

# Mapas de biomasa aérea de bosques del norte de Durango, México, utilizando variables subpixel, espectrales y texturales. ☆

## Aerial biomass maps of forests in Northern Durango, Mexico, using subpixel, spectral and textural variables.

Juan Andrés Almazán González<sup>a</sup>, Jorge Prado Molina<sup>a</sup>, Stéphane Couturier<sup>a,b</sup>, Lilia de Lourdes Manzo Delgado<sup>a</sup>

<sup>a</sup>Laboratorio de Análisis Geo-Espacial (LAGE), Instituto de Geografía, Universidad Nacional Autónoma de México (UNAM), Circuito Exterior, Ciudad Universitaria, Coyoacán, Apdo Postal 20850, CP 04510, Mexico City, Mexico.

<sup>b</sup>Integrative Crop Ecophysiology Group, Departament de Biologia Evolutiva, Ecologia i Ciències Ambientals, Facultat de Biologia, Universitat de Barcelona, Avda. Diagonal, 643, CP 08028, Barcelona.

---

### Resumen

Los mapas de biomasa forestal aérea disponibles en la literatura científica son, en su mayoría, de acceso restringido, en formato estático (pdf) y en estudios que se centran más en el modelo de estimación de biomasa en sí mismo. El propósito de este trabajo fue determinar la utilidad de las variables subpixel para generar mapas de biomasa forestal y cotejarlas frente a las variables espectrales y texturales. En una zona de estudio de cobertura forestal de aproximadamente 11 300 km<sup>2</sup> en el norte del estado de Durango (México), fueron utilizados 96 conglomerados de muestreo del Inventario Nacional Forestal y de Suelos 2009-2014, 9 imágenes SPOT5 y técnicas de regresión para generar los modelos de estimación de biomasa. La precisión del modelo de demezclado espectral con la variable subpíxel fracción de vegetación (FV), fue similar al del modelo con las variables espectrales, obtenidas con el NDVI43, ya que presentaron un RMSE de 56.54 Mg ha<sup>-1</sup> y R<sup>2</sup> de 0.69, y RMSE de 50.38 Mg ha<sup>-1</sup> y R<sup>2</sup> de 0.55, respectivamente. Y aunque los mapas mostraron una distribución de biomasa similar, el modelo con la FV fue más robusto para estimar valores extremos, tuvo mejor coeficiente de determinación, además de ser una variable de fácil interpretación. Los resultados están publicados como mapas web, con varias capas de información de acceso abierto.

**Palabras clave:** Mapa de biomasa, variables subpixel, demezclado espectral lineal, fracción de vegetación, variables espectrales, índice de vegetación de diferencia normalizada, variables texturales

### Abstract

Aerial forest biomass maps available in the scientific literature usually are of restricted access, in static (pdf) format, and the associated studies focus more on the biomass estimation model than on the map. The purpose of this work was to determine the usefulness of subpixel variables to generate forest biomass maps and compare their predictive results against the ones of spectral and textural variables. In a study area of forested cover of approximately 11 300 km<sup>2</sup> in the North of the Durango State (Mexico), ninety six (96) sampling clusters from the National Forest and Soil Inventory 2009-2014 and 9 SPOT5 images were employed. The precision of the linear spectral unmixing model with vegetation fraction (VF) was similar to the one with the spectral variable NDVI43, since they presented an RMSE of 56.54 Mg ha<sup>-1</sup> and R<sup>2</sup> of 0.69, and RMSE of 50.38 Mg ha<sup>-1</sup> and R<sup>2</sup> of 0.55, respectively. Although maps showed a similar biomass distribution, the model with the VF was more robust for estimating extreme values, had a better coefficient of determination, and in addition it is an easy to interpret variable. Results will be published as web maps, with several layers of information as open downloadable data.

**Keywords:** Biomass map, subpixel variables, lineal spectral unmixing, vegetation fraction, spectral variables, normalized difference vegetation index, textural variables.

---

## 1. Introducción

La biomasa en los ecosistemas juega un papel importante como sumidero de carbono para mitigar el cambio climático. El diseño de planes y políticas de conservación de los sumideros de carbono requiere contar con métodos prácticos y confiables para estimar los contenidos de biomasa y conocer su distribución espacial (Panel Intergubernamental del Cambio Climático [IPCC], 2014).

En las últimas décadas, los datos derivados de imágenes satelitales se han convertido en una fuente primaria para estimar la biomasa forestal aérea (BFA), cuya importancia se basa en su cobertura espacial, la repetitividad de los datos y el formato digital que permite un procesamiento relativamente rápido (Sanchez-Azofeifa *et al.*, 2017; Rodríguez-Veiga *et al.*, 2019).

Las variables predictoras para estimar BFA mediante imágenes satelitales se dividen en tres clases: espectrales, texturales y subpixel (Lu *et al.*, 2016). Las variables espectrales se derivan de las bandas satelitales, ya sea de manera individual, combinadas para formar índices (Eckert, 2012) o como resultado de alguna transformación como *Tasseled cap* y componentes principales (Yan *et al.*, 2015). Las variables texturales se derivan de cálculos estadísticos como la media y la varianza, que se obtienen en píxeles agrupados en una ventana determinada (Eckert, 2012; Kelsey y Neff, 2014).

Existen trabajos que han probado una gran cantidad de variables espectrales para estimar biomasa. Foody *et al.* (2003) utilizaron seis tipos diferentes de combinaciones de bandas de Landsat (todas, exceptuando la térmica), generando 230 variables diferentes. Lu *et al.* (2004) exploraron la relación entre 35 variables espectrales con biomasa, incluyendo bandas simples, combinaciones, transformaciones *tasseled cap* y componentes principales. En ambos casos las bandas del infrarrojo resultaron ser las más adecuadas.

Respecto de las variables texturales, Lu (2005) demostró que pueden ser útiles para mejorar el desempeño de los modelos de estimación de biomasa en zonas boscosas de estructura compleja. Eckert (2012) encontró que las variables texturales están mejor correlacionadas con bosques degradados, que las variables espectrales. Kelsey y Neff (2014) generaron un modelo para estimación de biomasa que sólo incluyó variables texturales para un área de estudio de bosque con edad y perturbaciones variables.

Las variables subpixel, por su parte, representan la proporción de materiales puros presentes en cada pixel. En un ecosistema forestal, cada pixel contiene una mezcla de componentes vegetales (hojas, tallos, ramas, hierbas, etc.), sombras producidas por estos componentes y también suelo expuesto. En cada

pixel existe una mezcla de los valores espectrales de cada uno de estos materiales, considerados puros. La técnica de demezclado espectral lineal, analiza el valor espectral de cada pixel en comparación con los valores típicos de los materiales puros, para encontrar la proporción de presencia de cada material puro en ese pixel (Roberts *et al.*, 1999).

Las variables subpixel y la técnica de demezclado espectral han mostrado ser útiles para mejorar la precisión de modelos de estimación de carbono forestal, construidos a partir de grandes conjuntos de variables espectrales y texturales, y regresiones multivariantes *stepwise* y logísticas, tanto en áreas urbanas (Sun *et al.*, 2015) como en zonas subtropicales (Yan *et al.*, 2015).

En México, los estudios para estimar la biomasa han mostrado preferencia por el uso de variables espectrales como el NDVI (Aguirre-Salado *et al.*, 2012; Aguirre-Salado *et al.*, 2014), aunque en otros casos se ha trabajado con variables texturales (Castillo-Santiago *et al.*, 2013; Galeana-Pizaña *et al.*, 2014).

Las variables subpixel han recibido poca atención para estimar biomasa en México; sin embargo, se han utilizado para elaborar la cartografía tanto de tamarisco o cedro salado (*Tamarix ramosissima Ledeb*) en los márgenes del Río Bravo, en la frontera entre México y Estados Unidos (Silván-Cárdenas y Wang, 2010), y de manglares en la bahía de La Paz, Baja California (Thayn, 2020). También han sido utilizadas para estimar la superficie de *Abies religiosa*, sotobosque, pastizal, suelo desnudo y sombra, en el Suelo de Conservación de la Ciudad de México (Silván-Cárdenas *et al.*, 2015), así como la distribución espacial de la biomasa de los bosques de *Abies religiosa* y *Pinus spp* en la misma zona (Galeana-Pizaña *et al.*, 2016).

Para atender la necesidad de monitoreo de carbono y cambios de cobertura forestal, se han generado y publicado mapas de BFA en muchas regiones, sin embargo, escasamente se pueden visualizar en línea, ni obtener los datos libremente. El propósito de nuestro trabajo fue determinar la utilidad de las variables subpixel para generar mapas de BFA y cotejarlas frente a las variables espectrales y texturales; de una zona de bosque templado en el norte de Durango, México, y publicarlos como mapas web, con documentación precisa, de tal forma que los datos pueden ser visualizados, explorados y descargados libremente.

## 2. Métodos

### 2.1. Zona de estudio

La zona de estudio es la UMAFOR 1001 que comprende los municipios de Ocampo, San Bernardo y Guanaceví, en el norte de Durango, con una superficie de 11,336.82 km<sup>2</sup> (figura 1). La región Oeste presenta topografía de lomeríos y sierras, clima templado semifrío, subhúmedo, con lluvias en verano y precipitación media anual de 700 a 1100 mm. En esta zona predominan los bosques de pino, de pino-encino, de encino-pino, de encino y de asociaciones de pino con otras latifoliadas. La región Este presenta topografía con pendientes poco pronunciadas, clima semiseco o semiárido templado con lluvias acentuadas en verano y precipitación media anual de 450 a 700 mm. En esta

© J. A. Almazán-González, J. Prado-Molina, S. Couturier, L. L. Manzo Delgado. This is an Open Access article distributed under the terms of the Creative Commons Attribution License (<https://creativecommons.org/licenses/by-nc-sa/4.0/>), which permits non-commercial sharing of the work and adaptations, provided the original work is properly cited and the new creations are licensed under identical terms.

\*E-mail address: andres\_almazan@hotmail.com

zona predominan los matorrales, chaparrales y pastizales mezclados con táscales (*Juniperus deppeana Steud.*) y huizaches (*Acacia farnesiana L. Willd.*) (Prieto y Hernández, 2007).

## 2.2. Datos de campo

Se consideraron inicialmente los 268 conglomerados de muestreo del Inventario Nacional Forestal y de Suelos (INFyS) 2009-2014 (Comisión Nacional Forestal [CONAFOR], 2014) incluidos en la UMAFOR 1001 (figura 1). Cada uno de dichos conglomerados, está compuesto de 4 sitios circulares de 400 m<sup>2</sup> (radio de 11.28 m). Fueron levantados los datos de todos los individuos arbóreos con diámetro a la altura de pecho  $\geq 7.5$  cm. De los 268 conglomerados, fueron utilizados 96; sólo aquellos cuya fecha de levantamiento se encontraba entre los años 2010 y 2011, esto con la finalidad de reducir al máximo la diferencia con la fecha de adquisición de las imágenes de satélite (2010 y 2011).

La biomasa por árbol fue calculada utilizando las ecuaciones alométricas publicadas por Rojas-García *et al.* (2015) y Vargas-Larreta *et al.* (2017). La biomasa de todos los individuos fue sumada para obtener el total por conglomerado y dividida entre el área para obtener la BFA en Mg ha<sup>-1</sup>.

## 2.3. Adquisición y procesamiento de las imágenes

Fueron utilizadas nueve imágenes SPOT5 con fechas de adquisición entre el 11 de diciembre de 2010 y el 15 de marzo de 2011, proporcionadas por la Estación de Recepción México (ERMEX), con el nivel de procesamiento 2A, que incluye la corrección geométrica y la proyección UTM Zona 13 con el datum WGS 84 (Spot Image, 2010). A partir de los valores digitales y de reflectancia en la parte alta de la atmósfera, se obtuvieron 201 variables predictoras: 6 espectrales, 3 subpixel y 192 texturales. Las variables subpixel y texturales fueron obtenidas con el software ENVI versión 4.7. Los valores de las variables espectrales en cada conglomerado fueron obtenidos con Arcmap versión 10.1. En la ubicación de cada conglomerado de muestreo fue obtenido un solo valor para cada variable predictor. Para ello, se consideró un círculo de radio igual a 60 metros con origen en las coordenadas del sitio central del conglomerado y fue calculado el promedio de la variable predictor.

## 2.4. Variables espectrales

Las variables espectrales consideradas fueron los valores de reflectancia de las cuatro bandas de la imagen SPOT5, los valores del NDVI (Rouse *et al.*, 1974) y los valores del índice NDVI43 (Aguirre-Salado *et al.*, 2009):

$$NDVI = (IRC - Rojo) / (IRC + Rojo)$$

$$NDVI43 = (IROC - IRC) / (IROC + IRC)$$

## 2.5. Variables subpixel

La reflectancia medida por el sensor satelital, considerando que la radiación electromagnética ha sido reflejada sólo una vez por algún material en la escena, puede ser modelada como la suma de las reflectancias de cada material, ponderada por su proporción en la escena (Adams *et al.*, 1993). Aquella, producto de la interacción de la radiación electromagnética con varios materiales, debe ser modelada de manera no lineal, aunque en muchas aplicaciones puede ser considerada despreciable (Roberts *et al.*, 1993).

En este caso, las variables subpixel fueron generadas con la técnica de demezclado espectral lineal, de acuerdo con la ecuación (Lu *et al.*, 2005):

$$R_b = \sum_{p=1}^n f_p R_{bp} + \varepsilon_b$$

En donde:

- $R_b$  es la reflectancia de un pixel en la banda  $b$ ,
- $n$  es el número de materiales puros,
- $f_p$  es la fracción del material puro  $p$  en ese pixel,
- $R_{bp}$  es la reflectancia del material puro  $p$  para la banda  $b$ ,
- $\varepsilon_b$  es un término de error para la banda  $b$ .

Los materiales puros deben ser aquellos que se presenten con mayor frecuencia en el área de estudio y puedan identificarse claramente. La reflectancia de cada material puro puede ser extraída de la imagen o de un banco de firmas espectrales. Lo más usual es utilizar la imagen porque conserva la misma escala espectral de manera consistente (Roberts *et al.*, 1999).

En el área de estudio fueron elegidos tres materiales puros: la vegetación, el suelo desnudo y la sombra; que han sido utilizados en zonas forestales en otros trabajos con variables subpixel derivadas de técnicas de demezclado espectral (Fernández-Manso *et al.*, 2014; Lu *et al.*, 2005). Una vez que se tienen las reflectancias de cada material puro se puede demezclar cada pixel para encontrar los valores de las fracciones de cada material puro: fracción de vegetación (FV), fracción de suelo desnudo y fracción de sombra.

Las reflectancias de los materiales puros fueron obtenidas de zonas en la imagen identificadas de manera visual como áreas en donde sólo está presente el material puro (figura 2).

## 2.6. Variables texturales

Las variables texturales se calcularon con base en la matriz de co-ocurrencia de niveles de gris (GLCM, del inglés Grey-Level Co-occurrence Matrix). La matriz contiene la cantidad de veces que un par de pixeles vecinos (pixeles separados por una distancia de  $n$  metros en una dirección establecida) tienen una determinada diferencia de niveles de gris dentro de una ventana, por tanto, es una matriz cuadrada con el número de filas igual

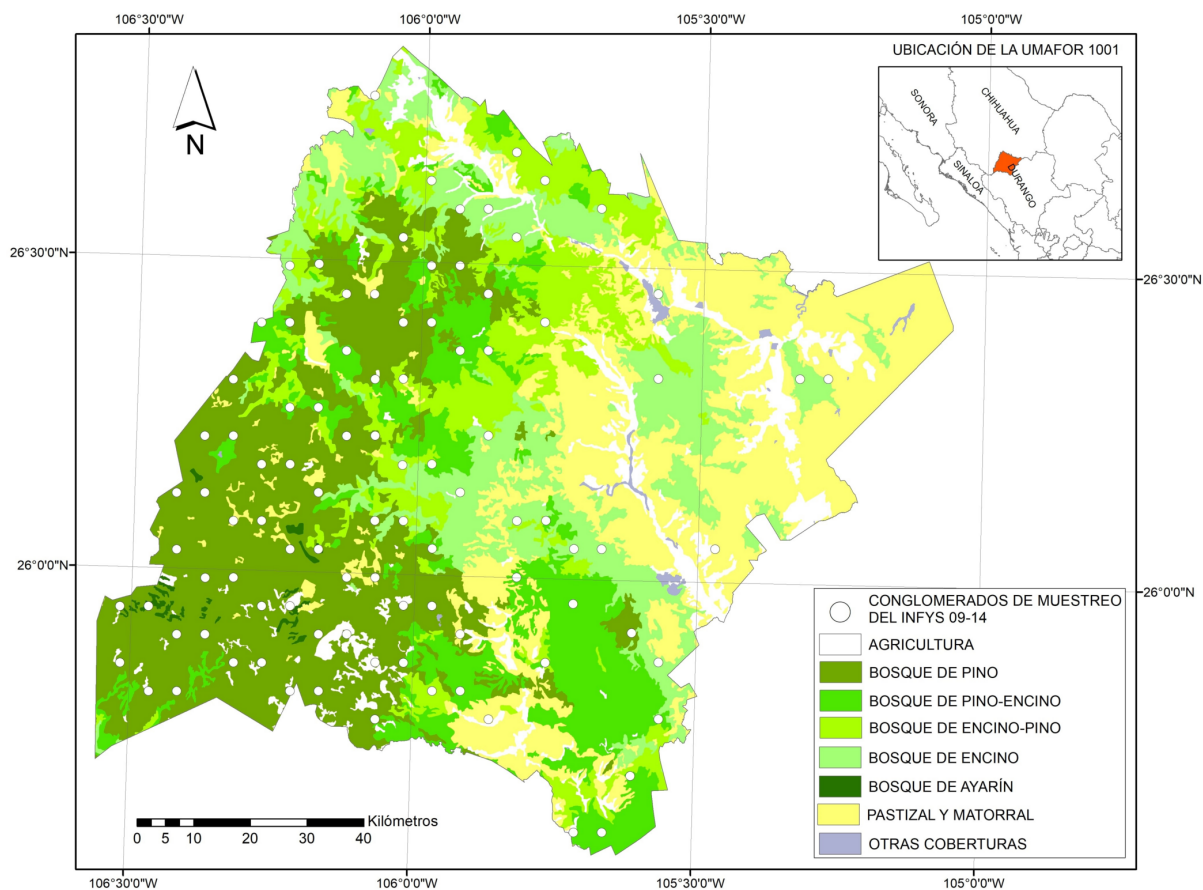


Figura 1. Zona de estudio UMAFOR 1001 y los conglomerados de muestreo del Inventario Nacional Forestal y de Suelos (INFyS) 2009-2014 contenidos en ella. Los tipos de cobertura de la zona fueron obtenidos de la Carta de Uso de Suelo y Vegetación del Instituto Nacional de Estadística y Geografía (INEGI) / Figure 1. UMAFOR 1001 study area and the sampling clusters of the National Forestry and Soil Inventory (INFyS) 2009-2014 contained therein. The coverage types of the area were obtained from the Land Use and Vegetation Chart of the National Institute of Statistics and Geography (INEGI).

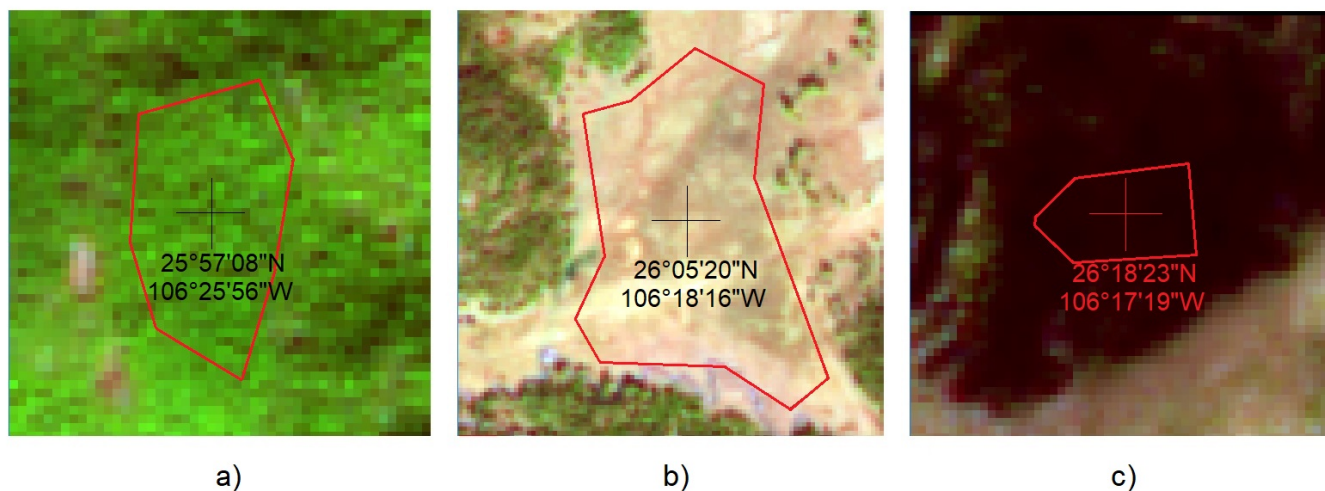


Figura 2. Ejemplos de selección de materiales puros (encerrados en un polígono rojo) a) vegetación, b) suelo desnudo y c) sombra. / Figure 2. Pure materials selection examples; enclosed in a red polygon: a) vegetation, b) bare soil and c) shadow.

al número de niveles de gris dentro de la ventana (Haralick y Shanmugam, 1973).

Las variables texturales fueron derivadas de cuatro bandas de las imágenes, la distancia al pixel vecino fue de 10 m (es decir, el pixel inmediatamente contiguo), en seis ventanas diferentes: 3x3, 5x5, 7x7, 9x9, 13x13 y 17x17 pixeles. Se calcularon 8 variables texturales:

$$\text{Media} = \sum_{i,j=0}^{N-1} i(P_{i,j})$$

$$\text{Varianza} = \sum_{i,j=0}^{N-1} P_{i,j}(i - \mu_i)^2$$

$$\text{Correlación} = \sum_{i,j=0}^{N-1} P_{i,j} \left[ \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right]$$

$$\text{Contraste} = \sum_{i,j=0}^{N-1} P_{i,j}(i - j)^2$$

$$\text{Disimilaridad} = \sum_{i,j=0}^{N-1} P_{i,j}|i - j|$$

$$\text{Homogeneidad} = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2}$$

$$\text{Segundo momento angular} = \sum_{i,j=0}^{N-1} (P_{i,j})^2$$

$$\text{Entropía} = \sum_{i,j=0}^{N-1} P_{i,j}(-\ln P_{i,j})$$

En donde:

- $i$  es el nivel de gris de la fila  $i$  en la GLCM,
- $j$  es el nivel de gris de la columna  $j$  en la GLCM,
- $P_{i,j}$  es la probabilidad asociada a la ocurrencia de que dos pixeles vecinos tengan los niveles de gris de  $i$  y  $j$ .
- $\mu_i$  es la variable textural media para  $i$
- $\mu_j$  es la variable textural media para  $j$
- $\sigma_i^2$  es la variable textural varianza para  $i$
- $\sigma_j^2$  es la variable textural varianza para  $j$

El tamaño de ventana más útil es obtenido de manera experimental probando diferentes tamaños (Kelsey y Neff, 2014), pues cada zona de estudio tiene sus propias características estructurales, aunque debe tomarse en consideración que el tamaño de la ventana debe ser menor o similar a la mínima unidad espacial que necesite ser caracterizada.

## 2.7. Construcción de modelos de estimación de biomasa forestal aérea

El coeficiente de correlación ( $r$ ) fue calculado entre cada una de las variables predictoras y la BFA en los conglomerados de muestreo de campo. Las variables predictoras y subpixel con mayores valores de  $r$ , fueron utilizadas para el ajuste de los modelos de estimación de BFA. Para cada uno de ellos se probó un ajuste lineal, uno polinomial de segundo orden y uno exponencial. También se construyó un modelo utilizando el conjunto de las 201 variables predictoras, con el método de regresión lineal *stepwise* (Draper y Smith, 1998). La calidad del ajuste de cada modelo se evaluó con el coeficiente de determinación ( $R^2$ ) y la raíz del error medio cuadrático (RMSE). Éste último también se evaluó con una validación cruzada.

## 3. Resultados

### 3.1. Coeficientes de correlación

Las variables espectrales que mayor valor de correlación presentaron con la BFA, fueron el NDVI43 con un  $r$  de -0.69 y el NDVI con  $r$  de 0.66 (tabla 1). La curva típica de la reflectancia en la vegetación muestra valores altos para la banda del IRC, y valores menores en la banda del IROC (Rock *et al.*, 1986). Por lo anterior, el NDVI43 tiende a ser negativo para una mayor cantidad de vegetación, lo cual explica el signo en el coeficiente de correlación. El NDVI también presenta un coeficiente de correlación alto con BFA con valores positivos asociados a una mayor reflectancia en el IRC, que en la banda del rojo (Rock *et al.*, 1986).

La FV y la fracción de sombra presentaron valores de correlación de 0.58 en valor absoluto (tabla 1). En términos ideales la FV debería tomar valores entre 0 y 1, sin embargo, puede tener resultados diferentes debido a la imprecisión en la caracterización de los materiales puros. En otros estudios, la caracterización de dichos materiales es llevada a cabo mediante la identificación de pixeles extremos en los gráficos de dispersión de las diferentes bandas espectrales (Fernández-Manso *et al.*, 2014), aunque Basuki *et al.* (2012) refinaron de manera recursiva la caracterización de los materiales puros, buscando que la menor cantidad de pixeles tomaran valores fuera del intervalo entre 0 y 1 al demezclar la imagen; encontrando que el 97 % de los pixeles tomaron valores dentro de ese intervalo, mientras que en el presente estudio, el 89 % de los valores de FV están dentro del mismo.

La variable textural media presentó la mayor correlación con la BFA, particularmente en la ventana de 17x17 para las bandas del verde y el rojo ( $r = -0.55$ ) (tabla 1). Se puede observar poco cambio en los valores de  $r$  de las variables texturales conforme aumenta la ventana, lo cual implica que el grado de generalización de los datos de la imagen, cuando menos para este intervalo de ventanas, tiene poca influencia sobre el potencial predictivo de las variables en nuestra zona de estudio.

Tabla 1: Coeficientes de correlación entre la biomasa y las variables: espectrales, subpixel y texturales / Table 1. Correlation coefficients between biomass and spectral, subpixel, and textural variables

Variables Espectrales						
	Verde	Rojo	IRC	IROC	NDVI	NDVI43
	-0.52	-0.52	-0.22	-0.49	0.66	-0.69
Variables Subpixel						
Fracción de vegetación	Fracción de suelo desnudo			Fracción de sombra		
0.58	-0.58			0.09		
Variable Textural Media						
	3x3	5x5	7x7	9x9	13x13	17x17
Verde	0.51	0.51	0.52	0.52	0.54	0.55
Rojo	0.52	0.52	0.53	0.53	0.54	0.55
IRC	0.22	0.22	0.22	0.22	0.22	0.23
IROC	0.48	0.48	0.49	0.49	0.51	0.52
Variable Textural Varianza						
Verde	0.18	0.19	0.21	0.24	0.27	0.30
Rojo	0.23	0.23	0.23	0.24	0.26	0.29
IRC	0.03	0.07	0.12	0.15	0.18	0.19
IROC	0.16	0.16	0.16	0.17	0.20	0.22
Variable Textural Homogeneidad						
Verde	0.31	0.32	0.33	0.33	0.34	0.35
Rojo	0.38	0.39	0.40	0.41	0.43	0.45
IRC	0.17	0.18	0.19	0.21	0.24	0.27
IROC	0.31	0.32	0.32	0.33	0.35	0.35
Variable Textural Contraste						
Verde	0.23	0.24	0.25	0.26	0.27	0.28
Rojo	0.27	0.29	0.30	0.31	0.33	0.34
IRC	0.09	0.09	0.11	0.12	0.16	0.19
IROC	0.17	0.18	0.18	0.20	0.22	0.25
Variable Textural Disimilaridad						
Verde	0.30	0.31	0.31	0.32	0.33	0.34
Rojo	0.36	0.37	0.38	0.39	0.41	0.43
IRC	0.15	0.16	0.17	0.19	0.22	0.25
IROC	0.28	0.29	0.30	0.31	0.32	0.33
Variable Textural Entropía						
Verde	0.35	0.38	0.40	0.41	0.44	0.46
Rojo	0.43	0.44	0.46	0.47	0.49	0.51
IRC	0.21	0.15	0.11	0.08	0.05	0.03
IROC	0.36	0.37	0.38	0.39	0.41	0.42
Variable Textural Segundo Momento Angular						
Verde	0.35	0.36	0.37	0.38	0.40	0.42
Rojo	0.43	0.45	0.46	0.47	0.49	0.52
IRC	0.21	0.18	0.17	0.16	0.16	0.15
IROC	0.38	0.39	0.40	0.42	0.45	0.47
Variable Textural Correlación						
Verde	0.27	0.29	0.27	0.31	0.40	0.42
Rojo	0.31	0.13	0.07	0.06	0.27	0.33
IRC	0.18	0.01	0.06	0.06	0.01	0.01
IROC	0.15	0.14	0.14	0.22	0.37	0.35

### 3.2. Mapas de estimación de biomasa forestal aérea

Las métricas de ajuste de los modelos lineal, polinomial y exponencial, teniendo como variable predictora al NDVI43, fueron similares, por lo que se utilizó la ecuación del modelo

lineal:  $BFA = -484.6512 \cdot NDVI43 + 80.4760$  (RMSE = 50.38  $Mg\ ha^{-1}$ , y  $R^2 = 0.55$ ).

Las métricas de ajuste de los modelos lineal, polinomial y exponencial, teniendo como variable predictora a la FV, fueron

similares, por tanto, se utilizó la ecuación del modelo lineal:  $BFA = 164.9277 * FV + 9.0992$  (RMSE =  $56.54 \text{ Mg ha}^{-1}$ , y  $R^2 = 0.69$ ).

El modelo construido con las 201 variables predictoras y la regresión *stepwise*, arrojó como resultado una ecuación igual al modelo lineal construido con el NDVI43, por lo que el aspecto multivariado, incluyendo las variables texturales, no aportó mayor poder predictivo que el modelo bivariado basado en el índice de vegetación NDVI43.

Con los modelos con NDVI43 y FV se construyeron los mapas correspondientes de BFA del área de estudio (ver lámina), usando el programa Arcmap 10.1. El modelo con el NDVI43 estimó la BFA promedio de la UMAFOR1001 en  $55.01 \text{ Mg ha}^{-1}$  y la BFA total en  $62.373 \text{ Tg}$ . Mientras que el modelo con la FV estimó la BFA promedio en  $57.65 \text{ Mg ha}^{-1}$  y la BFA total en  $65.360 \text{ Tg}$ .

López-Serrano *et al.* (2015) también construyeron un mapa de biomasa forestal de la UMAFOR 1001, con un modelo que combina el uso de árboles de decisión con regresiones lineales. Y López-Serrano *et al.* (2016), con un método similar, construyeron un mapa de biomasa forestal de la Sierra Madre Occidental, que también comprende la UMAFOR 1001. Estos cuatro mapas muestran una distribución espacial similar de BFA, presentando las áreas de mayor cantidad de biomasa en la zona Oeste, donde se concentran las áreas boscosas. Una ventaja del mapa del estudio aquí mostrado, es que también presenta estimaciones de BFA de la zona Este, donde abundan las llanuras y una cobertura de pastizales.

La FV, al estimar la proporción de vegetación en cada pixel, es de interpretación sencilla e intuitivamente se entiende que tendrá valores más altos en las zonas con mayor BFA, lo cual es una ventaja para los tomadores de decisiones no habituados a procesamientos geoespaciales. También puede presentar valores negativos debidos a la falta de perfección en la identificación y recolección de las firmas espectrales de los materiales puros. En este caso, cada vez que la FV sea menor a  $-0.055$  la estimación de BFA también será negativa. Se debe interpretar que la estimación de biomasa es igual a cero.

El RMSE del modelo con FV es de  $56.54 \text{ Mg ha}^{-1}$ , que puede ser considerado el error estándar de la estimación. En este caso, cada valor estimado de BFA que vemos en el mapa, tendrá un 67 % de probabilidades de estar en el intervalo definido entre la estimación  $\pm 56.54 \text{ Mg ha}^{-1}$ .

Una desventaja de construir mapas de biomasa con la FV, es que es necesario un determinado grado de conocimientos acerca de la interpretación y el procesamiento de imágenes satelitales para poder extraer los materiales puros, ya sea eligiéndolos en la imagen o en el espacio de reflectancias, para correr los procesos de demezclado espectral.

Los mapas de BFA que son parte de estudios como los de López-Serrano *et al.* (2015) y López-Serrano *et al.* (2016), o de otros (p. ej. Aguirre-Salado *et al.*, 2012, que también utiliza un tipo de variables subpixel), suelen ser de acceso restringido y es necesario tener una suscripción pagada para acceder al manuscrito, además que únicamente es posible observar en el

documento un mapa estático de pequeñas dimensiones, y comúnmente son estudios centrados en el diseño del método de producción del mapa.

En línea también es posible encontrar mapas de biomasa, algunos en formato estático (Alianza México RED+, 2013), otros pueden presentar varias capas de información pero no son descargables (CONAHCYT, s. f.), y algunos otros que sí lo son, únicamente presentan una capa de información (CONAFOR-GSNMF, 2022). Todos ellos mencionan los insumos del mapa y brevemente el método de procesamiento, pero sin el detalle suficiente para ser reproducible. En el presente trabajo proponemos un mapa web en donde el usuario puede consultarlo, encender y apagar varias capas de información y descargar los datos.

#### 4. Conclusiones

Muchos mapas de biomasa forestal aérea (BFA) presentes en la literatura son de acceso restringido, en formato estático y en estudios que se centran más en el modelo de estimación de biomasa en sí mismo. Aquellos encontrados en la web no pueden ser descargados o no describen con detalle su método de construcción. En este estudio se construyó un mapa de biomasa forestal aérea (BFA) en la UMAFOR 1001, de acceso libre, con varias capas de información que pueden ser visualizadas por el usuario, con datos descargables y con la descripción del método de construcción que lo sustenta.


Un mapa fue construido con un modelo basado en la variable subpixel fracción de vegetación (FV) obtenida con la técnica de desmezclado espectral lineal. Con este modelo la BFA promedio fue de  $57.65 \text{ Mg ha}^{-1}$  y la BFA total de  $65.360 \text{ Tg}$ . A modo de comparación, también se construyó otro mapa de BFA con la variable predictora con mayor correlación de biomasa, en este caso el NDVI43. Ambos mapas presentan distribuciones similares de BFA, con mayor concentración en las zonas boscosas. Una manera más apropiada de poder compararlas sería a través de un mapa de fuentes de incertidumbre. En la literatura existen propuestas de investigación que persiguen espacializar la incertidumbre de mapas de variables ambientales, no solo del modelo de estimación de biomasa, sino de cada dato fuente e hipótesis constitutiva del modelo. Conjuntamente con un análisis de sensibilidad, estos mapas pueden señalar incluso cuáles son las fuentes de incertidumbre que más peso tienen en las estimaciones presentadas en el mapa. Poder contar con el valor de la incertidumbre sobre la estimación en cada ubicación permitiría hacer análisis más detallados que con el simple hecho de sólo comparar los mapas de manera visual.

La FV es una variable de interpretación más sencilla que otras, ya que presenta la proporción de vegetación que es percibida por el sensor en cada pixel, sin embargo, tiene la desventaja de necesitar un determinado grado de conocimientos de percepción remota para generarla, pero los resultados demuestran que es una buena alternativa para generar mapas de biomasa forestal. Una técnica de demezclado espectral no lineal, junto con

# Mapas de biomasa forestal aérea de bosques del norte de Durango, México utilizando variables subpixel, espectrales y texturales.

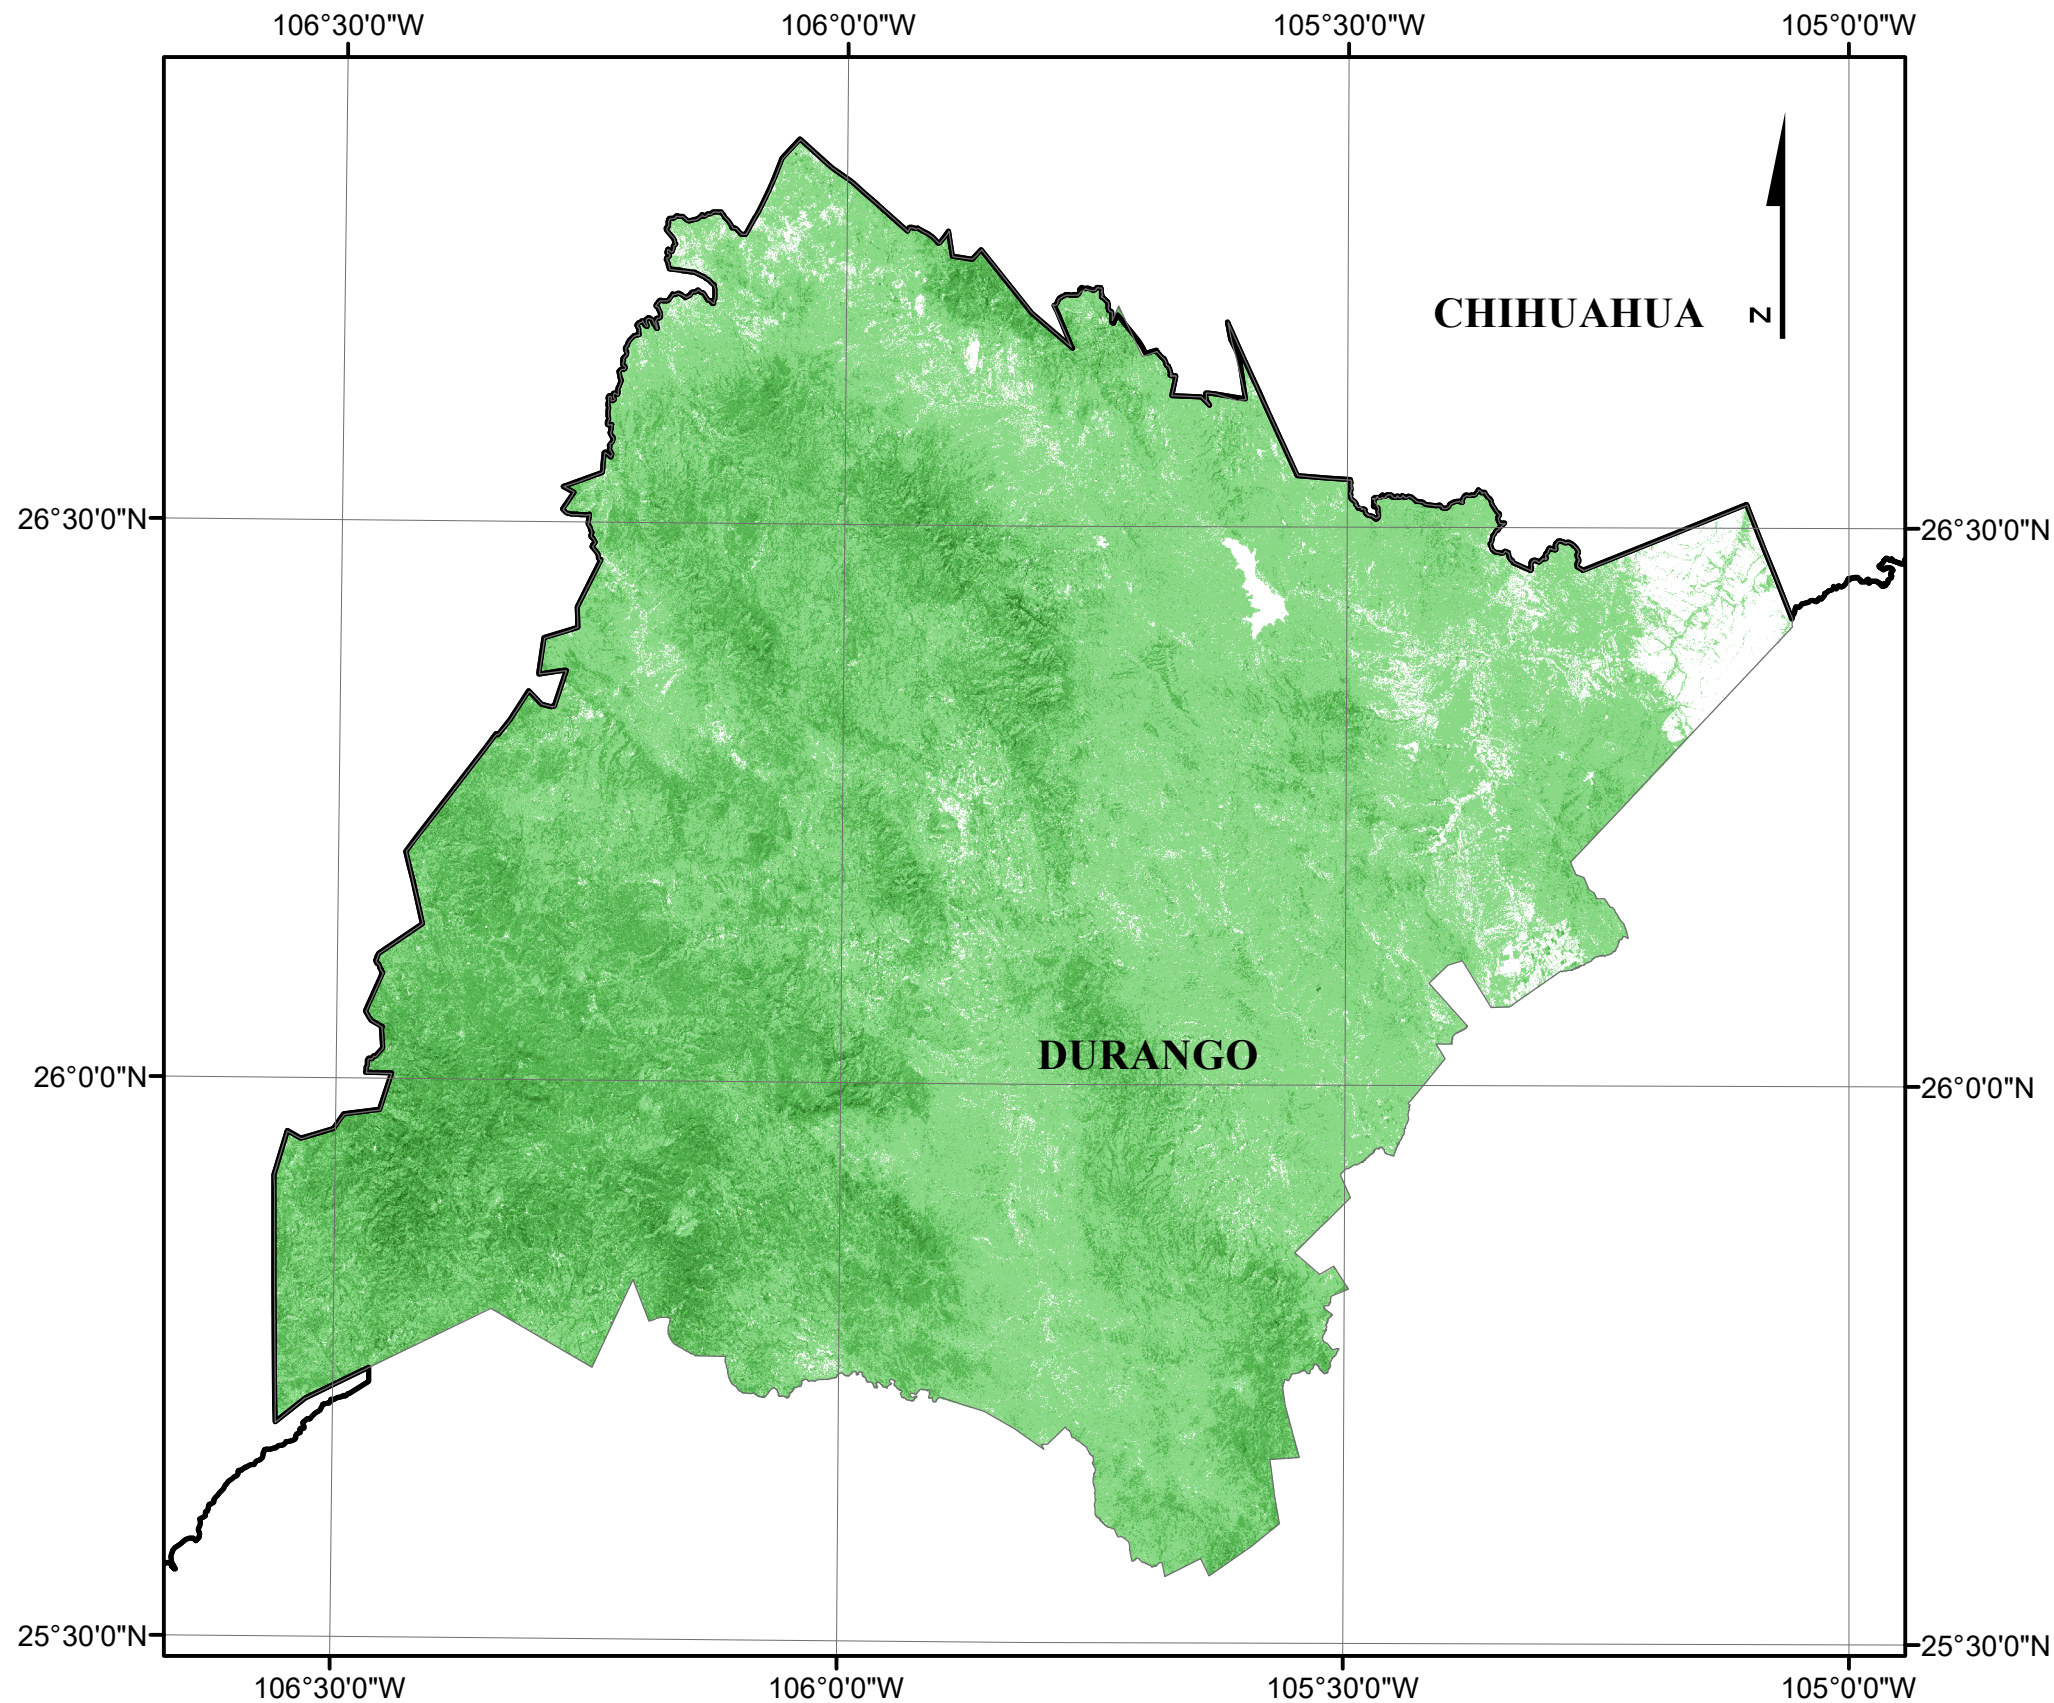
Juan Andrés Almazán González,<sup>1</sup> Jorge Prado Molina,<sup>1</sup> Lilia de Lourdes Manzo Delgado,<sup>1</sup> Stéphane Couturier.<sup>1</sup>

<sup>1</sup> Instituto de Geografía, UNAM.

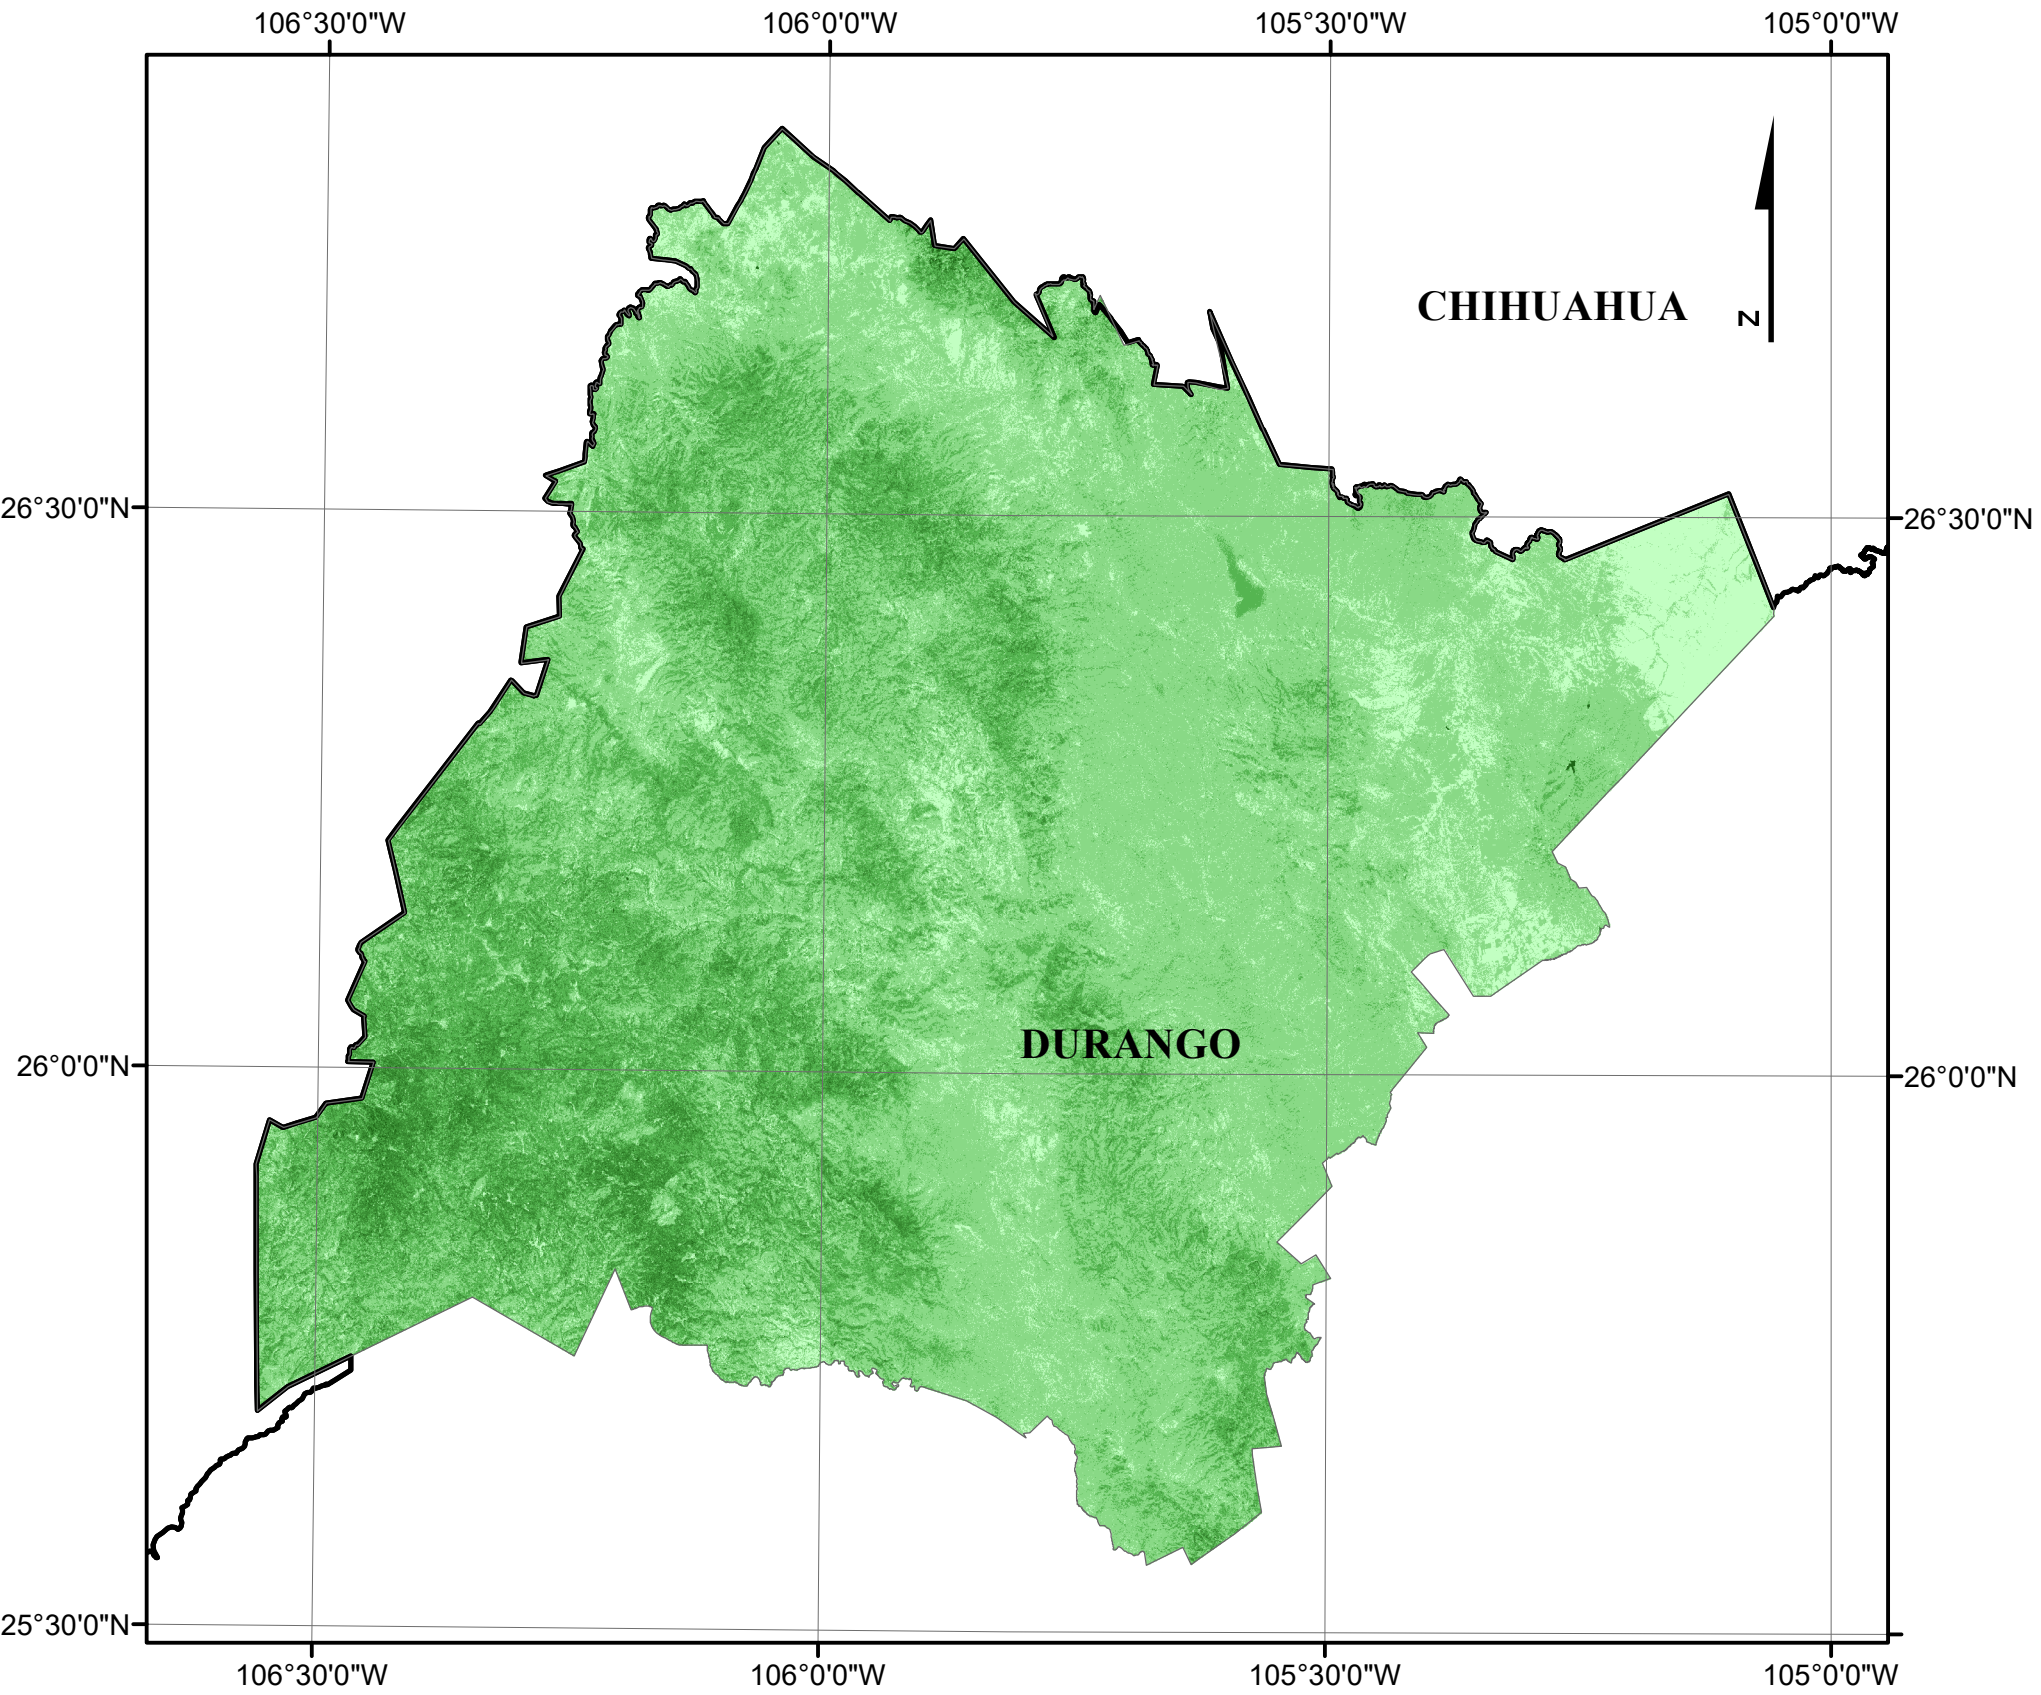


**terra digitalis**  
internacional e-journal of maps

## Mapa de biomasa aérea forestal con el modelo fracción de vegetación.




## Mapa de biomasa aérea forestal con el modelo NDVI43.



Ubicación de la UMAFOR 1001




**Biomasa en Mg ha<sup>-1</sup>**



Información Técnica:

Escala.....1:750000  
Esferoide.....WGS 84  
Datum.....WGS 84  
Proyección.....UTM  
Zona.....13N





una selección más rigurosa de las firmas espectrales de los materiales puros, pueden ser considerados en trabajos futuros para generar variables con mayor poder predictivo.

## Datos

- UMAFOR\_1001\_simple. Límite de la UMAFOR 1001, obtenido de la unión de los límites de los municipios de Ocampo, San Bernardo y Guanaceví (Durango) en el *shapefile* de división política municipal, descargado de la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO).
- Conglomerados\_Infys\_09-14\_UMAFOR\_1001\_2010-2011\_1. *Shapefile* de la ubicación de las parcelas de muestreo Inventario Nacional Forestal y de Suelos (INFyS) 2009-2014, utilizado para generar el mapa.
- MosaicUMAFOR1001\_TOAReflectance. Mosaico (ráster) que cubre la UMAFOR 1001 de la reflectancia en la parte alta de la atmósfera, generado de la unión de las imágenes SPOT 5.
- mapadb\_vege. Mapa (ráster) de la estimación de biomasa aérea forestal de la UMAFOR 1001, obtenido con el modelo de estimación utilizando la fracción de vegetación como variable predictora, derivada del desmezclado espectral lineal.
- mapadb\_ndviir. Mapa (ráster) de la estimación de biomasa aérea forestal de la UMAFOR 1001, obtenido con el modelo de estimación utilizando el NDVI43 como variable predictora, formado por las bandas infrarrojo cercano e infrarrojo de onda corta.

## Agradecimientos

Se agradece a CONAHCYT por el apoyo económico para el desarrollo de este artículo, a través de los proyectos: LN-CONACYT-2019-299139, LN-CONACYT-2020-314886, LN-CONACYT-2021-315858, and LN-CONAHCYT-2023,2024-321233. Una porción del análisis de los datos publicados aquí se realizó en el marco del proyecto PAPIIT IN304722 "De la historia ambiental a la defensa territorial: contribución a la conservación y restauración de la biodiversidad forestal en México mediante Tecnologías de la Información Geográfica", y del proyecto CTIC/5386/2024 Conservación de la biodiversidad en ecosistemas templados: una lectura cruzada desde prácticas forestales y agrícolas en áreas naturales protegidas de Occitania, Catalunya y de los valles centrales de México", ambos proyectos financiados por la DGAPA, UNAM.

## Referencias

- Adams, J. B., Smith, M. O., Gillespie, A. R., 1993. Imaging spectroscopy: interpretation based on spectral mixture analysis. En: Pieters, C. M., Englert, P. (Eds.), *Remote Geochemical Analysis: Elemental and Mineralogical Composition*. Cambridge University Press, New York.
- Aguirre-Salado, C., Treviño-Garza, E., Aguirre-Calderón, O., Jiménez-Pérez, J., González-Tagle, M., Valdez-Lazalde, J., Aguirre-Salado, A., 2012. Construction of aboveground biomass models with remote sensing technology in the intertropical zone in Mexico. *Journal of Geographical Sciences* 22 (4), 669–680, <https://doi.org/10.1007/s11442-012-0955-9>.
- Aguirre-Salado, C., Treviño-Garza, E., Aguirre-Calderón, O., Jiménez-Pérez, J., González-Tagle, M., Valdez-Lazalde, J., Miranda-Aragón, L., 2014. Mapping aboveground biomass by integrating geospatial and forest inventory data through a k-nearest neighbor strategy in north central Mexico. *Journal of Arid Land* 6 (1), 80–96, <https://doi.org/10.1007/s40333-013-0191-x>.
- Aguirre-Salado, C., Valdez-Lazalde, J., Ángeles Pérez, G., de los Santos-Posadas, H., Haapanen, R., Aguirre-Salado, A., 2009. Mapeo de carbono arbóreo aéreo en bosques manejados de pino patula en Hidalgo, México. *Agrociencia* 43 (2), 209–220, <https://doi.org/10.1007/s11442-012-0955-9>.
- Alianza México para la Reducción de Emisiones de Carbono por Deforestación y Degradación (Alianza México REDD+), 2013. Densidad de carbono en la biomasa leñosa aérea de los bosques y selvas de México. Disponible en: [https://www.alianza-mredd.org/wp-content/uploads/Files/Biblioteca%20Territorios/M-REDD%2BDensidadBiomasaLenosa\\_mapa.pdf](https://www.alianza-mredd.org/wp-content/uploads/Files/Biblioteca%20Territorios/M-REDD%2BDensidadBiomasaLenosa_mapa.pdf) (acceso 18.10.2024).
- Basuki, T., Skidmore, A., van Laake, P., van Duren, I., Hussin, Y., 2012. The potential of spectral mixture analysis to improve the estimation accuracy of tropical forest biomass. *Geocarto International* 27 (4), 329–345, <https://doi.org/10.1080/10106049.2011.634928>.
- Castillo-Santiago, M., Ghilardi, A., Oyama, K., Hernández-Stefanoni, J., Torres, I., Flamenco-Sandoval, A., Mas, J., 2013. Estimating the spatial distribution of woody biomass suitable for charcoal making from remote sensing and geostatistics in central Mexico. *Energy for Sustainable Development* 17 (2), 177–188, <https://doi.org/10.1016/j.esd.2012.10.007>.
- Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT), s.f. Oferta de biomasa. Disponible en: <https://energia.conahcyt.mx/planeas/biomasa/oferta> (acceso 18.10.2024).
- Eckert, S., 2012. Improved forest biomass and carbon estimations using texture measures from worldview-2 satellite data. *Remote Sensing* 4 (4), 810–829, <https://doi.org/10.3390/rs4040810>.
- Fernández-Manso, O., Fernández-Manso, A., Quintano, C., 2014. Estimation of aboveground biomass in Mediterranean forests by statistical modelling of aster fraction images. *International Journal of Applied Earth Observation and Geoinformation* 31, 45–56, <https://doi.org/10.1016/j.jag.2014.03.005>.
- Foody, G., Boyd, D., Cutler, M., 2003. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. *Remote Sensing of Environment* 85, 463–474, [https://doi.org/10.1016/S0034-4257\(03\)00039-7](https://doi.org/10.1016/S0034-4257(03)00039-7).
- Galeana-Pizaña, J., López-Caloca, A., López-Quiroz, P., Silván-Cárdenas, J., Couturier, S., 2014. Modeling the spatial distribution of above-ground carbon in Mexican coniferous forests using remote sensing and a geostatistical approach. *International Journal of Applied Earth Observation and Geoinformation* 30, 179–189, <https://doi.org/10.1016/j.jag.2014.02.005>.
- Galeana-Pizaña, J., Núñez Hernández, J., Corona Romero, N., 2016. Remote sensing-based biomass estimation. En: Marghany, M. (Ed.), *Environmental Applications of Remote Sensing*. IntechOpen, <https://doi.org/10.5772/61813>.
- Gerencia del Sistema Nacional de Monitoreo Forestal (CONAFOR-GSNMF), 2022. Contenido de biomasa formación forestal (Tn/Ha). Disponible en: [https://idefor.cnf.gob.mx/layers/geonode%3Abiomasa\\_estrato\\_4326](https://idefor.cnf.gob.mx/layers/geonode%3Abiomasa_estrato_4326) (acceso 18.10.2024).
- Haralick, R., Shanmugam, K., 1973. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics* 6, 610–621.
- IPCC, 2014. *Climate Change 2014: Synthesis Report*. Contribution of Working

- Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. IPCC, Geneva, Switzerland.
- Kelsey, K., Neff, J., 2014. Estimates of aboveground biomass from texture analysis of landsat imagery. *Remote Sensing* 6 (7), 6407–6422, <https://doi.org/10.3390/rs6076407>.
- López-Serrano, P., López-Sánchez, C., Díaz-Varela, R., Corral-Rivas, J., Vargas-Larreta, B., Álvarez González, J., 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 (2), 226–234, <http://doi.org/10.3832/ifor1504-008>.
- López-Serrano, P., López-Sánchez, C., Solís-Moreno, R., Corral-Rivas, J., 2016. Geospatial estimation of above ground forest biomass in the sierra madre occidental in the state of durango, mexico. *Forests* 7 (3), 70, <https://doi.org/10.3390/f7030070>.
- Lu, D., 2005. Aboveground biomass estimation using landsat tm data in the brazilian amazon. *International Journal of Remote Sensing* 26 (12), 2509–2525, <https://doi.org/10.1080/01431160500142145>.
- Lu, D., Batistella, M., Moran, E., 2005. Satellite estimation of aboveground biomass and impacts of forest stand structure. *Photogrammetric Engineering & Remote Sensing* 71 (8), 967–974, <https://doi.org/10.14358/PERS.71.8.967>.
- Lu, D., Chen, Q., Wang, G., Liu, L., Li, G., Moran, E., 2016. A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. *International Journal of Digital Earth* 9 (1), 63–105, <https://doi.org/10.1080/17538947.2014.990526>.
- Lu, D., Mausel, P., Brondízio, E., Moran, E., 2004. Relationships between forests stand parameters and landsat tm spectral responses in the brazilian amazon basin. *Forest Ecology and Management* 198 (1), 149–167, <https://doi.org/10.1016/j.foreco.2004.03.048>.
- Prieto R., J., Hernández D., J., 2007. Estudio regional forestal. Caso UMAFOR No. 1001, Guanaceví, Durango. Prieto R., J. A. y J. C. Hernández D. (eds.). Durango, México.
- Roberts, D., Batista, G., Pereira, J., Waller, E., Nelson, B., 1999. Change identification using multitemporal spectral mixture analysis: Applications in eastern amazonia. En: Luneta, R., Elvidge, C. (Eds.), *Remote sensing change detection: environmental monitoring methods and applications*. EU, pp. 137–161.
- Roberts, D., Smith, M., Adams, J., 1993. Green vegetation, nonphotosynthetic vegetation, and soils in aviris data. *Remote Sensing of Environment* 44 (2–3), 255–269.
- Rock, B., Vogelmann, J., Williams, D., Vogelmann, A., Hoshizaki, T., 1986. Remote detection of forest damage: Plant responses to stress may have spectral “signatures” that could be used to map, monitor, and measure forest damage. *Bioscience* 36 (7), 439–445, <https://doi.org/10.2307/1310339>.
- Rodríguez-Veiga, P., Quegan, S., Carreiras, J., Persson, H., Fransson, J., Hoscilo, A., Balzter, H., 2019. Forest biomass retrieval approaches from earth observation in different biomes. *International Journal of Applied Earth Observation and Geoinformation* 77, 53–68, <http://doi.org/10.1016/j.jag.2018.12.008>.
- Rojas-García, F., De Jong, B., Martínez-Zurimendí, P., Paz-Pellat, F., 2015. Database of 478 allometric equations to estimate biomass for mexican trees and forests. *Annals of Forest Science* 72 (6), 835–864, <https://doi.org/10.1007/s13595-015-0456->.
- Rouse, J., Haas, R., Schell, J., Deering, D., Harlan, J., 1974. Monitoring the vernal advancement of retrogradation of natural vegetation. National Aeronautics and Space Administration, Goddard Space Flight Center (NASA/GSFC), Greenbelt, Maryland, EEUU.
- Sanchez-Azofeifa, A., Antonio Guzmán, J., Campos, C., Castro, S., Garcia-Millan, V., Nightingale, J., Rankine, C., 2017. Twenty-first century remote sensing technologies are revolutionizing the study of tropical forests. *Biotropica* 49 (5), 604–619, <https://doi.org/10.1111/btp.12454>.
- Silván-Cárdenas, J. L., Corona-Guzmán, N., Galeana-Pizaña, J. M., Núñez-Hernández, J. M., Madrigal-Gómez, J. M., 2015. Geospatial technologies to support coniferous forests research and conservation efforts in Mexico. En: Weber, R. P. (Ed.), *Old-Growth Forests and Coniferous Forests: Ecology, Habitat and Conservation*. Nova Science Pub Inc., United Kingdom.
- Silván-Cárdenas, J. L., Wang, L., 2010. Retrieval of subpixel tamarix canopy cover from landsat data along the forgotten river using linear and nonlinear spectral mixture models. *Remote Sensing of Environment* 114 (8), 1777–1790, <https://doi.org/10.1016/j.rse.2010.04.003>.
- Spot Image, 2010. Niveles de procesamiento y precisión de localización. Disponible en: [https://www.intelligence-airbusds.com/files/pmedia/public/r2006\\_9\\_spot\\_niveles\\_de\\_preprocesamiento\\_esp\\_sept2010.pdf](https://www.intelligence-airbusds.com/files/pmedia/public/r2006_9_spot_niveles_de_preprocesamiento_esp_sept2010.pdf).
- Sun, H., Qie, G., Wang, G., Tan, Y., Li, J., Peng, Y., Luo, C., 2015. Increasing the accuracy of mapping urban forest carbon density by combining spatial modeling and spectral unmixing analysis. *Remote Sensing* 7 (11), 15114–15139, <https://doi.org/10.3390/rs71115114>.
- Thayn, J., 2020. Monitoring narrow mangrove stands in baja california sur, mexico using linear spectral unmixing. *Marine Geodesy* 43 (5), 493–508, <https://doi.org/10.1080/01490419.2020.1751753>.
- Vargas-Larreta, B., López-Sánchez, C., Corral-Rivas, J., López-Martínez, J., Aguirre-Calderón, C., Álvarez González, J., 2017. Allometric equations for estimating biomass and carbon stocks in the temperate forests of north-western mexico. *Forests* 8 (8), 269, <https://doi.org/10.3390/f8080269>.
- Yan, E., Lin, H., Wang, G., Sun, H., 2015. Improvement of forest carbon estimation by integration of regression modeling and spectral unmixing of landsat data. *IEEE Geoscience and Remote Sensing Letters* 12 (9), 2003–2007, <https://doi.org/10.1109/LGRS.2015.2451091>.

**This article accompanies the following material:**

Static map: [10.22201/igg.25940694e.2024.2.122.15](https://doi.org/10.22201/igg.25940694e.2024.2.122.15)

Interactive map: [10.22201/igg.25940694e.2024.2.122.16](https://doi.org/10.22201/igg.25940694e.2024.2.122.16)