventarios forestales estiman variables de interés con precisión y bajo costo. El objetivo de este trabajo fue estimar el área basal (AB), volumen maderable (VTA) y biomasa aérea (B) en diferentes ecosistemas de selvas mediante información Landsat ETM+ e Inventario Nacional Forestal y de Suelos (INFyS) en Quintana Roo, México. Se generó una matriz de correlación entre datos del INFyS e información espectral, posteriormente, un modelo de regresión lineal múltiple. Con las ecuaciones seleccionadas se generaron mapas de distribución espacial de AB ($\text{m}^2 \text{ha}^{-1}$), VTA ($\text{m}^3 \text{ha}^{-1}$) y B (Mg ha^{-1}). El inventario total se estimó mediante tres enfoques: i) estimadores de razón (ERaz), ii) estimadores de regresión (EReg) y iii) estimadores del muestreo simple al azar. Los dos primeros enfoques corresponden al inventario alternativo mediante sensores remotos y el tercero al inventario tradicional. El coeficiente de correlación resultó mayor del índice de diferencia normalizada con 0.35, 0.39 y 0.39 para AB, VTA y B. Los modelos de regresión presentaron coeficientes de determinación ajustada de 0.28, 0.32 y 0.32 para estimar AB, VTA y B, respectivamente. Los tres estimadores son estadísticamente diferentes y muestran que el EReg es el más conservador y con precisión en AB, VTA y B de 2.73%, 2.92% y 2.71%, respectivamente, además de intervalos de confianza de menor amplitud que el MSA y ERaz. Con la actualización del inventario mediante sensores remotos se mejora el proceso de evaluación de los recursos forestales y su planificación.

Palabras clave: biomasa aérea, estructura forestal, Landsat, modelos de regresión, sensores remotos.

Abstract

Remote sensors in combination with information derived from forest inventories estimate variables of interest with precision and low cost. The objective was to estimate the basal area (AB), timber volume (VTA) and aboveground biomass (B) in different forest ecosystems using Landsat ETM information and National Forest and Soil Inventory (INFyS) in Quintana Roo, Mexico. A correlation matrix was generated between INFyS data and spectral information, and later, a multiple linear regression model. With the selected equations, spatial distribution maps of AB ($\text{m}^2 \text{ ha}^{-1}$), VTA ($\text{m}^3 \text{ ha}^{-1}$) and B (Mg ha^{-1}) were generated. The total inventory was estimated using three approaches: i) Reason Estimators (ERaz), ii) Regression Estimators (EReg), and iii) Estimators of Random Simple Sampling. The first two approaches correspond to the alternative inventory using remote sensors and the third corresponds to the traditional inventory. The correlation coefficient was greater than the normalized difference index with 0.35, 0.39 and 0.39 for AB, VTA and B. The regression models had adjusted determination coefficients of 0.28, 0.32 and 0.32 to estimate AB, VTA and B, respectively. The three estimators are statistically different and show that the EReg is the most conservative and with precision in AB, VTA and B of 2.73%, 2.92% and 2.71%, respectively, in addition to confidence intervals of smaller amplitude than the MSA and ERaz. By updating the inventory using remote sensors, the process of evaluating forest resources and their planning is improved.

Keywords: aerial biomass, forest structure, Landsat, regression models, remote sensing.

Introducción

Los sensores remotos en combinación con información derivada de los inventarios forestales por medio de muestreo estiman las variables de interés con precisión aceptable y a costo relativamente accesible en comparación con los inventarios forestales tradicionales, razón por la cual, hoy en día han adquirido mayor importancia en la evaluación de las variables forestales (Solberg, Astrup, Breidenbach, Nilsen y Weydahl, 2013; Zhu y Liu, 2014; Aslan, Rahman, Warren y Robeson, 2016). Los bosques y selvas constantemente se encuentran en riesgo de degradación por las actividades antropogénicas y, de acuerdo con Rosete-Vergés *et al.* (2014), la tasa anual de deforestación en México oscila alrededor de 534 707 ha y donde los ecosistemas tropicales tienen la mayor tasa de cambio de usos de suelo con alrededor de 146 mil (Gobierno de la Republica, 2014). Por lo general, las selvas son valoradas por su diversidad y productividad alta (Martínez-Ramos *et al.*, 2007), por lo cual, es fundamental conocer su potencial productivo, y comprender el papel de estos ecosistemas (Huang, 2003; Peralta-Rivero, Galindo-Mendoza, Contreras-Servín, Algara-Siller y Mas-Caussel, 2016) en la captura de carbono y poder realizar aprovechamiento sostenible de sus recursos forestales, es necesario generar herramientas estadísticas que permitan evaluar las variables forestales con precisión aceptable (Acosta, Pérez, Romero, González y Martínez, 2017).

Generalmente, el método más empleado para estimar variables forestales (área basal (AB), volumen maderable (VTA), biomasa aérea total (B), entre otros) a pequeña o gran escala es por medio del inventario forestal basado en mediciones directas por medio de un muestreo (Solberg *et al.*, 2013; Ortiz-Reyes *et al.*, 2015). Sin embargo, este tipo de inventario implica tiempo y costos elevados en la evaluación de las variables forestales (Hawbaker *et al.*, 2010). Por tal razón, los métodos indirectos, como los que ofrecen los sensores remotos en combinación con

los datos del inventario forestal adquieren mayor relevancia en la actualidad porque ofrecen información actualizada de la estructura del bosque a costo relativamente accesible (Acosta *et al.*, 2017), con una optimización en tiempo, además ofrecen la ventaja de construir mapas cartográficos de la distribución espacial de cada variable forestal (Foody, Boyd y Cutler, 2003).

La existencia de sensores de resoluciones alta (SPOT 5 y 6, Quickbird, Ikonos, y otros), moderada (Landsat 5 TM, Landsat 7 ETM+ y Landsat 8 OLI) y baja (Aqua/Terra MODIS) permiten evaluar las variables forestales minimizando costos y tiempo (Hawbaker *et al.*, 2010; Torres-Rojas, Romero-Sánchez, Velasco-Bautista y González-Hernández, 2016; Nelson *et al.*, 2017), representan una opción para estimar las variables forestales de manera eficiente y confiable (Ortiz-Reyes *et al.*, 2015; Acosta *et al.*, 2017).

La asociación de las variables forestales con los datos espectrales de los sensores remotos no depende de manera directa en la escala que se analicen la información, sino del tipo de ecosistema y de la técnica de medición en campo, de esta forma es más fiable elegir el tipo de sensor que más se adecue para evaluar las variables forestales (Wulder, 1998; Nelson *et al.*, 2017). Por ejemplo, las imágenes Landsat han sido empleadas para evaluar las variables forestales para grandes áreas con precisión aceptable y de forma factible, aun cuando presentan una resolución moderada (Zhu y Liu, 2014; López-Serrano *et al.*, 2015), esto ha demostrado que la alta resolución espacial no aumenta la auto correlación y la estimación con las variables forestales (Torres-Rojas *et al.*, 2016).

Objetivos

Estimar el inventario del AB, VTA y B en diferentes ecosistemas de selvas mediante la combinación de la información del sensor Landsat ETM+ y del Inventario Nacional Forestal y

de Suelos (INFyS) en Quintana Roo, México, bajo la hipótesis de que los resultados de los estimadores obtenidos con información del inventario forestal tradicional y con sensores remotos no son estadísticamente diferentes entre ellos.

Materiales y métodos

Descripción del área de estudio

El estado de Quintana Roo, se ubica en el sureste de México en la parte oriental de la Península de Yucatán. Su extensión territorial es de 4 455 627.42 hectáreas de las cuales 3 773 023.27 ha (84.68%) se consideran como superficie forestal, las restantes 682 604.15 ha (15.32%) son consideradas como de uso agrícola, pastizal, demográfico, cuerpos de agua y áreas desprovistas de vegetación (Comisión Nacional Forestal [Conafor], 2014). De la superficie forestal total, 2 891 578.75 ha (76.6%) corresponden a selvas medianas y altas, 481 165.08 ha (12.8%) a selvas bajas, 217 036.5 ha (5.7%) a otras áreas forestales, y 183 242.94 ha (4.9%) a manglares (Conafor, 2014).

El clima que predomina corresponde al grupo cálido (*A*), particularmente, *Am* que corresponde al cálido húmedo con abundantes lluvias en verano, y *Aw* de tipo cálido subhúmedo con diferentes variaciones en la presencia de lluvias invernales (Instituto Nacional de Estadística y Geografía [Inegi], 2000; Inegi, 2015). Cuenta con una temperatura media anual de 26 °C (Conafor, 2014) y precipitación media anual de 1325 mm (Inegi, 2015). El relieve es plano, con una altitud promedio de 10 m sobre el nivel del mar y una leve inclinación que se presenta hacia el Mar Caribe (Inegi, 2015).

La hidrografía estatal consta de dos Regiones Hidrológicas: Yucatán Norte (RH32) y Yucatán Este (RH33), con una superficie de 30.9% y 69.1%, respectivamente. Los suelos predominantes

son: gleysol, leptosol, luvisol, regosol, phaeozem y vertisol (Inegi, 2015).

Datos derivados del inventario nacional forestal y de suelos (INFyS)

Los datos de campo se recolectaron de 2004, 2005 y 2006 en ecosistemas de selvas bajas, medianas y altas en Quintana Roo. En el área de estudio se establecieron 798 conglomerados o Unidad de Muestreo Primario (UMP) de tipo circular con una superficie de una ha, de acuerdo con el diseño por conglomerados (Conafor, 2014) (Fig. 1).

De acuerdo con la Conafor (2014), el diseño de las UMP corresponde a una parcela circular de una hectárea (56.42 m de radio) que se distribuyen a una equidistancia entre conglomerados de 5 km \times 5 km para selvas medianas y altas, y de 10 km \times 10 km para selvas bajas. Cada UMP está integrada por cuatro unidades de muestreo secundarias (UMS) rectangulares de 400 m², dispuestas geométricamente en forma de una “Y” invertida con respecto al Norte. La UMS uno constituye el centro y las UMS dos, tres y cuatro son consideradas periféricas (Conafor, 2014; Muñoz-Ruiz, Valdez-Lazalde, De los Santos-Posadas, Ángeles-Pérez y Monterroso-Rivas, 2014; Velasco-Bautista, Santos-Posadas, Ramírez-Maldonado y Rendón-Sánchez, 2016).

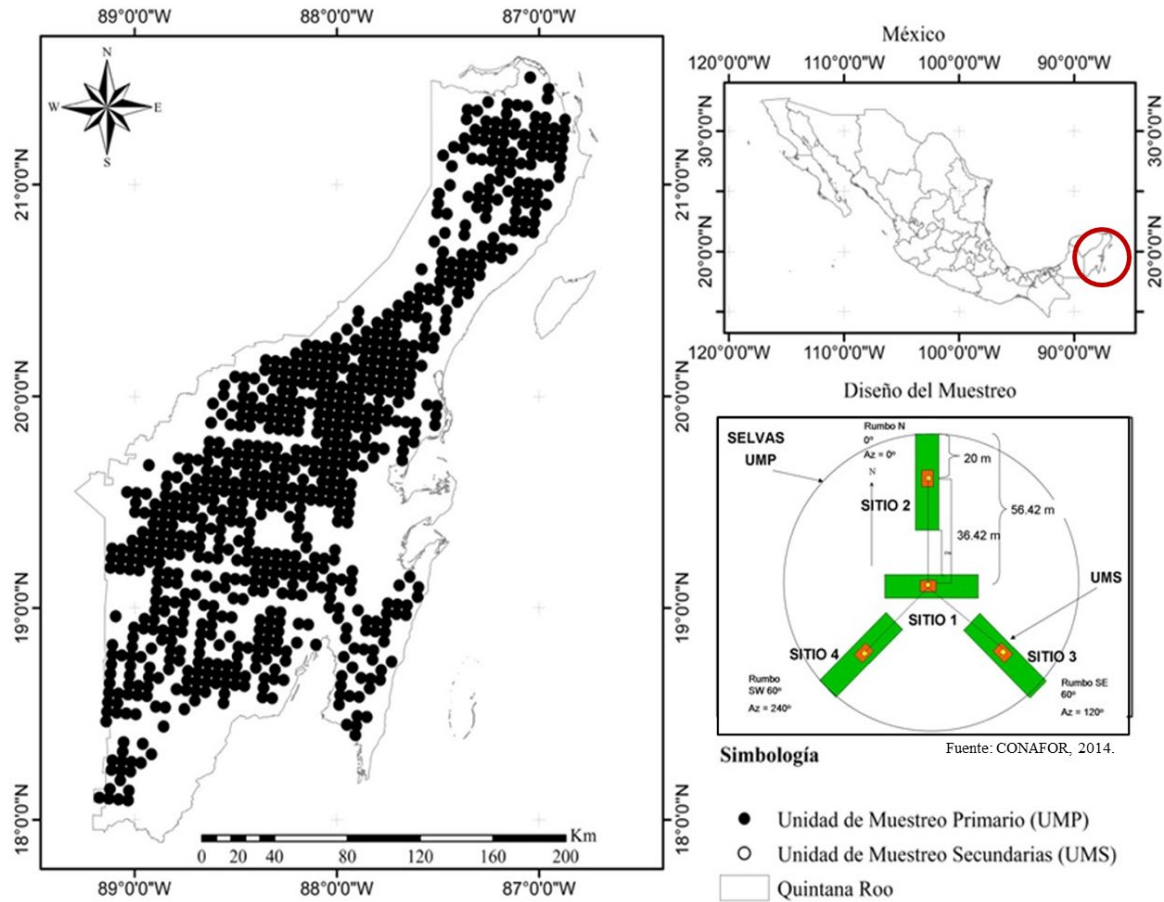


Figura 1. Ubicación del área de estudio, diseño y distribución de las unidades de muestreo en Quintana Roo, México.

Para todos los árboles vivos y especies identificadas de la categoría diamétrica de 10 cm (diámetro normal igual o mayor a 7.5 cm) dentro de cada UMS se midió el diámetro normal (D, en centímetros) y la altura total (H, en metros). La información del D y H de todos los árboles fue auditada y corregida. Posteriormente, se estimaron tres variables forestales: AB en metros cuadrados, VTA en metros cúbicos y B en kilogramos. El AB de cada árbol se estimó utilizando el modelo 1:

$$AB = \left(\frac{\pi}{40,000} \times D^2 \right) \quad [1].$$

Donde:

AB = área basal ($\text{m}^2 \text{ arbol}^{-1}$)

D = diámetro normal con corteza (cm)

El VTA, se estimó con los modelos 2 y 3, respectivamente: el modelo 2 fue generado por el proyecto “Sistema biométrico para la planeación del forestal sustentable de los ecosistemas con potencial maderable de México”, para 12 especies de alto valor comercial (Vargas-Larreta *et al.*, 2017), mientras que el modelo 3 por SAG (1976), utilizadas ampliamente en Quintana Roo para especies y grupos de especies (Cruz-Leyva *et al.*, 2010; Muñoz-Ruiz *et al.*, 2014; Velasco-Bautista *et al.*, 2016). Los modelos son de la forma:

$$VTA = \beta_0 D^{\beta_1} H^{\beta_2} + \beta_3 D^2 \quad [2]$$

$$VTA = \left[\left(e^{\beta_0 + \ln D^{\beta_1} + \ln H^{\beta_2}} \right) * 1.2 \right] \quad [3]$$

Donde:

VTA = volumen total árbol (m^3)

D = diámetro normal con corteza (cm)

H = altura total (m)

1.2 = factor de forma para convertir VFT a VTA

La B de cada árbol y especies, se calculó por medio del modelo 4 desarrollada para selvas medianas y altas, y para selvas bajas con el modelo 5, ambos emplean como variable independiente el VTA (Torres y Guevara, 2002).

$$B = (0.896 + 519.408 \times VTA) \quad [4]$$

$$B = (12.225 + 313,036 \times VTA) \quad [5]$$

Donde:

B = biomasa aérea total (kg)

VTA volumen total árbol (m^3)

Finalmente, los resultados de AB , VTA y B de cada árbol, se sumaron dentro de cada UMS, posteriormente por UMP y se extrapolaron a la unidad de superficie ($m^2 ha^{-1}$, $m^3 ha^{-1}$ y $Mg ha^{-1}$)

Pre-procesamiento de la información espectral del sensor Landsat 7 ETM+

Se adquirieron tres imágenes Landsat 7 ETM+ a nivel LT1 con resolución de $30 m \times 30 m$ ($900 m^2$) de los años 2004, 2005 y 2006 a través del United States Geological Survey (USGS) en 2017 (López-Serrano *et al.*, 2015; Hansen *et al.*, 2016). Se eliminaron los efectos atmosféricos, de radianza y reflectancia en cada una de las imágenes mediante el software ENVI 5.1 ® con el algoritmo Análisis Atmosférico de Línea de Visión de Hipercubos (FLAASH, por sus siglas en inglés). En la primera etapa del procedimiento de corrección atmosférica, los números digitales (ND) se convirtieron en radiancia mediante expresión 6 (Soudani, François, Le Marrie, Le Dantec y Dufrêne, 2006).

$$L_{sat}^i = \left[\left(\frac{LMAX^i + LMIN^i}{DCMIN^i - DCMAX^i} \right) \times (DC^i - DCMIN^i) + LMIN^i \right] \quad [6]$$

Donde:

L_{sat}^i = radiancia expresada en $W^{-1} m^{-2} sr^{-1} \mu m^{-1}$

$LMAX^i$ = ganancia $\times 255$

$LMIN^i$ = compensación

$DCMIN^i$ = valores mínimos de píxel

$DCMAX^i$ = valores máximos de píxel

DC^i = valores de píxel

En la segunda etapa los valores de radiación se convirtieron en unidades de reflectancia descontando el efecto de la radiación refractada por la atmósfera y captada por el sensor utilizando la expresión 7, con el propósito de utilizar imágenes multi-temporales (Soudani *et al.*, 2006).

$$p^i = \frac{[d^2 \pi (L_{sat}^i - L_p^i)]}{[T_V^i (T_z^i E_0^i \cos \phi_s + E_{down}^i)]} \quad [7]$$

Donde:

p^i = reflectancia planetaria adimensional

T_V^i y T_z^i = transmitancia de la atmósfera en las direcciones de vista e iluminación

E_{down}^i = radiación difusa

E_0^i = radiación exoatmosférica que entra en la atmósfera

ϕ_s = ángulo zenital del sol

d = distancia normalizada de la tierra-sol cuando las imágenes fueron adquiridas

L_p^i = radiación de camino debido a los efectos atmosféricos

Variables espectrales e índices de vegetación

Los valores de reflectancia de las cinco bandas de la imagen Landsat ETM+ y un índice de vegetación fueron utilizadas en este estudio: azul (A), verde (V), rojo (R), infrarrojo cercano (IRC), infrarrojo medio (IRM) y el índice de diferencia normalizada (NDVI) calculado con la expresión 8, por su utilidad diversos autores han empleado el NDVI debido a que presentan alta correlación con la variables forestales (Rouse, Haas, Schell, Deering y Harlan, 1974; Aguirre-Salado, Valdez-Lazalde, Ángeles-Pérez, De los Santos-Posadas y Aguirre-Salado, 2011; Muñoz *et al.*, 2014; Acosta *et al.*, 2017; Torres-Vivar, Valdez-Lazalde, Ángeles-Pérez, Santos Posadas, y Aguirre-Salado, 2017). En las imágenes Landsat ETM+ se georreferenciaron las UMS de cada UMP con coordenadas UTM, posteriormente, los valores de las variables espectrales y del NDVI fueron extraídas como un valor promedio de los píxeles correspondiente a un buffer de 10 000 m², mediante el procedimiento del comando Zonal Statistics as Table del programa ArcMap 10.2 ®.

$$NDVI = \left(\frac{IRC - R}{IRC + R} \right) \quad [8]$$

Donde:

NDVI = índice de diferencia normalizada

R = banda rojo

IRC = banda infrarrojo cercano

Análisis estadísticos de las variables de campo y de imágenes Landsat ETM+

Mediante un análisis de Matriz de Correlación de Pearson, se estudiaron las correlaciones asociadas entre las variables forestales con las variables espectrales e índices de vegetación, siendo esta una medida estadística para evaluar si dos variables cuantitativas guardan una

relación lineal. La información derivada de este análisis permitió seleccionar las variables espectrales e índice de vegetación de mayor grado de asociación con las variables forestales, como variables auxiliares para estimar el inventario total mediante los estimadores de razón (ERaz) y de regresión (EReg) (Acosta *et al.*, 2017).

Ajuste de modelos de regresión lineal

El método de ajuste utilizado para construir los modelos de regresión para estimar el AB ($\text{m}^2 \text{ ha}^{-1}$), VTA ($\text{m}^3 \text{ ha}^{-1}$) y B (Mg ha^{-1}) fue el procedimiento estadístico de *STEPWISE* (selección por pasos) del paquete estadístico *SAS/ETS®* (Institute, Inc. SAS, 2008). La estructura del modelo se expresa en la ecuación 9 (Huang, 2003; Ortiz-Reyes *et al.*, 2015; Zhang, 2016).

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon_i \quad [9]$$

Donde:

Y_i = variable forestal de interés (B (Mg ha^{-1}), VTA ($\text{m}^3 \text{ ha}^{-1}$) y ($AB \text{ m}^2 \text{ ha}^{-1}$))

X_i bandas; A, V, R, IRC, IRM, NDVI

β_i coeficientes de regresión

ε_i vector de error aleatorio

Con la finalidad de seleccionar y medir la capacidad predictiva de los modelos, se evaluaron tres indicadores de ajuste: i) mayor valor de coeficiente de determinación ajustado (R^2_{adj}); ii) menor valor de la raíz del cuadrado medio de error (RMSE); y iii) valor de probabilidad de rechazo en la prueba de hipótesis de los parámetros menor al 0.05 de confiabilidad (Avitabile, Baccini, Friedl, y Schmullius, 2012; López-Serrano *et al.*, 2015; Acosta *et al.*, 2017). Los modelos más precisos de cada variable fueron utilizados para generar mapas que describen la

distribución espacial de las variables forestales mediante la calculadora *Raster* del programa ArcMap 10.2 ® (Torres-Vivar *et al.*, 2017).

Estimadores muestrales para estimar el inventario total

La superficie utilizada para determinar el inventario total en AB, VTA y B fue de 3 372 743.83 ha, que corresponden a las selvas bajas, medianas y altas (Conafor, 2014). Para estimar el inventario total de cada variable, se emplearon estimadores clásicos basados en diseños como: Muestreo Simple al Azar (MSA), Estimadores de Razón (ERaz) y Regresión (EReg), que usan una media poblacional (μ_x) como valor verdadero. Uno de los supuestos básicos es que el valor de la variable auxiliar a nivel poblacional (N) es conocido sin error de muestreo, de forma que es posible lograr que el muestreo sea eficiente en términos de costo y tiempo, además, si el tamaño de la muestra es robusto, el estimador es más eficiente y de menor sesgo (Roldan, 2013). Por lo tanto, es posible estimar la media poblacional de las variables de interés Y_i (AB, VTA y B), con mayor precisión, cuando la variable auxiliar X_i (datos espectrales e índices de vegetación), muestran una alta correlación con la variable Y_i (Scheaffer, Mendenhall y Ott, 1986; Valdez-Lazalde, González-Guillén, y Santos-Posadas, 2006; Roldán-Cortés *et al.*, 2013; Ortiz-Reyes *et al.*, 2015). En la tabla 1 se muestran las expresiones matemáticas de las ecuaciones que describen a los estimadores del MSA, ME, ERaz y EReg.

Tabla 1. Estimadores utilizados para determinar las existencias totales en AB, VTA y B.

Estimadores	Parámetro	Ecuación	Expresión
MSA	Media	$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$	10
	Varianza muestral	$S_y^2 = \sum_{i=1}^n y_i^2 - \left(\frac{y_i - \bar{y}}{n}\right)^2 / n - 1$	11
	Varianza de la media	$S_y^2 = \frac{S^2}{n} \left(\frac{N-n}{N}\right)$	12
	Límite superior e inferior	$L.S e L.I = \bar{y} \pm t_{n,gl} \sqrt{S_y^2}$	13
	La precisión de la media	$P = t_{a,gl} \sqrt{S_y^2 / \bar{y}} \times 100$	14
	Inventario total	$\hat{T} = N \times \bar{y}$	15
ER	Razón	$R = \frac{\mu_y}{\mu_x}$	16
	Estimador de razón	$\hat{R} = \frac{\bar{y}}{\bar{x}} = \frac{\sum_{i=1}^n y_i}{n} / \frac{\sum_{i=1}^n x_i}{n}$	17
	Media población de la razón	$\bar{y}_R = \hat{R} \times \mu_x$	18
	Varianza de la media de la razón	$S_R^2 = \frac{\sum_{i=1}^n y_i^2 + \hat{R}^2 \sum_{i=1}^n x_i^2 - 2\hat{R} \sum_{i=1}^n x_i y_i}{n-1} \times \left(1 - \frac{n}{N}\right)$	19
	Límite superior e inferior	$L.S e L.I = \bar{y}_R \pm t_{n,gl} \sqrt{S_R^2}$	20
	La precisión de la media	$P = t_{a,gl} \sqrt{S_R^2 / \bar{y}_R} \times 100$	21
	Inventario total	$\hat{T} = N \times \bar{y}_R$	22
EReg	Media	$\bar{y}_{REG} = \bar{y} + \hat{\beta}(\mu_x - \bar{x})$	23
	Pendiente	$\hat{\beta} = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$	24
	Varianza de la media	$S_{Y_{REG}}^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2 - \beta^2 \sum_{i=1}^n (x_i - \bar{x})^2}{n-2} \times \left(1 - \frac{n}{N}\right)$	25
	Límite superior e inferior	$L.S e L.I = \bar{y}_{REG} \pm t_{n,gl} \sqrt{S_{Y_{REG}}^2}$	26
	La precisión de la media	$P = t_{a,gl} \sqrt{S_{Y_{REG}}^2 / \bar{y}_{REG}} \times 100$	10
	Inventario total	$\hat{T} = N \times \bar{y}_{REG}$	11

\bar{y} = media muestral del AB $m^2 ha^{-1}$, V $m^3 ha^{-1}$ y B $Mg ha^{-1}$ observado en el i -ésimo UMP, \bar{x} = media muestral del NDVI, μ_x = media poblacional del NDVI expresado como $\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i$, n = tamaño de la muestra, N = tamaño de la población, $\hat{\beta}$ = son estimados a partir de los datos de la muestra mediante mínimos cuadrados ordinarios (MCO), t distribución de Student a 95% de confiabilidad con $n-1$ grados de libertad (gl).

Con la finalidad de seleccionar y calificar al mejor estimador de muestreo en eficiencia estadística, se evaluaron con base en el menor valor la media del inventario ($m^3 ha^{-1}$), la más alta precisión (P , en porcentaje). Para la comparación anterior, se tomaron como referencia los

estimadores de los parámetros obtenidos con el MSA. Lo anterior permitió proponer una estrategia de muestreo (estimadores muestrales) práctico y eficiente en términos de tiempo y costo.

Resultados

Estadísticas descriptivas de las variables forestales

Los principales estadísticos de las variables forestales en el área de estudio se resumen en la tabla 2. El AB promedio estimado fue de 18.92 m³ ha⁻¹, VTA de 149.47 m² ha⁻¹ y B de 78.47 Mg ha⁻¹.

Tabla 2. Estadísticas descriptivas de las variables forestales

<i>Estadísticos</i>	<i>Área basal (m² ha⁻¹)</i>	<i>Volumen (m³ ha⁻¹)</i>	<i>Biomasa (Mg ha⁻¹)</i>
Media	18.92	149.47	78.47
Mínimo	1.64	10.53	6.04
Máximo	43.79	381.07	199.53
Muestra	798	798	798

Correlación entre variables forestales y los datos espectrales

La asociación entre las variables forestales y las reflectancias del sensor Landsat mostraron tendencias negativas, mientras que para los índices de vegetación fueron positivas (Tabla 3). Todas las correlaciones son altamente significativas con un $\alpha = 0.05$.

Tabla 3. Coeficientes de correlación de Pearson entre las variables espectrales y las variables forestales.

Variables espectrales e índices de vegetación	AB	VTA	B
Azul	-0.23	-0.24	-0.24
Verde	-0.33	-0.33	-0.34
Rojo	-0.34	-0.36	-0.36
Infrarrojo cercano (IRC)	0.12	0.17	0.17
Infrarrojo medio (IRM)	-0.33	-0.32	-0.32
NDVI	0.35	0.39	0.39

AB = área basal en $\text{m}^2 \text{ ha}^{-1}$, VTA = volumen en $\text{m}^3 \text{ ha}^{-1}$, B = biomasa en Mg ha^{-1} , NDVI = índice de diferencia normalizada.

El NDVI presentó coeficientes de correlación positivos mayores a las diferencias de las bandas espectrales, resultado que se atribuye a la reflectancia en respuesta a la clorofila de la vegetación. Por tanto, el NDVI mostró mayor asociación con las variables forestales con coeficientes de correlación mayor (r) de 0.35, 0.32 y 0.59 para AB, V, B, respectivamente.

Modelo de regresión lineal propuesto con el método STEPWISE

Los resultados de ajustes y significancia de los parámetros en los modelos evaluados mediante el procedimiento STEPWISE para estimar el AB, VTA, y B se resumen en la tabla 4. Los estimadores de los parámetros obtenidos en el ajuste fueron altamente significativos a 95% de confiabilidad.

Tabla 4. Parámetros e indicadores de ajuste de los modelos de regresión ajustados.

Modelo	Ecuación	R^2_{adj}	RMSE	ρ	Ψ	ε^{\dagger}	α
1	$AB = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2$	0.28	7.64	α_0	31.58161	5.2973	0.0001
				α_1	-936.624	70.8154	0.0001
				α_2	63.68698	4.6533	0.0001
2	$VTA = \beta_0 + \beta_1 X_1 + \beta_2 X_2$	0.32	68.39	β_0	230.433	47.4341	0.0001
				β_1	-8817.75	634.1	0.0001

				β_2	650.5635	41.6673	0.0001
3	$B = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2$	0.32	35.65	α_0	124.9765	24.7243	0.0001
				α_1	-4656.05	330.5	0.0001
				α_2	338.289	21.7184	0.0001

AB = área basal ($\text{m}^2 \text{ ha}^{-1}$), VTA= volumen total árbol ($\text{m}^3 \text{ ha}^{-1}$), B= biomasa (Mg ha^{-1}), X_1 = banda verde, X_2 = NDVI, ρ = parámetros del modelo, Ψ = valor de los parámetros, ϵ^\dagger = error estándar de los parámetros, α = nivel de significancia de los estimadores de los parámetros.

Los modelos de regresión propuestos consideran dos variables independientes: la banda verde que evalúa el vigor de la vegetación por medio la radiancia captada por las células de la vegetación, y el *NDVI* que expresa la reflectancia de las bandas espectrales del R y del IRC, mismas que ayudaron a generar estadísticos consistentes para estimar el *AB*, *VTA* y *B*.

Las estimaciones de las variables forestales obtenidas con el modelo de regresión lineal múltiple presentaron errores (*RMSE*) y coeficientes de determinación ajustado (R_{adj}^2) aceptables. Los valores de *RMSE* fueron de $7.64 \text{ m}^2 \text{ ha}^{-1}$, $68.39 \text{ m}^3 \text{ ha}^{-1}$ y 35.65 Mg ha^{-1} para el *AB*, *VTA* y *B*; mientras que los valores de R_{adj}^2 fueron de 0.28, 0.32 y 0.32 para el *AB*, *VTA* y *B*.

Distribución espacial de las variables forestales en Quintana Roo: Las ecuaciones de regresión lineal múltiple propuestas fueron utilizadas para estimar cada variable en toda el área de estudio, píxel por píxel, y en donde cada uno representa una superficie de 900 m^2 . Las diferentes tonalidades de colores describen la distribución espacial del *AB* ($\text{m}^2 \text{ ha}^{-1}$), *VTA* ($\text{m}^3 \text{ ha}^{-1}$) y *B* (Mg ha^{-1}) para el área de estudio. La superficie en blanco con valores de 0 representa a los terrenos no forestales.

La variación espacial es similar en las variables evaluadas, es decir, en las áreas donde se registran los valores más altos en *AB* (Fig. 2), también se encuentra los más altos valores del *VTA* (Fig. 3) y *B* (Fig. 4). Las distribuciones espaciales de las variables forestales adquieren

importancia en la planeación y en el manejo sostenible de los recursos forestales, ya que permite objetivamente realizar un esquema de manejo más eficiente e integrarlos en proyectos de pagos por servicios ambientales, tales como la captura de carbono. También, ofrecen la ventaja de detectar las tasas de cambio de usos de suelo mediante la observación visual de las zonas que han presentado mayor pérdida en la cobertura forestal y de esta manera proponer políticas ambientales para la optimización de los recursos forestales, fomentar la conservación de la biodiversidad y de la cultura forestal.

Las áreas con densidad baja y media en *AB* ($0 \text{ m}^2 \text{ ha}^{-1}$ a $30 \text{ m}^2 \text{ ha}^{-1}$), *VTA* ($0 \text{ m}^2 \text{ ha}^{-1}$ a $200 \text{ m}^3 \text{ ha}^{-1}$) y *B* (0 Mg ha^{-1} a 100 Mg ha^{-1}) cubren alrededor de 80% de la superficie total del estado y corresponden a bosques con densidad arbórea baja, bosques degradados por actividades antropogénicas, por incendios forestales, la tala clandestina, el cambio de usos suelos y la fragmentación de los bosques por actividades propias de cultivos agrícolas y de pastoreo.

Las áreas con densidad alta en *AB* ($30 \text{ m}^2 \text{ ha}^{-1}$ a $40 \text{ m}^2 \text{ ha}^{-1}$), *VTA* ($200 \text{ m}^3 \text{ ha}^{-1}$ a $300 \text{ m}^3 \text{ ha}^{-1}$) y *B* (100 Mg ha^{-1} a 150 Mg ha^{-1}) cubren cerca de 20% de la superficie total y corresponden a bosques con densidad arbórea alta o bosques denso con una mínima perturbación, áreas naturales protegidas o localizados en áreas sujetas a manejo forestal intensivo bajo un esquema sostenible.

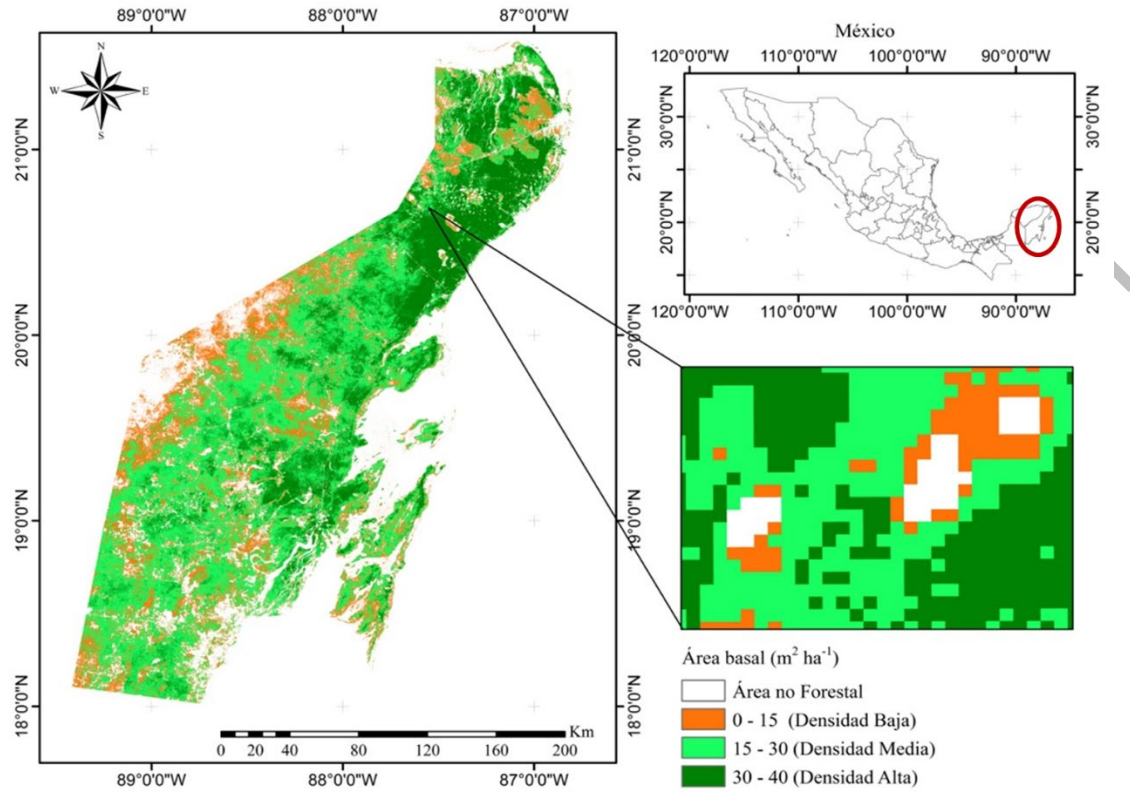


Figura 2. Distribución espacial de área basal estimada mediante regresión lineal múltiple para selva mediana en Quintana Roo.

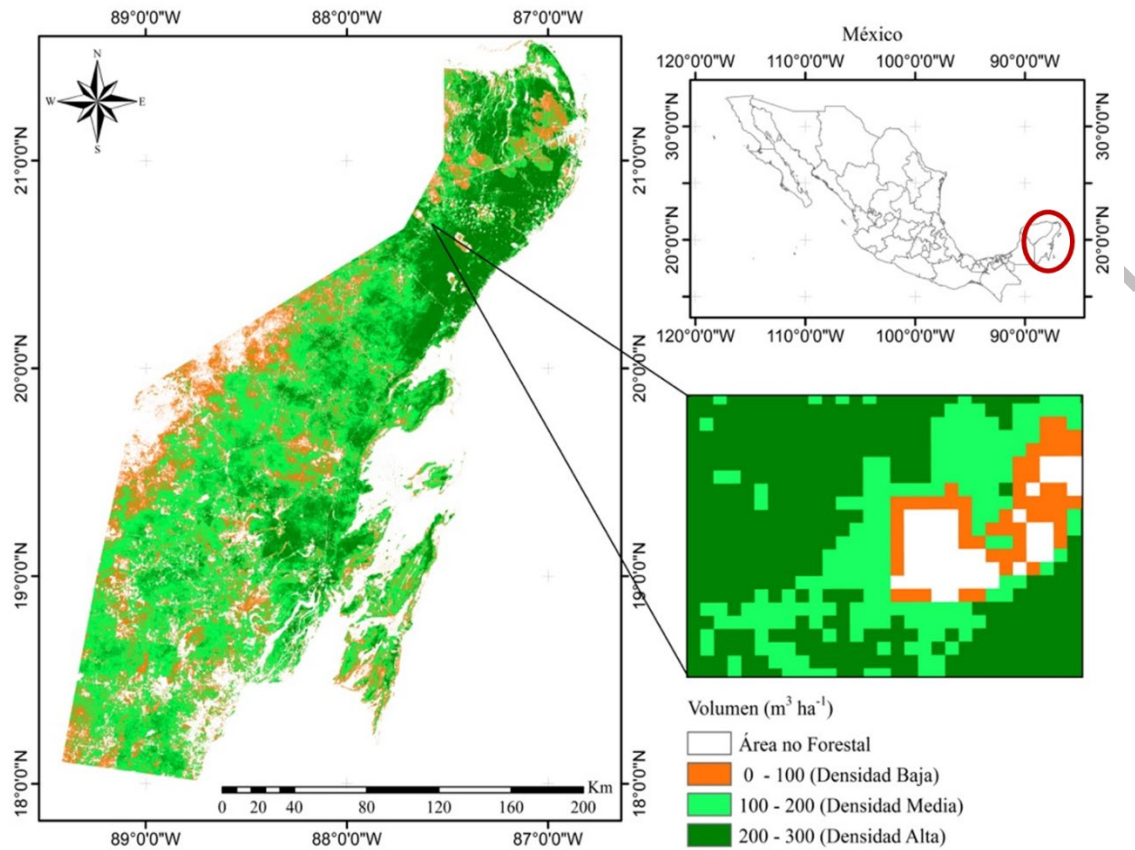


Figura 3. Distribución espacial de volumen estimado mediante regresión lineal múltiple para selva mediana en Quintana Roo.

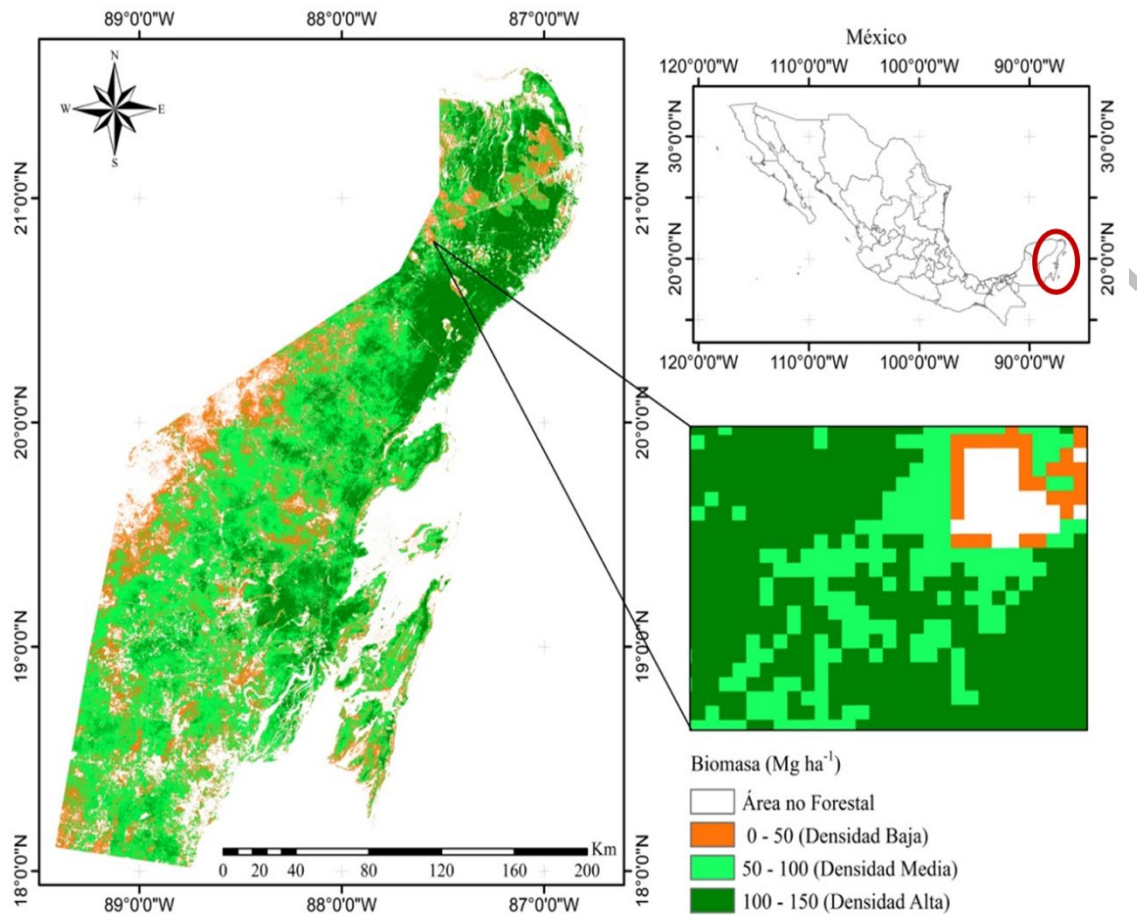


Figura 4. Distribución espacial de biomasa estimada mediante regresión lineal múltiple para selva mediana en Quintana Roo.

Estimaciones del inventario con el método tradicional vs percepción remota

En la tabla 5 se presentan las estimaciones del inventario en AB, VTA y B obtenidos con el método tradicional (MSA) y percepción remota (ERaz y EReg). Para los cálculos de inventario total, se trabajó con una superficie correspondiente a 2 891 579 ha con el objetivo de comparar cuál de los métodos presentan mejores estimaciones en términos de inventario, amplitud de intervalos de confianza y precisión.

El EReg presentó la más alta precisión (error menor a 10%) comparado con el MSA y el ERaz, esto es posible atribuir a la correlación existente entre el AB, el VTA y la B con el NDVI.

La ventaja del EReg es que incorpora variables auxiliares (*NDVI*) conocidas a nivel poblacional, es decir, considera toda la gama de variación en el área de estudio, lo que a su vez permitió mejorar la precisión con respecto al *MSA* y ERaz. El EReg presentó valores de precisión en *AB*, *VTA* y *B* de 2.73% 2.72% y 2.71%, respectivamente.

Tabla 5. Comparación del inventario tradicional vs método alternativo mediante percepción remota.

<i>Inventario</i>	<i>Estimadores</i>	<i>Parámetro</i>	<i>AB (m² ha⁻¹)</i>	<i>VTA (m³ ha⁻¹)</i>	<i>B (Mg ha⁻¹)</i>
Tradicional	MSA	Media	18.92	149.47	78.47
		L.I	18.29	143.69	75.45
		L.S	19.55	155.25	81.49
		P (%)	3.32	3.87	3.85
		Inventario	63 806 331	504 133 736	264 655 154
Percepción remota	ERaz	Media	18.51	146.26	76.78
		L.I	17.91	145.66	76.18
		L.S	19.11	146.85	77.38
		P (%)	3.23	3.76	3.74
		Inventario	62 433 221	493 284 790	258 959 781
	Reg	Media	18.13	141.50	74.31
		L.I	17.64	137.66	72.30
		L.S	18.63	145.35	76.32
		P (%)	2.73	2.72	2.71
		Inventario	61 155 868	477 249 759	250 627 328

MSA = muestreo simple al azar; L.I y L.S = intervalo de confianza inferior y superior a 95% de confiabilidad.

Estadísticamente, los métodos alternativos con respecto al método clásico ubicaron sus inventarios totales dentro del intervalo de confianza del *MSA*. Los dos métodos presentaron resultados muy similares en inventarios totales para cada variable de interés, aunque el *MSA* (método clásico) generó estimaciones más optimistas en inventarios y sus intervalos presentaron

mayor amplitud respecto al inventario estimado con los métodos alternativos: i) ERaz, y ii) EReg.

Discusión

Los promedios estimados en el estudio ($AB = 18.92 \text{ m}^2 \text{ ha}^{-1}$, $VTA = 149.47 \text{ m}^3 \text{ ha}^{-1}$ y $B = 78.47 \text{ Mg ha}^{-1}$) difieren a los valores registrados por la Conafor (2014) con VTA y AB de $112.83 \text{ m}^3 \text{ ha}^{-1}$ y $17.59 \text{ m}^2 \text{ ha}^{-1}$; y con los obtenidos por Cartus *et al.* (2014) al estimar las existencias de biomasa y carbono mayores a los 100 Mg ha^{-1} y 50 t ha^{-1} , respectivamente, ambos al utilizar datos del inventario forestal estatal del Estado de Quintana Roo, pero mostraron similitud a lo estimado por Rodríguez-Veiga, Saatchi, Tansey y Balzter (2016) quienes indican una media de B de 60 Mg ha^{-1} . Estas diferencias en AB , VTA y B , se consideran debido al empleo de las nuevas ecuaciones desarrolladas para ciertas especies en el estado de Quintana Roo por el proyecto “Sistema biométrico para la planeación del forestal sustentable de los ecosistemas con potencial maderable de México” (Vargas-Larreta *et al.*, 2017).

Las correlaciones negativas entre la asociación de variables forestales con las reflectancias del sensor Landsat y los índices positivos de vegetación coinciden con lo obtenido por Torres-Vivar *et al.* (2017) al realizar un inventario y mapeo de un bosque bajo manejo de pino con datos del sensor SPOT 6 y los obtenidos por Acosta *et al.* (2017) al realizar la estimación de la densidad forestal mediante imágenes Landsat ETM+.

La mayor asociación del $NDVI$ con las variables forestales expresada a través del coeficiente de correlación concuerdan con Torres-Rojas *et al.* (2016), quienes señalan una asociación similar del $NDVI$ con el carbono, con valores de $r = 0.48$ con información derivada del sensor QuickBird, y $r = 0.66$ con el sensor SPOT. Por su parte, Martínez *et al.* (2016), al utilizar

imágenes del sensor Landsat ETM+ para evaluar las variables forestales en los bosques de coníferas de Durango, México, obtuvieron para el *NDVI* valores de $r = 0.47$ y $r = 0.48$ para la *B* y *C*; mientras que Acosta *et al.* (2017) registraron valores con el *NDVI* de $r = 0.56$ a 0.61 para las mismas variables forestales estudiadas. Lo anterior, explica por qué el *AB* es una variable asociada linealmente con el VTA y la *B*, además de que está fuertemente correlacionada con la cobertura y área foliar (Cruz-Leyva, Valdez-Lazalde, Ángeles-Pérez y De los Santos-Posadas, 2010).

La correlación obtenida entre *AB*, *V* y *B* con el *NDVI* en términos reales no es elevada, sin embargo, es similar a los estudios citados anteriormente, y por tanto los resultados son aceptables y más para el tipo de ecosistema evaluado. A pesar de ello, el presente estudio es una de las pocas investigaciones realizadas para las selvas de Quintana Roo, razón por la cual puede servir como marco referencial para nuevas investigaciones en pro de seguir mejorando los análisis estadísticos entre los datos de campo y de los sensores remotos.

Wulder (1998) propone que el *NDVI* adquiere información por la cantidad de radiación absorbida por la vegetación, por lo que valores cercanos a 1 son producto de un alto valor del infrarrojo cercano (*IRC*) y un bajo valor del rojo visible (*R*), señalando que existe vegetación densa, caso contrario cuando existe poca o nula densidad de vegetación (suelo desnudo).

Los resultados obtenidos con los modelos de regresión y los inventarios totales mediante sensores remotos son confiables y demuestra la importancia que tiene el *NDVI* para estimar de forma indirecta las variables forestales, dado su alto nivel de asociación con las mismas. Sin embargo, el valor de *NDVI* obtenido para selvas es inferior con respecto a otros estudios desarrollados en ecosistemas de coníferas. Tales diferencias en el *NDVI* probablemente

respondan a que las especies que coexisten en selvas son de hoja caduca y en consecuencia existe una baja reflectividad o albedo que es captado por el sensor Landsat.

Tucker (1979) discute que el *NDVI* es un índice que expresa las características de la vegetación, como *B* y el contenido de clorofila, lo que explica la correlación mayor que existe entre el *NDVI* con el *AB*, *VTA* y *B*. Por su parte Heiskanen (2006) menciona que el valor de *NDVI* mayor representa a una vegetación saludable, lo que responde a una densidad mayor en las variables de *AB*, *V* y *B*. El *NDVI* mostró mayor correlación por lo que se optó utilizar como variable auxiliar (*n* muestral y *N* poblacional) para estimar el inventario total del *AB*, *VTA* y *B* mediante los estimadores de razón y de regresión. El presente estudio es uno de los primeros realizados para las selvas del estado de Quintana Roo y demuestra la importancia que tiene *NDVI* al generar estimaciones confiables en la estimación de cada variable forestal e inclusive generó resultados más conservadores en los inventarios totales. Sin embargo, es necesario seguir explorando con imágenes de teledetección de alta resolución y con los datos LiDAR (Light Detection And Ranging), esta última ofrece información tridimensional del bosque y es una de las novedades para estudiar variables forestales, pero los estudios con este tipo de información son demasiado costosos.

La banda verde y el IRC empleado en el modelo de regresión propuesto, es una respuesta de la absorción de la energía emitida por una vegetación saludable, clorofila y por los aspectos estructurales de las células que guardan la humedad de acuerdo con la mencionado por Harris (1987). Por lo tanto, es factible atribuir que los valores de R^2_{adj} fueron bajos debido a que los valores de reflectancia y *NDVI* fueron inferiores a los de una vegetación con follaje perenne o

persistente, pero no necesariamente sugiera una vegetación no saludable, al contrario, es una condición propia de las selvas de tipo caducifolias.

Los errores en las estimaciones de las variables obtenidas con el modelo de regresión lineal múltiple y los valores de R^2_{adj} fueron aceptables debido a que son ligeramente mayores a los errores encontrados por Muñoz-Ruiz *et al.* (2014), quienes presentan valores para los bosques templados de Hidalgo, México de *RMSE* para *AB* de $4.70 \text{ m}^2 \text{ ha}^{-1}$ y *VTA* de $41.45 \text{ m}^3 \text{ ha}^{-1}$, aunque los valores en R^2_{adj} (0.32 y 0.39 para el *AB* y *VTA*) fueron similares, tal contraste se debe al tipo de ecosistema que se evalúa y al manejo intensivo que se da a los bosques templados. En ese estudio se emplearon imágenes SPOT 4 y SPOT 5 de alta resolución espacial.

Los valores más contrastantes son los publicados por Aguirre-Salado *et al.* (2011): *RMSE* de $11.87 \text{ m}^2 \text{ ha}^{-1}$, $96.81 \text{ m}^3 \text{ ha}^{-1}$ y 52.56 Mg ha^{-1} , y R^2_{adj} de 0.76, 0.56 y 0.60 para el *AB*, *VTA* y la *B*, respectivamente, en un estudio realizado en los predios de la Mojonera y Atopixco en Zacualtipán, Hidalgo, México, empleando datos derivados del sensor SPOT 5 HRG. Probablemente, ellos obtuvieron dichos resultados por la resolución espacial mejorada de SPOT 5 HRG, es decir, 10 m en modo multiespectral respecto a la resolución espacial ofrecida por Landsat que es de 30 m.

Por su parte, Martínez *et al.* (2016) mencionan valores de *RMSE* de 54.74 Mg ha^{-1} y R^2_{adj} de 0.6241 para la *B*, quienes utilizaron imágenes Landsat ETM+ al evaluar la *B* en los bosques templados de cuatro municipios más productivos y representativos del sector forestal en Durango, México. Sin embargo, los resultados más contrastantes en *RMSE* son los encontrados por Acosta *et al.* (2017) quienes evaluaron la vegetación de selva baja caducifolia en el Sur del Estado de México mediante imágenes derivados del sensor Landsat ETM+, con valores de

$RMSE$ de $3.30 \text{ m}^2 \text{ ha}^{-1}$, $13.18 \text{ m}^3 \text{ ha}^{-1}$ y 5.91 Mg ha^{-1} para el AB , VTA y la B , y corresponden al orden mencionado, mientras que los valores del estadístico de R_{adj}^2 fueron de 0.52, 0.54 y 0.60 para el AB , VTA y la B , y corresponden al orden mencionado. Valores semejantes fueron hallados por Torres-Vivar *et al.* (2017), quienes evaluaron variables forestales (AB , VTA , y B) en los bosques de coníferas, sujetos a manejo intensivo, en Zacualtipán, Hidalgo, México, mediante imágenes SPOT 6, con valores de $RMSE$ en $AB = 5.82 \text{ m}^2 \text{ ha}^{-1}$, $V = 62.3 \text{ m}^3 \text{ ha}^{-1}$ y $B = 32 \text{ Mg ha}^{-1}$ y valores de R_{adj}^2 en AB , V y B de 0.66.

Torres-Rojas *et al.* (2016) mencionan que el continuo avance en el mejoramiento de las capacidades de los diferentes tipos del sensor ofrece la oportunidad de desarrollar técnicas de análisis que maximicen las capacidades de las plataformas satelitales disponibles, sin duda también proporcionará resultados eficientes en los estadísticos, ante este panorama, es posible que tal variación en $RMSE$ y R_{adj}^2 se atribuya también a la resolución espacial de las imágenes utilizadas en cada estudio de caso, a las condiciones ambientales en las cuales fueron adquiridas las imágenes, y al tipo de vegetación. Acosta *et al.* (2017) discuten que las diferencias antes señaladas, probablemente se deba al tipo de vegetación, debido que los bosques tropicales, sobre todo selva baja caducifolia presentan los valores más pequeños en AB , VTA y B con respecto a lo registrado en bosques de coníferas.

Los métodos alternativos: i) ERaz y ii) EReg presentaron intervalos de menor amplitud con respecto al MSA , sin embargo, el inventario derivado con el EReg fue el más conservador de los métodos evaluados, además, generó una precisión mayor, por lo que una característica a tomar en cuenta para la elección del método más preciso es con base a la amplitud de los intervalos de confianza y en el patrón de los datos (Ortiz-Reyes *et al.*, 2015), este resultado es factible

atribuirlas a la relación que existen entre el *AB*, *VTA* y *B* con del *NDVI*, por lo que se supone que la dispersión de los datos pasa cerca del origen y el mejor método para evaluar el comportamiento biológico fue el estimador de regresión. De acuerdo con Bailes y Brooks (2004) indican que la consecuencia de usar variables auxiliares (*NDVI*) de mayor correlación con la variable principal (*AB*, *VTA* y *B*) conduce a obtener estimadores más eficientes, además ofrece la ventaja de que es fácil, rápida y barata de medirse en campo, lo que conduce a optimizar la inversión en tiempo y costo durante la ejecución de inventarios en campo. Los inventarios derivados del EReg fueron eficientes al aproximar sus valores al *MSA*; dada su semejanza entre ellos, se recomiendan como la mejor alternativa para evaluar variables forestales, siendo un método que ofrece inventarios actualizados con precisión aceptable.

Conclusiones

Con los modelos de regresión lineal múltiple es posible estimar indirectamente cada variable forestal (pixel por pixel) con precisión aceptable (error menor a 10%) utilizando como variable independiente el índice de diferencia normalizada y la banda del infrarrojo cercano; de esta forma es posible evaluar los cambios en la distribución espacial de cada variable forestal y contar con un inventario actualizado cada 16 días (resolución temporal del sensor Landsat ETM+), tiempo en el que tarda el satélite en tomar dos imágenes del mismo sitio, siendo una herramienta útil para la toma de decisiones a nivel regional.

El *NDVI* mostró la correlación más alta con el área basal, el volumen y la biomasa, razón por la cual se utilizó como variable auxiliar para actualizar el inventario total de cada variable forestal con precisión mayor que el inventario forestal tradicional.

Reconocimientos

Al Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias por el financiamiento a través del proyecto con número SIGI: 1-1.6-10453832942-F-M.2-1.

Referencias

- Acosta M., M., Pérez, M. R., Romero, S. M. E., González, H. A., & Martínez, A. L. (2017). Estimación de la densidad forestal mediante imágenes Landsat ETM+ en la región sur del Estado de México. *Revista Mexicana de Ciencias Forestales*, 8(41), 30-55. doi: 10.29298/rmcf.v8i41.25
- Aguirre-Salado, C. A., Valdez-Lazalde, R. J., Ángeles-Pérez, G., De los Santos-Posadas, H. M., & Aguirre-Salado, I. A. (2011). Mapeo del índice de área foliar y cobertura arbórea mediante fotografía hemisférica y datos Spot 5 HRG: regresión y k-nn. *Agrociencia*, 45, 105-19.
- Aslan, A., Rahman, A. F., Warren, M. W., & Robeson, S. M. (2016). Mapping spatial distribution and biomass of coastal wetland vegetation in Indonesian Papua by combining active and passive remotely sensed data. *Remote Sensing of Environment*, 183, 65-81. doi: 10.1016/j.rse.2016.04.026

- Avitabile, V., Baccini, A., Friedl, M. A., & Schmullius, C. (2012). Capabilities and limitations of Landsat and land cover data for aboveground woody biomass estimation of Uganda. *Remote Sensing of Environment*, 117, 366-380.
- Bailes, W. W., and Brooks J. R. (2004). *A Comparison of two double sampling auxiliary variables with inventories of varying sample size*. En D. Yaussy, D. M Hix, P. Ch. Goebel, & R. P. Long (eds.), Proceedings of the 14th central hardwoods forest conference GTR-NE-316 (pp. 101-105). Wooster, Ohio: USDA Forest Service.
- Cartus, O., Kelldorfer, J., Walker, W., Franco, C., Bishop, J., Santos, L., and Michel F., J. M. (2014). A National, Detailed Map of Forest Aboveground Carbon Stocks in Mexico. *Remote sensing*, 6(6), 5559-5588. doi: 10.3390/rs6065559
- Comisión Nacional Forestal [Conafor] (2014). *Inventario Estatal Forestal y de Suelos - Quintana Roo 2013*. Zapopan, Jal., México.
- Cruz-Leyva, I. A., Valdez-Lazalde, J. R., Ángeles-Pérez, G., & De los Santos-Posadas, H. M. 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. doi: 10.21829/myb.2010.1631168

Foody, G. M., Boyd, D. S., & Cutler, M., E. J. (2003). Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. *Remote Sensing of Environment*, 85, 463-474. doi:10.1016/S0034-4257(03)00039-7

Gobierno de la Republica (2014). *Plan Nacional de Desarrollo 2013-2018*. Recuperado de <http://www.conafor.gob.mx:8080/documentos/docs/4/5382Programa%20Nacional%20Forestal%202014-2018.pdf>

Hansen, M. C., Potapov, P. V., Goetz, S. J., Turubanova, S., Tyukavina, A., Krylov, A., & Egorov, A. (2016). Mapping tree height distributions in Sub-Saharan Africa using Landsat 7 and 8 data. *Remote Sensing of Environment*, 185, 221-232. doi: 10.1016/j.rse.2016.02.023

Harris, R. (1987). *Satellite remote sensing*. An introduction. Routledge and Kegan Paul, London. 220 p.

Hawbaker, T. J., Gobakken, T., Lesak, A., Tromborg, E., Contrucci, K., & Radeloff, V. (2010). Light Detection and Ranging-Based Measures of Mixed Hardwood Forest Structure. *Forest Science*, 56, 313-326. doi: 10.1093/forestscience/56.3.313

- Heiskanen, J. (2006). Estimating aboveground tree biomass and leaf area index in a mountain birch forest using ASTER satellite data. *International Journal of Remote Sensing*, 27, 1135-1158. doi: 10.1080/01431160500353858
- Huang, C. (2003). A stepwise regression tree for nonlinear approximation: applications to estimating subpixel land cover. *International Journal of Remote Sensing*, 24(1), 75-90. doi: 10.1080/01431160305001
- Instituto Nacional de Estadística Geográfica e Informática (Inegi) (2000). *Anuario Estadístico de los Estados Unidos Mexicanos*, edición 2000. Aguascalientes: Inegi.
- Instituto Nacional de Estadística y Geografía [Inegi] (2015). *Anuario estadístico y geográfico de Quintana Roo*. México. Instituto Nacional de Estadística. Aguascalientes. 384 pp.
- López-Serrano, P. M., López-Sánchez, A. C., Díaz-Varela, A. R., Corral-Rivas, J. J., Solís-Moreno, R., Vargas-Larreta, B., & Álvarez-González, J. G. (2015). Estimating biomass of mixed and uneven-aged forests using spectral data and a hybrid model combining regression trees and linear models. *iForest Biogeosciences and Forestry*, 9: 226-234. doi: 10.3832 / ifor1504-008

- Martínez B., R. A., Aguirre C., O. A., Vargas L., B., Jiménez P., J., Treviño G., E. J., & Yerena, Y., J. I. (2016). Modelación de biomasa y carbono arbóreo aéreo en bosques del estado de Durango. *Revista Mexicana de Ciencias Forestales*, 7(35), 91-105.
- Martínez-Ramos, M. & García O., X. (2007). Sucesión ecológica y restauración de las selvas húmedas. *Boletín de la Sociedad Botánica de México*, 80, 69-84. doi: 10.17129/botsoci.1758
- Muñoz-Ruiz, M. Á., Valdez-Lazalde, J. R., De los Santos-Posadas, H. M., Ángeles-Pérez, G., & Monterroso-Rivas, A. I. (2014). Inventario y mapeo del bosque templado de Hidalgo, México mediante datos del satélite SPOT y de campo. *Agrociencia*, 48, 847-862.
- Nelson, R., Margolis, H., Montesano, P., Sun, G., Cook, B., Corp, L., & Prisley, S. (2017). Lidar-based estimates of aboveground biomass in the continental US and Mexico using ground, airborne, and satellite observations. *Remote Sensing of Environment*, 188, 127-140. doi: 10.1016/j.rse.2016.10.038
- Ortiz-Reyes, A. D., Valdez-Lazalde, J. R., De los Santos-Posadas, H. M., Ángeles-Pérez, G., Paz-Pellat, F., & Martínez-Trinidad, T. (2015). Inventario y cartografía de variables del bosque con datos derivados de LIDAR: comparación de métodos. *Madera y Bosques*, 21(3): 111-128. doi: 10.21829/myb.2015.213461

- Peralta-Rivero, C., Galindo-Mendoza, M. G., Contreras-Servín, C., Algara-Siller, M., & Mas-Causel, J. F. (2016). Percepción local respecto a la valoración ambiental y pérdida de los recursos forestales en la región Huasteca de San Luis Potosí, México. *Madera y Bosques*, 22(1), 71-93. doi: 10.4236/ojf.2014.42018
- Rodríguez-Veiga, P., Saatchi, S., Tansey, K., & Balzter, H. (2016). Magnitude, spatial distribution and uncertainty of forest biomass stocks in Mexico. *Remote Sensing of Environment*, 183, 265-281. doi: 10.1016/j.rse.2016.06.004
- Roldán-Cortés, M. A., De Los Santos-Posadas, H. M., Ramírez-Maldonado, H., Valdez-Lazalde, J. J., Ángeles-Pérez, G., & Velázquez-Martínez, A. (2013). Estimadores de muestreo para inventario de plantaciones forestales de eucalipto en el sureste de mexicano. *Revista Mexicana de Ciencias Forestales*, 5(26), 38-57.
- Rosete-Vergés, F. A., Pérez-Damián, J. L., Villalobos-Delgado, M., Navarro-Salas, E. N., Salinas-Chávez, E., & Remond-Noa, R. (2014). El avance de la deforestación en México 1976-2007. *Madera y Bosques*, 20(1): 21- 35. doi: 10.21829/myb.2014.201173
- Rouse, J. W., Haas, R. H., Schell, J. A., Deering, D. W., & Harlan, J. C. (1974). *Monitoring the vernal advancement of retrogradation of natural vegetation*. NASA/OSFC, Type III Final Report, Remote Sensing Center, Texas A&M University, College Station, TX, USA.

SAG (1976). *Inventario Forestal del Estado de Quintana Roo*. Publicación núm. 41. México DF: Dirección General del Inventario Nacional Forestal. Subsecretaría Forestal y de Fauna. SAG.

Scheaffer, L. R., Mendenhall, W., & Ott, L. (1986). *Elementary survey sampling*. Boston, MA, USA: PWS Publishers.

Solberg, S., Astrup, R., Breidenbach, J., Nilsen, B., & Weydahl, D. (2013). Monitoring spruce volume and biomass with inSAR data from TanDEM-X. *Remote sensing of Environment*, 139, 60-67. doi: 10.1016/j.rse.2013.07.036

Soudani, K., François, C., Le Marrie, G., Le Dantec V., & Dufrêne E. (2006). Comparative analysis of IKONOS, SPOT, and ETM+ data for leaf area index estimation in temperate coniferous and deciduous forest stands. *Remote Sensing of Environment*, 102, 161-175. DOI: 10.1016 / j.rse.2006.02.004

Statistical Analysis System (SAS). 2008. *SAS/STAT® 9.2 User's Guide*. Raleigh, NC USA: SAS Institute Inc.

- Torres R., J. M. & Guevara S., A. (2002). El potencial de México para la producción de servicios ambientales: captura de carbono y desempeño hidráulico. *Gaceta Ecológica*, 63, 40-59.
- Torres-Rojas, G., Romero-Sánchez, M. E., Velasco-Bautista, E., & González-Hernández, A. (2016). Estimación de parámetros forestales en bosques de coníferas con técnicas de percepción remota. *Revista Mexicana de Ciencias Forestales*, 7(36): 7-24.
- Torres-Vivar, J. E., Valdez-Lazalde, J. J., Ángeles-Pérez, G., Santos Posadas, H. M., & Aguirre-Salado, C. A. 2017. Inventario y mapeo de un bosque bajo manejo de pino con datos del sensor SPOT 6. *Revista Mexicana de Ciencias Forestales*, 8(39), 25-43.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8, 127-150. doi: 10.1016/0034-4257(79)90013-0
- United States Geological Survey (USGS). (2015). *Landsat data access*. Recuperado de <http://landsat.usgs.gov/landsat-data-access>
- Vargas-Larreta, B., Corral-Rivas, J. J., Aguirre-Calderón, O. A., López-Martínez, J. O., De los Santos-Posadas, H. M., Zamudio-Sánchez, F. J., Treviño-Garza, E. J., Martínez-Salvador,

- M., & Aguirre-Calderon, C. G. (2017). SiBiFor: Sistema biométrico Forestal para el manejo de los bosques de México. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 23(3): 437-455. doi: 10.5154/r.rchscfa.2017.06.040
- Valdez-Lazalde, J. R., González-Guillén, M. J., & Santos-Posadas, H. M. (2006). Estimación de cobertura arbórea mediante imágenes satelitales multiespectrales de alta resolución. *Agrociencia*, 40, 383-394.
- Velasco-Bautista, E., Santos-Posadas, H. M., Ramírez-Maldonado, H., & Rendón-Sánchez, G. (2016). Comparación de estimadores para volumen maderable en selva mediana del sureste de México. *Agrociencia*, 50, 119-132.
- Wulder, M. (1998). Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters. *Progress in physical Geography*, 22(4), 449-476. doi: 10.1177/030913339802200402
- Zhang, Z. (2016). Variable selection with stepwise and best subset approaches. *Annals of Translational Medicine*, 4(7): 136-141. doi: 10.21037 / atm.2016.03.35

Zhu, X. & Liu, D. (2014). Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. *Journal of Photogrammetry and Remote Sensing*, 10, 222-231. doi: 10.1016/j.isprsjprs.2014.08.014

Manuscrito recibido el 28 de octubre de 2018

Aceptado el 26 de junio de 2019

Publicado el 30 de marzo de 2020

Este documento se debe citar como:

Hernández-Ramos, J., García-Cuevas, X., Pérez-Miranda, R., González-Hernández, A., & Martínez-Ángel, L. (2020). Inventario y mapeo de variables forestales mediante sensores remotos en el estado de Quintana Roo, México. *Madera y Bosques*, 26(1), e2611884. doi: 10.21829/myb.2020.2611884