

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO  
DIVISIÓN DE AGRONOMÍA  
DEPARTAMENTO FORESTAL



Modelos de Predicción de Carbono Total en las Selvas del Sureste de México,  
Bajo Escenarios Climáticos al 2050

Por:

**AXEL RODRIGO GARCÍA HERNÁNDEZ**

TESIS

Presentada como requisito parcial para obtener el título de:

**INGENIERO FORESTAL**

Saltillo, Coahuila, México

Junio, 2023

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO  
DIVISIÓN DE AGRONOMÍA  
DEPARTAMENTO FORESTAL

Modelos de Predicción de Carbono Total en las Selvas del Sureste de México,  
Bajo Escenarios Climáticos al 2050

Por:

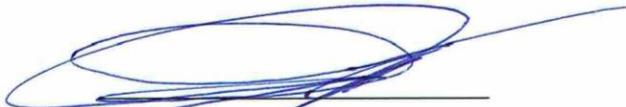
**AXEL RODRIGO GARCÍA HERNÁNDEZ**

TESIS

Presentada como requisito parcial para obtener el título de:

**INGENIERO FORESTAL**

Aprobado por el Comité de Asesoría:



Dr. Jorge Méndez González  
Asesor Principal



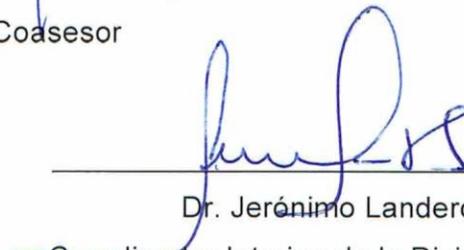
Dr. Andrés Flores García  
Asesor Principal Externo



Dr. Eladio Heriberto Cornejo Oviedo  
Coasesor



Dr. Celestino Flores López  
Coasesor



Dr. Jerónimo Landeros Flores  
Coordinador Interino de la División de Agronomía



Saltillo, Coahuila, México  
Junio, 2023

## DECLARACIÓN DE NO PLAGIO

El autor principal quien es el responsable directo, jura bajo protesta de decir verdad que no se incurrió en plagio o conducta académica incorrecta en los siguientes aspectos:

Reproducción de fragmentos o textos sin citar la fuente o autor original (corta y pega); reproducir un texto propio publicado anteriormente sin hacer referencia al documento original (auto plagio); comprar, robar o pedir prestados los datos o la tesis para presentarla como propia; omitir referencias bibliográficas o citar textualmente sin usar comillas; utilizar ideas o razonamientos de un autor sin citarlo; utilizar material digital como imágenes, videos, ilustraciones, graficas, mapas o datos sin citar al autor original y/o fuente, así mismo tengo conocimiento de que cualquier uso distinto de estos materiales como el lucro, reproducción, edición o modificación, será perseguido y sancionado por las autoridades correspondientes.

Por lo anterior me responsabilizo de las consecuencias de cualquier tipo de plagio en caso de existir y declaro que este trabajo es original.

Pasante



Axel Rodrigo García Hernández

## **DEDICATORIA**

El presente trabajo está dedicado a mis padres: Maricela Dolores Hernández Flores y Fabián García Flores, por poner su fe en mí, dándome todo su apoyo y amor incondicional que, espero algún día poder corresponder de la misma manera.

A mi hermana Alejandra García Hernández, que, con su apoyo, he podido seguir adelante a lo largo de mi estadía universitaria y vida personal

A la familia Hernández Flores, que, a lo largo de mi vida, me han apoyado y ayudado en seguir adelante, principalmente a mi Tía Juana Hernández Flores, que, sin su ayuda, no sería quien soy hoy actualmente.

Sé que no es suficiente con dedicar este trabajo, pero, considero que es una forma significativa de agradecimiento por ser y estar presentes en cada momento de la vida.

## **AGRADECIMIENTOS**

A la “Universidad Autónoma Agraria Antonio Narro” por permitirme realizarme como profesional y brindarme de los conocimientos necesarios para poder desempeñarme laboralmente.

Al Dr. Jorge Méndez González por su apoyo y paciencia, haciendo aporte con comentarios y conocimientos en la elaboración de este trabajo.

Al Dr. Celestino Flores López, por el apoyo para la realización del presente trabajo, por los consejos y aporte de sus comentarios

Al Dr. Eladio H. Cornejo Oviedo, por apoyarme en el desarrollo de este trabajo, por los consejos brindados y por el aporte de sus valiosos comentarios.

Al personal que labora en el Departamento Forestal por facilitar su apoyo en la formación como profesionista forestal.

A mis compañeros de generación por permitirme relacionarme y formar lazos de confianza, que, a lo largo de estos años de formación me han apoyado de distintas formas

A Ehecatl Hernández, Ramiro Dávalos, Romeo Guízar, Alejandro Ortega, Andy Mendieta, Jeff Mendieta, Francisco Solares, Marianela Echeveste por su amistad y apoyo constante durante estos últimos años.

A Alejandra García, Leonardo Macías, Jordán Macías y Abril Isabel por su apoyo y consejos que me han servido para poder seguir adelante.

A mis gatos “Mia, Bicha y Cosme” que me han ayudado en estos últimos años como soporte emocional y poder seguir adelante.

A todas aquellas personas y amigos, que por el momento no vienen a mi mente y sin tener la intención de omitir, pero que de alguna manera formaron parte de esta etapa universitaria y me brindaron su apoyo.

## TABLA DE CONTENIDO

	Página
<b>ÍNDICE DE TABLAS .....</b>	<b>VII</b>
<b>ÍNDICE DE FIGURAS .....</b>	<b>VIII</b>
<b>RESUMEN .....</b>	<b>VIX</b>
<b>SUMMARY.....</b>	<b>IX</b>
<b>1. INTRODUCCIÓN .....</b>	<b>1</b>
1.1. OBJETIVO GENERAL .....	2
1.2. OBJETIVOS ESPECÍFICOS .....	2
1.3. HIPÓTESIS .....	2
<b>2. REVISIÓN DE LITERATURA.....</b>	<b>3</b>
2.1. Inventario Nacional Forestal y de Suelos (INFyS) .....	3
2.2. Captura de carbono .....	3
2.3. Cambio Climático.....	4
2.4. Modelos de Circulación General.....	4
2.5. Escenarios de cambio climático .....	6
2.6. Variables Climáticas .....	6
2.7. Modelos de Predicción.....	7
2.8. Influencia del Cambio Climático en la captura de Carbono .....	8
<b>3. MATERIALES Y MÉTODOS .....</b>	<b>10</b>
3.1. Área de estudio .....	10
3.2. Carbono total.....	10
3.4. Limpieza de los datos y regionalización bioclimática del área de estudio ..	11
3.5. Generación y validación de los modelos.....	12
3.6. Predicciones de carbono actual.....	12
3.7. Escenarios de carbono total al 2050 .....	13
<b>4. RESULTADOS Y DISCUSIÓN .....</b>	<b>14</b>
<b>5. CONCLUSIONES .....</b>	<b>34</b>
<b>6. LITERATURA CITADA .....</b>	<b>35</b>

## ÍNDICE DE TABLAS

Página

<b>Tabla 1.</b> Variables bioclimáticas utilizadas en la construcción del modelo de predicción de carbono total	11
<b>Tabla 2.</b> Coeficientes de regresión y estadísticas de ajuste de los modelos para predecir el carbono total en tres regiones de selvas del sureste de México.	17
<b>Tabla 3.</b> Valores de probabilidad de los coeficientes de regresión en los modelos de las tres regiones, a diferentes tamaños de muestra.	21
<b>Tabla 4.</b> Validación de los modelos de predicción de carbono, de cada región en selvas del sureste de México.	23
<b>Tabla 5.</b> Estadísticas descriptivas de las variables bioclimáticas, por región y en diferentes escenarios climáticos (a) y estadísticos de la prueba de Kruskal – Wallis y tamaño del efecto de las diferencias de las medias de rangos entre grupos.	30
<b>Tabla 6.</b> Estadísticos de la prueba no paramétrica de Wilcoxon para la comparación de grupos de variables Bioclimáticas ante escenario climáticos drásticos (RCP 4.5) y moderados (RCP 8.5) al 2050.	31

## ÍNDICE DE FIGURAS

	Página
<b>Figura 1.</b> Círculo de correlación (a), varianza explicada por cada componente (b) y contribución de las variables Bioclimáticas en el Análisis de Componentes Principales (c), realizado para la regionalización de las selvas del sureste de México. _____	14
<b>Figura 2.</b> Ubicación del área de estudio en el contexto global (a), nacional (b) y regiones bioclimáticas (c) generadas a través de análisis de componentes principales. Círculos en negro representan los sitios de muestreo del INFyS. ____	15
<b>Figura 3.</b> Análisis de residuales de los modelos para predecir carbono total en las selvas del sureste de México: arriba región I, en medio región II y abajo región III. _____	18
<b>Figura 4.</b> Influencia de las variables bioclimáticas para predecir el carbono de las selvas del sureste de México. _____	20
<b>Figura 5.</b> Importancia de las variables en la predicción de carbono de las selvas del sureste de México, determinada a través de la prueba de jackknife, en la región I (a), II (b) y III (c). _____	22
<b>Figura 6.</b> Carbono total (tC ha <sup>-1</sup> ) estimado con variables bioclimáticas en las selvas del sureste de México. _____	24
<b>Figura 7.</b> Diferencias de carbono total (tC ha <sup>-1</sup> ) del 2050, con respecto al carbono actual, estimado con variables bioclimáticas en las selvas del sureste de México, en un escenario climático moderado, RCP 4.5 (arriba) y drástico, RCP 8.5 (abajo). _____	27
<b>Figura 8.</b> Comparación de grupos de las variables bioclimáticas en diferentes escenarios climáticos que estiman el carbono total en las selvas del sureste de México. Región I (arriba), región II (medio) y región III (abajo). Cajas en color azul representa precipitación, cajas en rojo representan temperatura. Líneas horizontales con el símbolo *, representan la significancia estadística según la prueba no paramétrica de Wilcoxon. _____	28

## RESUMEN

Las selvas, son los ecosistemas con más riqueza de especies, registran importantes almacenes de carbono y con ello, regulan el clima mundial; sin embargo, el cambio climático está afectado significativamente todos los ecosistemas del mundo. El objetivo de este estudio fue generar un modelo bioclimático para evaluar los efectos de dos escenarios climáticos (moderado y drástico) al 2050, sobre los almacenes de carbono total en las selvas del sureste de México. Los datos del carbono se obtuvieron del Inventario Nacional Forestal y de Suelos (INFyS) y las variables bioclimáticas (Bios) de Worldclim. El mejor set de predictores se obtuvo con la librería 'glmulti', que utiliza stepwise y algoritmo genético. Después, el modelo fue entrenado con el 80% de los datos y validado con el 20% restante, a través de Machine Learning (ML) con la librería 'caret' de R. Con el modelo generado, se realizaron predicciones e interpolaciones de carbono actual y al 2050. Mediante álgebra de rasters se identificaron las áreas con y sin cambios. Los estadísticos de ajuste y validación indican que el modelo generado no es aleatorio. Las variables bioclimáticas explican entre el 8% y el 18% del carbono total en las selvas. Las bios de precipitación son las de mayor importancia en el modelo (entre el 60 % y el 100 %). El modelo bioclimático predice que el 38 % de la superficie de las selvas del sureste de México se podría mantener sin cambios, 44 % podría mostrar ganancias de carbono y 25 % sufriría pérdidas. La tasa de decremento de carbono (37 %) es casi el doble (21 %) que la tasa de incremento. Los cambios en los almacenes de carbono debidos al cambio climático obedecen a un decremento promedio del 17 % en precipitación y un incremento de entre 0.92 y 1.29 °C (Bio 11) en algunos sitios. En conclusión, las selvas del sureste de México podrían ser altamente vulnerables al cambio climático ante cualquier escenario.

**Palabras Clave:** Aprendizaje de Máquinas, Bioclimáticas, Cambio Climático, Carbono, México, Selvas.

## SUMMARY

Rainforests, also known as "selvas" in Spanish, are the most species-rich ecosystems on Earth and play a crucial role in regulating the global climate by storing important carbon reserves, however, climate change is significantly affecting all ecosystems worldwide. The objective of this study was to generate a bioclimatic model to evaluate the effects of two climate scenarios (moderate and drastic) by 2050 on the total carbon stores in the southeastern rainforests of Mexico. The carbon data was obtained from the National Forest and Soil Inventory (INFyS), and the bioclimatic variables (Bios) were obtained from Worldclim. The best set of predictors was obtained using the 'glmulti' library, which uses stepwise and genetic algorithms. Then, the model was trained with 80 % of the data and validated with the remaining 20 % through Machine Learning (ML) using the 'caret' library in R. With the generated model, predictions and interpolations of current and 2050 carbon were made. Using raster algebra, areas with and without changes were identified. The adjustment and validation statistics indicate that the generated model is not random. Bioclimatic variables explain between 8 % and 18 % of the total carbon in the southeastern rainforests. Precipitation variables (Bios) are the most important in the model (between 60 % and 100 %). The bioclimatic model predicts that 38 % of the surface of southeastern rainforests of Mexico could remain unchanged, 44 % could show carbon gains and 25 % would suffer losses. The carbon decrement rate (37 %) is almost double (21 %) the increment rate. Changes in carbon stocks due to climate change are related to an average 17 % decrease in precipitation and an increase between 0.92 and 1.29 °C (Bio 11) in some locations. In conclusion, southeastern rainforests of Mexico could be highly vulnerable to climate change under any scenario.

**Key words:** Machine Learning, Bioclimatic, Climate change, Carbon, Mexico, Rainforests.

## 1. INTRODUCCIÓN

El cambio climático representa un serio problema para los ecosistemas terrestres, problema que recae en la alteración de las variables climáticas (IPCC, 2022). Se espera un incremento de temperatura media global de 1.5 °C para los próximos 30 años (IPCC, 2019). Ante esto, los almacenes y secuestro del carbono en estos últimos años, han sufrido pérdidas por más de 7 mil toneladas de CO<sub>2</sub> al año en toda la vegetación mundial (UNESCO et al., 2023).

Los bosques tropicales representan 45 % de los bosques del mundo (FAO, 2019), y almacenan alrededor del 42 % del carbono fijado a nivel global; por lo que desempeñan un papel crucial en el ciclo global del carbono y en la mitigación de los efectos invernadero (Granados, 2007). México posee 30 millones de hectáreas de superficie tropical (21.8 % de la superficie nacional), por lo que se estima, almacenes de más de 45 tC ha<sup>-1</sup> (CONAFOR, 2019). No obstante, los bosques tropicales se consideran vulnerables al cambio climático, ante el incremento de la temperatura y disminución de la precipitación (IPCC, 2022).

Para México, la estimación de la biomasa en selvas para 2014 registra cerca de 49.2 tC ha<sup>-1</sup>, con decesos de 3.2 tC ha<sup>-1</sup> para 2018 y aumento de aproximadamente 1 tC ha<sup>-1</sup> en 2020 .(Cartus et al., 2014; Urbazaev et al., 2018; SNMF, 2023). Bajo esta premisa, el carbono total de 2020 en selvas mexicanas se encuentra cerca de 47 tC ha<sup>-1</sup>, distribuida en 32.7 y 14.3 tC ha<sup>-1</sup> en selvas altas, medianas y selvas baja (SNMF, 2023). Dicha información será de utilidad para poder conocer el carbono total actual y futuro, áreas críticas con decesos importantes del carbono total, donde enfocar esfuerzos para conservación de las selvas entre otros.

Al usar modelos de predicción, dichos modelos pueden ser útiles para estimar el crecimiento de los árboles y la biomasa forestal, lo que a su vez permite estimar la cantidad de carbono que se almacena en el bosque a partir de variables ambientales como la temperatura y la humedad (Hao et al., 2020; Krammer et al., 2010).

Se ha demostrado que las variables climáticas, pueden predecir la biomasa y el carbono en diferentes ecosistemas terrestres (Khan et al., 2019; Paroshy et al., (2021; He et al., 2022), por ejemplo, Epstein et al. (1997), Burbano (2018) y FAO, (2019) demuestran que la temperatura es un buen predictor en modelos de predicción de carbono. Otros autores (Hernández-Stefanoni et al., 2021) indican que la precipitación puede predecir adecuadamente la biomasa. Estudios de este tipo, han sido desarrollados en bosques tropicales y subtropicales (Mathews-Saldaña 2012; He et al., 2022; Li et al., 2022) algunos de ellos (Ruíz-Corral et al., 2016; Sun et al., 2016). Vieilledent et al., 2016; Li et al., 2022) revelan un panorama poco favorable para los bosques tropicales, con pérdidas de entre 15 y 32 % ante un incremento de entre 0.5 y 1 °C.

Para determinar los efectos del clima sobre los almacenes de carbono, es necesario utilizar variables climáticas, no solo promedios o totales, sino considerar la variabilidad anual e interanual de la región. En este sentido, desde hace más de 35 años, Busby (1986) desarrolló 19 variables bioclimáticas derivadas de precipitación y temperatura que consideran este efecto. No obstante, los predictores deben ser cuidadosamente elegidos (Calcagno, 2020) y el modelo validado, para asegurar estimaciones reales de los almacenes de carbono (Hastie et al., 2009; Krammer et al., 2010; Hao et al., 2020). Aunado a lo anterior, se han mejorado los modelos de circulación general, MCG (Ficks y Hijmans 2017), lo que permite conocer las líneas evolutivas del clima futuro en diferentes escenarios o trayectorias de concentración de CO<sub>2</sub> (rcp's) (Ruíz-Corral et al., 2016; Pérez, 2019), con ello, permitir evaluar los efectos del clima futuro sobre los almacenes de carbono.

### **1.1. OBJETIVO GENERAL**

Generar un modelo para predecir carbono total las selvas del sureste de México, con base en variables bioclimáticas y bajo escenarios de cambio climático.

### **1.2. OBJETIVOS ESPECÍFICOS**

Identificar las variables bioclimáticas que predicen el carbono total en selvas del sureste de México y cuantificar sus cambios en diferentes escenarios de cambio climático al 2050.

Desarrollar y validar un modelo para predecir el carbono total en selvas del sureste de México utilizando variables bioclimáticas, ante un escenario climático moderado (RCP 4.5) y drástico (RCP 8.5) al 2050.

Identificar las tasas de cambio del carbono total en selvas del sureste de México ante un escenario climático moderado (rcp 4.5) y drástico (rcp 8.5) al 2050.

### **1.3. HIPÓTESIS**

El carbono total en selvas del sureste de México se puede predecir utilizando un modelo que incorpora variables bioclimáticas y considera los efectos del cambio climático.

Cualquier escenario climático, drástico o moderado al 2050 afecta los almacenes de carbono total de las selvas de mexicanas.

## **2. REVISIÓN DE LITERATURA**

### **2.1. Inventario Nacional Forestal y de Suelos (INFyS)**

El Inventario Nacional Forestal y de Suelos (INFyS) es un instrumento técnico que contempla información actualizada sobre la condición, cuantificación y ubicación de los recursos forestales del país que inició actividades en 2004 con registros de 81,665 sitios de muestreo de la vegetación del país (CONAFOR, 2009).

Dentro de sus registros, se contempla el registro de información general, tal como: especies de los árboles, arbustos y hierbas, comunidad vegetal, tipo de vegetación y la clasificación del tipo de vegetación; asimismo, considera también la medición de datos dasométricos que permitan la estimación del volumen, densidad del arbolado, cobertura, edad, índices de incremento, niveles de disturbios, repoblación y la cuantificación de la biomasa, y captura de carbono (CONAFOR, 2009).

### **2.2. Captura de carbono**

La captura de carbono es un concepto considerado dentro del sector ambiental, como un importante servicio que genera procesos de separación del CO<sub>2</sub> del ambiente, los cuales consisten en tres fases importantes: captura, transporte y almacenamiento del CO<sub>2</sub>; con capacidad de disminuir los actuales niveles de gases de efecto invernadero, por lo que su relevancia recae en el establecimiento y conservación de los recursos naturales (Montoya et al., 1998; Arribas, 2013). La captura de carbono se encuentra estrechamente relacionada con las funciones ecológicas de los ecosistemas, que se enfoca principalmente en la captura terrestre del ciclo de carbono (Vargas-Mena & Yañez, 2004).

### **2.3. Cambio Climático**

Existen diversos conceptos para referirse al cambio climático, el común refiere a la noción de la alteración paulatina de la atmósfera por actividades humanas; en ese sentido, el Panel Intergubernamental sobre Cambio Climático (IPCC) de la Organización de las Naciones Unidas, define al cambio climático como: la modificación del clima en un periodo de tiempo indefinido, influenciado por la naturaleza o actividades humanas (IPCC, 2022). Con esta premisa, el impacto del cambio climático se asociará con sucesos hidrometeorológicos extremos, que tendrán efectos severos en las zonas costeras, áreas inundables y laderas de montaña (Zamora, 2015).

El IPCC (2022) estima un aumento de la temperatura media global de 1.5 °C para los próximos veinte años, provocando diversos escenarios drásticos por lo que es necesario establecer estrategias a futuro en el combate y/o adaptación al cambio climático; para ello es necesario la participación de la población, el manejo de ecosistemas con énfasis en la resiliencia y la reducción de vulnerabilidad al cambio climático y atender necesidades de subsistencia de las comunidades (Zamora, 2015).

### **2.4. Modelos de Circulación General**

La comprensión acerca de la modificación del clima permitirá visualizar y realizar estimaciones de proyecciones climáticas, para emplear como herramienta básica los modelos de circulación general, caracteriza que emplean algoritmos matemáticos para la simulación del sistema climático de la tierra, los cuales describen tres líneas evolutivas de las condiciones climáticas, las cuales relacionan con aspectos socioeconómicos, emisiones de gases de efecto invernadero y aerosoles asociados (Pérez, 2019).

Existen un sinnúmero de MCG, empleados en la proyección del clima para el futuro, tales como: CCSM4 (Community Climate, System Model versión 4), HadGEM2-AO

(configuración del modelo HadGEM2) y MIROC5 (Modelo de investigación interdisciplinaria sobre el clima, tomando como base a MIROC3.2); el modelo CCSM4 o modelo del sistema climático comunitario, es un modelo climático creado en 1983 para simular el sistema climático de la Tierra, disponible de manera gratuita para la comunidad científica; compuesto por cinco modelos separados que se asemejan a la atmósfera, océano, tierra, hielo terrestre y el hielo del mar (Danabasoglu et al., 2012). A diferencia del modelo CCSM4, HadGem2-AO, además de ser una simulación atmosférica, contempla componentes del sistema terrestre, tales como ciclo de carbono terrestre, oceánico y la química troposférica, con consideraciones ambientales en la vegetación terrestre y carbono representados de forma dinámica (TRIFFID), simulado la cobertura arbórea y balance de carbono de cinco tipos distintos de vegetación (Collins et al., 2011).

MIROC5 es un modelo de circulación general que emplea tres distintos modelos de componentes: modelo de componentes oceánicos del CCSR, modelo de hielo marino y modelo terrestre que incluyen los modelos de ríos.; dicho modelo fue creado por el Centro de Investigación del Sistema Climático (CCSR), Universidad de Tokio, Instituto de Estudios Ambientales (NIES) y la Agencia japonesa para la ciencia y tecnología de la tierra (Watanabe et al., 2010)

La comprensión acerca de la modificación del clima, permitirá visualizar y realizar estimaciones de proyecciones climáticas al emplear algoritmos matemáticos para la simulación del sistema climático de la tierra, que relacionan aspectos socioeconómicos, emisiones de gases de efecto invernadero y aerosoles asociados, para ello es necesario usar los modelos de circulación general (Pérez, 2019).

## **2.5. Escenarios de cambio climático**

Los escenarios de cambio climático son una representación plausible y resumida del clima futuro, con bases en datos meteorológicos actuales y pasados (IPCC, 2019). Dichos escenarios describen la afectación de los balances de radiación respecto a los gases de efecto invernadero (GEI), considerando parámetros relacionados con el suelo y la cubierta de la tierra y para ello el IPCC (2019) definió cuatro escenarios de emisión caracterizados por el forzamiento radiativo total para un año en específico, lo cual permite saber el nivel de cambios en la composición de la atmósfera, además de los niveles de aporte de entrada y salida de radiación en watts metro<sup>-2</sup> ( $W m^{-2}$ ) en diferentes cantidades de gases activos radiativos (Moss et al., 2010).

Las trayectorias 2.6 RCP comprenden un escenario donde se asume emisiones globales anuales de GEI de  $\sim 3 W m^{-2}$ , con valores máximos entre 2010 a 2020, con tendencia a disminuir en los años venideros, con esfuerzos en mitigación que conducen a un nivel de forzamiento muy bajo (Moss et al., 2010; IPCC, 2019).

Tanto el RCP 4.5 y 6.5 son referidos como escenarios de estabilización, donde el RCP 4.5 refiere a forzamientos radiativos de  $\sim 4.5 W m^{-2}$ , con valores máximos al 2040 para posteriormente disminuir, mientras que para el RCP 6.5 sus valores máximos serán para 2080 y a partir de ese punto habrá una reducción (Moss et al., 2010; IPCC, 2019).

Para el RCP 8.5 el forzamiento radiativo considerado, es de  $\sim 8.5 W m^{-2}$ , con emisiones que aumentarán durante el próximo siglo (Moss et al., 2010; IPCC, 2019).

## **2.6. Variables Climáticas**

Las variables climáticas son medidas cuantitativas que describen las condiciones meteorológicas en una determinada ubicación y período de tiempo (Busby, 1986). Estas variables incluyen, entre otras, la temperatura del aire, la precipitación, la humedad relativa, la velocidad y dirección del viento, la radiación solar y la presión atmosférica (Hijmans et al., 2005). Los valores de esas variables se basan en

conjuntos de observaciones de estaciones meteorológicas y modelos climáticos, que proporcionan información detallada sobre las variables climáticas a una resolución espacial de 1 km y 30 segundos (Fick & Hijmans, 2017; Hijmans et al., 2005).

## **2.7. Modelos de Predicción**

Los modelos de predicción son instrumentos estadísticos que funcionan base a variables de interés que evalúan los niveles de afectación de presencia o ausencia, logrando explicar de manera lógica y matemática dicha relación, contando con variables dependientes e independientes, siguiendo una estructura de ponderado x predictor en la mayoría de estudios:  $\text{resultado} = \text{ponderación}_1 \times \text{predictor}_1 + \text{ponderación}_2 \times \text{predictor}_2 + \dots \text{ponderación}_n \times \text{predictor}_n$  (Núñez et al., 2011).

Es necesario la exploración de diversos modelos que obliguen una elección del mejor modelo que mejor se relacione con la realidad y contemple aspectos teóricos que ayude a aplicar de manera adecuada los modelos estadísticos (Guerra et al., 2003).

Guerra et al. (2003) y Núñez et al. (2011) consideran parámetros explicativos y dinámicos en la selección de modelos estadísticos de predicción debe, tales como: método de ajuste, error estándar de los estimadores, coeficientes de variación de los estimadores, límites de confianza, test de redundancia de los parámetros, análisis de varianza relacionado con el modelo, coeficientes de determinación ( $R^2$  y  $R^2$  ajustada), error estándar de estimación, análisis de efecto de transformación en el modelo, diagnóstico y tratamiento de la multicolinealidad, validación de las predicciones y análisis residuales.

## **2.8. Influencia del Cambio Climático en la captura de Carbono**

Con el aumento de las emisiones de GEI, la vulnerabilidad de los bosques respecto al cambio climático se ha ido evidenciando, reflejado en la modificación de absorción del carbono, lo que compromete la captura y almacenamiento de los principales ecosistemas mediadores de carbono (bosques tropicales y templados), donde actividades como la deforestación y el cambio de uso del suelo juegan un papel importante (Benjamín & Masera, 2001).

Actualmente, la alteración de las variables climáticas respecto al cambio climático afecta negativamente a la captura de carbono, con una disminución en los registros de captura de carbono (Vieilledent et al., 2016).

La importancia de la captura del carbono recae en su influencia en los procesos de desarrollo de los ecosistemas, que forman parte de un ciclo entre los bosques, el carbono y la atmósfera, por lo que es necesario la protección, monitoreo y contribución de las tendencias de las diferentes reservas del carbono en los distintos ecosistemas en adaptación al cambio climático (Benjamín & Masera, 2001; Carroll & Ray, 2021).

Vieilledent et al. (2016) utilizaron modelos con variables bioclimáticas (temperatura y precipitación) para proyectar cambios en la distribución del carbono en los bosques de Madagascar bajo diferentes escenarios climáticos que indican la disminución en la cantidad de carbono almacenado en los bosques de la región, además de que las principales correlaciones encontradas en el estudio fue la cantidad de carbono almacenado en los bosques y la precipitación anual, donde áreas con mayores precipitaciones tienden a tener mayores niveles de carbono almacenado en los bosques (Vieilledent et al., 2016).

Además, dichos autores encuentran que la temperatura media anual también tuvo un impacto en la cantidad de carbono almacenado en los bosques, con menor carbono almacenado en áreas frías (Vieilledent et al., 2016). Los resultados a nivel general indican que la mayoría de las áreas de bosque en Madagascar experimentarán una disminución en el carbono almacenado debido al cambio climático, con una reducción promedio 15 % en el carbono almacenado en 2080 en comparación con las condiciones actuales Vieilledent et al. (2016).

Sun et al. (2016) al evaluar la proyección del stock del carbono para el Tíbet, encuentran resultados similares a los de Vieilledent et al. (2016). Sun et al. (2016) reportaron que la precipitación tuvo influencias positivas en la acumulación de carbono, en contraste, la temperatura anual tuvo una influencia negativa, encontrando que áreas de mayor altitud y áreas más húmedas - cálidas hay una mayor variación en los stocks de carbono, dado que la temperatura juega un papel importante en el desarrollo del árbol (Li et al., 2022).

Para 2050 en el Tíbet, se espera una disminución del 32 %, este resultado es alarmante, ya que, los bosques del Tíbet son importantes sumideros de carbono y su degradación puede contribuir significativamente al cambio climático; pues la región del Tíbet es una zona de alta biodiversidad y los bosques albergan una gran cantidad de especies endémicas (Sun et al., 2016).

Contrario a estos dos anteriores estudios, Li et al. (2022) al estimar la biomasa aérea forestal, mostraron que la temperatura es la variable climática más importante para la estimación de la biomasa aérea forestal, seguida de la precipitación. Además, se encontraron que la biomasa aérea forestal está fuertemente relacionada con la cobertura del suelo y la topografía, lo que indica que estas variables también deben tenerse en cuenta en la estimación de la biomasa forestal.

Respecto a los dos RCP sometidos, en el escenario RCP 2.6, la disminución será menor (alrededor del 5 %) en comparación con el escenario RCP 8.5, donde la disminución puede ser de hasta el 25 % de la biomasa aérea (Li et al., 2022).

### **3. MATERIALES Y MÉTODOS**

#### **3.1. Área de estudio**

El estudio se realizó en las selvas del sureste de México (Rzedowski, 2006), ubicadas entre las coordenadas 97° y 87° longitud Oeste y 16° a 22° latitud Norte, compuesta principalmente por bosques tropicales caducifolios, subcaducifolios y perennifolios. El clima es tipo Aw (cálidos subhúmedos) y Am (cálidos húmedos) (Trejo-Vázquez, 1999) registrando precipitaciones de 600 a 4000 mm (CONABIO, 2023) con temperaturas entre los 22 y 26 °C (Trejo, 1999; Avendaño et al., 2021).

#### **3.2. Carbono total**

Los datos de carbono total empleados para este estudio fueron los reportados por (Arasa-Gisbert, 2017). La información es proveniente de muestreos sistemáticos del INFyS (2009 - 2021). El cálculo de carbono aéreo, subterráneo y por sumatoria de ambos, el carbono total, en cada sitio, se obtuvo en base a las ecuaciones alométricas publicadas, basadas en diámetro normal y altura total (Arasa-Gisbert, 2017).

#### **3.3. Variables Bioclimáticas**

Las variables bioclimáticas actuales, empleadas para la predicción del carbono total, fueron desarrolladas por Ficks y Hijmans (2017), descargadas de <https://www.worldclim.org/data/worldclim21.html> (Tabla 1). Las variables son derivadas de promedios de temperatura y precipitación de 47, 554 estaciones meteorológicas de 194 países del periodo de 1950 al 2000 (Hijmans et al., 2005), siendo un total de 19 capas digitales a una resolución de 30 segundos de arco (0.86 km<sup>2</sup>).

**Tabla 1.** Variables bioclimáticas utilizadas en la construcción del modelo de predicción de carbono total

<b>Variable</b>	<b>Descripción</b>
Bio 1	Temperatura Promedio Anual (°C)
Bio 2	Rango Diurno Promedio (°C)
Bio 3	Isotermalidad (°C)
Bio 4	Estacionalidad de la Temperatura (C.V.)
Bio 5	Temperatura Máxima del Mes más Cálido (°C)
Bio 6	Temperatura Mínima del Mes más Frío (°C)
Bio 7	Rango Anual de Temperatura (°C)
Bio 8	Temperatura Promedio del Trimestre más Lluvioso (°C)
Bio 9	Temperatura Promedio del Trimestre más Seco (°C)
Bio 10	Temperatura Promedio del Trimestre más Cálido (°C)
Bio 11	Temperatura Promedio del Trimestre más Frío (°C)
Bio 12	Precipitación Anual (mm)
Bio 13	Precipitación del Mes más Lluvioso (mm)
Bio 14	Precipitación del Mes más Seco (mm)
Bio 15	Estacionalidad de la Precipitación (C.V.)
Bio 16	Precipitación del Trimestre más Lluvioso (mm)
Bio 17	Precipitación del Trimestre más Seco (mm)
Bio 18	Precipitación del Trimestre más Cálido (mm)
Bio 19	Precipitación del Trimestre más Frío (mm)

### **3.4. Limpieza de los datos y regionalización bioclimática del área de estudio**

La limpieza de los datos, se realizó a través de análisis de componentes principales (ACP) en las librerías “FactoMineR” (Lê et al., 2008), “Factoshiny” y “factoextra” (Kassambara & Mundt, 2020; Vaissie et al., 2021) para ello, a cada sitio, se extrajeron los valores de las Bios y altitud (<https://www.inegi.org.mx/app/geo2/elevacionesmex/>), para su análisis en forma estandarizada, generando una elipse al 95 %, los datos (sitios) fuera de ella, fueron

eliminados. En una exploración preliminar se observó alta variabilidad climática en el área de estudio, por lo que se procedió a regionalizar para mejorar las predicciones del carbono total. La regionalización se derivó del ACP, al utilizar los valores de la primera dimensión, y generar isolíneas en un SIG, en valores 3.

### **3.5. Generación y validación de los modelos**

Para la selección del mejor conjunto de predictores del carbono total en cada region, se utilizaron tres procedimientos; stepwise, algoritmo exhaustivo y algoritmo genético, con apoyo de la librería “glmulti” (Calcagno, 2020). Se probaron distintas transformaciones de las variables, tales como: logarítmica, raíz, exponencial y en caso de ser necesario, transformación Box-Cox.

Para generar el modelo en cada región, los datos fueron separados en dos conjuntos de “entrenamiento” y “validación”; para ello, se utilizó la librería “caret” (Kuhn, 2022) la cual aleatoriza por cuantiles. Se utilizó esta misma librería, el modelo fue entrenado con 80 % de los datos, a través de machine learning (ML), con la técnica de bootstrap (25 repeticiones). De cada modelo generado, se verificó el cumplimiento de: normalidad (Kolmogorov-Smirnov), homogeneidad (Breusch-Pagan), independencia (Durbin-Watson) y no multicolinealidad (factor de inflación de varianza). La validación del modelo (20 %), se realizó usando cuatro métodos: a) Leave One Out Cross-Validation, b) k-fold validation (10 folds), c) repeated CV (10 folds, 10 repeticiones) y d) Validación cruzada (Bootstrap, 100 repeticiones), que calculó el coeficiente de determinación ( $R^2$ ), error cuadrático medio (RMSE) y el error medio absoluto (MAE).

### **3.6. Predicciones de carbono actual**

Con el modelo generado en cada región, se realizaron predicciones de carbono total, en el área de estudio (ecorregión), para después realizar una interpolación en ArcMap, con uso de la técnica de krigging.

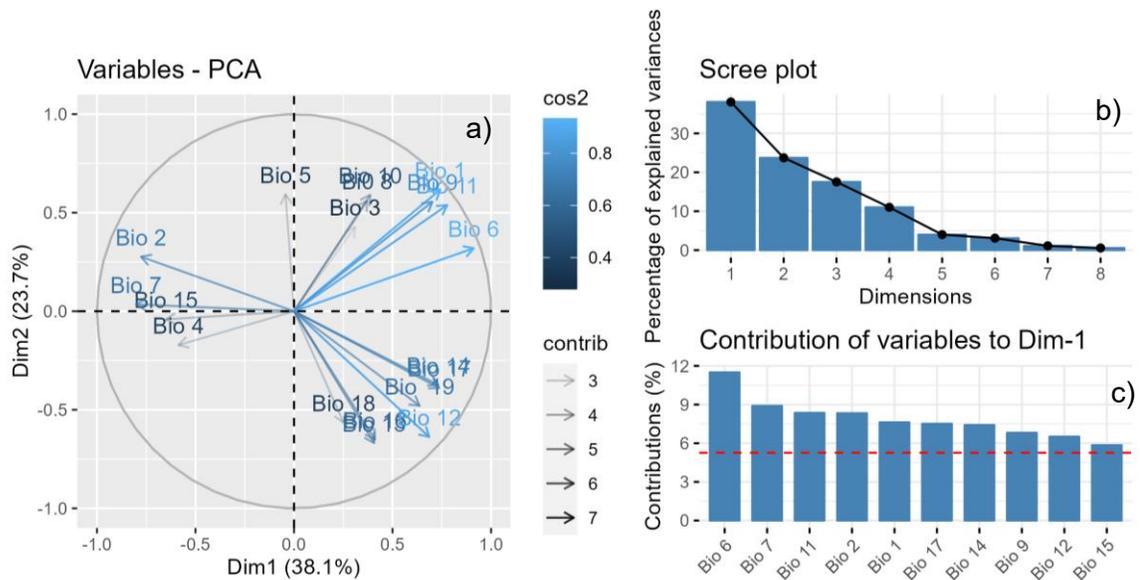
### **3.7. Escenarios de carbono total al 2050**

Para predecir el carbono total al 2050 se utilizaron tres distintos modelos de circulación general, MCG (CCSM4, HadGEM-AO y MIROC5) obtenidos de <https://www.worldclim.org/data/cmip6/cmip6climate.html> del periodo de 2041 - 2060 (Taylor et al., 2012). Las bios elegidas por el algoritmo, en cada región, fueron descargadas de cada MCG y promediadas. Después se obtuvieron los valores nuevamente a cada sitio y con ello, se aplicó la ecuación de cada región para hacer las predicciones de carbono total al 2050. En este estudio, se evaluaron dos escenarios climáticos: moderado, RCP 45 ( $\sim 4.5 \text{ W m}^{-2}$ ) y drástico, RCP 85 ( $\sim 8.5 \text{ W m}^{-2}$ ).

Las predicciones de carbono al 2050, en cada región y de cada escenario climático, fueron interpoladas en ArcMap con la técnica de krigging y por álgebra de rasters se calcularon las diferencias de carbono con respecto al escenario actual.

#### 4. RESULTADOS Y DISCUSIÓN

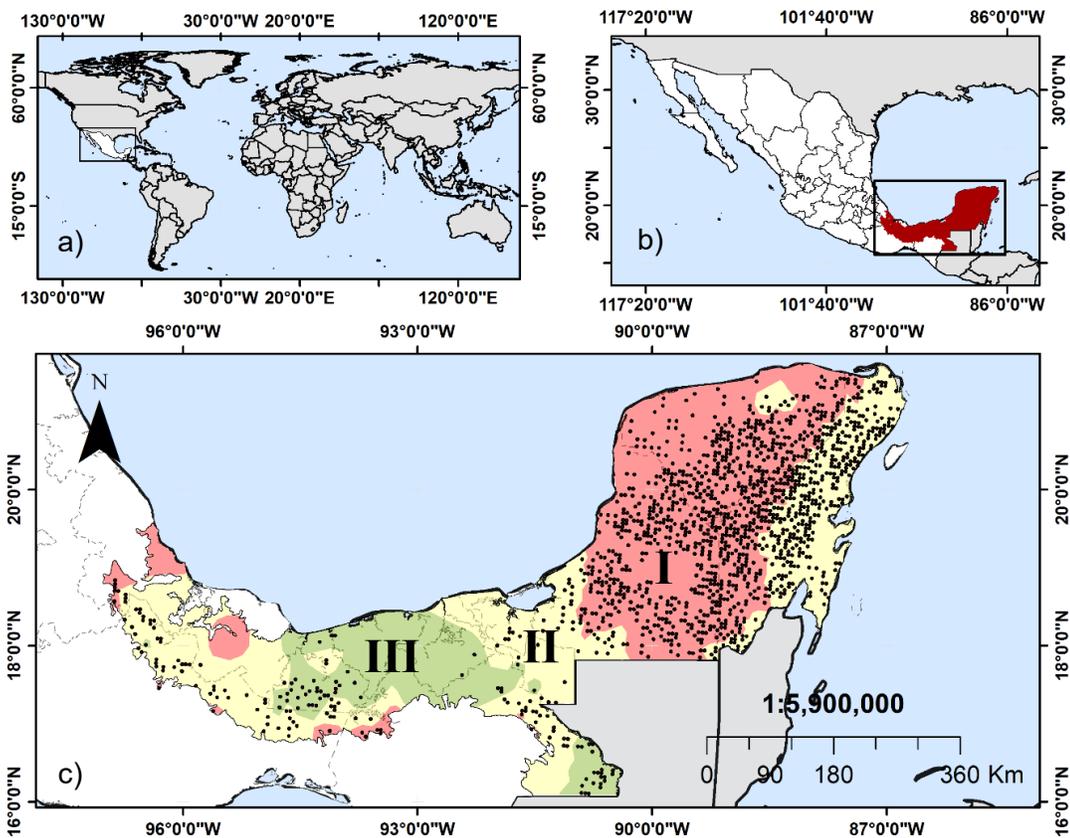
Los resultados muestran que los componentes 1 y 2 del ACP, explicaron 61.8 % de la varianza (38.8 y 23.1 % respectivamente), conformado tres grupos de variables bioclimáticas (Fig. 1a), que disminuye gradualmente la varianza explicada en cada componente (Fig. 1b), con la variable de temperatura, Bio 6 (Temperatura Mínima del Mes más Frío), la de mayor contribución (11.8 %), seguida de Bio 7 (8.89 %) y Bio 11 (8.35 %), en la dimensión 1 (Fig. 1c).



**Figura 1.** Círculo de correlación (a), varianza explicada por cada componente (b) y contribución de las variables Bioclimáticas en el Análisis de Componentes Principales (c), realizado para la regionalización de las selvas del sureste de México.

Los eigenvalores de PCA 1 dieron origen a tres regiones bioclimáticas, denominadas I, II y III, con una superficie de 103,043, 94,986 y 36, 938 km<sup>2</sup> respectivamente (Figura 2c). De los 1,493 sitios registrados en selvas con 915, 496 y 62 para las regiones I, II y III. López-Díaz et al. (2022) generaron biozonas en referencia a sus variables Bioclimáticas en regiones áridas y semiáridas, en

contraste Ruíz-Corral et al. (2016), emplearon valores climáticos de 11 modelos de circulación general para generar biozonas en los diferentes ecosistemas de México.



**Figura 2.** Ubicación del área de estudio en el contexto global (a), nacional (b) y regiones bioclimáticas (c) generadas a través de análisis de componentes principales. Círculos en negro representan los sitios de muestreo del INFyS.

Los tres algoritmos seleccionaron las mismas variables bioclimáticas (de precipitación para la región I; y de precipitación y temperatura en las regiones II y III), todas estadísticamente significativas (Tabla 1). Khan et al. (2019) en su estudio de predicción de carbono de la biomasa del tallo en especies de *Larix gmelinii* (Rupr.) Rupr. y *Betula platyphylla* Sukaczev en las montañas de Mongolia, las variables de temperatura mínima, máxima y media y precipitación presentaron una  $R^2$  del 0.67 para la precipitación, 0.64 en la temperatura máxima, 0.50 para la mínima y 0.31 para las temperaturas medias. En este estudio, entre 8 % (Región I)

y 18 % (Región III) del carbono total en las selvas es explicado en su totalidad por variables bioclimáticas.

En bosques/selvas, la relación entre precipitación y biomasa total, muestran relaciones lineales y no lineales ( $R^2 > 0.90$ ), con valores constantes en caso que la precipitación y/o la biomasa aumente (Paz Pellat & Díaz-Solís, 2018). Algunos autores (Epstein et al., 1997; Burbano, 2018; FAO, 2019) encontraron que la temperatura fue una variable con importante influencia en la biomasa y/o carbono total, con correlaciones altas ( $R^2 > 0.50$ ) en los ecosistemas (incluidos bosques tropicales) y suelos del mundo.

El supuesto de normalidad ( $p > 0.05$ ) solo se cumplió en la región III (Tabla 2, Figura 3), no así para las regiones I y II; no obstante, por la teoría de los grandes números, que expresa que “a medida que el tamaño de la muestra aumenta, la media de la muestra se acerca a la media de la población”, denotada por:  $(\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n X_i = \mu)$ , asegura que el valor del estimador se aproxime al parámetro. El supuesto de homogeneidad de varianza ( $p > 0.05$ ) fue cumplido en los tres modelos (Tabla 2 y Figura 3). Los residuales de los modelos en la región I y II fueron dependientes ( $p < 0.05$ ); es decir; existió una correlación espacial entre los sitios del INFyS, pero, no se eliminaron lo cual evitó disminuir el tamaño de muestra. Sin embargo, al no tratarse de series de tiempo, el modelo fue adecuado.

Las variables predictivas en el modelo de la región III presentaron correlaciones de nulas a moderadas ( $5 > VIF < 10$ ), en el resto de las regiones, las variables predictivas se presentan independientes (Fig. 3). Los modelos en cada región, garantizaron lo estipulado por Montgomery et al. (2012), eficiencia y robustez en las predicciones.

Los modelos que predijeron el carbono total en cada región de las selvas del sureste de México quedaron de la siguiente manera:

Región I:  $Ln(Y) = \beta_0 + (\beta_1 * \text{Bio 15}) + (\beta_2 * \text{Bio 17}) + (\beta_3 * \text{Bio 12})$  Ec. (1)

Región II:  $(Y^{0.541}) = \beta_0 + (\beta_1 * \text{Bio 4}) + (\beta_2 * \text{Bio 18}) + (\beta_3 * \text{Bio 19})$  Ec. (2)

Región III:  $(Y^{0.097}) = \beta_0 + (\beta_1 * \text{Bio 3}) + (\beta_2 * \text{Bio 11}) + (\beta_3 * \text{Bio 18})$  Ec. (3)

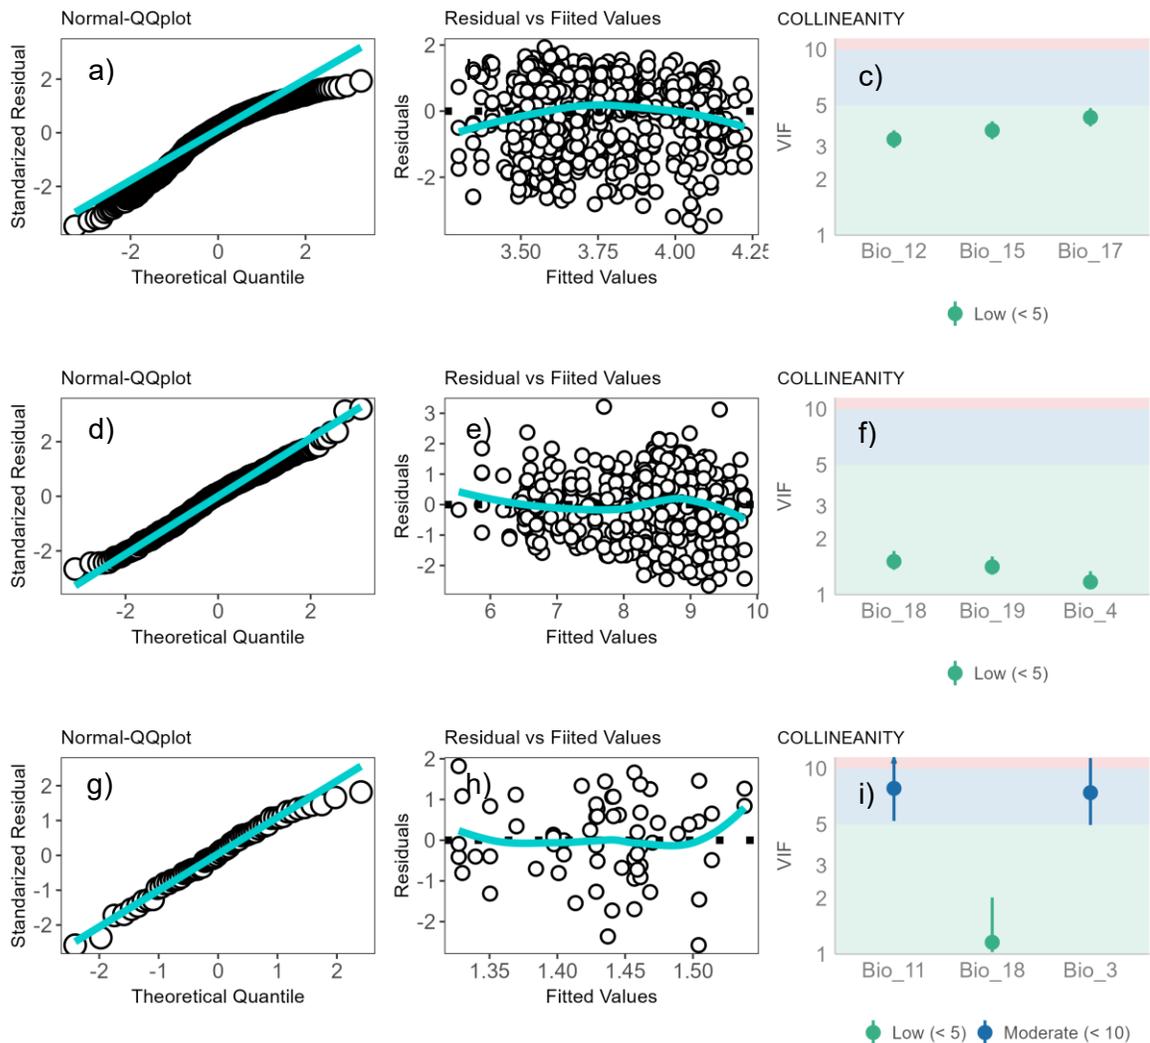
Tanto Zárate-Razo et al. (2013) y Cuenca et al. (2014) hacen uso de la transformación logarítmica en sus trabajos de predicción del carbono, mientras que las transformaciones Box Cox, están como buenas alternativas en trabajos de predicción dasonómicos (Fischer, 2016). Por lo que el uso de dichas transformaciones se justificó

**Tabla 2.** Coeficientes de regresión y estadísticas de ajuste de los modelos para predecir el carbono total en tres regiones de selvas del sureste de México.

Región	Coef.	Est.	S.E	T- Value	Pr(> t )	R <sup>2</sup>	KS	BP	D-W
<b>I</b> (n = 915)	$\beta_0$	6.427	0.337	19.076	< 2e-16	0.08	0.001	0.306	< 0.01
	$\beta_1$ (Bio 15)	-0.048	0.006	-8.707	< 2e-16				
	$\beta_2$ (Bio 17)	-0.022	0.002	-9.293	< 2e-16				
	$\beta_3$ (Bio 12)	0.002	0	7.322	5.35E-13				
<b>II</b> (n = 496)	$\beta_0$	13.749	1.087	12.65	< 2e-16	0.10	0.013	0.144	< 0.01
	$\beta_1$ (Bio 4)	-0.042	0.006	-6.821	2.65E-11				
	$\beta_2$ (Bio 18)	0.008	0.002	4.541	7.06E-06				
	$\beta_3$ (Bio 19)	-0.006	0.002	-2.298	0.022				
<b>III</b> (n = 62)	$\beta_0$	2.137	7.03E-01	3.041	0.004	0.18	0.4	0.624	0.453
	$\beta_1$ (Bio 3)	0.03	1.02E-02	2.975	0.004				
	$\beta_2$ (Bio 11)	-0.106	5.30E-02	-2.01	0.049				
	$\beta_3$ (Bio 18)	0.0001	9.27E-05	-1.782	0.08				

Donde:  $\beta_0$ ,  $\beta_1$  y  $\beta_3$  = son los coeficientes de regresión. S.E = error estándar. R<sup>2</sup> = coeficiente de determinación. Los valores de las columnas KS, BP y D-W, representan el valor de p de la prueba de normalidad (Kolmogorov-Smirnov), homogeneidad de la varianza (Breusch Pagan) e independencia (Durbin Watson).

Al igual que Liu et al. (2013), su estudio en bosques tropicales y subtropicales, la relación entre las variables temperatura y precipitación con respecto al carbono de la biomasa fue de tipo lineal positivo, con valores de  $R^2$  inferiores a 25 %. De las variables bioclimáticas elegidas en las tres regiones, el 77.7 % correspondieron a precipitación y el resto a temperatura. Los resultados de este estudio demostraron que, no existe un patrón claro, ya que las variables bioclimáticas y el carbono total se correlaciono positiva y negativamente (Fig. 4).



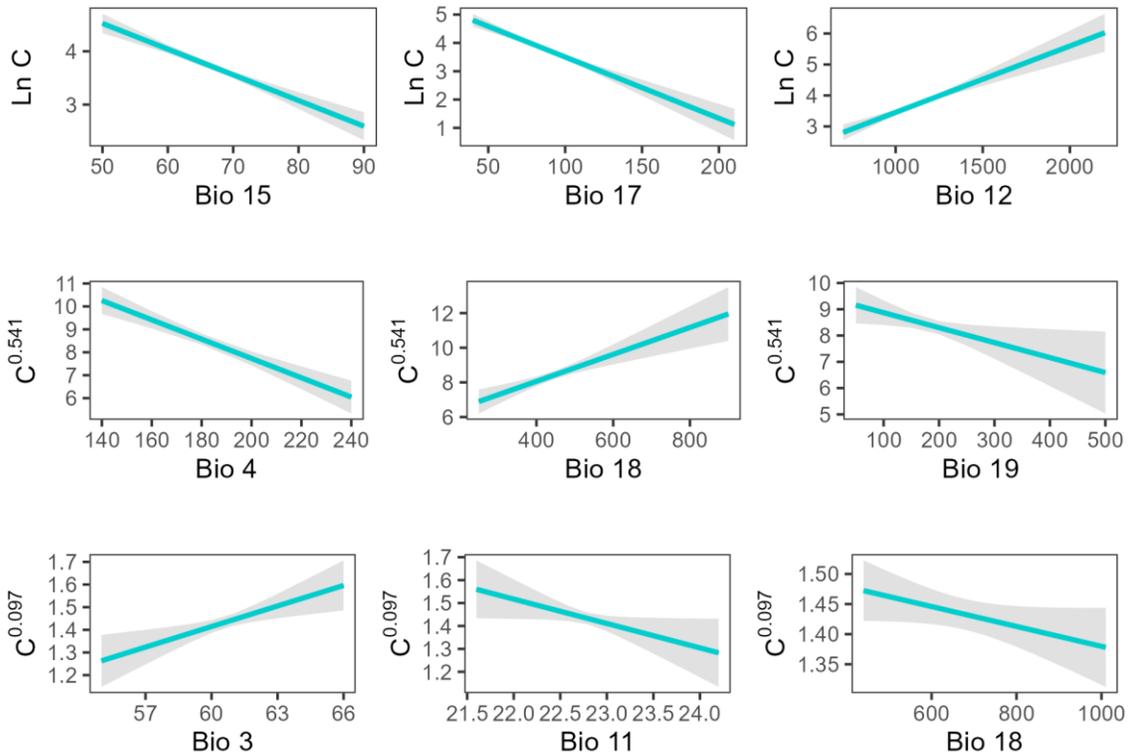
**Figura 3.** Análisis de residuales de los modelos para predecir carbono total en las selvas del sureste de México: arriba región I, en medio región II y abajo región III.

La regionalización bioclimática sirvió para eliminar la posible heteroscedasticidad en los modelos. Zhang et al. (2022), hicieron uso de un ajuste ponderado con variables de precipitación y temperatura para eliminar este efecto, en la predicción del carbono total en una plantación de coníferas. Para reducir los problemas de colinealidad en la cuantificación de la biomasa total y aérea en los bosques de China, He et al. (2022), hicieron uso de categorizar en tres distintos modelos.

Hernández-Stefanoni et al. (2021) demostraron que la evapotranspiración, el déficit hídrico y la precipitación pueden servir como buenos predictores de carbono total en selvas, explicando en promedio ( $R^2$ ) 29 %, con un RMSE de 33 y 38 %, la influencia de las variables climáticas con respecto al carbono fue de 8, 10 y 18 %.

Los intervalos de predicción de carbono total de este estudio fueron más estrechos en la región I y más amplios hacia la región III (Fig. 4). Estos resultados coinciden con lo establecido por Paroshy et al. (2021), a nivel mundial, ya que los autores reportaron correlaciones de almacenes de carbono en ocho tipos de biomas, entre ellos selvas tropicales, tanto positivas como negativas, con respecto a las variables de temperatura y precipitación, con  $R^2$  de 0.013 y 0.055, valores similares a este estudio.

Los resultados reportados por He et al. (2022), al incluir variables climáticas en sus modelos de predicción de biomasa aérea para plantaciones de alerces, disminuyeron la incertidumbre de los modelos, asimismo, reportaron que el porcentaje de influencia, ronda en 98 % (Luo et al., 2017; He et al., 2022).



**Figura 4.** Influencia de las variables bioclimáticas para predecir el carbono de las selvas del sureste de México.

Los resultados demostraron que si el modelo generado en las regiones I y II, se aplica a diferentes tamaños de muestra ( $100 - 50$ ), existen suficientes elementos para rechazar las hipótesis nulas  $H_0: \beta_j = 0$  ( $\alpha = 0.05$ ), de cada coeficiente de regresión de la correspondiente variable independiente ( $x_j$ ) y el ajuste ( $R^2$ ) sería similar (Tabla 3). En la región III, si  $n$  disminuye, los coeficientes de regresión serían estadísticamente significativos al 90 % de confiabilidad. El análisis anterior demuestra que el modelo generado en este estudio no es aleatorio.

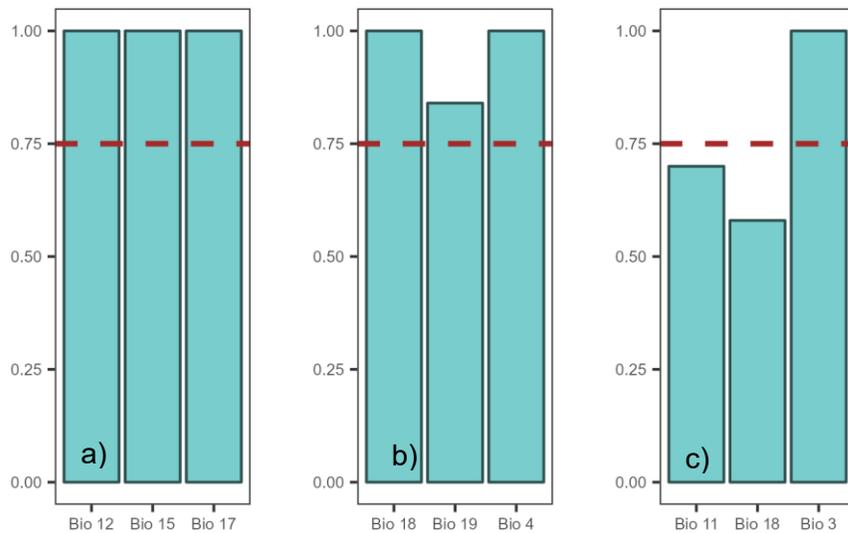
**Tabla 3.** Valores de probabilidad de los coeficientes de regresión en los modelos de las tres regiones, a diferentes tamaños de muestra.

Región	C.F.	Tamaño de muestra (%)						$\bar{x}$ Coef.	$\bar{x}$ de D.E
		100	90	80	70	60	50		
I	$\beta_0$	< 2e-16	< 2e-16	< 2e-16	< 2e-16	< 2e-16	< 2e-16	6.503	3.524
	$\beta_1$ (Bio 15)	< 2e-16	< 2e-16	1.13E-14	1.17E-15	5.11E-10	2.01E-11	-0.050	-1.446
	$\beta_2$ (Bio 17)	< 2e-16	< 2e-16	4.64E-16	< 2e-16	6.26E-11	7.33E-11	-0.022	-1.546
	$\beta_3$ (Bio 12)	5.35E-13	5.62E-13	5.91E-11	7.23E-13	1.12E-06	3.38E-06	0.002	1.221
	$R^2$	0.087	0.087	0.086	0.102	0.075	0.098		
II	$\beta_0$	< 2e-16	< 2e-16	< 2e-16	< 2e-16	< 2e-16	2.54E-13	13.741	1.318
	$\beta_1$ (Bio 4)	2.65E-11	5.49E-11	3.83E-10	1.34E-07	2.95E-05	2.29E-04	-0.040	0.007
	$\beta_2$ (Bio 18)	7.06E-06	2.92E-05	1.14E-04	3.92E-04	9.11E-03	1.22E-02	0.007	0.002
	$\beta_3$ (Bio 19)	0.022	4.24E-02	2.96E-02	1.24E-02	3.65E-02	0.124	-0.006	0.003
	$R^2$	0.100	0.109	0.107	0.097	0.068	0.053		
III	$\beta_0$	0.004	2.40E-02	7.21E-03	0.013	0.188	0.830	1.587	0.893
	$\beta_1$ (Bio 3)	0.004	0.0233	0.02458	0.036	0.626	0.763	0.019	0.013
	$\beta_2$ (Bio 11)	0.049	0.1702	0.102	0.141	0.912	0.327	-0.050	0.069
	$\beta_3$ (Bio 18)	0.080	0.087	0.04298	0.024	0.050	0.043	-2.13E-04	1.05E-04
	$R^2$	0.180	0.177	0.172	0.194	0.097	0.314		

C.F = Coeficientes,  $\bar{X}$  Coef = Promedio de los coeficientes,  $\bar{X}$  de D.E = Promedio de la desviación estándar.

Acorde a la prueba de jacknife, en las selvas, las tres variables predictivas (Bio 15, Bio 17 y Bio 12) en la región I, tuvieron la misma importancia (100 %). En la región II, Bio 18 y Bio 4 fueron las más importantes con 100 %. En la región III, Bio 3 representó el 100 % el resto, Bio 11 y Bio 18 no superan el 75 % (Figura 5). Con menor porcentaje de importancia que la región III, Mathews-Saldaña, (2012) en la estimación de biomasa en selvas, registró importancias con la temperatura de 7 % y de 10 a 54 % para la precipitación, mientras que Sun et al. (2021), en sus estudios de predicción de carbono aéreo en humedales costeros, registraron de 5 a 12 % de importancia de la temperatura media anual y precipitación, dicha importancia relativa de cada variable independiente se calculó con funciones de ponderación base a sus coeficientes de regresión.

De las 19 variables evaluadas por Li et al. (2022) en bosques subtropicales en la cuantificación de la biomasa aérea, tres de nuestras variables climáticas estuvieron entre sus seis primeras de variables con mayor importancia (Bio 18, 19 y 17), con las que se calculó la contribución fraccionaria y el número relativo de veces que se utiliza una característica en los árboles.



**Figura 5.** Importancia de las variables en la predicción de carbono de las selvas del sureste de México, determinada a través de la prueba de jackknife, en la región I (a), II (b) y III (c).

La validación de los modelos para predecir carbono total en las selvas de México, demostró, que independientemente del método, las predicciones que se realicen con datos que jamás vio el modelo) serán adecuadas, incluso mejor, ya que el valor de  $R^2$  (de validación/realístico) superó al coeficiente obtenido en el entrenamiento del modelo, en especial en la región III (Tabla 4). Snee, (1977) y Arboretti & Salmaso, (2003) mencionan que es indispensable el uso de los datos independientes para la validación de los modelos, acorde con lo hallado en este trabajo. A diferencia de Bennett et al. (2020) en la predicción de biomasa de los bosques y sabanas que solo usó cross-validation, en este estudio se utilizaron cuatro distintos métodos de validación.

**Tabla 4.** Validación de los modelos de predicción de carbono, de cada región en selvas del sureste de México.

Región	Validación	Set	n	R <sup>2</sup>	RMSE	MAE
I	(Cross-Validation)	Entrenamiento	915	0.08	0.69	0.49
		Validación	180	0.04	0.67	0.52
		Validación	180	0.19	0.57	0.52
		Validación	180	0.12	0.66	0.52
		Validación	180	0.06	0.67	0.52
II	(Cross-Validation)	Entrenamiento	496	0.10	2.69	1.93
		Validación	96	0.05	2.67	2.17
		Validación	96	0.29	2.17	2.16
		Validación	96	0.17	2.62	2.15
		Validación	96	0.08	2.68	2.19
III	(Cross-Validation)	Entrenamiento	62	0.18	0.22	0.07
		Validación	12	0.04	0.13	0.10
		Validación	12	0.18	0.10	0.10
		Validación	12	0.32	0.11	0.10
		Validación	12	0.37	0.16	0.14

Donde: LOOCV = Leave One Out Cross- Validation, Cross- Validation = K-fold validation, RMSE = Desviación Estándar de los valores residuales, MAE = Error Absoluto Medio y Modelo Fit = Modelo con datos originales.

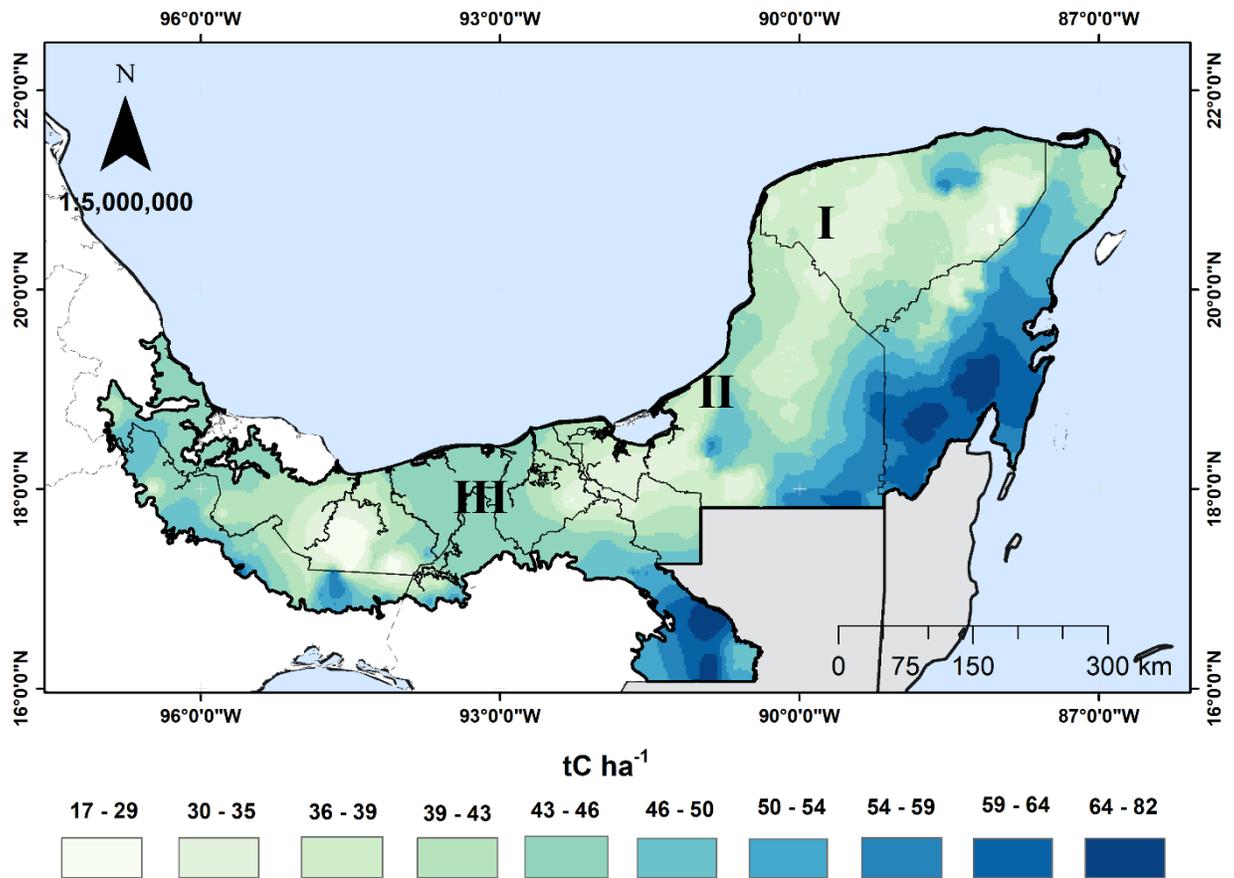
### Captura de carbono total

El carbono total estimado con variables bioclimáticas, varió desde 17.42 (región III) hasta 82.82 tC ha<sup>-1</sup> (región II), lo cual fue 32 tC ha<sup>-1</sup> menos que lo estimado por Hernández-Stefanoni (2021) en las selvas de México, lo cual se explica por el tipo de variables utilizadas (Pretzsch & Dieler, 2012; Fayolle et al., 2016), pues dichas ecuaciones fueron desarrolladas para especies y lugares específicos, lo cual arroja alta incertidumbre (Jenkins et al., 2003; Temesgen et al., 2015).

En promedio, la región II registró los mayores almacenes de carbono (50.96 tC ha<sup>-1</sup>), con rangos desde 17.42 hasta 67.00 tC ha<sup>-1</sup>, mientras que en la región I se

estiman  $43.93 \text{ tC ha}^{-1}$  (Fig.6). La parte sur de cada región registró los mayores almacenes de carbono, contrario a lo que ocurrió en la parte norte (Fig. 6).

Paz-Pellat et al. (2020) resaltan que desde el periodo 2004 - 2012 se registró una disminución del carbono de la biomasa aérea en los bosques tropicales de México, yendo desde  $66$  hasta  $48 \text{ Mg ha}^{-1}$ .



**Figura 6.** Carbono total ( $\text{tC ha}^{-1}$ ) estimado con variables bioclimáticas en las selvas del sureste de México.

La estimación del carbono total actual de este estudio, empata con lo reportado por Cartus et al. (2014) en los bosques y selvas de Yucatán y Campeche. Dichos autores indican que, en México, la biomasa aérea en bosques tropicales se mantiene con valores encima de las  $50 \text{ tC ha}^{-1}$ . Los bosques templados de Chiapas, registraron acumulaciones de carbono de  $46.71 \text{ tC ha}^{-1}$  (Aryal et al., 2018);

acumulaciones inferiores a la región II ( $50 \text{ tC ha}^{-1}$ ) y superiores a las regiones I y III que reporta este estudio.

Poorter et al. (2015) estimaron para los bosques tropicales del Sur de América, un secuestro potencial de  $8.48 \text{ Pg C}$  para los próximos 40 años (2008 - 2048); los autores encontraron que México, fue el tercer país con mayor potencial de almacenamiento de carbono en un 95.1 %, resultados que, se verán en deceso considerando los resultados predichos para 2050 en ambos escenarios.

VARIABLES como la altitud, tiene influencia en la captura de carbono de la vegetación con patrones impulsados de variables climáticas (precipitación y temperatura); casos como Cai et al. (2020) muestran que, a mayor desplazamiento altitudinal, el almacenamiento del carbono irá en aumento. Al igual que dichos autores, en esta investigación, a mayores elevaciones altitudinales, el almacenamiento del carbono total se encontró con valores por encima de  $55 \text{ tC ha}^{-1}$ , con rangos de  $56.66 - 82.82 \text{ tC ha}^{-1}$  en las altitudes mayores o iguales a 400 msnm.

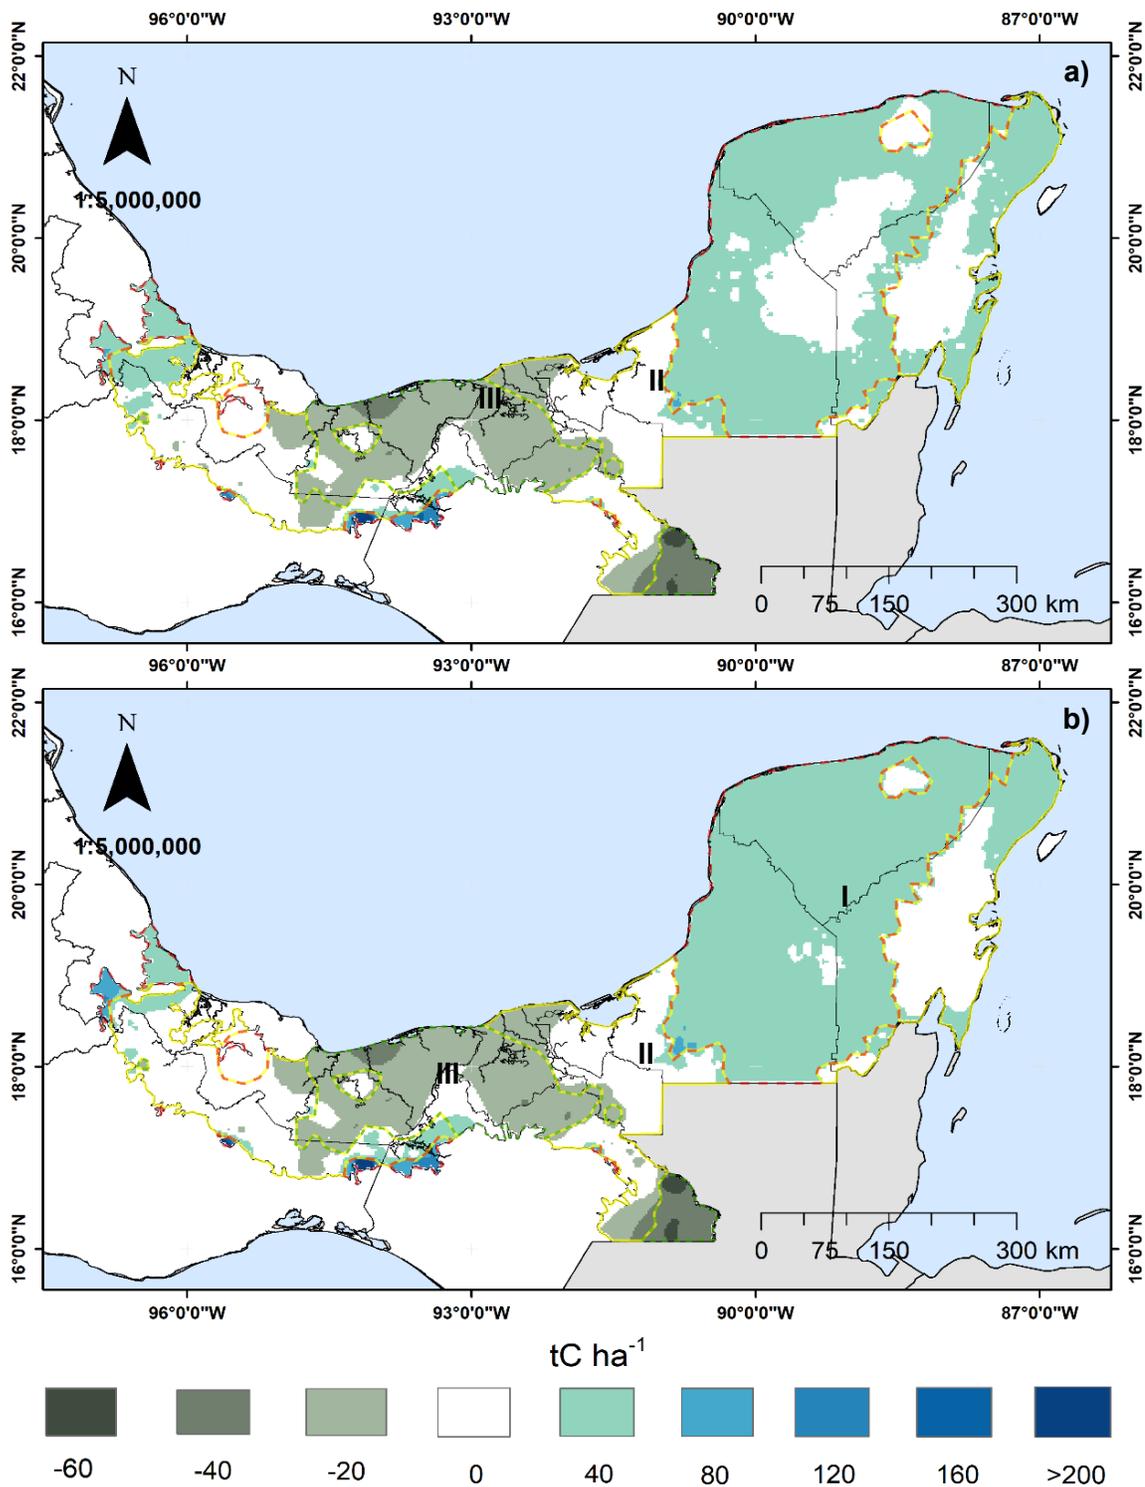
### **Captura de carbono total bajo escenarios 4.5 y 8.5 para 2050**

Según los modelos generados para el 2050 se estimaron pérdidas promedio desde  $-2.67 \text{ tC ha}^{-1}$  (5.42 %) en la región II bajo escenarios climáticos moderados (RCP 4.5) y de hasta  $-5.42 \text{ tC ha}^{-1}$  (10.61 %) ante un posible escenario drástico (RCP 8.5). No obstante, se predicen ganancias promedio del carbono total en la región I desde 4.49 hasta  $15.01 \text{ tC ha}^{-1}$ , lo cual representaron del 10 al 34.16 % en escenarios moderados y drásticos.

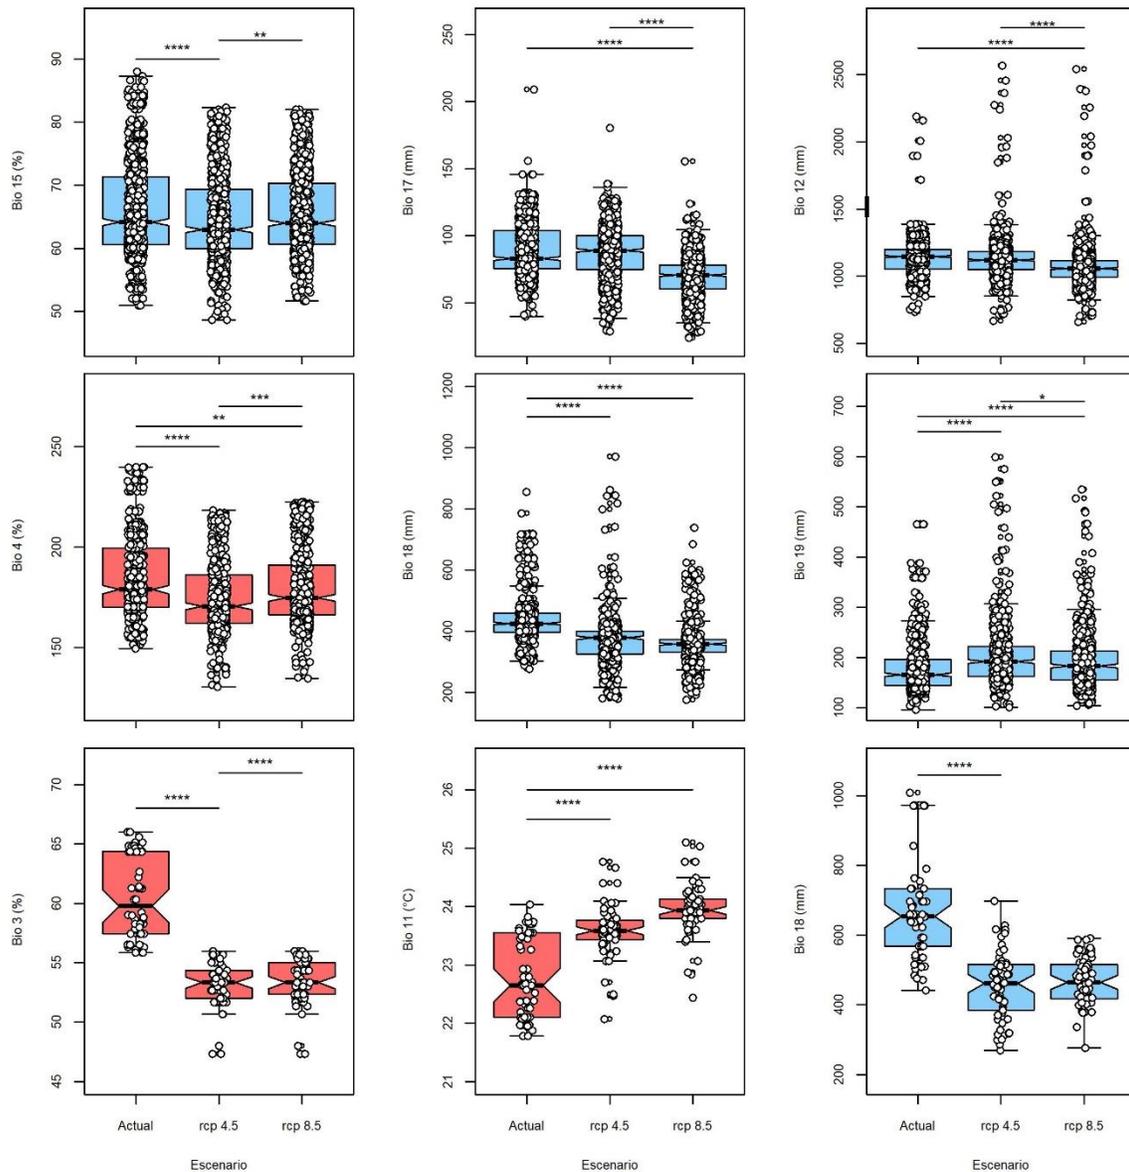
En comparación, Sun et al. (2016) en su estudio para los bosques templados del Tibet, estimaron pérdidas del  $38.8 \text{ tC ha}^{-1}$  de carbono total para 2050. Vieilledent et al. (2016) registraron pérdidas en las reservas de carbono total del 8 y 17 % para 2050 y 2080 en los bosques tropicales de Madagascar. Li et al. (2022) registró pérdidas en la captura de biomasa aérea de 5 a 25 % en escenarios 2.6 y 8.5, pudiendo predecir a la par la edad, altura y diámetro, al emplear siete modelos de circulación general: ACCESS 1.0, CCSM4, GISS-E2-R, HadGEM2-ES, IPSL-

CM5ALR, MIROC5 y NorESM1-M, de los cuales, dos fueron utilizados para este estudio.

En la región III, al 2050 se estimaron pérdidas significativas de carbono desde 36.22 tC ha<sup>-1</sup> (RCP 4.5) hasta 37.29 tC ha<sup>-1</sup> (RCP 4.5) lo que representa -82 % en algunos sitios, lo que representa que sea la región la más vulnerable (Fig. 7b). Para una recuperación de entre 30 y 60 % de la biomasa, es necesario un tiempo de espera sin perturbaciones de 20 años (Poorter *et al.* 2015) situación imposible ante escenarios económicos, antropogénicos y climáticos.



**Figura 7.** Diferencias de carbono total ( $tC\ ha^{-1}$ ) del 2050, con respecto al carbono actual, estimado con variables bioclimáticas en las selvas del sureste de México, en un escenario climático moderado, RCP 4.5 (arriba) y drástico, RCP 8.5 (abajo).



**Figura 8.** Comparación de grupos de las variables bioclimáticas en diferentes escenarios climáticos que estiman el carbono total en las selvas del sureste de México. Región I (arriba), región II (medio) y región III (abajo). Cajas en color azul representa precipitación, cajas en rojo representan temperatura. Líneas horizontales con el símbolo \*, representan la significancia estadística según la prueba no paramétrica de Wilcoxon.

La cantidad de lluvia es una condición que influye de manera directa en los controladores de almacén del carbono de bosques tropicales, donde, en dado caso la precipitación sufriera una disminución del 50 %, las existencias de carbono pueden reducirse en 20 % en bosques tropicales (Fischer et al., 2014; Paz-Pellat et al., 2020). Los resultados demostraron que existieron diferencias en las medias de los rangos de cada variable bioclimáticas, del escenario actual con respecto a los escenarios RCP 4.5 y 8.5 (sección b, Tabla 6) lo que quedó de la siguiente manera:

Región I. decremento de: 1.8 % en Bio 15 (RCP 4.5); disminuciones de 12.36 mm (14.9 %) en el escenario drástico (RCP 8.5) en Bio 17 y de 26.35 mm (2.3 %) en Bio 12 (RCP 4.5).

Región II. Bio 4, disminución de 4.6 y 2.3 % (RCP 4.5 y RCP 8.5) respectivamente. Disminución de 46.75 y 67.57 mm en Bio 18, equivalente a 11.0 y 15.9 % (RCP 4.5 y RCP 8.5), respectivamente. Aumento de 26.31 y 17.37 mm (15.9 y 10.5 %) en Bio 19 ante un RCP 4.5 y 8.5, en dicho orden.

Región III: decremento de 10.8 % (RCP 4.5) en Bio 3, aumento de 0.92 y 1.29 °C en Bio 11, correspondiente a 4.1 y 5.7 % (RCP 4.5 y RCP 8.5), pero disminución de 192.93 y 189 mm en Bio 18, lo que correspondió a 29.5 y 29.0 %, en los escenarios 4.5 y 8.5 correspondientemente.

**Tabla 5.** Estadísticas descriptivas de las variables bioclimáticas, por región y en diferentes escenarios climáticos (a) y estadísticos de la prueba de Kruskal – Wallis y tamaño del efecto de las diferencias de las medias de rangos entre grupos.

Estadísticas descriptivas (a)												Prueba de Kruskal – Wallis (b)				
Región	Escen.	Variable	n	Min	Max	Mediana	Iqr	Media	SD	SE	CI	Estadístico	DF	Valor de p	Valor de eta <sup>2</sup>	Magnitud
I	Actual	Bio 15	915	50.95	88	64.17	10.75	66.23	7.6	0.25	0.49	21.6	2	> 0.0001	0.01	Pequeño
	RCP 4.5	Bio 15	915	48.67	82.33	63	9.33	64.62	7.02	0.23	0.46					
	RCP 8.5	Bio 15	915	51.67	82	64	9.67	65.6	6.59	0.22	0.43					
	Actual	Bio 17	915	40	209	83	28.5	88.97	19.58	0.65	1.27	582	2	> 0.0001	0.21	large
	RCP 4.5	Bio 17	915	28.67	180.33	89	25	87.15	18.84	0.62	1.22					
	RCP 8.5	Bio 17	915	24	155.67	70.67	18	69.29	14.43	0.48	0.94					
	Actual	Bio 12	915	732	2190	1146	144	1134.14	135.97	4.5	8.82	230	2	> 0.0001	0.08	moderate
	RCP 4.5	Bio 12	915	667.67	2570	1119.67	134.5	1129.44	155.98	5.16	10.12					
	RCP 8.5	Bio 12	915	658.33	2542.33	1057	123	1069.85	152.99	5.06	9.93					
II	Actual	Bio 4	496	149.42	239.75	178.77	29.34	184.2	21.23	0.95	1.87	49.1	2	> 0.0001	0.03	small
	RCP 4.5	Bio 4	496	130.43	218.3	170.5	23.99	175.46	19.19	0.86	1.69					
	RCP 8.5	Bio 4	496	134.57	222.57	174.6	24.89	179.66	19.67	0.88	1.74					
	Actual	Bio 18	496	276	855	425	62	443.08	86.9	3.9	7.67	421	2	> 0.0001	0.28	large
	RCP 4.5	Bio 18	496	179.33	970.67	378.17	74.08	372.53	89.43	4.02	7.89					
	RCP 8.5	Bio 18	496	175.33	738	357.5	40.33	357.26	71.54	3.21	6.31					
	Actual	Bio 19	496	96	465	165.5	52	183.06	58.09	2.61	5.13	60.7	2	> 0.0001	0.04	small
	RCP 4.5	Bio 19	496	101	598.67	191.83	59	204.77	67.79	3.04	5.98					
	RCP 8.5	Bio 19	496	103.67	534.67	182.83	56.67	194.98	60.43	2.71	5.33					

Estadísticas descriptivas (a)											Prueba de Kruskal – Wallis (b)					
Región	Escen.	Variable	n	Min	Max	Mediana	Iqr	Media	SD	SE	CI	Estadístico	DF	Valor de p	Valor de eta <sup>2</sup>	Magnitud
	Actual	Bio 3	62	55.84	66.01	59.77	6.93	60.61	3.52	0.45	0.89					
	RCP 4.5	Bio 3	62	47.33	56	53.33	2.17	53.11	1.81	0.23	0.46	123	2	> 0.0001	0.66	large
	RCP 8.5	Bio 3	62	47.33	56	53.33	2.67	53.41	1.94	0.25	0.49					
III	Actual	Bio 11	62	21.78	24.04	22.65	1.45	22.79	0.69	0.09	0.18					
	RCP 4.5	Bio 11	62	22.07	24.77	23.58	0.33	23.59	0.45	0.06	0.12	84.2	2	> 0.0001	0.45	large
	RCP 8.5	Bio 11	62	22.43	25.1	23.93	0.33	23.95	0.45	0.06	0.12					
	Actual	Bio 18	62	442	1008	654	165.75	677.79	152.44	19.36	38.71					
	RCP 4.5	Bio 18	62	269	697.67	461.17	126.83	453.73	95.32	12.11	24.21	87.4	2	> 0.0001	0.47	large
	RCP 8.5	Bio 18	62	276.67	591	464.5	96.75	466.43	67.34	8.55	17.1					

Donde: n = número de individuos, Min = Mínimo, Max = Máximo, Media, Iqr = Rango del intercuartil, SD = Desviación estándar de la media, SE = Error estándar de la media, CI= intervalo de confianza de la media (95 %).

**Tabla 6.** Estadísticos de la prueba no paramétrica de Wilcoxon para la comparación de grupos de variables Bioclimáticas ante escenario climáticos drásticos (RCP 4.5) y moderados (RCP 8.5) al 2050.

Región	Variable	Grupo 1	Grupo 2	n1	n2	estadístico	Valor de p	p.adj	p.adj.signif
I	Bio 15	Actual	RCP 4.5	915	915	467849	0	0	****
		Actual	RCP 8.5	915	915	431047	0.271	0.813	ns
		RCP 4.5	RCP 8.5	915	915	379217	0.0005	0.001	**
	Bio 17	Actual	RCP 4.5	915	915	422008	0.764	1	ns
		Actual	RCP 8.5	915	915	657810.5	0	0	****
		RCP 4.5	RCP 8.5	915	915	651453	0	0	****
Bio 12	Actual	RCP 4.5	915	915	449421.5	0.006	0.019	*	
	Actual	RCP 8.5	915	915	572329.5	0	0	****	

Región	Variable	Grupo 1	Grupo 2	n1	n2	estadístico	Valor de p	p.adj	p.adj.signif
II	Bio 18	Actual	RCP 4.5	496	496	193691	0	0	****
		Actual	RCP 8.5	496	496	207691.5	0	0	****
		RCP 4.5	RCP 8.5	496	496	150502	0	0	****
	Bio 19	Actual	RCP 4.5	496	496	88712.5	0	0	****
		Actual	RCP 8.5	496	496	100599.5	0	0	****
		RCP 4.5	RCP 8.5	496	496	136265	0.003	0.01	**
	Bio 4	Actual	RCP 4.5	496	496	153735	0	0	****
		Actual	RCP 8.5	496	496	137891	0.001	0.003	**
		RCP 4.5	RCP 8.5	496	496	104673.5	0	0.0001	***
III	Bio 3	Actual	RCP 4.5	62	62	3841	0	0	****
		Actual	RCP 8.5	62	62	3835	0	0	****
		RCP 4.5	RCP 8.5	62	62	1698.5	0.264	0.792	ns
	Bio 11	Actual	RCP 4.5	62	62	790	0	0	****
		Actual	RCP 8.5	62	62	263	0	0	****
		RCP 4.5	RCP 8.5	62	62	874.5	0	0	****
	Bio 18	Actual	RCP 4.5	62	62	3517.5	0	0	****
		Actual	RCP 8.5	62	62	3560.5	0	0	****
		RCP 4.5	RCP 8.5	62	62	1789.5	0.509	1	ns

En este estudio, la reducción de precipitación fue de 2 hasta casi 30 % en algunas variables bioclimáticas e incremento de temperatura, que ocasionaron las posibles pérdidas de carbono en las selvas de México. Ruíz-Corral et al. (2016), estimaron incremento de entre 0.5 y 1.5 °C para México al 2050 y pérdidas de 25 a 50 mm en la lluvia, bajo un RCP 4.5, valores similares a lo encontrado en este estudio

Las temperaturas constituyen una fuente en la variabilidad en los modelos de predicción de carbono total en selvas, además de influir directamente en el crecimiento de los árboles (Vieilledent et al., 2016) que, para este estudio, su variación fue poca.

## 5. CONCLUSIONES

Las variables de precipitación, fueron las de mayor contribución en la predicción de carbono total en las selvas del sureste de México. Se predicen cambios significativos de las reservas de carbono total en las selvas de México al 2050, debidas meramente al cambio climático: 38 % de la superficie de las selvas México se podría mantener sin cambios, 44 % de la superficie podría incrementar y 25 % sufrir pérdidas, aunque este porcentaje es efecto de la variabilidad espacial de los sitios de muestreo. No obstante, la tasa de decremento de carbono (37 %) es significativamente más alto y casi el doble que la tasa de incremento (21 %), lo anterior, fue debido principalmente a una reducción de precipitación en promedio de 17 %, pero incremento de temperatura de alrededor de 1 °C.

Las variables bioclimáticas 15, 17, 12, 4, 18, 19, 3 y 4 fueron las variables que predicen adecuadamente el carbono actual y futuro, influyendo positiva y negativamente en la captura del carbono total.

En ambos escenarios RCP se registraron pérdidas en el almacenamiento de carbono, destacando el escenario RCP 8.5, teniendo las mayores pérdidas del carbono total.

## 6. LITERATURA CITADA

- Arasa-Gisbert, R. (2017). National Forest Inventory of Mexico 2009-2012. Instituto de Investigación En Ecosistemas y Sustentabilidad, PANGAEA, <https://doi.org/10.1594/PANGAEA.882176>.
- Arboretti G, R., & Salmaso, L. (2003). Model performance analysis and model validation in logistic regression. *Statistica*, 63(2), 375–396. <https://doi.org/10.6092/issn.1973-2201/358>.
- Arribas, C. (2013). Captura y almacenamiento del carbono. *El Ecologista*, 79.
- Aryal, D. R., Gómez Castro, H., Del Carmen García, N., José Ruiz, O. de J., Molina Paniagua, L. F., Jiménez Trujillo, J. A., Venegas Venegas, J. A., Pinto Ruiz, R., Ley de Coss, A., & Guevara Hernández, F. (2018). Potencial de almacenamiento de carbono en áreas forestales en un sistema ganadero. *Revista Mexicana de Ciencias Forestales*, 9(48). <https://doi.org/10.29298/rmcf.v8i48.184>
- Avendaño Arrazate, C. H., Suárez Venero, G. M., Mendoza López, A., Martínez Bolaños, M., Reyes Reyes, J., & Espinosa Zaragoza, S. (2021). Composición arbórea de especies asociadas al cacao: selva Lacandona y sistemas agroforestales, Chiapas, México. *Agronomía Mesoamericana*, 32(2), 365–381. <https://doi.org/10.15517/am.v32i2.41630>
- Benjamín-Ordóñez, J. A., & Maser, O. (2001). Captura de carbono ante el cambio climático. *Madera y Bosques*, 7(1), 3–12.
- Bennett, A. C., Penman, T. D., Arndt, S. K., Roxburgh, S. H., & Bennett, L. T. (2020). Climate more important than soils for predicting forest biomass at the continental scale. *Ecography*, 43(11), 1692–1705. <https://doi.org/10.1111/ecog.05180>
- Burbano O, H. (2018). El carbono orgánico del suelo y su papel frente al cambio climático. *Revista de Ciencias Agrícolas*, 35(1), 82. <https://doi.org/10.22267/rcia.183501.85>
- Busby, J. (1986). A biogeoclimatic analysis of *Nothofagus cunninghamii* (Hook.) Oerst. in southeastern Australia. *Austral Ecology*, 11(1), 1–7. <https://doi.org/10.1111/j.1442-9993.1986.tb00912.x>
- Cai, Q., Ji, C., Zhou, X., Bruelheide, H., Fang, W., Zheng, T., Zhu, J., Shi, L., Li, H., Zhu, J., & Fang, J. (2020). Changes in carbon storages of *Fagus* forest ecosystems along an elevational gradient on Mt. Fanjingshan in Southwest China. *Journal of Plant Ecology*, 13(2), 139–149. <https://doi.org/10.1093/jpe/rtz055>.

- Calcagno, V., & de Mazancourt, C. (2010). glmulti: An R Package for easy automated model selection with (Generalized) linear models. *Journal of Statistical Software*, 34(12), 1–29. <https://doi.org/10.18637/jss.v034.i12>
- Carroll, C., & Ray, J. C. (2021). Maximizing the effectiveness of national commitments to protected area expansion for conserving biodiversity and ecosystem carbon under climate change. *Global Change Biology*, 27(15), 3395–3414. <https://doi.org/10.1111/gcb.15645>
- Cartus, O., Kellndorfer, J., Walker, W., Franco, C., Bishop, J., Santos, L., & Fuentes, J. (2014). A national, detailed map of forest aboveground carbon stocks in Mexico. *Remote Sensing*, 6(6), 5559–5588. <https://doi.org/10.3390/rs6065559>
- Collins, W. J., Bellouin, N., Doutriaux-Boucher, M., Gedney, N., Halloran, P., Hinton, T., Hughes, J., Jones, C. D., Joshi, M., Liddicoat, S., Martin, G., O'Connor, F., Rae, J., Senior, C., Sitch, S., Totterdell, I., Wiltshire, A., & Woodward, S. (2011). Development and evaluation of an Earth-System model – HadGEM2. *Geoscientific Model Development*, 4(4), 1051–1075. <https://doi.org/10.5194/gmd-4-1051-2011>
- Comisión Nacional Forestal (CONAFOR). (2009). Inventario nacional forestal y de suelos México 2004-2009 (Primera Edición). Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT).
- Comisión Nacional Forestal (CONAFOR). (2019). El sector forestal mexicano en cifras; Bosque para el bienestar social y climático.
- Cuenca, M. E., Jadán, O., Cueva, K., & Aguirre, C. (2014). Carbono y ecuaciones alométricas para grupos de especies y bosques de tierras bajas, Amazonía. *CEDAMAZ*, 4(1), 21–31.
- Danabasoglu, G., Bates, S. C., Briegleb, B. P., Jayne, S. R., Jochum, M., Large, W. G., Peacock, S., & Yeager, S. G. (2012). The CCSM4 ocean component. *Journal of Climate*, 25(5), 1361–1389. <https://doi.org/10.1175/JCLI-D-11-00091.1>
- Epstein, H. E., Lauenroth, W. K., & Burke, C. (1997). Effects of temperature and soil texture on ANPP in the U.S. great plains. *Ecological Society of America*, 78(8), 2628–2631.
- FAO. (2019). World Reference Base for Soil Resources 2014: International soil classification system for naming soils and creating legends for soil maps. Update 2015. World Soil Resources Reports No. 106.
- Fayolle, A., Loubota Panzou, G. J., Drouet, T., Swaine, M. D., Bauwens, S., Vleminckx, J., Biwole, A., Lejeune, P., & Doucet, J.-L. (2016). Taller trees, denser stands and greater biomass in semi-deciduous than in evergreen

- lowland central African forests. *Forest Ecology and Management*, 374, 42–50. <https://doi.org/10.1016/j.foreco.2016.04.033>
- Fick, S. E., & Hijmans, R. J. (2017). WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, 37(12), 4302–4315. <https://doi.org/10.1002/joc.5086>
- Fischer, C. (2016). Comparing the logarithmic transformation and the box-cox transformation for individual tree basal area increment models. *Forest Science*, 62(3), 297–306. <https://doi.org/10.5849/forsci.15-135>
- Fischer, R., Armstrong, A., Shugart, H. H., & Huth, A. (2014). Simulating the impacts of reduced rainfall on carbon stocks and net ecosystem exchange in a tropical forest. *Environmental Modelling & Software*, 52, 200–206. <https://doi.org/10.1016/j.envsoft.2013.10.026>
- Granados, J. (2007). Las Selvas Tropicales y el Cambio Climático. *Ciencia*, 58(4), 41-49.
- Grupo Intergubernamental sobre el cambio climático (IPCC). (2019). Calentamiento global de 1,5 °C Informe especial del IPCC sobre los impactos del calentamiento global de 1,5 °C con respecto a los niveles preindustriales y las trayectorias correspondientes que deberían seguir las emisiones mundiales de gases de efecto invernadero, en el contexto del reforzamiento de la respuesta mundial a la amenaza del cambio climático, el desarrollo sostenible y los esfuerzos por erradicar la pobreza; Resumen para responsables de políticas Resumen técnico Preguntas frecuentes.
- Guerra, C. W., Cabrera, A., & Fernández, L. (2003). Criterios para la selección de modelos estadísticos en la investigación científica. *Revista Cubana de Ciencia Agrícola*, 37(1), 3–10.
- Hao, Z., Zheng, X., Wang, Y., Hu, H., Tang, Z., Zhang, Q., & Chen, Y. (2020). Prediction of soil organic carbon content using machine learning models: A case study in the Chinese Loess Plateau. *Science of the Total Environment*.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning; data mining, inference and prediction (second). *Springer*.
- He, X., Lei, X., Zeng, W., Feng, L., Zhou, C., & Wu, B. (2022). Quantifying the effects of stand and climate variables on biomass of larch plantations using random forests and national forest inventory data in north and northeast China. *Sustainability*, 14(9), 5580. <https://doi.org/10.3390/su14095580>
- Hernández-Stefanoni, J. L., Castillo-Santiago, M. Á., Andres-Mauricio, J., Portillo-Quintero, C. A., Tun-Dzul, F., & Dupuy, J. M. (2021). Carbon stocks, species diversity and their spatial relationships in the Yucatán Peninsula, Mexico. *Remote Sensing*, 13(16), 3179. <https://doi.org/10.3390/rs13163179>

- Hijmans, R. J., Cameron, S. E., Parra, J. L., Jones, P. G., & Jarvis, A. (2005). Very high-resolution interpolated climate surfaces for global land areas. *International Journal of Climatology*, 25(15), 1965–1978. <https://doi.org/10.1002/joc.1276>
- IPCC, 2022: Climate Change 2022: Impacts, adaptation, and vulnerability. contribution of working group II to the sixth assessment report of the intergovernmental panel on climate change [H.-O. Pörtner, D.C. Roberts, M. Tignor, E.S. Poloczanska, K. Mintenbeck, A. Alegría, M. Craig, S. Langsdorf, S. Lösschke, V. Möller, A. Okem, B. Rama (eds.)]. Cambridge University Press. Cambridge University Press, Cambridge, UK and New York, NY, USA, 3056 pp., doi:10.1017/9781009325844.
- Jenkins, J. C., Chojnacky, D. C., Heath, L. S., & Birdsey, R. A. (2003). National scale biomass estimators for United States tree species. *Forest Science*, 49, 12–35.
- Kassambara, A., & Mundt, F. (2020). factoextra: Extract and Visualize the Results of Multivariate Data Analyses\_. R package version 1.0.7. <<https://CRAN.R-Project.Org/Package=factoextra>>.
- Khan, D., Muneer, M. A., Nisa, Z.-U.-, Shah, S., Amir, M., Saeed, S., Uddin, S., Munir, M. Z., Lushuang, G., & Huang, H. (2019). Effect of climatic factors on stem biomass and carbon stock of *Larix gmelinii* and *Betula platyphylla* in Daxing'anling mountain of inner Mongolia, China. *Advances in Meteorology*, 2019, 1–10. <https://doi.org/10.1155/2019/5692574>
- Krammer, M. G., Sollins, P., & Sletten, R. S. (2010). Spatially explicit estimation of soil organic carbon in the conterminous United States using the random forest approach. *Global Change Biology*, 16(4), 1553–1565.
- Kuhn, M. (2008). Building predictive models in R using the caret package. *Journal of Statistical Software*, 28(5). <https://doi.org/10.18637/jss.v028.i05>
- Lê, S., Josse, J., & Husson, F. (2008). FactoMineR, package for multivariate analysis. *Journal of Statistical Software*, 25(1). <https://doi.org/10.18637/jss.v025.i01>
- Li, Y., Li, M., & Wang, Y. (2022). Forest aboveground biomass estimation and response to climate change based on remote sensing data. *Sustainability*, 14(21), 14222. <https://doi.org/10.3390/su142114222>
- Liu, Y., Yu, G., Wang, Q., & Zhang, Y. (2013). How temperature, precipitation and stand age control the biomass carbon density of global mature forests. *Global Ecology and Biogeography*, 23(3), 323–333. <https://doi.org/10.1111/geb.12113>
- López-Díaz, J. Ó. M., Méndez-González, J., López-Serrano, P. M., Sánchez-Pérez, F. de J., Méndez-Encina, F. M., Mendieta-Oviedo, R., Sosa-Díaz, L., Flores, A., García-Montiel, E., Cambrón-Sandoval, V. H., Zermeño-González, A., & Corral Rivas, J. J. (2022). Dummy regression to predict dry fiber in *Agave lechuguilla*

- Torr. in two large-scale bioclimatic regions in Mexico. *Plos one*, 17(9), e0274641. <https://doi.org/10.1371/journal.pone.0274641>
- Luo, H., Zhang, C., & Wei, A. (2017). The effect of climate on the biomass of *Pinus yunnanensis* standing forest. *Southwest Forestry University*, 37(6), 99–104.
- Mathews-Saldaña, L. J. (2012). Relación de las Variables Climáticas en la Producción de Biomasa y Almacenamiento de Carbono Contenido en la Hojarasca (Necromasa Foliar) En un Bosque de Terraza en Jenaro Herrera - Loreta [Tesis]. Universidad Nacional de la Amazonia Peruana.
- Montgomery, D. C., Peck, E. A., & Geoffrey-Vining, G. (2012). Introduction to linear regression analysis (D. J. Balding, N. A. C. Cressie, & G. M. Fitzmaurice, Eds.; Fifth Edition). Wiley Series in Probability and Statistics.
- Montoya G, G., Soto P, L., De Jong, B. H. J., Nelson, K. C., Farías C, P., Yakactic Pajal, & Taylor, J. H. (1998). Desarrollo forestal sustentable: Captura de carbono en las zonas tzeltal y tojolabal del estado de Chiapas (Instituto Nacional de Ecología (INE), Ed.).
- Moss, R. H., Edmonds, J. A., Hibbard, K. A., Manning, M. R., Rose, S. K., van Vuuren, D. P., Carter, T. R., Emori, S., Kainuma, M., Kram, T., Meehl, G. A., Mitchell, J. F. B., Nakicenovic, N., Riahi, K., Smith, S. J., Stouffer, R. J., Thomson, A. M., Weyant, J. P., & Wilbanks, T. J. (2010). The next generation of scenarios for climate change research and assessment. *Nature*, 463(7282), 747–756. <https://doi.org/10.1038/nature08823>
- Núñez, E., Steyerberg, E. W., & Núñez, J. (2011). Estrategias para la elaboración de modelos estadísticos de regresión. *Revista Española de Cardiología*, 64(6), 501–507. <https://doi.org/10.1016/j.recesp.2011.01.019>
- Paroshy, N. J., Doraisami, M., Kish, R., & Martin, A. R. (2021). Carbon concentration in the world's trees across climatic gradients. *New Phytologist*, 232(1), 123–133. <https://doi.org/10.1111/nph.17587>
- Paz Pellat, F., & Díaz-Solís, H. (2018). Relaciones entre la precipitación, producción de biomasa e índices espectrales de la vegetación: alcances y limitaciones. *Revista Terra Latinoamericana*, 36(2), 153. <https://doi.org/10.28940/terra.v36i2.235>
- Paz-Pellat, F., de Jong, B., Acosta-Mireles, M., Ángeles-Peréz, G., Manuel Dupuy-Rada, J., Guevara-Santamaría, M., Manzano-Camarillo, M., Méndez-González, J., Rojas-García, F., Salas-Aguilar, V., Soto-Pinto, L., Vargas-Larreta, B., Vargas, R., Velázquez-Rodríguez, A. S., & Tecnológico El Salto, I. (2020). Almacenes y Dinámica del Carbono en Selvas y Bosques de México: Parametrizaciones y Fuentes de Incertidumbre

- Pérez D, C. (2019). Efectos del cambio climático en la distribución actual y potencial de *Rhynchopsitta terrisi*, *Pinus pinceana* y *Pinus cembroides* [Tesis de Maestro en Ciencias en Ingeniería de Sistemas de Producción]. Universidad Autónoma Agraria Antonio Narro.
- Poorter, L., van der Sande, M.T., Thompson, J., Arets, E.J.M.M., Alarcón, A., Álvarez-Sánchez, J., Ascarrunz, N., Balvanera, P., Barajas-Guzmán, G., Boit, A., Bongers, F., Carvalho, F.A., Casanoves, F., Cornejo-Tenorio, G., Costa, F.R.C., de Castilho, C.V., Duivenvoorden, J.F., Dutrieux, L.P., Enquist, B.J., Fernández-Méndez, F., Finegan, B., Gormley, L.H.L., Healey, J.R., Hoosbeek, M.R., Ibarra-Manríquez, G., Junqueira, A.B., Levis, C., Licona, J.C., Lisboa, L.S., Magnusson, W.E., Martínez-Ramos, M., Martínez-Yrizar, A., Martorano, L.G., Maskell, L.C., Mazzei, L., Meave, J.A., Mora, F., Muñoz, R., Nytch, C., Pansonato, M.P., Parr, T.W., Paz, H., Pérez-García, E.A., Rentería, L.Y., Rodríguez-Velazquez, J., Rozendaal, D.M.A., Ruschel, A.R., Sakschewski, B., Salgado-Negret, B., Schiatti, J., Simões, M., Sinclair, F.L., Souza, P.F., Souza, F.C., Stropp, J., ter Steege, H., Swenson, N.G., Thonicke, K., Toledo, M., Uriarte, M., van der Hout, P., Walker, P., Zamora, N. and Peña-Claros, M. (2015), Carbon storage in tropical forests. *Global Ecology and Biogeography*, 24: 1314-1328. <https://doi.org/10.1111/geb.12364>
- Pretzsch, H., & Dieler, J. (2012). Evidence of variant intra- and interspecific scaling of tree crown structure and relevance for allometric theory. *Ecologia*, 169(3), 637–649. <https://doi.org/10.1007/s00442-011-2240-5>
- Ruíz-Corral, J. A., Medina-García, G., Rodríguez-Moreno, V. M., Sánchez-González, J. de J., García, R. V., Puga, N. D., Grageda, J. G., & García, G. E. (2016). Regionalización del cambio climático en México. *Revista Mexicana de Ciencias Agrícolas*, 13(01), 2451–2464.
- Rzedowski, J. (2006). Vegetación de México (1era Edición digital, Vol. 1). Comisión Nacional para el Conocimiento y Uso de la Biodiversidad.
- Sistema Nacional de Monitoreo Forestal (SNMF). (2023). Carbono Almacenado. <https://Snmf.Cnf.Gob.Mx/Principaleindicadoresforestalesciclo-2015-2020/>.
- Snee, R. D. (1977). Validation of Regression Models: Methods and Examples. *Technometrics*, 19(4), 415–428. <https://doi.org/10.1080/00401706.1977.10489581>
- Sun, S., Wang, Y., Song, Z., Chen, C., Zhang, Y., Chen, X., Chen, W., Yuan, W., Wu, X., Ran, X., Wang, Y., Li, Q., & Wu, L. (2021). Modelling aboveground biomass carbon stock of the Bohai Rim coastal wetlands by integrating remote sensing, terrain, and climate data. *Remote Sensing*, 13(21), 4321. <https://doi.org/10.3390/rs13214321>

- Sun, X., Wang, G., Huang, M., Chang, R., & Ran, F. (2016). Forest biomass carbon stocks and variation in Tibet's carbon-dense forests from 2001 to 2050. *Scientific Reports*, 6(1), 34687. <https://doi.org/10.1038/srep34687>
- Taylor, K. E., Stouffer, R. J., & Meehl, G. A. (2012). An overview of CMIP5 and the experiment design. *Bulletin of the American Meteorological Society*, 93(4), 485–498. <https://doi.org/10.1175/BAMS-D-11-00094.1>
- Temesgen, H., Affleck, D., Poudel, K., Gray, A., & Sessions, J. (2015). A review of the challenges and opportunities in estimating above ground forest biomass using tree-level models. *Scandinavian Journal of Forest Research*, 1–10. <https://doi.org/10.1080/02827581.2015.1012114>
- Trejo Vázquez, I. (1999). El Clima de la selva baja caducifolia en México. *Investigaciones Geográficas*, Boletín 39, 40- 52.
- UNESCO, WRI y UICN, 2023: Bosques del Patrimonio Mundial: Sumideros de carbono bajo presión, Paris, UNESCO; Washington DC, WRI; Gland, UICN
- Urbazaev, M., Thiel, C., Cremer, F., Dubayah, R., Migliavacca, M., Reichstein, M., & Schullius, C. (2018). Estimation of forest aboveground biomass and uncertainties by integration of field measurements, airborne LiDAR, and SAR and optical satellite data in Mexico. *Carbon Balance and Management*, 13(1), 5. <https://doi.org/10.1186/s13021-018-0093-5>
- Vaissie, P., Monge, A., & Husson, F. (2021). Factoshiny: Perform Factorial Analysis from “FactoMineR” with a Shiny Application\_. R package version 2.4, <<https://CRAN.R-Project.Org/Package=Factoshiny>>.
- Vargas-Mena, A., & Yañez S, A. (2004). La captura de carbono en bosques: ¿una herramienta para la gestión ambiental? *Gaceta Ecológica*, 70, 5–18.
- Vieilledent, G., Gardi, O., Grinand, C., Burren, C., Andriamanjato, M., Camara, C., Gardner, C. J., Glass, L., Rasolohery, A., Rakoto Ratsimba, H., Gond, V., & Rakotoarijaona, J.-R. (2016). Bioclimatic envelope models predict a decrease in tropical forest carbon stocks with climate change in Madagascar. *Journal of Ecology*, 104(3), 703–715. <https://doi.org/10.1111/1365-2745.12548>
- Watanabe, M., Suzuki, T., O'ishi, R., Komuro, Y., Watanabe, S., Emori, S., Takemura, T., Chikira, M., Ogura, T., Sekiguchi, M., Takata, K., Yamazaki, D., Yokohata, T., Nozawa, T., Hasumi, H., Tatebe, H., & Kimoto, M. (2010). Improved Climate Simulation by MIROC5: Mean States, Variability, and Climate Sensitivity. *Journal of Climate*, 23(23), 6312–6335. <https://doi.org/10.1175/2010JCLI3679.1>
- Zamora M, M. C. (2015). Cambio Climático. *Revista Mexicana de Ciencias Forestales*, 6(31), 4-7.

- Zárate-Razo, R., Gordillo-Martínez, A. J., Rodríguez-Laguna, R., Maycotte-Morales, C., & Acevedo-Sandoval, O. (2013). Estimación de biomasa y carbono almacenado en árboles de oyamel afectados por el fuego en el Parque nacional “El Chico”, Hidalgo, México. *Madera y Bosques*, 19(2), 73–86.
- Zhang, L., Lai, G., Zeng, W., Zou, W., & Yi, S. (2022). Effect of climate on carbon storage growth models for three major coniferous plantations in China based on national forest inventory data. *Forests*, 13(6), 882. <https://doi.org/10.3390/f13060882>