



Leaf area index and total aboveground biomass in *Eucalyptus urophylla* S. T. Blake plantations using satellite sensors

Índice de área foliar y biomasa aérea total en plantaciones de *Eucalyptus urophylla* S. T. Blake estimados con sensores satelitales

Adrián Hernández-Ramos^{1,2}; José René Valdez-Lazalde^{2*};
Gregorio Ángeles-Pérez²; Héctor Manuel de los Santos-Posadas²;
Jonathan Hernández-Ramos³

¹Colegio de Postgraduados, Postgrado en Ciencias Forestales, Campus Montecillo. km 36.5 Carretera México-Texcoco, Montecillo. C. P. 56264. Texcoco de Mora, Estado de México, México.

²Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP)-Campo Experimental Saltillo. Carretera Saltillo-Zacatecas, km 342 + 119, núm. 9515, Hacienda de Buenavista. C. P. 25315. Saltillo, Coahuila, México.

³Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP)-Campo Experimental Bajío. Carretera Celaya-San Miguel Allende, km 6.5. C. P. 38110. Celaya, Guanajuato, México.

*Corresponding author: valdez@colpos.mx

Abstract

Introduction. Commercial forest plantations require management systems based on timely tree measurements to maximize productivity. Spectral data collected through remote sensors provide an alternative for generating the required information.

Objective. To estimate and map total aboveground biomass (AGB) and leaf area index (LAI) in commercial *Eucalyptus urophylla* S. T. Blake plantations in Huimanguillo, Tabasco, Mexico, using a combination of inventory data and spectral variables derived from satellite sensors.

Materials and methods. The AGB and LAI variables from a traditional inventory were compared with those estimated using multiple linear regression methods and ratio and regression estimators, in which spectral variables from the SPOT 7 and Landsat 8 satellite remote sensors were used as predictors.

Results. AGB and LAI showed strong correlations with the spectral bands (red and green) and vegetation indices from the SPOT 7 sensor. Ratio estimators produced values closer to those from the traditional inventory; however, the maps showed higher prediction errors. Therefore, the multiple linear regression model was selected for the prediction and mapping of AGB and LAI.

Conclusion. The use of spectral information for predicting AGB and LAI was reliable. Data derived from satellite remote sensors are a useful tool for quantifying these tree measurement variables in commercial eucalyptus forest plantation.

Keywords: eucalyptus, vegetation indices, Landsat 8, remote sensors, SPOT 7.

Resumen

Introducción. Las plantaciones forestales comerciales requieren sistemas de manejo basados en información dasométrica oportuna que maximicen la productividad. Los datos espectrales colectados mediante sensores remotos son una opción para generar la información requerida.

Objetivo. Estimar y mapear la biomasa aérea total (Bt) y el índice de área foliar (IAF) de plantaciones forestales comerciales de *Eucalyptus urophylla* S. T. Blake en Huimanguillo, Tabasco, México, a partir de la combinación de datos de inventario y variables espectrales derivadas de sensores satelitales.

Materiales y métodos. Las variables Bt e IAF de un inventario tradicional se compararon con las estimadas a través de métodos de regresión lineal múltiple y estimadores de razón y regresión, en los cuales se emplearon variables espectrales de los sensores remotos satelitales SPOT 7 y Landsat 8 como predictoras.

Resultados. La Bt e IAF tuvieron correlaciones altas con las bandas espectrales (roja y verde) e índices de vegetación del sensor SPOT 7. Los estimadores de razón presentaron valores más cercanos al inventario tradicional; sin embargo, el mapeo resultó con errores de predicción más altos, por ello se eligió el modelo de regresión lineal múltiple para la predicción y mapeo de la Bt y el IAF.

Conclusión. El empleo de información espectral para la predicción de Bt e IAF fue confiable. Los datos derivados de sensores remotos satelitales son una herramienta útil para la cuantificación de dichas variables dasométricas en plantaciones forestales comerciales de eucalipto.

Palabras clave: eucalipto, índices de vegetación, Landsat 8, sensores remotos, SPOT 7.

Please cite this article as follows (APA 7): Hernández-Ramos, A., Valdez-Lazalde, J. R., Ángeles-Pérez, G., de los Santos-Posadas, H. M., & Hernández-Ramos, J. (2026). Leaf area index and total aboveground biomass in *Eucalyptus urophylla* S. T. Blake plantations using satellite sensors. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 32, e25016. <https://doi.org/10.5154/r.rchscfa.2025.03.016>



Introduction

Commercial forest plantations (CFP) cover approximately 131 million hectares, representing 3 % of the global forest area (Food and Agriculture Organization [FAO], 2020), and account for about 46 % of the industrial wood supply worldwide (Payn et al., 2015). In addition to timber production, CFP provide environmental benefits; for example, they support high levels of wildlife biodiversity and have the potential to absorb large amounts of CO₂ and reduce the high concentration of greenhouse gases in the atmosphere (García-Cuevas et al., 2022; Solís-Silva et al., 2022). Although they compete with other productive land uses, CFP make a significant contribution to meeting the growing demand for wood products. Therefore, it is necessary to increase productivity per unit area, which largely depends on the amount of foliage available (leaf area) for photosynthesis (Hernández-Ramos et al., 2021; Liu et al., 2015), the process responsible for biomass production and wood accumulation in trees (Sun et al., 2019).

Estimating total aboveground biomass (AGB) in plantations is essential for quantifying stored carbon, a key input for climate change and forest management studies (FAO, 2020; Hernández-Ramos et al., 2017). In this context, periodic assessment of leaf area index (LAI) and AGB in a plantation is crucial for evaluating its health status (Solís-Silva et al., 2022), planning the timely implementation of silvicultural practices (Muñoz-Ruíz et al., 2014), and monitoring its productivity (Hernández-Ramos et al., 2021). Therefore, it is important that these variables be estimated efficiently.

Forest inventories based on field sampling are the most used method for quantifying forest variables at the local scale (Hernández-Ramos et al., 2020; López Serrano et al., 2021). However, they become impractical when it is necessary to characterize the spatial distribution of variables over large areas or to conduct repeated assessments at short time intervals (Wang et al., 2023; Zhu et al., 2020). In this context, satellite remote sensors provide an alternative for estimating forest variables, because they offer spectral information with broad spatial and temporal coverage (Qiao et al., 2023; Xu et al., 2018; Yi-Min & Meng-Jun, 2019); moreover, they can significantly reduce inventory costs (Mattos et al., 2020).

Eucalyptus is one of the most widely used genera for establishing timber CFP in Mexico, accounting for 21 % of the total planted area (Comisión Nacional Forestal [CONAFOR], 2020). *Eucalyptus urophylla* S. T. Blake has the largest planted area in southeastern Mexico due to its high adaptability and rapid growth (Hernández-Ramos et al., 2017). The objective of this study was to estimate and map total aboveground biomass and leaf

Introducción

Las plantaciones forestales comerciales (PFC) abarcan cerca de 131 millones de hectáreas, lo que representa 3 % de la superficie forestal mundial (Food and Agriculture Organization [FAO], 2020) con una producción alrededor de 46 % de la madera industrial demandada a nivel global (Payn et al., 2015). Además de la producción de madera, las PFC proporcionan beneficios ambientales; por ejemplo, albergan alta biodiversidad de vida silvestre y tienen potencial para absorber gran cantidad de CO₂ y reducir la concentración alta de gases de efecto invernadero de la atmósfera (García-Cuevas et al., 2022; Solís-Silva et al., 2022). A pesar de que compiten con otras actividades productivas por el uso de la tierra, las PFC contribuyen fuertemente a satisfacer la demanda creciente de productos maderables. Por ello, es necesario aumentar la productividad por unidad de superficie, la cual depende en buena medida de la cantidad de hojas disponibles (área foliar) para realizar fotosíntesis (Hernández-Ramos et al., 2021; Liu et al., 2015), actividad responsable de la generación de biomasa y de acumulación de madera en los árboles (Sun et al., 2019).

El conocimiento de la biomasa aérea total (Bt) acumulada en las plantaciones es indispensable para la estimación del carbono almacenado, insumo para estudios de cambio climático y de gestión forestal (FAO, 2020; Hernández-Ramos et al., 2017). En este contexto, la evaluación periódica del índice de área foliar (IAF) y Bt de una plantación es clave para evaluar su estado sanitario (Solís-Silva et al., 2022), planificar la aplicación oportuna de labores silvícolas (Muñoz-Ruíz et al., 2014) y dar seguimiento a su productividad (Hernández-Ramos et al., 2021). Por ello, es importante que dichas variables sean estimadas de forma eficiente.

El inventario forestal basado en un muestreo en campo es el método más utilizado para la cuantificación de variables forestales a escala local (Hernández-Ramos et al., 2020; López Serrano et al., 2021). Sin embargo, resulta impráctico cuando se requiere caracterizar la distribución espacial de las variables en superficies grandes o de manera repetida en intervalos cortos de tiempo (Wang et al., 2023; Zhu et al., 2020). En este sentido, los sensores remotos satelitales representan una alternativa para la estimación de variables forestales, debido a que proveen información espectral con cobertura amplia, espacial y temporal (Qiao et al., 2023; Xu et al., 2018; Yi-Min & Meng-Jun, 2019); además, pueden reducir los costos de inventario significativamente (Mattos et al., 2020).

Eucalyptus es uno de los géneros más utilizados para establecer PFC maderables en México; esta especie concentra 21 % de la superficie total plantada (Comisión Nacional Forestal [CONAFOR], 2020). En particular,

area index in *E. urophylla* plantations established in Huimanguillo, Tabasco, Mexico, using a combination of inventory data and spectral variables derived from SPOT 7 and Landsat 8.

Materials and Methods

Study area

The study was conducted in commercial *E. urophylla* forest plantations located in the municipality of Huimanguillo, Tabasco, Mexico ($17^{\circ} 55' N$, $94^{\circ} 06' W$; mean elevation of 30 m) (Figure 1). The region is characterized by a warm humid (Am) climate, with abundant summer rainfall, a mean annual precipitation of 2 500 mm, and a mean annual temperature ranging from $25.4^{\circ} C$ to $26.2^{\circ} C$. The predominant soil type is Phaeozem (Instituto Nacional de Estadística y Geografía [INEGI], 2014), and the native vegetation is classified as tropical rainforest (INEGI, 2021).

Field data

E. urophylla plantations of varying ages (1 to 7 years) were sampled using a random sampling design consisting of 28 rectangular plots (20 x 25 m), each with an area of 500 m². Tree measurements were collected in each plot in July of year one (beginning of the study) and August of year two (end of the study), recording diameter at breast height (DBH, cm) and total height (Ht, m) for all individuals. These data were used to estimate basal area (Ba, m²), total volume (Vol, m³), total aboveground biomass (AGB, Mg), and foliar biomass

Eucalyptus urophylla S. T. Blake es la especie de mayor superficie plantada en el sureste de México, debido a su adaptabilidad alta y crecimiento rápido (Hernández-Ramos et al., 2017). El objetivo de este estudio fue estimar y mapear la biomasa aérea total y el índice de área foliar de plantaciones de *E. urophylla*, establecidas en Huimanguillo, Tabasco, México, a partir de la combinación de datos de inventario y variables espectrales de imágenes satelitales SPOT 7 y Landsat 8.

Materiales y métodos

Área de estudio

El estudio se realizó en PFC de *E. urophylla* establecidas en el municipio de Huimanguillo, Tabasco, México ($17^{\circ} 55' N$, $94^{\circ} 06' O$ y elevación promedio de 30 m) (Figura 1). El clima de la zona es cálido húmedo (Am) con lluvias abundantes en verano, precipitación media anual de 2 500 mm y temperatura media anual entre $25.4^{\circ} C$ y $26.2^{\circ} C$. El suelo dominante es Phaeozem (Instituto Nacional de Estadística y Geografía [INEGI], 2014) y la vegetación nativa de la zona está categorizada como selva alta perennifolia (INEGI, 2021).

Datos de campo

Se muestrearon plantaciones de *E. urophylla* de edad variable (1 a 7 años) mediante un sistema de muestreo aleatorio conformado por 28 sitios rectangulares (20 x 25 m) de 500 m². En cada sitio se hicieron mediciones dasométricas en julio del año uno (inicio del estudio) y agosto del año dos (final del estudio) donde se registraron

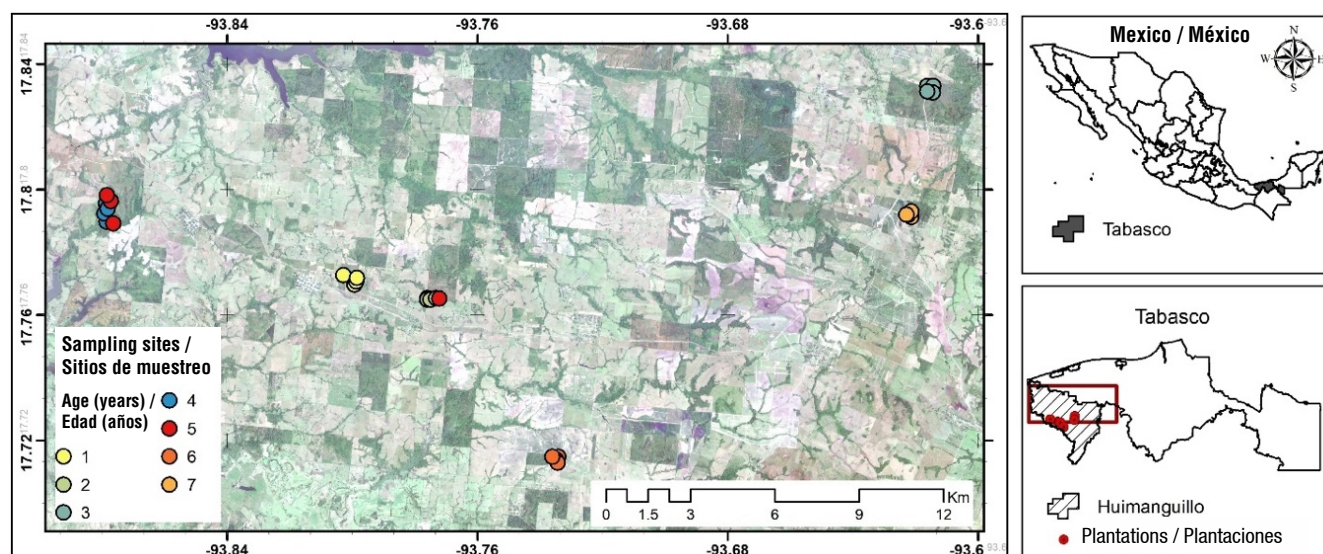


Figure 1. Geographic location of the sampling sites and commercial *Eucalyptus urophylla* forest plantations established in Huimanguillo, Tabasco, Mexico.

Figura 1. Ubicación geográfica de los sitios de muestreo y de las plantaciones forestales comerciales de *Eucalyptus urophylla* establecidas en Huimanguillo, Tabasco, México.

(Bf, Mg) at the tree level using the models developed by Hernández-Ramos et al. (2017) for this species. Subsequently, the results were expressed at the plot and per-hectare (ha) levels. Foliar biomass (Bf) was then used as the basis for estimating the allometric leaf area index (LAI_A) for each plot using the individual projected leaf area model (PLA_{ind}), developed for *E. urophylla* in the same study plantations (Table 1).

In parallel, site-level LAI was estimated using both an optical method (LAI_O) and a litterfall approach (LAI_H). To estimate LAI_O , five hemispherical photographs were taken at each sampling site: four distributed within 12.5×10 m quadrants and one additional photograph at the center of the site. These images were analyzed using the Hemisfer application ©Patrick Schleppei version 2.13 application (Schleppei et al., 2007). LAI_H was calculated as the product of the total litterfall collected per site from four litter traps over a 12-month period and the specific leaf area (SLA) for *E. urophylla*, estimated following the methodology described by Hernández et al. (2021). Finally, a calibrated LAI (LAI_C) was obtained using a model that relates optical LAI data (Table 1).

Spectral data and vegetation indices

A satellite image from the SPOT 7 sensor was used, with a spatial resolution of 6 m, four spectral bands (blue, green, red, and infrared), a radiometric resolution of 16 bits, and a temporal resolution of one to three days (ASTRIUM, 2013). The scene was provided by the Estación de Recepción México Nueva Generación (ERMEX-NG), with a Standard Ortho processing level, corresponding to an orthorectified image georeferenced to the UTM 15N coordinate system, WGS84 datum and ellipsoid. The spectral data were converted to top-of-atmosphere radiance and subsequently to reflectance using the following equations (ASTRIUM, 2013):

las variables diámetro normal (Dn, cm) y altura total (At, m) de todos los individuos. Estos datos se emplearon para calcular el área basal (Ab , m^2), volumen total (Vt , m^3), biomasa aérea total (Bt, Mg) y biomasa foliar (Bf, Mg) a nivel árbol con los modelos generados por Hernández-Ramos et al. (2017) para la especie. Posteriormente, los resultados se calcularon a valores por sitio y por hectárea (ha). La Bf sirvió de base para estimar el índice de área foliar alométrico (IAF_A) de cada sitio con el modelo de área foliar proyectada individual (AFP_{ind}), creado para *E. urophylla* en las mismas plantaciones de estudio (Cuadro 1).

Paralelamente, se estimó el IAF a nivel sitio por un método óptico (IAF_O) y mediante 'caída de hojarasca' (IAF_H). Para estimar el IAF_O , se capturaron cinco fotografías hemisféricas en cada sitio de muestreo: cuatro distribuidas en los cuadrantes de 12.5×10 m y una adicional ubicada en el centro del sitio, mismas que se analizaron con la aplicación Hemisfer ©Patrick Schleppei versión 2.13 (Schleppei et al., 2007). El IAF_H se calculó como el producto de la sumatoria de la hojarasca recolectada por sitio en cuatro trampas de captura durante 12 meses y el área foliar específica (AFE) para *E. urophylla* estimada con la metodología empleada por Hernández et al. (2021). Finalmente, se estimó un IAF calibrado (IAF_C) con un modelo que relaciona los datos de IAF óptico (Cuadro 1).

Datos espectrales e índices de vegetación

Se utilizó una imagen de satélite del sensor SPOT 7 con resolución espacial de 6 m, espectral de cuatro bandas (azul, verde, rojo e infrarrojo), radiométrica de 16 bits y temporal de uno a tres días (ASTRIUM, 2013). La escena fue proporcionada por la Estación de Recepción México Nueva Generación (ERMEX-NG), con el grado de procesamiento Standard Ortho, correspondiente a una imagen ortorrectificada y georreferenciada al sistema

Table 1. Equations for estimating forest parameters of *Eucalyptus urophylla* in commercial plantations of varying age.

Cuadro 1. Ecuaciones para estimar los parámetros forestales de *Eucalyptus urophylla* en plantaciones comerciales con edad variable.

Variable	Equation	Ecuación	Source / Fuente
Total aboveground biomass (AGB)/ Biomasa aérea total (Bt)	$AGB = 179.3627 * (DBH^2Ht)^{0.750777}$	$Bt = 179.3627 * (Dn^2At)^{0.750777}$	Hernández-Ramos et al. (2017)
Foliar biomass (Bf)/ Biomasa foliar (Bf)	$Bf = 1.998759 + 44.66013 * DBH - 0.27063 * Ht$	$Bf = 1.998759 + 44.66013 * Dn - 0.27063 * At$	Hernández-Ramos et al. (2017)
Individual projected leaf area (PLA_{ind}) / Área foliar proyectada individual (AFP_{ind})	$PLA_{ind} = 7.952315 * Bf^{1.006678}$	$AFP_{ind} = 7.952315 * Bf^{1.006678}$	Hernández-Ramos et al. (2021)
Allometric leaf area index (LAI_A) per site / Índice de área foliar alométrico (IAF_A) por sitio	$LAI_A = \Sigma PLA_{ind} / SA$	$IAF_A = \Sigma AFP_{ind} / SS$	Hernández-Ramos et al. (2021)
Calibrated leaf area index (LAI_C) / Índice de área foliar calibrado (IAF_C)	$LAI_C = 1.650636 * LAI_O^{0.956617}$	$IAF_C = 1.650636 * IAF_O^{0.956617}$	Hernández-Ramos et al. (2021)

DBH: diameter at breast height at 1.30 m above ground (cm); Ht: total height (m); LAI_O : optical leaf area index ($m^2 \cdot m^{-2}$); SA: site area (m^2).

Dn: diámetro normal a 1.30 m del suelo (cm); At: altura total (m); IAF_O : Índice de área foliar óptico ($m^2 \cdot m^{-2}$); SS: superficie del sitio (m^2).

$$L_b(p) = \frac{DC(p)}{GAIN(b)} + BIAS(b) \text{ and } \rho_b(p) = \frac{\pi L_b(p)}{E_0(b) \cos(\theta_s)}$$

where, $L_b(p)$ = top-of-atmosphere radiance ($W \cdot sr^{-1} \cdot m^{-2} \cdot \mu m^{-1}$), $DC(p)$ = pixel digital numbers, $GAIN(b)$ = band gain calibration coefficient, $BIAS(b)$ = band multiplicative factor, $\rho_b(p)$ = spectral reflectance of each band, $E_0(b)$ = mean solar irradiance of the band ($W \cdot m^{-2} \cdot \mu m^{-1}$), θ_s = solar zenith angle of the image ($^\circ$).

A multispectral image from the Landsat 8 sensor was also used, with a spatial resolution of 30 m, 11 spectral bands, and a radiometric resolution of 16 bits (Ariza, 2013). The scene was obtained from the archive managed by the United States Geological Survey (USGS), with a Level-1 Terrain (L1T) processing and georeferenced to the UTM 15N coordinate system, WGS84 datum and ellipsoid. For this sensor, digital numbers were converted to top-of-atmosphere reflectance values using the following equation (Ariza, 2013):

$$\rho_b(p) = \frac{M_p ND + A_p}{\cos(\theta_s)}$$

where, $\rho_b(p)$ = spectral reflectance of each band, M_p = band-specific multiplicative rescaling factor, DN = pixel digital numbers, A_p = band-specific additive rescaling factor, θ_s = solar zenith angle of the image ($^\circ$).

Following the radiometric correction of the images, four vegetation indices were calculated for each sensor using the relationship between the red and near-infrared bands (Flores-Rodríguez et al., 2020; Hurtado Abril & Lizarazo, 2022; Qin et al., 2022) (Table 2).

Extraction of spectral values by site

Complementary to vegetation indices, spectral information from each sensor's bands was analyzed. For SPOT 7, the blue (B), green (G), red (R), and near-

de coordenadas UTM 15N, datum y elipsoide WGS84. Los datos espectrales se convirtieron a radiancia al tope de la atmósfera y, posteriormente, a reflectancia con las ecuaciones siguientes (ASTRIUM, 2013):

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

donde, $L_b(p)$ = radiancia al tope de la atmósfera ($W \cdot sr^{-1} \cdot m^{-2} \cdot \mu m^{-1}$), $DC(p)$ = números digitales del píxel, $GAIN(b)$ = coeficiente de calibración de las ganancias de la banda, $BIAS(b)$ = factor multiplicativo de la banda, $\rho_b(p)$ = reflectancia espectral de cada banda, $E_0(b)$ = radiancia solar media de la banda ($W \cdot m^{-2} \cdot \mu m^{-1}$), θ_s = ángulo solar de la imagen ($^\circ$).

Se utilizó también una imagen multiespectral del sensor Landsat 8, con resolución espacial de 30 m, espectral de 11 bandas y radiométrica de 16 bits (Ariza, 2013). La escena se obtuvo del archivo administrado por United States Geological Survey (USGS), con un grado de procesamiento Nivel-1 Terrain (L1T) y georreferenciada al sistema de coordenadas UTM 15N, datum y elipsoide WGS84. Para este sensor, los números digitales se convirtieron a valores de reflectancia en el tope de la atmósfera con la ecuación siguiente (Ariza, 2013):

$$\rho_b(p) = \frac{M_p ND + A_p}{\cos(\theta_s)}$$

donde, $\rho_b(p)$ = reflectancia espectral de cada banda, M_p = factor multiplicativo de escalado específico por banda, ND = números digitales del píxel, A_p = factor aditivo de escalado específico por banda, θ_s = ángulo solar de la imagen ($^\circ$).

Posterior a la corrección radiométrica de las imágenes se calcularon cuatro índices de vegetación para cada sensor, tomando la relación entre las bandas roja e infrarroja (Flores-Rodríguez et al., 2020; Hurtado Abril & Lizarazo, 2022; Qin et al., 2022) (Cuadro 2).

Table 2. Vegetation indices derived from the relationship between the red (R) and near-infrared (NIR) bands of Landsat 8 and SPOT 7 multispectral images.

Cuadro 2. Índices de vegetación generados con la relación entre las bandas rojo (R) e infrarrojo cercano (IRC) de las imágenes multiespectrales Landsat 8 y SPOT 7.

Vegetation index / Índice de vegetación	Equation	Ecuación
Simple ratio (SR) / Relación Simple (RS)	SR = NIR / R	RS = IRC / R
Normalized Difference Vegetation Index (NDVI) / Índice de vegetación de diferencia normalizada (NDVI)	NDVI = (NIR - R) / (NIR + R)	NDVI = (IRC - R) / (IRC + R)
Transformed Vegetation Index (TVI) / NDVI transformado (TVI)	TVI = $\sqrt{NDVI + 0.5}$	TVI = $\sqrt{NDVI + 0.5}$
Normalized Ratio Vegetation Index (NRVI) / Relación simple normalizada (NRVI)	NRVI = SR - [1 / (SR + 1)]	NRVI = RS - [1 / (RS + 1)]

infrared (NIR) bands were included; for Landsat 8, the aforementioned bands as well as the shortwave infrared (SWIR) band were used. Reflectance values and vegetation indices were extracted from the imagery as the average of the pixels located within the 500 m² sampling sites. Satellite images were processed using ArcMap 10.4® (Esri, 2016).

Statistical analysis

Estimation of traditional inventory using ratio and regression estimators

Field data were analyzed using simple random sampling (SRS) and stratified sampling (SS) based on plantation age to estimate the total inventory of the variables Ba, Vol, AGB and LAI. The results from these methods were considered the “traditional inventory.” These values were used as a reference for comparison with the other methods applied to estimate AGB and LAI. Based on the relationship between the red and near-infrared spectral bands and vegetation indices with stand variables, the data were also analyzed using ratio estimators (REr) and regression estimators (REg) to generate confidence intervals with smaller amplitudes than those obtained using SRS and SS (Pérez et al., 2018; Valdez-Lazalde et al., 2006). REr and REg are based on an auxiliary variable (X) to predict the variable of interest (Y). In the former, the approach consisted of estimating the proportion of Y relative to X, where R is a population constant defined as $R = \bar{Y}/\bar{X}$. For REg, an auxiliary variable was used to estimate population means of Y through regression.

Multiple regression models

In the regression analysis, two approaches were considered for model development. The first consisted of a Pearson correlation analysis between the spectral bands and vegetation indices from the SPOT7 and Landsat 8 sensors and the variables of interest (AGB and the different LAI estimates by method), selecting those variables that showed the strongest relationship. Subsequently, multiple linear regression (MLR) was applied to generate the model with the best predictive performance. The second approach consisted of a stepwise regression to select a model including the variables with the greatest contribution to prediction. Finally, both models were compared to select the best one, based on the highest adjusted coefficient of determination (R^2_{adj}) and the lowest root mean square error (RMSE):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}^{(i)})^2}{n}}$$

Extracción de valores espectrales por sitio

Además de los índices de vegetación se analizó la información espectral de las bandas de cada sensor. Para SPOT 7 se agregaron las bandas azul (A), verde (V), rojo (R) e infrarrojo (IRC); para Landsat 8, las bandas antes mencionadas y el infrarrojo de onda corta (IROC). Los valores de reflectancia y de los índices de vegetación se extrajeron de la imagen como el promedio de los píxeles localizados dentro de los sitios de muestreo de 500 m². Las imágenes de satélite se procesaron en el programa ArcMap 10.4® (Esri, 2016).

Análisis estadístico

Estimación de inventario tradicional y mediante estimadores de razón y regresión

Los datos colectados en campo se analizaron mediante estimadores de muestreo simple al azar (MSA) y muestreo estratificado (ME) por la edad de plantación, para estimar el inventario total de las variables Ab, Vt, Bt e IAF. El resultado de estos métodos se consideró como ‘inventario tradicional’. Los valores obtenidos se utilizaron como punto de comparación en el resto de los métodos empleados para estimar la Bt y el IAF. Con base en la relación existente entre las bandas espectrales rojo, infrarroja y los índices de vegetación con las variables del rodal, los datos se analizaron también con estimadores de razón (ERa) y regresión (ERe), para construir intervalos de confianza de menor amplitud que los obtenidos mediante MSA y ME (Pérez et al., 2018; Valdez-Lazalde et al., 2006). Los ERa y ERe se basan en una variable auxiliar (X) para predecir la variable de interés (Y). En el primero se empleó el enfoque de estimar la proporción de Y respecto a X, donde R es una constante poblacional definida como $R = \bar{Y}/\bar{X}$. Para los ERe se utilizó una variable auxiliar para estimar medias totales de Y a partir de la regresión.

Modelos de regresión múltiple

En el análisis de regresión se consideraron dos enfoques para la construcción del modelo. El primero consistió en un análisis de correlación de Pearson entre las bandas e índices de vegetación del sensor SPOT 7 y Landsat 8 y las variables de interés (Bt y los diferentes IAF por método), seleccionando las variables que presentaron mejor relación. Posteriormente, se empleó la técnica de regresión lineal múltiple (RLM) para generar el modelo de mejor predicción. El segundo enfoque consistió en una regresión *stepwise* para la elección de un modelo que tuviera las variables con mayor aporte a la predicción. Finalmente, se compararon los dos modelos para elegir el mejor, a partir del mayor valor del coeficiente de determinación ajustado (R^2_{Adj}) y del valor más bajo de la raíz del error cuadrático medio (RECM):

where $\hat{Y}^{(i)}$ is the value predicted by the methods used, Y_i corresponds to the observed value in the traditional inventory, and n is the number of observations.

Comparative sampling and error estimation

Mapped AGB and LAI were compared with baseline values derived from SRS and SS. The latter was considered the true value of the population mean and total plantation inventory. A second comparison consisted of calculating the RMSE of the estimates obtained from linear regression and from both ratio and regression estimators.

Results and Discussion

At the beginning of the evaluation, the mean total inventory of Ba, Vol, AGB, and LAI_A in *E. urophylla* plantations was 16.23 m²·ha⁻¹, 161.18 m³·ha⁻¹, 90.73 Mg·ha⁻¹, and 2.59 m²·m⁻², respectively. By the end of the evaluation (one year later), these values increased to 18.00 m²·ha⁻¹, 168.30 m³·ha⁻¹, 95.00 Mg·ha⁻¹, and 2.90 m²·m⁻²; both sets of values were calculated using SRS. Estimates obtained using SS, REr, and REg showed improved precision by reducing sampling error; the population mean (μ_x) estimated through SS exhibited the highest precision (Table 3).

The inventory estimated using SRS was the least reliable, with a sampling error greater than the recommended threshold (10 %) and wider confidence intervals, likely due to the high variability associated with plantation age, as reported by Acosta Mireles et al. (2017) and Pérez Miranda et al. (2018). In contrast, the age-based SS showed lower sampling errors across all variables. Therefore, this method was selected as the baseline for comparison with the other methods used. The REr and REg estimators were only calculated for AGB and LAI; the results were satisfactory for AGB but not for LAI, for which the sampling error was high in the case of REr. Similar results were obtained in the estimation of a temperate forest inventory in Hidalgo, Mexico, where SS improved estimates compared to SRS (Muñoz-Ruíz et al., 2014).

Correlation between field data and spectral variables

The spectral bands and vegetation indices from the SPOT 7 satellite showed significantly higher correlation with LAI_H and LAI_C. In contrast, for the Landsat 8 satellite, the relationships were low and significant only for the LAI_A values calculated at the beginning of the study. Initial AGB showed a higher correlation with two spectral bands from both SPOT 7 and Landsat 8; however, this correlation was not significant, which

$$RECM = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}^{(i)})^2}{n}}$$

donde $\hat{Y}^{(i)}$ es el valor predicho por el método empleado, Y_i corresponde al valor observado en el inventario tradicional y n es el número de observaciones.

Muestreo comparativo y estimación del error

La Bt y el IAF mapeados se compararon con los valores base, calculados mediante el MSA y el ME. Este último fue tomado como valor real de la media poblacional e inventario total de las plantaciones. Un segundo proceso de comparación fue el cálculo de los RECM de las estimaciones de regresión lineal, estimadores de razón y regresión.

Resultados y discusión

Al inicio de la evaluación, el inventario total promedio de Ab, Vt, Bt e IAF_A de las plantaciones de *E. urophylla*, fue 16.23 m²·ha⁻¹, 161.18 m³·ha⁻¹, 90.73 Mg·ha⁻¹ y 2.59 m²·m⁻², respectivamente. Al final de la evaluación (un año después), los valores incrementaron a 18.00 m²·ha⁻¹, 168.30 m³·ha⁻¹, 95.00 Mg·ha⁻¹ y 2.90 m²·m⁻²; ambos grupos de valores se calcularon bajo MSA. Los valores estimados con ME, ERA y ERe mejoraron en precisión, reduciendo el error de muestreo; la media poblacional (μ_x) obtenida mediante ME tuvo la mayor precisión (Cuadro 3).

El inventario estimado mediante MSA resultó el menos confiable con error de muestreo mayor que el recomendado (10 %) y amplitud mayor de los intervalos de confianza, debido probablemente a la variación alta generada por la edad de las plantaciones, tal como mencionan Acosta Mireles et al. (2017) y Pérez Miranda et al. (2018). De manera contraria, el ME por la edad tuvo errores de muestreo menores en todas las variables. Por tanto, este método se eligió como base para la comparación con el resto de los métodos utilizados. Los estimadores ERA y ERe solo se calcularon para Bt e IAF; los resultados fueron adecuados para Bt, pero no para IAF cuyo error de muestreo fue alto en el caso de ERA. Resultados similares se obtuvieron en la estimación del inventario de un bosque templado de Hidalgo, México, donde el ME mejoró las estimaciones en comparación con el MSA (Muñoz-Ruíz et al., 2014).

Correlación entre los datos de campo y las variables espectrales

Las bandas espectrales e índices de vegetación del satélite SPOT 7 tuvieron correlación significativamente mayor con el IAF_H y el IAF_C. En cambio, para el satélite Landsat 8, las relaciones fueron bajas y significativas solo con los valores de IAF_A calculado al inicio del estudio. La Bt inicial

Table 3. Forest inventory estimated using simple random sampling (SRS), stratified sampling (SS), ratio estimators (REr), and regression estimators (REg) for *Eucalyptus urophylla* plantations in Huimanguillo, Tabasco, Mexico.

Cuadro 3. Inventario forestal mediante muestreo simple al azar (MSA), muestreo estratificado (ME), estimadores de razón (ERa) y regresión (ERe) para plantaciones de *Eucalyptus urophylla* en Huimanguillo, Tabasco, México.

Estimation method Método de estimación		Beginning of the evaluation/ Inicio de evaluación				End of the evaluation/ Final de evaluación			
		Ba (m ² ·ha ⁻¹)/ Ab (m ² ·ha ⁻¹)	Vol/Vt (m ³ ·ha ⁻¹)	AGB /Bt (Mg·ha ⁻¹)	LAI/ IAF	Ba (m ² ·ha ⁻¹)/ Ab (m ² ·ha ⁻¹)	Vol/Vt (m ³ ·ha ⁻¹)	AGB /Bt (Mg·ha ⁻¹)	LAI/ IAF
SRS/ MSA	Mean/Media	16.24	161.18	90.73	2.59	18.00	168.30	95.00	2.90
	CI+/IC+	19.35	200.26	110.94	2.74	20.32	198.84	110.38	3.08
	CI-/IC-	13.12	122.10	70.53	2.44	15.68	137.77	79.62	2.72
	SE/EM	19	24	22	6	13	18	16	6
SS/ ME	Mean/Media	16.15	163.83	93.47	2.31	17.56	175.97	99.78	2.46
	CI+/IC+	16.93	172.42	98.13	2.41	18.37	185.32	104.85	2.56
	CI-/IC-	15.37	155.24	88.80	2.21	16.75	166.61	94.70	2.35
	SE/EM	5	5	5	4	5	5	5	4
REr/ ERa	Mean/Media			93.95	2.32			102.31	2.52
	Ratio/Razón			5.79	2.86			5.68	2.80
	SE/EM			4	20			5	17
REg/ ERe	Mean/Media			90.19	2.60			103.62	2.89
	Slope (b)/ Pendiente (b)			6.44	0.13			6.52	-0.31
	SE/EM			3	6			3	6

Ba: Basal area; Vol: total volume; AGB: total aboveground biomass; LAI: allometric leaf area index; CI+: upper confidence interval; CI-: lower confidence interval; SE: sampling error (%).

Ab: área basal; Vt: volumen total; Bt: biomasa aérea total; IAF: índice de área foliar alométrico; IC+: intervalo de confianza superior; IC-: intervalo de confianza inferior; EM: error de muestreo (%).

may be due to variability in estimates across different plantations ages and the low spatial resolution of the sensors (Table 4).

The blue, green, and red spectral bands showed negative correlations in the SPOT 7 sensor and a decreasing trend as LAI increases (Table 4). This behavior is driven by the high chlorophyll content in leaves, which collectively controls the absorption and reflectance of solar radiation (Solís-Silva et al., 2022). In addition, low reflectance values in these bands are characteristic of a dense canopy and photosynthetically active vegetation, indicating growing plantations such as those evaluated in this study. These results are consistent with those reported by Acosta-Mireles et al. (2017) and Torres-Vivar et al. (2017), who found negative correlations between spectral bands from the SPOT 6 and Landsat 7 sensors with high-density areas and dense vegetation, respectively. Similarly, Hernández-Ramos et al. (2020), using Landsat 7 data, and López Serrano et al. (2021), using Sentinel-2A data, reported negative relationships in sites with abundant AGB due to the absorption of visible light by tree vegetation.

The NIR band showed behavior opposite to that of the visible spectrum bands, i.e., a positive correlation with

presentó correlación mayor con dos bandas espectrales de SPOT 7 y de Landsat 8, aunque esta no fue significativa, lo que podría deberse a la variación generada en las estimaciones a diferentes edades de plantación y a la baja resolución espacial de los sensores (Cuadro 4).

Las bandas espectrales azul, verde y rojo tuvieron correlaciones negativas en el sensor SPOT 7 y una tendencia decreciente conforme el IAF aumenta (Cuadro 4). Este comportamiento es causado por los contenidos altos de clorofila en las hojas, que en conjunto controlan la absorción y reflectancia de la luz solar (Solís-Silva et al., 2022). Además, los valores bajos de reflectancia en estas bandas son característicos de un dosel denso y de vegetación fotosintéticamente activa, que indican plantaciones en crecimiento como las evaluadas en el presente estudio. Estos resultados concuerdan con lo reportado por Acosta Mireles et al. (2017) y Torres-Vivar et al. (2017), quienes encontraron correlaciones negativas entre las bandas espectrales de los sensores SPOT 6 y Landsat 7 con áreas de densidad alta y vegetación vigorosa, respectivamente. De forma similar, Hernández-Ramos et al. (2020) con datos de Landsat 7 y López Serrano et al. (2021) con datos de Sentinel-2A encontraron relaciones negativas en sitios con Bt abundante, debido a la absorción de la luz visible por la vegetación arbórea.

Table 4. Pearson correlation between spectral variables (SV) and leaf area index (LAI) and total aboveground biomass (AGB) in *Eucalyptus urophylla* plantations.**Cuadro 4. Correlación de Pearson entre las variables espectrales (VE) y el índice de área foliar (IAF) y biomasa aérea total (Bt) en plantaciones de *Eucalyptus urophylla*.**

Sensor	SV/VE	LAI _{A1} / IAF _{A1}	LAI _{O1} / IAF _{O1}	LAI _{A2} / IAF _{A2}	LAI _{O2} / IAF _{O2}	LAI _C / IAF _C	LAI _H / IAF _H	AGB ₁ / Bt ₁	AGB ₂ / Bt ₂
SPOT 7	Blue/Azul	0.00	-0.46**	-0.08	-0.37	-0.37*	-0.56***	-0.46*	-0.14
	Green/Verde	-0.03	-0.38**	-0.16	-0.51***	-0.51***	-0.70***	0.12	0.15
	Red/Rojo	-0.08	-0.49***	-0.20	-0.50	-0.50***	-0.75***	-0.34*	-0.06
	NIR/IRC	0.19	-0.22	0.35	0.36*	0.36*	0.38**	0.13	0.23
	NDVI	0.19	0.04	0.36	0.47**	0.47**	0.58***	0.24	0.19
	SRVI/RASI	0.18	0.04	0.33	0.47**	0.47**	0.58***	0.24	0.19
	TVI	0.19	0.04	0.37	0.47**	0.47**	0.58***	0.24	0.19
	NRVI	0.18	0.04	0.33	0.47**	0.47**	0.58***	0.24	0.19
Landsat 8	Blue/Azul	0.38**	-0.16	0.40*	0.01	0.02	-0.07	-0.04	0.05
	Green/Verde	0.37*	-0.10	0.38*	0.03	0.03	-0.04	-0.02	0.03
	Red/Rojo	0.42**	-0.07	0.43*	0.09	0.09	0.03	-0.02	0.00
	NIR/IRC	0.08	0.27	0.04	0.09	0.09	0.30	0.08	0.16
	SWIR/IROC	0.46**	0.04	0.46**	0.23	0.23	0.20	-0.06	-0.13
	NDVI	-0.28	0.36*	-0.39*	0.01	0.01	0.28	0.10	0.12
	NRVI	-0.32*	0.31	-0.41*	-0.05	-0.05	0.24	0.12	0.20
	SRVI/RASI	-0.33*	0.30	-0.42*	-0.06	-0.06	0.22	0.12	0.23
TVI	-0.26	0.38**	-0.38	0.04	0.04	0.30	0.08	0.028	

NIR: infrared; SWIR: shortwave infrared; NDVI: normalized difference vegetation index; NRVI: transformed NDVI; SRVI: simple ratio; TVI: transformed simple ratio; LAI_{A1}, LAI_{O1}, LAI_{A2}, LAI_{O2}, LAI_C, LAI_H: initial allometric, initial optical, final allometric, final optical, calibrated, and litterfall-derived leaf area index, respectively. Significance levels: $p = 0.1^*$, 0.05^{**} and 0.001^{***} , respectively.

IRC: infrarrojo; IROC: infrarrojo de onda corta; NDVI: índice de vegetación de diferencia normalizada; NRVI: NDVI transformado; RASI: razón simple; TVI: razón simple transformada; IAF_{A1}, IAF_{O1}, IAF_{A2}, IAF_{O2}, IAF_C, IAF_H: índice de área foliar alométrico inicial, óptico inicial, alométrico final, óptico final, calibrado y calculado mediante hojarasca, respectivamente. Significancias: $p = 0.1^*$, 0.05^{**} y 0.001^{***} , respectivamente.

the LAI of *E. urophylla* plantations. In turn, vegetation indices showed a positive relationship with LAI and AGB, particularly those derived from SPOT 7 satellite data. The correlation trend between vegetation indices and stand variables is directly proportional to the presence and conditions of vegetation. Torres-Rojas et al. (2016), Hernández-Ramos et al. (2020) and López-Serrano et al. (2021), consistent with the present study, reported positive correlations between vegetation indices constructed from NIR spectral bands and forest parameters of tree species in temperate and tropical ecosystems.

The highest correlation coefficients were recorded for the red and green spectral bands, as well as for vegetation indices derived from the SPOT 7 sensor. For Landsat 8, the bands that showed the strongest correlation with LAI were the SWIR, red and blue bands; however, no significant relationship with AGB was found. These variables were selected to develop a predictive model for LAI_H and initial AGB (Figure 2).

La banda del IRC tuvo comportamiento inverso a las bandas del espectro visible, *i. e.*, una correlación positiva con respecto al IAF de las plantaciones de *E. urophylla*. Por su parte, los índices de vegetación presentaron relación positiva con el IAF y la Bt, principalmente los calculados con información del satélite SPOT 7. La tendencia de correlación de los índices de vegetación con las variables del rodal es directamente proporcional a la presencia de vegetación y a su vigorosidad. Torres-Rojas et al. (2016), Hernández-Ramos et al. (2020) y López-Serrano et al. (2021), al igual que en el presente trabajo, encontraron correlaciones positivas entre los índices de vegetación construidos con las bandas espectrales del IRC y parámetros forestales de especies arbóreas de ecosistemas templados y tropicales.

Los coeficientes mayores de correlación lo presentaron las bandas del espectro rojo, verde y los índices de vegetación para el sensor SPOT 7. Para Landsat 8, las bandas mejor correlacionadas solo con el IAF fueron IROC, rojo y azul, ya que no presentaron relación significativa con

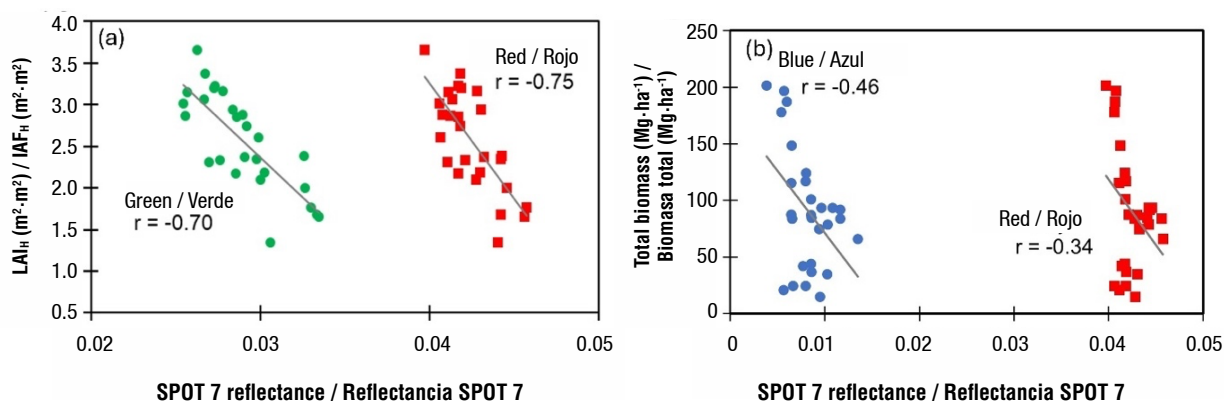


Figure 2. Correlation (r) between the red, green, and blue spectral bands of the SPOT 7 satellite and the leaf area index calculated from litterfall (LAI_H) (a), as well as total aboveground biomass (b), in *Eucalyptus urophylla* plantations in Huimanguillo, Tabasco, Mexico.

Figura 2. Correlación (r) entre las bandas espectrales roja, verde y azul del satélite SPOT 7 con el índice de área foliar calculado con la caída de hojarasca (IAF_H) (a) y con la biomasa aérea total (b) de plantaciones de *Eucalyptus urophylla* en Huimanguillo, Tabasco, México.

The results are consistent with previous studies, which have reported that reflectance in the red and near-infrared regions is sensitive to vegetation density and the accumulation of aboveground biomass (Qiao et al., 2023; Wang et al., 2023). This suggests that medium- and high-resolution optical sensors are a strong tool for the structural characterization of homogeneous plantations, with potential applications in low-cost forest inventories.

The relationships between LAI and AGB with the visible and infrared spectral bands are consistent with those reported in previous studies. Aguirre-Salado et al. (2011) found a strong relationship between the red spectral band and the NDVI derived from the SPOT 5 satellite with LAI and tree canopy cover (Cov, m^2) in *Pinus patula* Schltld. & Cham. forests in Hidalgo, Mexico. On the other hand, Torres-Vivar et al. (2017) found that the infrared band from the SPOT 6 sensor showed the highest correlation with Ba, Cov, AGB, and Vol. In addition, Muñoz-Ruíz et al. (2014) reported that both the water stress index and the simple ratio vegetation index (SRVI) from SPOT 4-5 satellites showed high correlation with variables from the National Forest and Soil Inventory (INFyS) (INFyS: Ba, Vol and Cov).

For the Landsat sensor, Soudani et al. (2006) found a strong correlation between optical LAI and the red spectral band (-0.75) from SPOT 4 and Landsat ETM+, as well as the NDVI-ETM+ (>0.80) in temperate coniferous forests in France. In mixed forests of Durango, Mexico, Pérez Miranda et al. (2018) reported a strong relationship between NDVI derived from Landsat 7 spectral values and forest variables such as Ba, Vol, and AGB. Similarly, Hernández-Ramos et al. (2020)

la Bt. Estas variables se seleccionaron para construir un modelo de predicción del IAF_H y la Bt inicial (Figura 2). Los resultados muestran que estas relaciones son consistentes con lo reportado en otros trabajos, donde se ha documentado que la reflectancia en el rojo y el infrarrojo cercano son sensibles a la densidad de la vegetación y a la acumulación de biomasa aérea (Qiao et al., 2023; Wang et al., 2023). Esto implica que los sensores ópticos de resolución mediana y alta constituyen una herramienta robusta para la caracterización estructural de las plantaciones homogéneas, con potencial de aplicación en inventarios forestales de bajo costo.

Las relaciones del IAF y Bt con las bandas del espectro visible y el IRC son similares a las observadas en otras investigaciones. Aguirre-Salado et al. (2011) demostraron relación alta de la banda del espectro rojo y el NDVI del satélite SPOT 5 con las variables IAF y cobertura arbórea (Cob, m^2) en bosques de *Pinus patula* Schltld. & Cham. en Hidalgo, México. Por otro lado, Torres-Vivar et al. (2017) determinaron que la banda del IRC del sensor SPOT 6 presentó la mejor correlación con el Ab, Cob, Bt y V. Por su parte, Muñoz-Ruíz et al. (2014) reportaron que el índice de estrés hídrico y el índice de vegetación de razón simple (RASI) de los satélites SPOT 4-5 tuvieron correlación alta con las variables del inventario nacional forestal y de suelos (INFyS: Ab, Vt y Cob).

Para el caso del sensor Landsat, Soudani et al. (2006) encontraron correlaciones altas entre el IAF óptico y la banda del espectro rojo (-0.75) de SPOT 4 y Landsat ETM+, además del NDVI-ETM+ (>0.80) en bosques templados de coníferas de Francia. En bosques mixtos de Durango, México, Pérez Miranda et al. (2018) encontraron relación alta entre el NDVI construido

and Perea-Ardila et al. (2021) found that NDVI derived from Landsat 7 and Landsat 8 is strongly correlated with forest variables such as Vol and AGB. Specifically, for commercial *Pinus* plantations, Peduzzi et al. (2010) indicated that NDVI from Landsat TM shows a strong correlation with LAI across different growth seasons (winter and summer).

Although the results of this study confirm the usefulness of these spectral bands and vegetative indices, the prediction may present limitations in areas with higher canopy cover or complex vertical stratification. Future research should include the integration of LiDAR data and multispectral or hyperspectral sensors mounted on unmanned aerial platforms, which would improve the estimation of vegetation attributes (Fassnacht et al., 2014; Maesano et al., 2022).

Regression models for leaf area index and total biomass

The best models for estimating LAI_H and AGB of *E. urophylla* were those composed of spectral information from the SPOT 7 satellite, since Landsat 8 data showed no strong relationships with the forest variables. The model for estimating LAI_H was obtained using a stepwise approach and included the blue (B) and red (R) spectral bands: $LAI_H = 24.15006 - 550.58366 * R + 217.55202 * B$, which yielded an adjusted $R^2_{Adj} = 0.652$, $RMSE = 0.349$ and a good graphical fit (Figure 3a). For AGB, the best-fitting model included the green (G) band, NIR band and SRVI: $AGB = -550.19249 + 29518 * G - 11280 * NIR + 436.72397 * SRVI$ with $R^2_{Adj} = 0.649$ and $RMSE = 31.742$ (Figure 3b).

The relationship between LAI and AGB with the SPOT 7 red band shows a declining reflectance trend as the

con valores espectrales del Landsat 7 y las variables forestales Ab, V y Bt. De la misma forma, Hernández-Ramos et al. (2020) y Perea-Ardila et al. (2021) encontraron que el NDVI de Landsat 7 y de Landsat 8 se correlaciona de manera alta con las variables forestales Vt y Bt. Específicamente, para PFC de *Pinus*, Peduzzi et al. (2010) indicaron que el NDVI del satélite Landsat TM presenta correlación alta con el IAF en diferentes épocas de desarrollo (invierno y verano).

Si bien los resultados de este estudio confirman la utilidad de estas bandas espectrales e índices de vegetación, las predicciones podrían presentar limitaciones en áreas con mayor cobertura arbórea o con estratificación vertical compleja. Una línea futura de investigación debería incluir la integración de datos LiDAR y de sensores multispectrales o hiperespectrales montados en plataformas aéreas no tripuladas, lo cual permitiría mejorar la estimación de los atributos de la vegetación (Fassnacht et al., 2014; Maesano et al., 2022).

Modelos de regresión para índice de área foliar y biomasa total

Los mejores modelos para estimar el IAF_H y la Bt de *E. urophylla* fueron los compuestos con información espectral del satélite SPOT 7, debido a que la información de Landsat 8 no presentó relaciones altas con las variables forestales. El modelo para estimar el IAF_H se obtuvo con el enfoque de *stepwise*, conformado con las bandas espectrales azul (A) y roja (R): $IAF_H = 24.15006 - 550.58366 * R + 217.55202 * A$, el cual presentó $R^2_{Aju} = 0.652$, $RECM = 0.349$ y ajuste gráfico adecuado (Figura 3a). Para la Bt, el modelo con mejor ajuste está compuesto de la banda verde (V), la del IRC y RASI: $Bt = -550.19249 + 29518 * V - 11280 * IRC + 436.72397 * RASI$ con $R^2_{Aju} = 0.649$ y $RECM = 31.742$ (Figura 3b).

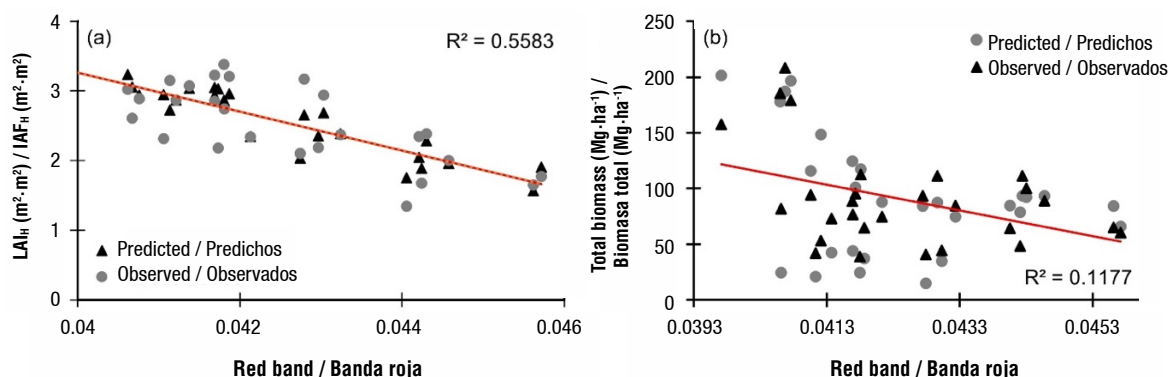


Figure 3. Scatterplot of observed and predicted values of (a) leaf area index (LAI_H) and (b) total aboveground biomass estimated in *Eucalyptus urophylla* plantations in relation to the red spectral band of the SPOT 7 sensor.

Figura 3. Diagrama de dispersión de valores observados y predichos del (a) índice de área foliar (IAF_H) y (b) biomasa aérea total estimados en plantaciones de *Eucalyptus urophylla* contra la banda espectral roja del sensor SPOT 7.

values of the forest variables increase (Figure 3), which is caused by the absorption of this spectral region by chlorophyll pigments. The red spectral band is widely used to characterize vegetation properties, as reported by Acosta-Mireles et al. (2017), Pérez-Miranda et al. (2018), Hernández-Ramos et al. (2020) and López-Serrano et al. (2021). These authors characterized forest parameters using the red band and vegetation indices based on Landsat and Sentinel satellite data, respectively. Similarly, Castillo et al. (2017) found that the best model for predicting AGB in mangrove forests included the combination of the red and infrared bands from the Sentinel-2 sensor.

Comparison of the traditional inventory versus ratio and regression estimators

The total inventory of LAI and AGB were estimated using SS. These values were used as a reference to compare the estimates obtained from spectral data. For RER and REg, the red spectral band from the SPOT 7 satellite was used as the auxiliary variable, as it showed the highest correlation with LAI_H and AGB. The estimates obtained using RER were the most similar to those from SS for both variables, as well as the most conservative for LAI_H. REg and MLR showed similar LAI_H values. For AGB, the most conservative estimates were obtained using the MLR compared to the traditional inventory (Table 5).

The methods used to estimate LAI_H and AGB produced satisfactory results. A comparison of these results with the confidence intervals of the traditional inventory

La gráfica de los valores del IAF y Bt contra la banda roja del sensor SPOT 7 muestra una respuesta decreciente de la reflectancia conforme los valores de las variables forestales aumentaron (Figura 3), causado por la absorción de este intervalo del espectro por los pigmentos de clorofila. La banda del espectro rojo es útil para describir las características de la vegetación, como lo demuestran Acosta-Mireles et al. (2017), Pérez-Miranda et al. (2018), Hernández-Ramos et al. (2020) y López-Serrano et al. (2021). Dichos autores describieron los parámetros forestales a partir de la banda roja y los índices de vegetación generados con información de los sensores satelitales Landsat y Sentinel, respectivamente. En el mismo sentido, Castillo et al. (2017) encontraron que el mejor modelo para predecir la Bt de bosques de manglares presentaba la combinación de las bandas roja e IRC del sensor Sentinel-2.

Comparación del inventario tradicional vs. estimadores de razón y regresión

El inventario total del IAF y la Bt se realizó mediante ME. Los valores resultantes se utilizaron para comparar las estimaciones obtenidas con los datos espectrales. Para ERa y ERe se utilizó la banda del espectro rojo del satélite SPOT 7 como variable auxiliar, por presentar la mayor correlación con las variables IAF_H y Bt. Las estimaciones mediante los ERa fueron las más semejantes al ME en las dos variables, además de las más conservadoras para el IAF_H. Los ERe y la RLM obtuvieron valores similares entre ellos en cuanto al IAF_H. Para la Bt, los resultados conservadores los presentó la RLM con respecto al inventario tradicional (Cuadro 5).

Table 5. Comparison of the traditional inventory and the estimates of leaf area index (LAI_H) and total aboveground biomass (AGB) using spectral information in *Eucalyptus urophylla* plantations.

Cuadro 5. Comparación del inventario tradicional y las estimaciones del índice de área foliar (IAF_H) y de biomasa aérea total (Bt) mediante información espectral para plantaciones de *Eucalyptus urophylla*.

Estimation method/ Método de estimación	LAI _H / IAF _H	CI ₋₉₅ / IC ₋₉₅	CI ₊₉₅ / IC ₊₉₅	RMSE/ RECM	AGB/ Bt	CI ₋₉₅ / IC ₋₉₅	CI ₊₉₅ / IC ₊₉₅	RMSE/ RECM
Traditional inventory / Inventario tradicional								
Stratified sampling/ Muestreo estratificado	2.31	2.21	2.41		93.47	88.80	98.13	
Remote sensing / Percepción remota								
Ratio estimator (RER)/ Estimador de razón (ERa)	2.29	2.09	2.48	0.79	92.51	71.80	113.21	53.90
Regression estimator (REg)/ Estimador de regresión (ERe)	2.58	2.43	2.73	0.62	95.81	76.47	115.16	49.42
Multiple linear regression (MLR)/ Regresión lineal múltiple (RLM)	2.57			0.35	90.72			29.39

CI₋₉₅: lower and upper confidence intervals at $\alpha = 0.05$; RMSE: root mean square error.

IC₋₉₅: intervalo de confianza inferior y superior a un $\alpha = 0.05$; RECM: raíz del error cuadrático medio.

indicates that RER performed best, followed by REg, and lastly MLR. However, mapping with the first two methods does not allow for a precise characterization of the distribution of variables by age, because they are highly sensitive to variation and sample size, calculating only the overall inventory mean. This is evident when site-level averages are extracted from each generated map (Figures 4 and 5) and compared with the observed values, where RMSE was high for both the ratio estimator ($AGB = 58\%$ e $LAI_H = 34\%$) a regression estimator ($AGB = 54\%$ e $LAI_H = 24\%$). Therefore, in this regard, the MLR method performed best, with errors of 32% and 13% for estimating and mapping LAI_H and AGB , respectively, in *E. urophylla* plantations in Huimanguillo, Tabasco, Mexico.

The MLR method provides good predictions of LAI_H and AGB ; however, it should be considered that the relationships among the variables used change substantially when applying this technique (Cohrs et al., 2020), which may lead to different estimates in future predictions. Moreover, the low relationships observed among some variables may be influenced by temporal mismatches between the image acquisition date and the timing of the inventory, as well as by the specific growth conditions of the trees in each plantation (López-Serrano et al., 2021; Pérez-Miranda et al., 2018). To address this issue, it is recommended

Los métodos empleados para estimar el IAF_H y la Bt presentaron resultados satisfactorios. Un comparativo de tales resultados con los intervalos de confianza del inventario tradicional indica que el mejor fue el ERA, seguido por el ERe y por último la RLM. Sin embargo, el mapeo de los primeros dos métodos no permite la caracterización precisa de la distribución de las variables por edad, ya que son muy sensibles a la variación y al tamaño de muestra, calculando únicamente el promedio del inventario total. Esto se observa al extraer los promedios por sitio de cada mapa generado (Figuras 4 y 5) y compararlos con el valor observado, donde la RECM fue alta en los estimadores de razón ($Bt = 58\%$ e $IAF_H = 34\%$) y regresión ($Bt = 54\%$ e $IAF_H = 24\%$). Por consiguiente, en este aspecto, el método de RLM fue el mejor con un error 32% y 13% para estimar y mapear el IAF_H y la Bt , respectivamente, en plantaciones de *E. urophylla* en Huimanguillo, Tabasco, México.

El método de RLM presenta buenas predicciones del IAF_H y Bt ; sin embargo, se debe considerar que la relación entre las variables utilizadas cambia drásticamente al aplicar esta técnica (Cohrs et al., 2020), lo que puede generar estimaciones diferentes en predicciones futuras. Además, la baja relación observada entre algunas variables puede estar influenciada por desfases temporales entre la fecha de adquisición de las imágenes y la realización del

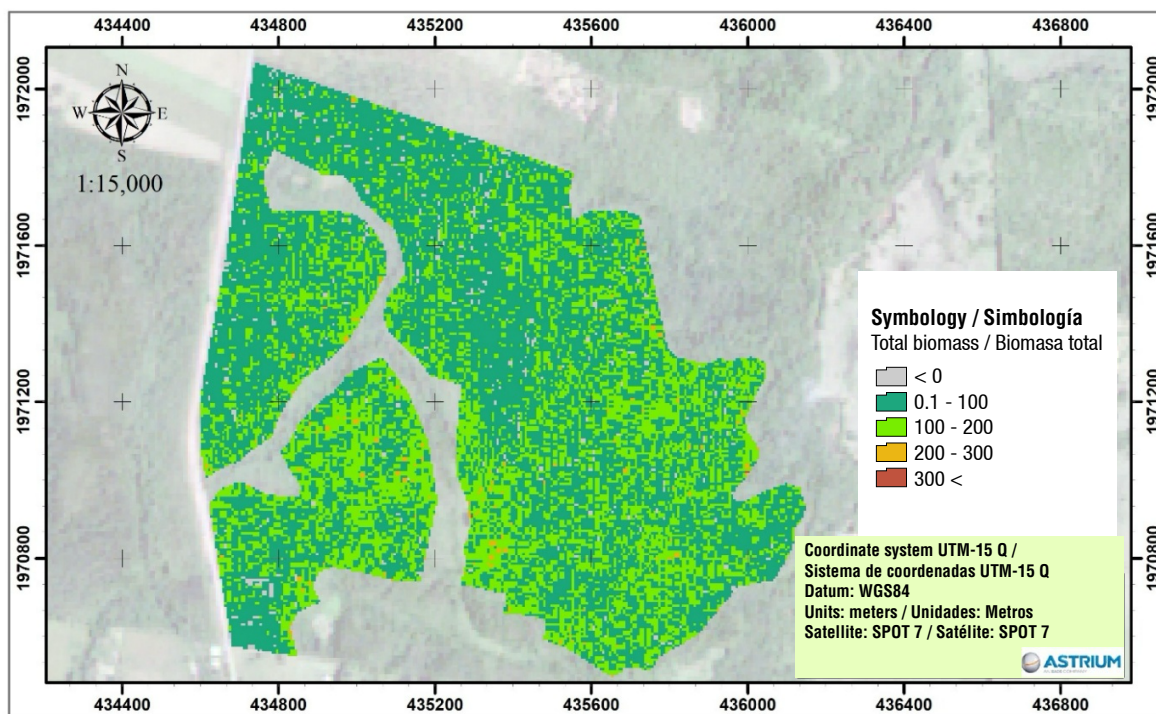


Figure 4. Total aboveground biomass using multiple linear regression for *Eucalyptus urophylla* plantations in Huimanguillo, Tabasco, Mexico.

Figura 4. Biomasa aérea total mediante regresión lineal múltiple para plantaciones de *Eucalyptus urophylla* en Huimanguillo, Tabasco, México.

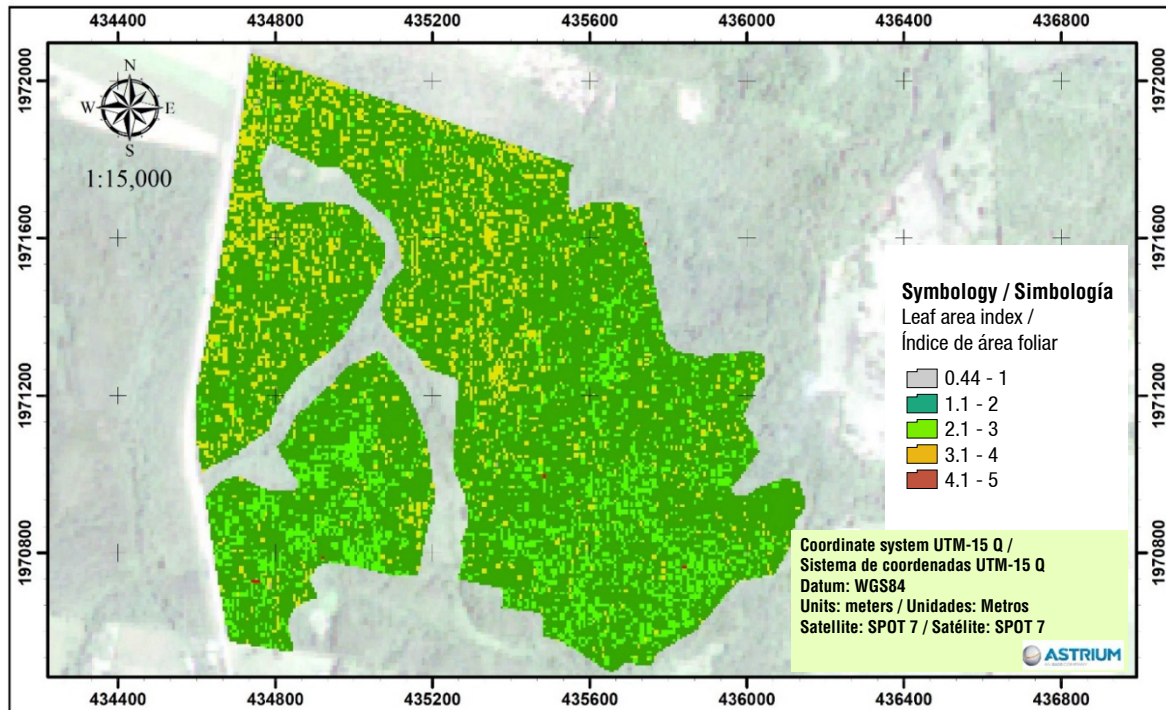


Figure 5. Leaf area index using multiple linear regression for *Eucalyptus urophylla* plantations in Huimanguillo, Tabasco, Mexico.
Figura 5. Índice de área foliar mediante regresión lineal múltiple para plantaciones de *Eucalyptus urophylla* en Huimanguillo, Tabasco, México.

to incorporate cross-validation processes at different spatial and temporal scales, as well as to use models derived from machine learning or multivariate techniques that can capture nonlinear relationships and reduce estimation bias (Fassnacht et al., 2014).

Aguirre-Salado et al. (2011) reported that the best model for LAI mapping was linear regression, with an error of 7.51 % for LAI_C. These authors improved the geospatial estimates of LAI by complementing spectral information from the SPOT 5 satellite with field data. In another study, Salas et al. (2010) reported errors below 5 % in the prediction of stand variables when using linear mixed-effects and multiple linear regression models; these performed better than least squares and *K*-nearest neighbor methods and showed similar results when using Landsat 7 satellite data. On the other hand, Torres-Vivar et al. (2017) and Pérez-Miranda et al. (2018) found that regression estimators provide greater accuracy in estimating forest variables than the traditional SS method, due to the integration of auxiliary variables from remote sensing available at the population level.

AGB and LAI_H variables were mapped using, as an example, a four-year-old *E. urophylla* plantation at the end of the measurement period. The average values estimated from the traditional inventory were 88.44 Mg·ha⁻¹ for AGB and 2.31 m²·m⁻² for LAI calculated

inventario, así como por las condiciones particulares de crecimiento del arbolado en cada plantación (López-Serrano et al., 2021; Pérez-Miranda et al., 2018). Para contrarrestar esta problemática, es recomendable la incorporación de procesos de validación cruzada en diferentes escalas espaciales y temporales, así como el empleo de modelos derivados de aprendizaje automático o técnicas multivariadas que permitan la captación de relaciones no lineales y reducción del sesgo en la estimación (Fassnacht et al., 2014).

Aguirre-Salado et al. (2011) reportaron que el mejor método para el mapeo del IAF fue la regresión lineal con un error de 7.51 % para IAF_C. Estos autores mejoraron las estimaciones geoespaciales del IAF al complementar la información espectral del satélite SPOT 5 con información de campo. En otro estudio, Salas et al. (2010) obtuvieron errores inferiores de 5 % en la predicción de variables del rodal cuando utilizaron un modelo lineal de efectos mixtos y lineal múltiple; estos fueron superiores a las estimaciones de mínimos cuadráticos y *K*-ésimo vecino más cercano, y similares con información del satélite Landsat 7. Por otro lado, Torres-Vivar et al. (2017) y Pérez-Miranda et al. (2018) determinaron que los estimadores de regresión tienen mayor precisión en la estimación de las variables forestales sobre el método tradicional de ME, debido a la integración de variables auxiliares de sensores remotos conocidas a nivel poblacional.

using the litterfall method. The generated maps show negative AGB values, a common issue in linear regression models, due to the low correlation between AGB and the spectral variables and vegetation indices from SPOT 7 and Landsat 8 satellites (Figure 4). In contrast, LAI_H shows a spatial distribution of values that is consistent with variation in plantation age (Figure 5).

The use of spectral variables to assess AGB and LAI in *E. urophylla* plantations would reduce the time required to conduct forest inventories; moreover, it provides a simple way to evaluate plantation development by enabling periodic monitoring with satellite imagery and through the application of the model developed in this study. However, the best results were obtained using the SPOT 7 sensor, which involves image acquisition costs representing a practical limitation.

Conclusions

The use of spectral information for predicting total aboveground biomass (AGB) and leaf area index (LAI) was reliable. The estimated values were similar to those obtained from the traditional inventory, and the root mean square error was lower when using multiple linear regression. Data from the SPOT 7 sensor, with higher spatial resolution (6 m), compared to Landsat 8 (30 m), showed stronger correlation with stand variables and produced the best results in modeling AGB and LAI. This study provides a reliable tool for the structural characterization of *Eucalyptus urophylla* plantations in southeastern Mexico from a spatial perspective, as it demonstrates the usefulness of remote sensing and predictive models in estimating key variables. This methodology is applicable to low-cost forest inventories and is suitable for the optimal management of commercial forest plantations

Acknowledgments

This research was partially funded by the International Programs Office of the U.S. Department of Agriculture Forest Service through the Northern Research Station and the Sustainable Landscapes Program of the U.S. Agency for International Development, as well as by PORTEAK, the company that owns the plantations where this study was carried out.

Conflict of Interest Declaration

The authors declare that they have no economic conflicts of interest or known personal relationships that could have influenced the research presented in this article.

End of English version

Las variables Bt y IAF_H se mapearon tomando como ejemplo la plantación de *E. urophylla* con cuatro años al final de la medición. Los datos promedios estimados mediante inventario tradicional fueron 88.44 Mg·ha⁻¹ de Bt y 2.31 m²·m⁻² de IAF calculado mediante caída de hojarasca. En los mapas generados se observan valores negativos de Bt, problema común de los modelos de regresión lineal, debido a la baja correlación de Bt con las variables espectrales e índices de vegetación de los satélites SPOT 7 y Landsat 8 (Figura 4). Contrariamente, el IAF_H presenta una distribución espacial de valores, adecuada a la variación de la edad de plantación (Figura 5).

El empleo de variables espectrales para evaluar Bt e IAF de las plantaciones de *E. urophylla* reduciría el tiempo de elaboración del inventario forestal; además, sería una forma sencilla para evaluar el estado de desarrollo de las plantaciones al permitir el monitoreo periódico con imágenes de satélite y mediante la aplicación del modelo generado en este estudio. No obstante, los mejores resultados se obtuvieron con el sensor montado en SPOT 7, lo que implica un costo por la adquisición de las imágenes, el cual representa una desventaja práctica.

Conclusiones

El empleo de información espectral para la predicción de la biomasa total (Bt) e índice de área foliar (IAF) fue confiable. Los valores estimados fueron similares a los calculados mediante inventario tradicional; la raíz del error cuadrático medio fue menor con la técnica de regresión lineal múltiple. La información del sensor SPOT 7, de alta resolución espacial (6 m) comparada con Landsat 8 de menor resolución (30 m), fue la que mayor correlación presentó con las variables del rodal y la que generó los mejores resultados en la modelización de Bt e IAF. Este estudio constituye una herramienta robusta para la caracterización estructural de las plantaciones de *Eucalyptus urophylla* del sureste de México desde una perspectiva espacial, ya que demuestra la utilidad de los sensores remotos y modelos predictivos en la estimación de atributos clave. Esta metodología es aplicable en inventarios forestales de bajo costo y es viable para la gestión óptima de plantaciones forestales comerciales.

Agradecimientos

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., y por la empresa PORTEAK, dueña de las plantaciones donde se desarrolló la investigación.

Referencias / Referencias

- Acosta Mireles, M., Pérez Miranda, R., Romero Sánchez, M. E., González Hernández, A., & Martínez Ángel, 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. <https://doi.org/10.29298/rmcf.v8i41.25>
- Aguirre-Salado, C. A., Valdez-Lazalde, J. R., Ángeles-Pérez, G., Santos-Posadas, H. M., & Aguirre-Salado, A. I. (2011). Mapeo del índice de área foliar y cobertura arbórea mediante fotografía hemisférica y datos Spot 5 HRG: Regresión y K-nn. *Agrociencia*, 45(1), 105-119. <https://www.scielo.org.mx/pdf/agro/v45n1/v45n1a10.pdf>
- Ariza, A. (2013). *Descripción y corrección de productos Landsat 8 LDCM (Landsat Data Continuity Mission)*. <http://www.un-spider.org/sites/default/files/LDCM-L8.R1.pdf>
- ASTRIUM. (2013). *SPOT 6 & SPOT 7 Imagery User Guide (Versión 1.0)*. Toulouse, Cedex, France. Astrium Services. https://www.spaceoffice.nl/blobs/Dataportal/User_Guide_SPOT6_V1.0.pdf
- Castillo, J. A. A., Apan, A. A., Maraseni, T. N., & Salmo, S. G. S. (2017). Estimation and mapping of above-ground biomass of mangrove forests and their replacement land uses in the Philippines using Sentinel imagery. *Journal of Photogrammetry and Remote Sensing*, 134, 70-85. <https://doi.org/10.1016/j.isprsjprs.2017.10.016>
- Cohrs, C. W., Cook, R. L., Gray, J. M., & Albaugh, T. J. (2020). Sentinel-2 leaf area index estimation for pine plantations in the Southeastern United States. *Remote Sensing*, 12(9), 1406. <https://doi.org/10.3390/rs12091406>
- Comisión Nacional Forestal (CONAFOR). (2020). *El sector forestal mexicano en cifras 2019. Bosques para el bienestar social y climático*. <https://www.gob.mx/conafor/documentos/el-sector-forestal-mexicano-en-cifras-2019>
- Esri. (2016). *ArcMap (Versión 10.4)* [Software de computación]. Redlands, CA: Environmental Systems Research Institute.
- Fassnacht, F., Hartig, F., Latifi, H., Berger, C., Hernández, J., Corvalán, P., & Koch, B. (2014). Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. *Remote Sensing of Environment*, 154, 102-114. <https://doi.org/10.1016/j.rse.2014.07.028>
- Flores-Rodríguez, A. G., Flores-Garnica, J. G., González-Eguiarte, D. R., Gallegos-Rodríguez, A., Zarazúa-Villaseñor, P., & Mena-Munguía, S. (2020). Revisión de métodos de sensores remotos para la detección y evaluación de la severidad de incendios forestales. *Gestión y Ambiente*, 23(2), 273-283. <https://doi.org/10.15446/ga.v23n2.93682>
- Food and Agriculture Organization of the United Nations (FAO). (2020). *Global forest resources assessment 2020: Main report*. FAO, Rome. <https://doi.org/10.4060/ca9825en>
- García-Cuevas, X., Sáenz-Reyes, J. T., Muñoz-Flores, H. J., Hernández-Ramos, A., Hernández-Ramos, J., Rueda-Sánchez, A., & Orozco-Gutiérrez, G. (2022). Aportaciones científicas del programa de plantaciones forestales en el INIFAP. *Revista Mexicana de Ciencias Forestales*, 13(70), 3-41. <https://doi.org/10.29298/rmcf.v13i70.1162>

Declaración de conflictos de intereses

Los autores declaramos que no tenemos conflictos de intereses económicos ni relaciones personales conocidas que pudieran haber influido en la investigación presentada en este artículo.

Fin de la versión en español

- Hernández-Ramos, A., Valdez-Lazalde, J. R., Ángeles-Pérez, G., de los Santos-Posadas, H. M., Hernández-Ramos, J., Peduzzi, A., & Carrero, O. (2021). Métodos para estimar el índice de área foliar y su dinámica estacional en plantaciones de *Eucalyptus urophylla* en Tabasco, México. *Revista Mexicana de Ciencias Forestales*, 12(63), 114-137. <https://doi.org/10.29298/rmcf.v12i63.808>
- 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. <https://doi.org/10.21829/myb.2020.2611884>
- Hernández-Ramos, J., Santos-Posadas, H. M., Valdez-Lazalde, J. R., Tamarit-Urias, J. C., Ángeles-Pérez, G., Hernández-Ramos, A., Peduzzi, A., & Carrero, O. (2017). Biomasa aérea y factores de expansión en plantaciones forestales comerciales de *Eucalyptus urophylla* S. T. Blake. *Agrociencia*, 51(8), 921-938. <https://www.agrociencia-colpos.org/index.php/agrociencia/article/view/1336>
- Hurtado Abril, J. L., & Lizarazo, I. (2022). Nuevo índice espectro-temporal para la detección de pérdida forestal en áreas de bosque tropical. Caso de estudio Amazonia colombiana. *Revista Cartográfica*, (104), 11-35. <https://doi.org/10.35424/rcarto.i104.1096>
- Instituto Nacional de Estadística y Geografía (INEGI). (2021). *Uso del suelo y vegetación, escala 1:250000, serie VII (continuo nacional)*. <http://geoportail.conabio.gob.mx/metadatos/doc/html/usv250s7gw.html>
- Instituto Nacional de Estadística y Geografía (INEGI). (2014). *Conjunto de datos vectoriales edafológico, escala 1:250000 Serie II*. (Continuo Nacional). http://www.conabio.gob.mx/informacion/gis/?vns=gis_root/edafo/tsuelo/eda250s2gw
- Liu, Z., Jin, G., & Zhou, M. (2015). Evaluation and correction of optically derived leaf area index in different temperate forests. *iForest: Biogeosciences and Forestry*, 9, 55-62. <https://doi.org/10.3832/ifer1350-008>
- López Serrano, P. M., Vega Nieva, D. J., Ramírez Aldaba, H., García Montiel, E., & Corral Rivas, J. J. (2021). Estimación de parámetros forestales mediante datos de Sentinel 2A en Pueblo Nuevo, Durango. *Revista Mexicana de Ciencias Forestales*, 12(68), 81-106. <https://doi.org/10.29298/rmcf.v12i68.1075>
- Maesano, M., Santopuoli, G., Moresi, F. V., Matteucci, G., Lasserre, B., & Scarascia, M. G. (2022). Above ground biomass estimation from UAV high resolution RGB images and LiDAR data in a pine forest in Southern Italy. *iForest*, 15, 451-457. <https://doi.org/10.3832/ifer3781-015>

- Mattos, E. M., Binkley, D., Campoe, O. C., Alvares, C. A., & Stape, J. L. (2020). Variation in canopy structure, leaf area, light interception, and light use efficiency among *Eucalyptus* clones. *Forest Ecology and Management*, 463, 118038. <https://doi.org/10.1016/j.foreco.2020.118038>
- Muñoz-Ruíz, M. A., Valdez-Lazalde, J. R., 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(8), 847-862. <https://agrociencia-colpos.mx/index.php/agrociencia/article/view/1124>
- Payn, T., Carnus, J. M., Freer-Smith, P., Kimberley, M., Kollert, W., Liu, S., Orazio, C., Rodriguez, L., Silva, L. N., & Wingfield, J. (2015). Changes in planted forests and future global implications. *Forest Ecology and Management*, 352, 57-67. <https://doi.org/10.1016/j.foreco.2015.06.021>
- Peduzzi, A., Lee A., H., & Wynne, R. H. (2010). Leaf area of overstory and understory in pine plantations in the flatwoods. *Southern Journal of Applied Forestry*, 34(4), 154-160. <https://doi.org/10.1093/sjaf/34.4.154>
- Perea-Ardila, M. A., Andrade-Castañeda, H. J., & Segura-Madrigal, M. A. (2021). Estimación de biomasa aérea y carbono con teledetección en bosques alto-andinos de Boyacá, Colombia. Estudio de caso: Santuario de Fauna y Flora Iguaque. *Revista Cartográfica*, (102), 91-123. <https://doi.org/10.35424/rcarto.i102.821>
- Pérez Miranda, R., Romero Sánchez, M. E., González Hernández, A., Martínez Ángel, L., & Arriola Padilla, V. J. (2018). Estimación de atributos forestales mediante teledetección en bosques mixtos de Durango, México. *Áreas Naturales Protegidas Scripta*, 4(2), 49-70. <https://doi.org/10.18242/anpscripta.2018.04.02.0003>
- Qiao, Y., Zheng, G., Du, Z., Ma, X., Li, J., & Moskal, L. M. (2023). Tree-species classification and individual-tree-biomass model construction based on hyperspectral and LiDAR data. *Remote Sensing*, 15(5), 1341. <https://doi.org/10.3390/rs15051341>
- Qin, H., Zhou, W., Yao, Y., & Wang, W. (2022). Individual tree segmentation and tree species classification in subtropical broadleaf forests using UAV-based LiDAR, hyperspectral, and ultrahigh-resolution RGB data. *Remote Sensing of Environment*, 280, 113143. <https://doi.org/10.1016/j.rse.2022.113143>
- Salas, C., Ene, L., Ojeda, N., & Soto, H. (2010). Métodos estadísticos paramétricos y no paramétricos para predecir variables de rodal basados en Landsat ETM+: una comparación en un bosque de *Araucaria araucana* en Chile. *Bosque*, 31(3), 179-194. <http://doi.org/10.4067/S0717-92002010000300002>
- Schleppi, P., Conedera, M., Sedivy, I., & Thimonier, A. (2007). Correcting non-linearity and slope effects in the estimation of the leaf area index of forests from hemispherical photographs. *Agricultural and Forest Meteorology*, 144(3-4), 236-242. <https://doi.org/10.1016/j.agrformet.2007.02.004>
- Solís-Silva, R., Sánchez-Gutiérrez, F., Islas-Jesús, R. E., Gerónimo-Torres, J. C., Pozo-Santiago, C. O., & Sánchez-Díaz, B. (2022). Estimación del índice de área foliar a partir de imágenes Sentinel en plantaciones de *Eucalyptus grandis* W. Hill. *Revista Tecnología en Marcha*, 35(2), 39-47. <https://doi.org/10.18845/tm.v35i2.5535>
- Soudani, K., Francois, C., Le-Maire, G., Le-Dantec, V., & Dufrene, 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. <https://doi.org/10.1016/j.rse.2006.02.004>
- Sun, Q., Gu, X., Sun, L., Yang, G., Zhou, L., & Guo, W. (2019). Dynamic change in rice leaf area index and spectral response under flooding stress. *Paddy and Water Environment*, 18(1), 223-233. <https://doi.org/10.1007/s10333-019-00776-5>
- 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. <https://doi.org/10.29298/rmcf.v7i36.56>
- Torres-Vivar, J. E., Valdez-Lazalde, J. R., 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. <https://doi.org/10.29298/rmcf.v8i39.41>
- 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(3), 383-394. <https://agrociencia-colpos.mx/index.php/agrociencia/article/view/472>
- Wang, Y., Jia, X., Chai, G., Lei, L., & Zhang, X. (2023). Improved estimation of aboveground biomass of regional coniferous forests integrating UAV-LiDAR strip data, Sentinel-1 and Sentinel-2 imageries. *Plant Methods*, 19(65), 19. <https://doi.org/10.1186/s13007-023-01043-9>
- Xu, J., Zhao, H., Yin, P., Jia, D., & Li, G. (2018). Remote sensing classification method of vegetation dynamics based on time series Landsat image: a case of opencast mining area in China. *Journal on Image and Video Processing*, 1(113), 1-10. <https://doi.org/10.1186/s13640-018-0360-0>
- Yi-Min, Z., & Meng-Jun, J. (2019). Comparison of inversion method of maize leaf area index based on UAV hyperspectral remote sensing. *Multimedia Tools and Applications*, 79, 16385-16401. <https://doi.org/10.1007/s11042-019-7318-9>
- Zhu, Y., Feng, Z., Lu, J., & Liu, J. (2020). Estimation of forest biomass in Beijing (China) using multisource remote sensing and forest inventory data. *Forests*, 11(2), 163. <https://doi.org/10.3390/f11020163>