

UNIVERSIDAD AUTONOMA AGRARIA ANTONIO NARRO

SUBDIRECCIÓN DE POSGRADO



EFFECTOS DEL CAMBIO CLIMÁTICO SOBRE LA DENSIDAD DE CARBONO DE  
LA BIOMASA VIVA AÉREA EN BOSQUES DE MÉXICO

Tesis

Que presenta CARMELA SANDOVAL GARCÍA

Como requisito parcial para obtener el grado de  
MAESTRO EN CIENCIAS EN INGENIERÍA DE SISTEMAS DE PRODUCCIÓN

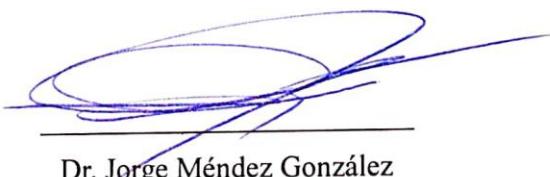
Saltillo, Coahuila

Diciembre 2024

EFECTOS DEL CAMBIO CLIMÁTICO SOBRE LA DENSIDAD DE CARBONO DE  
LA BIOMASA VIVA AÉREA EN BOSQUES DE MÉXICO.

Tesis

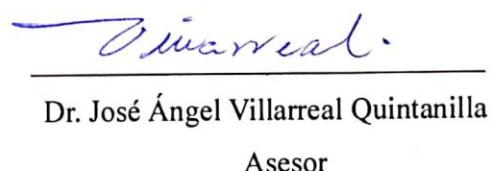
Elaborada por CARMELA SANDOVAL GARCÍA como requisito parcial para obtener  
el grado de Maestro en Ciencias en Ingeniería de Sistemas de Producción con la  
supervisión y aprobación del comité de Asesoría



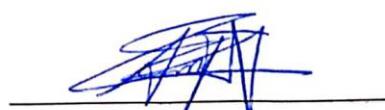
Dr. Jorge Méndez González  
Director de Tesis



Dr. Eladio Heriberto Cornejo Oviedo  
Asesor



Dr. José Ángel Villarreal Quintanilla  
Asesor



Dr. Antonio Flores Naveda  
Subdirector de Postgrado  
UAAAN

Saltillo, Coahuila

Diciembre 2024

## AGRADECIMIENTOS

A Dios por la vida y salud que me brinda hasta el día de hoy, por cuidar mi entrada y salida en todo momento, por bendecirme y protegerme en todo momento, gracias, Dios por que hasta aquí me has ayudado.

A mis Padres por ser cómplice y aliados de mis decisiones porque siempre me respaldan en ellas.

A la *Universidad Autónoma Agraria Antonio Narro* por ser la institución que me ha formado profesional y académicamente.

Al *Consejo Nacional de Humanidades Ciencias y Tecnología* (CONAHCYT) por el apoyo económico para mi formación como Maestro en Ciencias.

Al *Dr. Jorge Méndez González* eternamente gracias por todos los conocimientos brindados para mi formación profesional, por creer en mí y demostrarme que la excelencia se trabaja constantemente, gracias por que sus enseñanzas son y serán valiosas para toda mi vida, gracias por ser inspiración a manera profesional y a mejorar día a día.

Al *Dr. Eladio Heriberto Cornejo Oviedo* y al *Dr. José Ángel Villarreal Quintanilla* por compartirme de sus conocimientos durante la carrera y maestría y ser parte fundamental de mi formación profesional.

Al *M.C Félix de Jesús Sánchez Pérez* por sus conocimientos valiosos brindados en mi formación

Al *Dr. Alejandro Zermeño González* gracias por su amistad, por las vivencias y enseñanzas brindadas durante estos dos años.

A mis amistades formadas durante la maestría Néstor, Marino, Leticia, Carmen gracias aprendí mucho de ustedes.

Al programa de Maestría en Ciencias en Ingeniería de Sistemas de Producción por el apoyo durante en todos los trámites administrativos

## DEDICATORIA

Esta investigación se la dedico especialmente a:

*Dios* porque como lo menciona la biblia, y todo lo que hagáis, hacedlo de corazón, como para el señor y no para los hombres, Colosenses 3:23

A mi abuela paterna *Agustina Mendoza Rojas* † tu partida durante mi maestría me enseño que la vida hay que vivirla porque se nos va en un instante.

A mi madre *Feliciiana García Pérez* porque sin su apoyo nada tendría sentido, gracias, madre por tus consejos y enseñanzas brindadas en toda mi vida, eres la mejor mamá que pude tener.

A mi padre *Isaias Sandoval Mendoza* por sus consejos de vida, su cariño y apoyo en todas las decisiones que he tomado en mi vida confiando que será por mi bien.

A mis hermanos, *Severiana, Felipe y María* porque siempre han confiado en mí y me han apoyado en cada etapa de mi vida gracias.

A mis hermanos *Celestino y Rufino* gracias por todo su apoyo y motivación durante toda mi vida profesional, por ser mentores y aliados en mis decisiones muchas gracias.

Al *Dr. Humberto Reyes Valdés* por su amistad brindada estos años, gracias por inspirarme a escribir y demostrarme que cuando haces lo que te gusta todo el camino será más fácil y que en los senderos de la vida hay que detenernos un ratito a contemplar el paisaje.

A la persona que me enseño que el amor es paciente gracias, gracias por corregirme para ser mejor, gracias por inspirarme y gracias por tu sonrisa.

## ÍNDICE GENERAL

AGRADECIMIENTOS .....	iii
DEDICATORIA .....	iv
RESUMEN.....	x
INTRODUCCIÓN .....	1
REVISIÓN DE LITERATURA .....	4
Bosques de coníferas en México .....	4
Variables bioclimáticas .....	5
Selección de variables predictoras.....	6
Generación de modelos predictivos.....	7
Predicciones actuales y futuras.....	8
Estudios afines.....	9
MATERIALES Y MÉTODOS .....	13
Descripción del área de estudio .....	13
Proceso de adquisición y limpieza de Datos .....	13
Modelado predictivo de DCBVa .....	14
Predicción actual, futura y tasa de cambio de DCBVa.....	15
Predictores Bioclimáticos: Análisis Actual y Proyecciones Futuras .....	17
RESULTADOS Y DISCUSIÓN .....	18
Distribución de la densidad de carbono de la biomasa viva aérea .....	18
Modelos para la predicción de la densidad de carbono de biomasa viva aérea .....	18
Validación de modelos predictivos de la densidad de carbono de biomasa viva área..	21
Predicción actual y futura de la densidad de carbono de biomasa viva aérea.....	22
Evaluación de proyecciones climáticas en variables que predicen DCBVa en bosques de coníferas de México.....	26
Variables predictoras de biomasa aérea .....	30

Correlación entre variables bioclimáticas y densidad de carbono .....	31
Capacidad predictiva de los modelos .....	32
Proyección actual y futura de la densidad de carbono de biomasa viva aérea .....	33
CONCLUSIONES .....	35
REFERENCIAS.....	36
ANEXOS .....	42

## LISTA DE TABLA

<b>Tabla 1.</b> Coeficientes de regresión para la predicción de la densidad de carbono de la biomasa viva aérea por estrato, en los bosques de coníferas de México. ....	19
<b>Tabla 2.</b> Estadísticas descriptivas de la densidad de carbono de la biomasa viva aérea observada y de sus predictores (periodo de 1950-2000), en los bosques de coníferas de México.....	21
<b>Tabla 3.</b> Validación de los modelos de regresión para la predicción de la densidad de la biomasa viva aérea en los bosques de coníferas en México. ....	22
<b>Tabla 4.</b> Número de pixeles contenidos en el buffer de 40 km de radio alrededor de cada sitio de muestreo del INFyS para diferenciar cambios en la densidad de la biomasa viva aérea en los bosques de coníferas de México, ante escenarios climáticos futuros. Cada píxel mide 0.98 x 0.98 km de cada lado.....	26

## ÍNDICE DE FIGURAS

<b>Figura 1.</b> Distribución de los sitios del Inventario Nacional Forestal y de Suelos (2009 - 2012), estrato I (a), estrato II (b) y estrato III (c). Tamaño de los círculos y color de la rampa, indican los valores de la densidad de carbono de la biomasa viva área ( $Mg C ha^{-1}$ ). ....	18
<b>Figura 2.</b> Predicción actual de la densidad de carbono de la biomasa viva aérea, en bosques de coníferas México, a través de modelos bioclimáticos: estrato I (a), estrato II (b), estrato III (c). Tamaño de los círculos y color de la rampa, indican los valores de la densidad de carbono de la biomasa viva área ( $Mg C ha^{-1}$ ). ....	23
<b>Figura 3.</b> Cambios en la densidad carbono de biomasa viva aérea en bosques de coníferas de México, bajo los escenarios RCP 2.6 al 8.5 (de izquierda a derecha), para los años 2050 (arriba) y 2070 (abajo), en el estrato I. Áreas coloreadas representan buffers de 40 km de radio alrededor de cada sitio del INFyS; áreas sin relleno de color, corresponden a zonas no boscosas. ....	24
<b>Figura 4.</b> Lo mismo que figura 3, pero para el estrato II. ....	25
<b>Figura 5.</b> Lo mismo que figura 3, pero para el estrato III. ....	25
<b>Figura 6.</b> Prueba Wilcoxon para la comparación de las medianas de la variable actual con cada escenario climático, en el estrato I (a-b), II (b-c) y III (e-f). Bio 5: temperatura máxima del mes más cálido ( $^{\circ}C$ ); Bio 10: temperatura media del trimestre más cálido ( $^{\circ}C$ ); Bio 12: precipitación anual (mm); Bio 13: precipitación del mes más lluvioso (mm); Bio 18: precipitación del trimestre más cálido(mm). Significancia estadística: "* $p < 0.05$ ": Significativo; "** $p < 0.01$ ": Altamente significativo; "*** $p < 0.001$ ": Muy altamente significativo. Significancia estadística: "ns": No significativo; "* $p < 0.05$ ": Significativo; "*** $p < 0.01$ ": Altamente significativo; "*** $p < 0.001$ ": Muy altamente significativo; "**** $p < 0.0001$ ": Extremadamente altamente significativo. ....	28
<b>Figura 7.</b> Incertidumbre (error estándar) estimada de la densidad de carbono de biomasa viva aérea, en bosques de coníferas de México, para los estratos I (a), II (b) y III (c) para el RCP85 y para el año 2070.....	29

RESUMEN

EFECTOS DEL CAMBIO CLIMÁTICO SOBRE LA DENSIDAD DE CARBONO DE  
LA BIOMASA VIVA AÉREA EN BOSQUES DE MÉXICO

POR

CARMELA SANDOVAL GARCÍA

MAESTRIA EN CIENCIAS EN INGENIERÍA DE SISTEMAS DE PRODUCCIÓN  
UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO

DR. JORGE MÉNDEZ GONZÁLEZ -ASESOR-

Saltillo Coahuila

Diciembre 2024

## RESUMEN

Las variaciones climáticas en temperatura y precipitación impactan significativamente la productividad forestal. La precipitación influye en la fisiología y crecimiento de las especies, mientras que la temperatura regula la fotosíntesis, respiración y transpiración. Este estudio desarrolló modelos bioclimáticos para evaluar cómo el cambio climático afectará la densidad de carbono de la biomasa aérea (DCBVA) en bosques de coníferas de México para 2050 y 2070. Utilizamos datos de DCBVA del Inventario Forestal Nacional y Suelos (INFyS) de México (2009-2012) y 19 variables bioclimáticas de WorldClim ver. 2.0. Los mejores predictores de DCBVA se obtuvieron mediante técnicas de 'machine learning' con la librería 'caret' de R. El modelo se entrenó con el 80% de los datos y se validó con el 20% restante utilizando Modelos Lineales Generalizados (GLM). Se generaron mapas de predicciones actuales de DCBVA utilizando los mejores predictores. La DCBVA futura se calculó con el promedio de tres modelos de circulación general (MCG) de proyecciones climáticas futuras del Proyecto de Intercomparación de Modelos Acoplados Fase 5 (CMIP5), bajo cuatro Trayectorias de Concentración Representativas (RCP): 2.6, 4.5, 6.0 y 8.5 W/m<sup>2</sup>. Los resultados indican pérdidas de DCBVA en todos los escenarios climáticos, alcanzando hasta 15 Mg C ha<sup>-1</sup>, y podrían ocurrir bajo el escenario RCP 8.5 hacia 2070 en el centro del país. Las variables relacionadas con la temperatura fueron más importantes que las de precipitación. La validación del modelo con datos independientes sugiere que las variables bioclimáticas pueden explicar hasta el 20% de la varianza total de DCBVA. Se espera que la temperatura en el área de estudio aumente 2.66 °C para 2050 y 3.36 °C para 2070, mientras que la precipitación oscile en ±10% respecto a la actual, lo que podría redistribuir geográficamente la DCBVA de los bosques de coníferas del país. Estos hallazgos subrayan la necesidad de que la gestión forestal se enfoque no solo en la conservación de la biodiversidad, sino también en la capacidad de almacenamiento de carbono en estos ecosistemas.

**Palabras clave:** Biomasa aérea, Modelos bioclimáticos, Cambio climático, Bosques de coníferas, Aprendizaje automático

ABSTRACT

EFFECTS OF CLIMATE CHANGE ON THE CARBON DENSITY OF AERIAL  
LIVING BIOMASS IN MEXICO

BY

CARMELA SANDOVAL GARCÍA

MASTER OF SCIENCE IN PRODUCTION SYSTEMS ENGINEERING  
UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO

DR. JORGE MÉNDEZ GONZÁLEZ ASESOR -ADVISOR-

Saltillo, Coahuila,

December 2024

## ABSTRACT

Climatic variations in temperature and precipitation significantly impact forest productivity. Precipitation influences the physiology and growth of species, while temperature regulates photosynthesis, respiration and transpiration. This study developed bioclimatic models to evaluate how climate change will affect the carbon density of aboveground biomass (DCBVa) in coniferous forests in México for 2050 and 2070. We used DCBVa data from the National Forest Inventory and Soils (INFyS) of Mexico (2009-2012) and 19 bioclimatic variables from WorldClim ver. 2.0. The best predictors of DCBVa were obtained using machine learning techniques with the R library 'caret'. The model was trained with 80% of the data and validated with the remaining 20% using Generalized Linear Models (GLM). Maps of current DCBVa predictions were generated using the best predictors. Future DCBVa was calculated by averaging three general circulation models (GCMs) of future climate projections from the Coupled Model Intercomparison Project Phase 5 (CMIP5), under four Representative Concentration Paths (RCPs): 2.6, 4.5, 6.0 and 8.5 W /m<sup>2</sup>. The results indicate DCBVa losses in all climate scenarios, reaching up to 15 Mg C ha<sup>-1</sup>, and could occur under the RCP 8.5 scenario around 2070 in the center of the country. The variables related to temperature were more important than those of precipitation. Validation of the model with independent data suggests that bioclimatic variables can explain up to 20% of the total variance of DCBVa. The temperature in the study area is expected to increase by 2.66 °C by 2050 and 3.36 °C by 2070, while precipitation will oscillate by ±10% compared to the current one, which could geographically redistribute the DCBVa of the forests of conifers of the country. These findings underscore the need for forest management to focus not only on biodiversity conservation, but also on the carbon storage capacity in these ecosystems.

**Keywords:** Aboveground Biomass, Bioclimatic Models, Climate Change, Coniferous Forests, Machine Learning.

## INTRODUCCIÓN

Los bosques abarcan aproximadamente el 31 % de la superficie terrestre global, unos 4.06 mil millones de hectáreas, desempeñan un papel crucial en la regulación climática al funcionar como sumideros de carbono; se estima almacenan alrededor de 662 G t de carbono, distribuidos en un 44 % en biomasa viva, 45 % en materia orgánica del suelo, y 11 % en madera muerta y hojarasca (FAO, 2022). México cuenta con alrededor de 64.8 millones de hectáreas de bosques, lo que representa aproximadamente el 33 % del territorio nacional (FAO, 2022), abarcan varios tipos de bosques templados, latifoliados, mixtos, tropicales (Arasa-Gisbert *et al.*, 2018) y se estima que almacenan 1.69 G t C (Rodríguez-Veiga *et al.*, 2016). El cambio climático influye en los bosques al alterar la temperatura y las precipitaciones, lo que afecta el crecimiento de los bosques del mundo, la biomasa y el secuestro de carbono (Guo *et al.*, 2019; Ma *et al.*, 2023).

Las bases científicas para estudiar el cambio climático son incuestionables, los hallazgos irrefutables, la temperatura media global de la superficie terrestre ha aumentado 1.09 °C entre 2011-2020 en comparación con 1850-1900, se intensifica más en el hemisferio norte, y más sobre la tierra (1.59 °C) que en los océanos (0.88 °C); las precipitaciones aumentan en las latitudes altas y disminuyen en los subtrópicos, los extremos climáticos serán más frecuentes e intensos, y los sumideros de carbono serán menos eficientes (IPCC, 2021). En México, la temperatura media incrementó en 0.31°C por década, en el período de 1971 a 2020, y es más pronunciado en la meseta del norte durante verano; bajo un escenario climático SSP3-7.0 se proyecta un aumento de 0.82 °C para los años 2020-2039 y 1.63 °C para los años 2040-2059; se experimentan disminuciones significativas de precipitación en algunos estados del norte (Climate Risk Profile: México 2023).

Es bien conocido que la precipitación y temperatura influye directamente en la productividad de biomasa de los bosques, por ejemplo, la precipitación es crucial en la fisiología de las especies, influye directamente en la transpiración, la absorción de nutrientes, conductancia estomatal, disponibilidad de nutrientes (Bennett *et al.*, 2020; Cysneiros *et al.*, 2021) y en las estrategias de crecimiento; su disponibilidad y variabilidad afecta la eficiencia del uso del agua (Gao *et al.*, 2017; Yuan *et al.*, 2022), esto conlleva a

que la productividad de biomasa este en una relación directa con la precipitación (Arasa-Gisbert *et al.*, 2018).

Similarmente la temperatura influye en el crecimiento de las plantas afectando la fotosíntesis, la respiración y la transpiración (Guo *et al.*, 2019; Xin *et al.*, 2022). La temperatura, regula las reacciones químicas y las tasas de asimilación de CO<sub>2</sub> (Eamus, 2003). El aumento de la temperatura promueve el crecimiento de la biomasa en los bosques boreales y lo inhibe en los bosques tropicales (Liu *et al.*, 2013), pero también muy altas temperaturas reducen el crecimiento, alteran la pigmentación foliar, afectan el sistema radicular y provocan estrés hídrico alterando los patrones de crecimiento (Sim-Hee Han *et al.*, 2012). Las plantas de climas templados muestran cierta tolerancia al frío; pero temperaturas muy bajas afectan negativamente varios procesos, como la división celular, fotosíntesis, metabolismo en la respiración, disminución de su productividad (Devi *et al.*, 2023).

Por las variaciones climáticas, los bosques se están volviendo cada vez más dinámicos (Pan *et al.*, 2013), con ello, se modifica la composición de especies de los árboles en el ecosistema (Yuan *et al.*, 2022). Las alteraciones simultáneas en temperatura y precipitación conducen a una reducción/aumento en la biomasa de los ecosistemas, lo que influye en la configuración de la distribución de los bosques del mundo (Keith *et al.*, 2009).

Se ha demostrado que la biomasa aérea de los bosques está influenciada tanto positiva como negativamente por la temperatura (Guo *et al.*, 2019; He *et al.*, 2022; Chen *et al.*, 2023). Por otro lado, se ha encontrado que la precipitación se correlaciona positivamente con la biomasa aérea (Dai *et al.*, 2019; Xin *et al.*, 2022). Estos estudios se han realizado en bosques templados, tropicales y boreales (Liu *et al.*, 2013), e incluso a nivel de especie (Bennett *et al.*, 2020; Girón-Gutiérrez *et al.*, 2024) demostraron que, en 10 especies de coníferas, la precipitación se correlaciona positivamente ( $0 \leq \rho \leq 0.20$ ) con la densidad de biomasa aérea, mientras que la temperatura muestra una correlación negativa ( $-0.20 \leq \rho \leq 0$ ). No obstante, la literatura revela que la magnitud de la correlación de la biomasa aérea en los ecosistemas forestales depende de la escala (Reich *et al.*, 2014), del tipo de bosque (Guo *et al.*, 2019) y de la especie (Khan *et al.*, 2019; Xin *et al.*, 2022) entre otros.

Con base en lo expuesto anteriormente, el objetivo de este estudio fue desarrollar modelos bioclimáticos para evaluar cómo el cambio climático afecta la distribución geoespacial de la densidad de carbono de la biomasa viva aérea en los bosques de coníferas de México, se consideran cuatro escenarios climáticos posibles según las trayectorias de concentración representativas (RCP) 2.6, 4.5, 6.0 y 8.5 W/m<sup>2</sup>, proyectados para los años 2050 y 2070. Se hipotetiza que las proyecciones climáticas futuras afectaran significativamente la densidad de carbono de la biomasa aérea de los bosques de coníferas de México.

## REVISIÓN DE LITERATURA

### Bosques de coníferas en México

Los bosques de coníferas en México son frecuentes en zonas de clima templado y semi frío, presentando una amplia diversidad ecológica, los pinos en México se distribuyen de una manera restringida en el país, existen 35 especies del género *Pinus* representando el 37 % del total en el mundo, ocupando el 15 % de la superficie del territorio mexicano (Rzedowski, 2006).

Los bosques de pino abarcan alrededor de 5,238,681 ha caracterizándose con el 80 % del género *Pinus* spp los cuales se distribuyen en regiones montañosas del territorio mexicano, con temperaturas de 6° y 28° C y altitudes entre 1500 y 3000 msnm, de las especies presentes en el país algunas tienen un valor económico por su aprovechamiento maderable (Granados-Sánchez *et al.*, 2007).

De las seis familias de coníferas reconocidas a nivel mundial, cuatro están presentes en México, existen 94 especies de coníferas, 43 de las cuales son endémicas del país representando un 46 % del total, algunas de ellas se encuentran en peligro de extinción; entre estas, el género *Pinus* destaca con 22 especies endémicas, seguido de *Juniperus* con 10, *Abies* con 5, *Callitropsis* y *Picea* con tres cada una, Además, 18 especies endémicas tienen áreas de distribución restringidas a tres o menos estados (Gernandt y Pérez-De La Rosa 2014).

Por su riqueza estructural los bosques en México contribuyen en el almacenamiento y reserva de carbono, esto puede variar según el tipo de bosque, y aspectos como el clima, diversidad, topografía, suelo, pendiente y factores de perturbación (Arasa-Gisbert *et al.*, 2018).

Las reservas de carbono en México abarcan un rango del 20 t C/ha<sup>-1</sup> para parcelas del Inventario Nacional Forestal y Suelos y por debajo de 50 t C/ha<sup>-1</sup> de la densidad de carbono aérea en terrenos planos (Cartus *et al.*, 2014).

## Variables bioclimáticas

Las variables bioclimáticas demuestran ser una herramienta flexible para mapear la distribución de cualquier entidad, tienen la capacidad de predecir alteraciones ante el cambio climático, se obtuvieron 16 parámetros climáticos de estimaciones mensuales en función a temperatura y precipitación, con registros de valores medios estacionales y extremos que constituyen un perfil climático en Australia (Busby, 1991).

Las variables bioclimáticas son componentes cruciales en la investigación climática ya que abarcan factores como precipitación, temperatura y altitud. Estas variables desempeñan un papel importante en la predicción del clima y en la compresión de procesos ambientales según Fick y Hijmans (2017).

Fang *et al.* (2024) mencionan que variables como temperatura y precipitación determinan el crecimiento, adaptación y distribución de las plantas, incluyendo aquellas tolerantes a la sequía como la *Acacia senegal* (L.) Britton, ante escenarios climáticos SSP1-2.6, SSP2-4.5, SSP3-7.0 y SSP5-8.5 las variables Bio 3 (Isotermalidad), Bio 4 (Estacionalidad de la temperatura), Bio 11 (temperatura media del trimestre más frío) y Bio 12 (precipitación anual), destacan con la mayor importancia en la precisión en los modelos ecológicos.

Las variables climáticas desempeñan un papel fundamental al influir en la distribución de las plantas, y características de los ecosistemas, algunos estudios han identificado que variables climáticas como la temperatura media del trimestre más cálido, temperatura mínima del mes más frío, precipitación anual y precipitación de los trimestres más cálidos y fríos afectan en la vegetación (Wang-Jun 2016).

Xin *et al.* (2022) elaboraron modelos de biomasa para tres especies de coníferas (*Pinus koraiensis* Siebold & Zucc.) (*Larix olgensisi* A. Henry) (*Pinus sylvestris* var. *mongolica* Litv.), determinaron variables como el área basal y altura dominante, mediante estadísticas avanzadas evaluaron la eficacia del ajuste realizando la técnica de validación cruzada en los modelos, identificando las variables climáticas que contribuyen de manera

significativa a la biomasa de las especies de coníferas, obtuvieron como resultados que los modelos de biomasa que incluyeron variables climáticas tuvieron el mejor ajuste, además los autores encontraron que el efecto de las variables climáticas en los diferentes componentes de la biomasa de las coníferas era consistente en los coeficientes de regresión estimados por los modelos.

### **Selección de variables predictoras**

La selección de variables predictoras puede afectar significativamente el rendimiento de un modelo, por ello para seleccionar variables predictoras mediante el aprendizaje automático es fundamental considerar varios factores, como el impacto en el rendimiento del modelo y la transferibilidad (Solberg *et al.*, 2024). Se han utilizado métodos automatizados para la selección de variables climáticas que influyen en la distribución de las plantas, específicamente la temperatura media y la precipitación como factores influyentes (Wang-Jun 2016).

Los algoritmos de aprendizaje automático desempeñan un papel crucial en las predicciones espaciales, los que aprenden por conjuntos, como Random Forest (RF) y Machine learning suelen utilizarse para cartografiar atributos de los bosques debido a su capacidad de integrar varios modelos y mejorar la precisión en comparación con algoritmos individuales (López-Serrano *et al.*, 2020). Se han utilizado algoritmos de aprendizaje automático como Random Forest en estudios para predecir reservas de carbono en función de variables climáticas y del suelo, comprobando que pueden ser robustos y eficaces en el manejo de datos complejos, superando análisis de regresión simple y otras técnicas de aprendizaje automático para la estimación de biomasa forestal (Bennett *et al.*, 2020).

Luo *et al.* (2021) compararon tres algoritmos de aprendizaje automático: RFR, XGBoost y CatBoost, en la optimización de un modelo utilizaron un método de selección, evaluaron indicadores de precisión como  $R^2$ , RMSE, RMSE % y Bias, los resultados mostraron que

el algoritmo CatBoost fue el más preciso, con un RMSE de  $26.81 \text{ Mg/ha}^{-1}$  en la estimación de biomasa forestal aérea en bosques de coníferas en China.

### **Generación de modelos predictivos**

La generación de modelos predictivos implica la utilización de algoritmos avanzados como Random Forest, reconocidos por su robustez y eficiencia, variables como los rangos de temperatura y precipitación desempeñan un papel crucial en la estabilidad del modelo, garantizan una amplia variación en las variables independientes al mejorar su capacidad predictiva (Usoltsev *et al.*, 2020).

Arasa-Gisbert *et al.* (2018). mencionan que los modelos lineales generalizados (GLM) son una herramienta estadística utilizadas en varios campos de la investigación, ya que estos ofrecen un marco flexible para analizar datos, los cuales no cumplen con los supuestos de los modelos lineales tradicionales, los GLM son útiles cuando se abordan aspectos relacionados con variables de medición que se desvían de los requisitos de los modelos lineales.

Cartus *et al.*, (2014) prevén que la densidad total de carbono aéreo en los bosques de México sea de 2.21 Pg. C, un 30 % más que en el informe de la FAO 2010 con 1.69 Pg C.

### **Validación de modelos**

La validación cruzada por omisión (LOOCV) es una técnica que se utiliza para evaluar la precisión de los modelos predictivos al omitir sistemáticamente un conjunto de datos para su validación utilizando los datos restantes para el entrenamiento (Peng *et al.*, 2019).

La validación cruzada repetida es una técnica importante en la evaluación de los modelos ya que utiliza métricas como  $R^2$ , RMSE, RRMSE para evaluar el rendimiento del modelo, determinaron los hiperparámetros óptimos para el desarrollo del modelo, al combinar

estos enfoques los investigadores pueden mejorar la precisión y generalizar los modelos probándolos y refinándolos en diferentes conjuntos de datos conduciéndolos hacia predicciones más sólidas y confiables (He *et al.*, 2022).

Bennett *et al.* (2020) utilizaron la validación cruzada de K-fold con el 90 % de los datos para entrenamiento y el 10 % de prueba del modelo, evaluaron el rendimiento del modelo y el poder explicativo mediante el  $R^2$  como indicador de la influencia de la variable predictora de la AGB, dando los valores más altos de la  $R^2$  en los modelos con variables climáticas.

### **Predicciones actuales y futuras**

Guo *et al.* (2019) estimaron las densidades de carbono actuales y futuras (2050 y 2070) en escenarios climáticos RCP 2.6, RCP 4.5 y RCP 8.5, en cinco tipos de bosques a nivel mundial en respuesta a factores climáticos y del suelo, encontraron que los bosques tropicales tienen mayor densidad de carbono en comparación con los bosques boreales que presentan las más bajas en ambos escenarios, mientras que los bosques templados presentarían impactos positivos tanto en el 2050 y 2070, la temperatura media anual (MAT) tuvo diferentes efectos sobre la densidad total de carbono en diferentes bosques en el 2070.

En el período de 1971 a 2020, la temperatura media en México incrementó en 0.31 °C por década, con el cambio más pronunciado observado en la meseta del norte durante los meses de verano, bajo un escenario climático SSP3-7.0 se proyecta un aumento de temperatura media anual de 0.82 °C para los años 2020-2039 y 1.63 °C para los años 2040-2059 anticipándose que para este periodo el país presentara un mayor riesgo de calor extremo, las temperaturas más altas y la disminución de la precipitación reducirán la biomasa total neta en gran parte del país hacia finales del siglo, afectando la producción de cultivos, en consecuencia, la seguridad alimentaria (Climate Risk Profile; México 2023).

Heiderman y Kimsey (2023) desarrollaron modelos lineales mixtos generalizados para evaluar los impactos de las variables ambientales en el crecimiento y supervivencia de *Pseudotsuga menziesii* Mirb. y *Tsuga heterophylla* Raf. con bajo escenarios climáticos futuros RCP 4.5 y RCP 8.5 para los años 2050 y 2080, presentaron disminuciones del 5.4 y 11.4 % respectivamente en los bosques de *Pseudotsuga menziesii* Mirb Franco, mientras que en los bosques de *Tsuga heterophylla* Raf sería de un 6.6 y 8.9 % en el RCP 4.5 para el 2050 y RCP 8.5 para el 2080.

### **Estudios afines**

Reich *et al.* (2014) mencionan que la distribución global de la biomasa forestal varía en función de la temperatura y las precipitaciones, los bosques de Gimnospermas tienen una mayor biomasa de raíces en comparación con los bosques de Angiospermas, la relación de biomasa total con MAT fue positiva en 7 de 8 géneros boreales y templados fríos ( $-1^{\circ}\text{C} < \text{MAT} < 9^{\circ}\text{C}$ ) y una relación negativa en templados cálidos o subtropicales ( $13^{\circ}\text{C} < \text{MAT} < 21^{\circ}\text{C}$ ), además la temperatura media del trimestre más cálido del año y la precipitación total de este mismo trimestre se relaciona linealmente con MAT y MAP.

Rodríguez-Veiga *et al.*, (2016) estimaron la biomasa aérea (AGB) en los bosques mexicanos utilizando datos del Inventario Nacional Forestal y Suelos (INFyS) e imágenes de teledetección MODIS de vegetación, estratificando la base de datos en siete tipos de bosques, (perennifolio, caducifolio, mixto perennifolio y bosque tropical caducifolio) realizaron modelaciones en MaxEnt obtuvieron predicciones de  $180 \text{ t ha}^{-1}$ , los valores más altos de AGB por ha para México ocurren en altitudes, pendientes y precipitaciones más altas.

Chen *et al.*, (2023) crearon un modelo con el método bayesiano para predecir la biomasa aérea en bosques a nivel global en función de la edad, la predicción media anual (MAP) y la temperatura media anual (MAT), donde el bosque siempre verde de hoja ancha que presentó un aumento de AGB promedio más alto  $50,83 \pm 76,02 \text{ Mg ha}^{-1}$  mientras que para los bosques siempre verde de hoja acicular fue  $42,9 \pm 46,76 \text{ Mg ha}^{-1}$ , los efectos

MAT cuantifican los cambios en la tasa de acumulación de AGB por un cambio de 1 °C en MAT y acumulación inicial y saturada de AGB por un cambio de 1 mm en MAP.

Barreras *et al.* (2009) realizaron un mapeo y monitoreo de bosques en México utilizaron datos satelitales y técnicas de aprendizaje automático en predicciones generados por un modelo, los autores consideraron atributos de los bosques como altura y densidad de los árboles, los autores mencionan que este tipo de mapeos produce predicciones precisas con un  $r^2 = 0.35$  al predecir la altura de los árboles, para la densidad fue un  $r^2 = 0.23$  en bosques latifoliados y coníferos-latifoliados.

Pan *et al.*, (2013) mencionan que las herramientas digitales a escala global se volverán cada vez más poderosas para analizar cuestiones ecológicas importantes para el futuro, aunque actualmente la disponibilidad de imágenes tridimensionales a gran escala permite mapear la estructura forestal no existe ningún sistema satelital que proporcione información suficiente para este tipo de tareas, así como la capacidad para utilizar plenamente la información enfocada a la necesidad que exista para mapear la estructura forestal y comprender la distribución de los bosques y su impacto con el cambio climático.

Liu *et al.* (2014) utilizaron el mapa de las zonas ecológicas globales por la FAO (2001) para su clasificación, que se compone de bosques boreales, templados, subtropicales y tropicales en 897 sitios forestales, los autores realizaron una regresión obteniendo como resultados que a nivel global la densidad de carbono de la biomasa aérea (DCBVA) más alto se encuentran en los bosques maduros con temperaturas medias anuales de 8 a 10 °C y precipitaciones media anual de entre 1000 y 2500 mm en bosques con edades de 80 y 450.

Stegen *et al.* (2011) desarrollaron un modelo analítico para la variación de la biomasa en los bosques globales, encontrando que la correlación entre la biomasa forestal y la precipitación del trimestre más seco no fueron significativas, sin embargo, aumento con la precipitación del trimestre más seco en los bosques templados ( $R^2 = 0.2$ ,  $P = 0.009$ ) y tropicales secos ( $R^2 = 0.33$ ,  $P = 0.001$ ), los resultados mostraron que existe una fuerte

correlación positiva entre la biomasa del bosque, temperatura y precipitación anual, los autores encontraron que los bosques tropicales albergan más de la mitad de la biomasa mundial almacenada en la vegetación terrestre sin embargo los bosques boreales y templados también son importantes reservas de biomasa.

Ma *et al.*, (2023) evaluaron la relación entre características estructurales de los rodales y la biomasa aérea en bosques (AGB) en 25 países y el impacto del clima en estas relaciones, para ello realizaron una transformación logarítmica de cada variable ajustándola a una distribución normal, mediante una regresión lineal múltiple (MLR), los autores analizaron el MAT y MAP y las características estructurales de los rodales utilizando el factor de inflación de varianza ( $VIF > 10$ ), encontraron una correlación positiva ( $P < 0.05$ ) entre las estructuras del rodal y factores climáticos indican la influencia entre el área basal (BA) y AGB en relación al clima como MAT ( $r = 0.262$ ,  $p < 0.01$ ) y MAP ( $r = 0.231$ ,  $p < 0.05$ ), en el bosque templado estacional.

Luo *et al.*, (2021) emplearon algoritmos de aprendizaje automático y técnicas de selección de variables para mejorar la precisión de la estimación de la biomasa aérea (AGB) utilizando datos de teledetección, los autores compararon varios modelos seleccionados por diferentes métodos de selección de variables, este estudio demuestra que se pueden usar algoritmos de aprendizaje automático y técnicas de selección de las mejores variables para mejorar la precisión de la estimación de la biomasa aérea (AGB) utilizando datos de teledetección, además muestra que el algoritmo CatBoost es ligeramente superior al XGBoost.

Las altas temperaturas reducen las tasas de crecimiento en el desarrollo de las plantas, alterando la pigmentación en las hojas, aumentando la actividad de las enzimas antioxidantes, afectan el crecimiento de las raíces lo que provoca restricciones en la absorción de nutrientes provocando estrés en el desarrollo de los árboles, afectan también procesos como la fotosíntesis, transpiración y conductancia en los estomas, el aumento de la temperatura provoca el estrés hídrico, alteran los patrones de crecimiento y asignación de los recursos disponibles en el suelo (Sim-Hee Han, 2012).

Las plantas tropicales y subtropicales son sensibles a las bajas temperaturas, mientras que las plantas de climas templados muestran grados variables de tolerancia al frío, las bajas temperaturas afectan negativamente varios procesos en las plantas, como en la división celular, fotosíntesis, metabolismo en la respiración, reducen su productividad en las plantas, las raíces pueden restringir la absorción del agua como mecanismo de tolerancia al estrés por las bajas temperatura similar al de la sequía (Devi *et al.*, 2023).

La precipitación desempeña un papel crucial en aspectos fisiológicos del desarrollo de los árboles afectan la transpiración, adquisición de nutrientes y estrategias de crecimiento, la variabilidad en las precipitaciones afecta la eficiencia del uso del agua por parte de los árboles durante las altas tasas de transpiración durante periodos secos (Gao *et al.*, 2017). La mayoría de las plantas requieren un rango de temperatura óptimo para su crecimiento y desarrollo, al aproximarse a los límites de este rango, el crecimiento puede detenerse, disminuir o incluso llevar a la muerte de la planta, el aumento de la temperatura puede favorecer el crecimiento arbóreo al extender su período de crecimiento y aumentar la mineralización del nitrógeno, aunque estos efectos varían significativamente según la región y la especie del árbol (Sim-Hee Han, 2012).

## MATERIALES Y MÉTODOS

### **Descripción del área de estudio**

Las coníferas en México se encuentran desde el nivel del mar hasta por encima de los 4,000 m de altitud, concentrándose la mayor diversidad en la Sierra Madre Occidental (SMOc) y la Sierra Madre Oriental (SMO), así como en otros sistemas montañosos como la Península de Baja California y las Sierras del Norte de México; México alberga 49 especies de pino, lo que representa el 40 % de las aproximadamente 120 especies de pino en el mundo (Gernandt y Pérez-De La Rosa, 2014). Abarcan aproximadamente desde los 32°N de latitud norte hasta los 19°N, y desde los 105°W de longitud oeste hasta los 98°W, sobre suelos derivados de rocas ígneas y metamórficas (Rzedowski y Huerta, 2006). Estos ecosistemas se caracterizan por tener un clima templado a semi frío, con precipitaciones anuales de 350 a 1200 mm y temperaturas medias que oscilan entre los 6 y 28° C (Granados-Sánchez *et al.*, 2007), con veranos lluviosos e inviernos secos y fríos, cuya vegetación está dominada por coníferas como pinos (*Pinus spp.*), abetos (*Abies spp.*), cedros (*Cupressus spp.*) y enebros (*Juniperus spp.*) (Challenger, 1998).

### **Proceso de adquisición y limpieza de Datos**

Un total de 22 parámetros de tipo, topográfico, riqueza de especies, biomasa y carbono (aéreo y subterráneo), índices de sanidad, clima, geográfica y dasométricas, fueron obtenidas de (Arasa-Gisbert *et al.*, 2018). De ella, utilizamos los datos de densidad de carbono en la biomasa viva aérea (*DCBVa*), coordenadas geográficas (lat, long) y ID de cada conglomerado, exclusivamente del parámetro type= “bosques de coníferas”. La densidad de carbono de la biomasa viva aérea (*DCBVa*), es carbono total de la biomasa por unidad de área, de la biomasa viva contenida en los árboles vivos, incluidos tallos, ramas, hojas, semillas (IPCC, 2003). Los datos obtenidos corresponden a información del inventario Forestal Nacional y Suelos (INFyS) de México (2009-2012). Además, utilizamos 19 variables bioclimáticas de WorldClim versión 2.0, correspondientes al período de 1970 a 2000 (Apéndice B), en formato *raster* con una resolución de 30

arcseconds, publicadas en enero de 2020 (Fick y Hijmans, 2017), estas variables han sido utilizadas previamente en estudios similares (Liu *et al.*, 2013; Reich *et al.*, 2014; Bennett *et al.*, 2020; Cysneiros *et al.*, 2021; Xin *et al.*, 2022; Li *et al.*, 2022).

Se utilizó la librería '*raster*' de R (Hijmans, 2010), empleando las coordenadas geográficas de cada conglomerado para extraer los valores de las 19 variables bioclimáticas (Bio). Para identificar datos erróneos o atípicos en *DCBVa*, aplicamos un análisis de componentes principales (PCA) a la matriz centrada y escalada de *DCBVa* y 19 Bios, se utilizó la librería '*FactoMineR*' v.2.9 (Lê *et al.*, 2008). Se consideran como datos atípicos aquellos que quedan fuera de la elipse del PCA al 95 %, mismos que fueron excluidos de la base de datos para asegurar la coherencia y fiabilidad de los resultados.

### **Modelado predictivo de DCBVa**

Debido a la gran variabilidad climática registrada en los bosques de coníferas del país (Rzedowski y Huerta, 2006), y con el objetivo de mejorar las predicciones de *DCBVa*, se realizó una estratificación bioclimática de las áreas de los bosques de coníferas en México. Para ello utilizamos las 19 variables bioclimáticas en formato ráster, utilizando la librería "GeoStratR" (Bivand, 2022), creando estratos (espacio geográfico) en el mismo formato. Los conglomerados del INFyS ubicados en cada estrato generado, se separaron para ser analizados de manera independiente.

Para la selección de predictores (Bios) de *DCBVa*, en cada estrato, se empleó la técnica de '*machine learning*' (ML) usando validación cruzada con k folds=10, empleando la técnica de selección hacia atrás (backward selection). Se utilizó una cuadrícula de ajuste (tuneGrid) que consideró de 1 a 7 predictores (nvmax = 1:7) (Kuhn, 2008). De cada subset de predictores arrojados por ML, se evaluó la significancia estadística de los coeficientes de regresión ( $p < 0.05$ ) y el factor de inflación de la varianza (VIF) a fin de evitar efectos de multicolinealidad.

Con el subset de predictores que cumplió estos criterios, el modelo fue entrenado utilizando el método de Modelos Lineales Generalizados (glm) con la función de enlace "identity". Para ello se utilizó 80 % de datos (obtenidos aleatoriamente y por cuantiles) de la matriz limpiada anteriormente. Este enfoque (glm), es apropiado para variables de respuesta continuas y positivas (Arasa-Gisbert *et al.*, 2018; Cysneiros *et al.*, 2021), en este tipo de estudios. El ajuste del modelo se realizó utilizando la librería 'caret' de R (Kuhn, 2008). Se utilizaron pruebas de Hipótesis ( $\alpha = 0.05$ ) sobre los coeficientes de regresión ( $H_0 : \beta_i = 0$  vs  $H_1 : \beta_i \neq 0, \dots, \beta_{ij}$ ) del modelo final. Usamos la métrica "lmg", para calcular la importancia de cada variable bioclimática (como porcentaje de lo que explica el modelo), que proporciona una descomposición de la varianza explicada en el modelo en contribuciones no negativas (Grömping, 2006).

Con el 20 % de los datos restantes, el modelo fue validado usando diferentes técnicas: Validación Cruzada por omisión (LOOCV), Validación Cruzada (CV; k=10), Validación Cruzada Repetida (RCV, k=10, rep=10) y Bootstrap (reps=100), calculando: raíz del error cuadrático medio, (RMSE), coeficiente de determinación ( $R^2$ ) y error cuadrático medio (MAE) para evaluar el rendimiento del modelo, también usando la librería de R 'caret' (Kuhn, 2008).

### **Predicción actual, futura y tasa de cambio de DCB<sub>Va</sub>**

Con los modelos bioclimáticos generados, se realizaron predicciones actuales de *DCB<sub>Va</sub>* en cada estrato, empleando los predictores bioclimáticos correspondientes. Se utilizó la librería *raster* del software R (Hijmans, 2010) con el argumento type = "response", para generar mapas ráster de predicciones de *DCB<sub>Va</sub>*.

Para predecir la *DCB<sub>Va</sub>* futura, se obtuvieron capas ráster de 3 diferentes Modelos de Circulación General (GCM): MIROC-6, GISS-E2 y CMCC-ESM2, eligiendo de ellos, únicamente los predictores bioclimáticos de la *DCB<sub>Va</sub>* para cada estrato. Los GCM provienen de proyecciones climáticas futuras del Proyecto de Intercomparación de modelos acoplados fase 5 (CMIP5), a una resolución de 2.5 grados. Se usaron cuatro

Trayectorias de Concentración Representativas (RCP) desarrolladas por el Panel Intergubernamental sobre el Cambio Climático (IPCC, 2013), las cuales se caracterizan por su Forzamiento Radiativo (FR) total proyectado para el año 2100, oscilando entre 2.6, 4.5, 6.0 y 8.5 W/m<sup>2</sup>. considerando los años 2050 y 2070. Estos escenarios RCP se utilizan para proyectar posibles trayectorias futuras del cambio climático, en función de diferentes niveles de emisiones y esfuerzos de mitigación.

A través del álgebra de *rasters*, se promediaron las 3 capas ráster de cada GCM, RCP y año. Con el promedio, se realizó la predicción futura de la *DCBVA* para cada estrato. Similarmente se utilizó la librería ráster R (Hijmans, 2010), argumento type = "response", para generar mapas ráster de predicciones futuras de *DCBVA*. Para identificar los cambios en la *DCBVA* futura con respecto al escenario actual, se utilizó la siguiente expresión: *DCBVA* (futura) – *DCBVA* (actual). Los resultados resultan: 0, si los valores de los píxeles son iguales en ambos escenarios; positivos, si la *DCBVA* es mayor en el futuro; y negativa, si la *DCBVA* es mayor en el escenario actual.

Para visualizar las áreas de bosques de coníferas de México vulnerables a los cambios en *DCBVA*, debido al cambio climático, se generó un buffer de 40 km de radio alrededor de cada sitio del Inventario Nacional Forestal y de Suelos (INFyS). Esto permitió delimitar las áreas boscosas que podrían verse potencialmente afectadas. Posteriormente, se cuantificó el número de píxeles de cada categoría o tasa de cambio de la *DCBVA* dentro de estos polígonos buffer. El resultado de esta ecuación (tasa de cambio) fue presentada en forma de mapa, para cada RCP y año.

En adición, la incertidumbre en las predicciones futuras de la *DCBVA* se cuantificó utilizando el error estándar:  $(EE(\theta) = \sqrt{[Var(\theta)]})$ . Para ello se utilizó como repetición las predicciones de *DCBVA* de: MIROC-6 + GISS-E2 + CMCC-ESM2, en cada RCP y año, las cuales fueron promediadas utilizando la librería “*raster*” (Hijmans, 2010) y calculando y generando un mapa ráster de  $EE(\theta)$ .

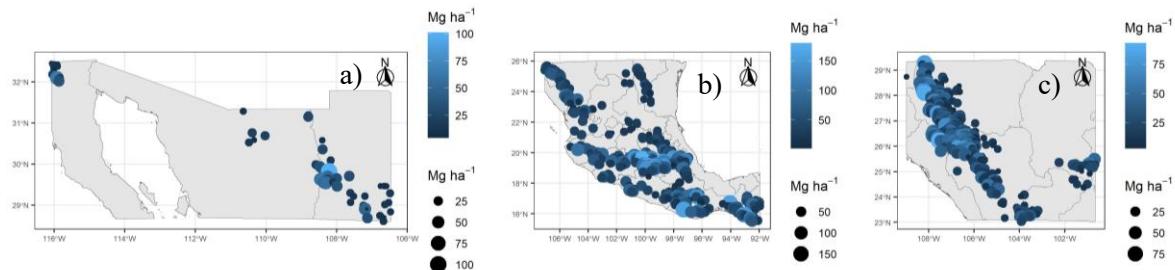
## Predictores Bioclimáticos: Análisis Actual y Proyecciones Futuras

Con el objetivo de determinar la influencia de los predictores bioclimáticos futuros en los cambios de *DCBVa* de los bosques de México, se empleó la prueba no paramétrica de Wilcoxon, o prueba de rangos con signo. Esta prueba se utilizó para evaluar si existen diferencias significativas entre las medianas de dos muestras: el predictor bioclimático actual y el predictor bioclimático futuro (e. g., Bio 1 actual vs. Bio 1 2050, RCP 4.0). Se utilizó un nivel de significancia del 95 %. Para ello, se extrajeron los valores actuales y futuros (promedio de 3 MCG, RCP y año) de los predictores de cada estrato (Bios), utilizando las coordenadas geográficas de cada conglomerado y empleando la librería *raster* (Hijmans, 2010). Estos análisis fueron representados en gráficas de violín, mostrando en color naranja las Bios derivadas de temperatura y en azul las Bios derivadas de precipitación, con la significancia estadística indicada con el símbolo \* en la parte superior.

## RESULTADOS Y DISCUSIÓN

### Distribución de la densidad de carbono de la biomasa viva aérea

El proceso de estratificación de los bosques de coníferas de México generó tres estratos: estrato I noroeste del país (Fig. 1a; n = 60), estrato II centro-sur del país (Fig. 1b; n = 450) y estrato III, ubicado en la Sierra Madre Occidental, SMO (Fig. 1c; n = 463).



**Figura 1.** Distribución de los sitios del Inventario Nacional Forestal y de Suelos (2009 - 2012), estrato I (a), estrato II (b) y estrato III (c). Tamaño de los círculos y color de la rampa, indican los valores de la densidad de carbono de la biomasa viva área ( $Mg C ha^{-1}$ ).

### Modelos para la predicción de la densidad de carbono de biomasa viva aérea

Las variables bioclimáticas seleccionadas por los algoritmos resultaron estadísticamente significativas ( $p < 0.05$ ) para predecir la  $DCBVa$ . Los predictores (Bios) de  $DCBVa$  fueron representativos tanto de variables de precipitación (3 de 6) como de temperatura (3 de 6); aunque a nivel de estrato, las variables de temperatura son más importantes (Imp., Tabla 1) que las variables de precipitación. Bio 5 (Temperatura máxima del mes más cálido) fue el mejor predictor de  $DCBVa$  en 2 estratos (I y II). Ningún modelo presentó multicolinealidad ( $VIF < 1.16$ ), lo que hace que no se sobreestimen las predicciones de  $DCBVa$ .

**Tabla 1.** Coeficientes de regresión para la predicción de la densidad de carbono de la biomasa viva aérea por estrato, en los bosques de coníferas de México.

Estrato	Coeficiente	Estimador			Std. Err	T value	Pr (> t )	Residual deviance	VIF	Imp. (%)
			2.5	97.5						
I n=48	$\beta_0$ (intercepta)	64.8332	22.7606	97.3943	23.2221	2.79	0.00772 **			
	$\beta_1$ ( <b>Bio 5</b> )	-0.1897	-0.2932	-0.0544	0.0737	-2.57	0.01355 *	13.246	1.02	10.33
	$\beta_2$ ( <b>Bio 18</b> )	0.0586	0.0337	0.0829	0.0123	4.77	2.02e-05 ***		1.02	8.74
II n=360	$\beta_0$ (intercepta)	87.6362	66.3661	108.9076	10.4558	8.38	1.22e-15 ***			
	$\beta_1$ ( <b>Bio 5</b> )	-0.2572	-0.3296	-0.1841	0.0376	-6.84	3.37e-11 ***	172.17	1.03	8.04
	$\beta_2$ ( <b>Bio 12</b> )	0.0190	0.0106	0.0272	0.0037	5.12	4.91e-07 ***		1.03	3.35
III n=370	$\beta_0$ (intercepta)	26.6379	12.3682	40.4383	8.4994	3.13	0.00186 **			
	$\beta_1$ ( <b>Bio 10</b> )	-0.0959	-0.1571	-0.0293	0.0391	-2.45	0.01461 *	132.39	1.16	3.28
	$\beta_2$ ( <b>Bio 13</b> )	0.0933	0.0708	0.1160	0.0135	6.93	1.8e-11 ***		1.16	14.95

Donde:  $\beta_0$ ,  $\beta_1$  y  $\beta_2$  = son los coeficientes de regresión; 2.5 y 97.5: intervalos de confianza de los coeficientes de regresión al 95 %; Std. Err: error estándar de los coeficientes de regresión; VIF: factor de la inflación de la varianza; Imp = valor de importancia de las variables. Bio 05: temperatura máxima del mes más cálido (°C); Bio 10: Temperatura media del trimestre más cálido (°C); Bio 12: precipitación media anual (mm); Bio 13: Precipitación del mes más lluvioso (mm); Bio 18: precipitación del trimestre más cálido (mm). Significancia estadística: "\* p < 0.05": Significativo; "\*\*\* p < 0.01": Altamente significativo; "\*\*\*\* p < 0.001": Muy altamente significativo.

Bio 1: temperatura media anual (°C); Bio 2: rango medio diurno (temp max- temp min) (°C); Bio 3: isothermalidad (Bio02/Bio07) ( $\times 100$ ) (%); Bio 4: estacionalidad de la temperatura (desviación estándar  $\times 100$ ) (%); Bio 5: temperatura máxima del mes más cálido (°C); Bio 6: temperatura mínima del mes más frío (°C); Bio 07: rango anual de la temperatura (Bio5–Bio6) (°C); Bio 8: temperatura media del trimestre más húmedo (°C); Bio 9: temperatura media del trimestre más seco (°C); Bio 10: temperatura media del trimestre más cálido (°C); Bio 11: temperatura media 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 (Coeficiente de variación) (%); Bio 16: precipitación del trimestre más húmedo (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).

Las ecuaciones para la estimación de la *DCBVa* en cada estrato quedaron de la siguiente manera:

$$\text{Estrato I: } DCBVa \text{ (Mg C ha}^{-1}\text{)} = 64.8332 + -0.1897 * \text{Bio 5 (}^{\circ}\text{C x10)} + 0.0586 * \text{Bio 18 (mm)}$$

Ec. 1

$$\text{Estrato II: } DCBVa \text{ (Mg C ha}^{-1}\text{)} = 87.6362 + -0.2572 * \text{Bio 5 (}^{\circ}\text{C x10)} + 0.0190 * \text{Bio 12 (mm)} \text{ Ec. 2}$$

$$\text{Estrato III: } DCBVa \text{ (Mg C ha}^{-1}\text{)} = 26.6379 + -0.0959 * \text{Bio 10 (}^{\circ}\text{C x10)} + 0.0933 * \text{Bio 13 (mm)} \text{ Ec. 3}$$

La media de la *DCBVa* no sigue un patrón entre estratos; es decir, no es menor en estrato I y mayor en estrato III. La media de *DCBVa* en el estrato II representa en promedio hasta 1.6 veces más que en el estrato I y III; y varía desde 23.14 Mg C ha<sup>-1</sup> (estrato I) hasta 42.57 Mg C ha<sup>-1</sup> (estrato II), con máximos de hasta casi 180 Mg C ha<sup>-1</sup> (Tabla 2) pero también es la que posee la mayor variabilidad (CV >60 %). Ninguna de las variables mostró normalidad ( $p < 0.0001$ ) acorde a las pruebas de Shapiro-Wilk y Anderson-Darling (Tabla 2).

**Tabla 2.** Estadísticas descriptivas de la densidad de carbono de la biomasa viva aérea observada y de sus predictores (periodo de 1950-2000), en los bosques de coníferas de México.

Estrato	Variable	n	Min	P25	Media	Mediana	P75	Max	SD	CV	Shapiro p-value	Anderson p-value
I	<i>DCBVA</i>		4.23	11.54	23.14	16.23	33.35	62.05	15.04	65	0.0001	0.0001
	Bio 5	48	27.7	28.7	29.97	29.6	30.75	36	1.76	5.89	0.0001	0.0001
	Bio 18		62	223	256.89	290	330.5	397	101.66	39.57	0.0001	0.0001
II	<i>DCBVA</i>		4.46	19.87	42.57	34.35	54.75	179.69	33.01	77.54	0.0001	0.0001
	Bio 5	360	17.5	22.78	25.72	25.3	28.7	34.6	3.93	15.28	0.0001	0.0001
	Bio 12		426	895.25	1109.42	1092	1314.25	2216	367.25	33.1	0.0001	0.0001
III	<i>DCBVA</i>		3.15	12.76	26.26	23.24	35.98	92.92	16.56	63.05	0.0001	0.0001
	Bio 10	370	14.7	17.4	18.55	18.3	19.4	26.3	1.74	9.39	0.0001	0.0001
	bio13		53	154	184.03	181	219	357	52.54	28.55	0.0001	0.0001

Donde: DCBVA: Densidad de Carbono de Biomasa Viva Aérea observada ( $\text{Mg C ha}^{-1}$ ); Bio 5: temperatura máxima del mes más cálido ( $^{\circ}\text{C}$ ); Bio 18: precipitación del trimestre más cálido (mm); Bio 12: precipitación anual (mm); Bio 10: temperatura media del trimestre más cálido ( $^{\circ}\text{C}$ ); Bio 13: precipitación del mes más lluvioso (mm); n = número de sitios en el estrato; Min: valor mínimo; P25 y P75: percentil 25 y 75; Max: valor máximo; SD: desviación estándar; CV: coeficiente de variación (%).

**Validación de modelos predictivos de la densidad de carbono de biomasa viva área**  
Acorde a la pseudo  $R^2$ , derivada del procedimiento de validación, las variables bioclimáticas explican en promedio 19% de la *DCBVA* (Tabla 3). El método LOOCV es el que calcula una  $R^2$  más baja (0.10), mientras que el resto de los métodos arrojan un promedio de  $R^2$  de 0.22 acorde a la validación, al usar los modelos para predecir *DCBVA* con datos independientes a los de entrenamiento, los errores de estimación (RMSE) podrían ser desde 13.18  $\text{Mg C ha}^{-1}$  (estrato III) hasta 42.42  $\text{Mg C ha}^{-1}$  (estrato I), observando las mejores estimaciones en el estrato III.

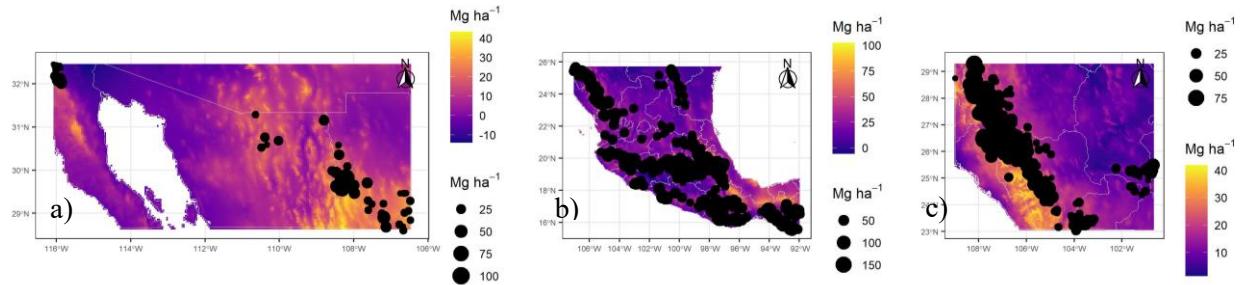
**Tabla 3.** Validación de los modelos de regresión para la predicción de la densidad de la biomasa viva aérea en los bosques de coníferas en México.

Estrato	Método	Set	n	Pseudo R <sup>2</sup>	RMSE	MAE
I	Entrenamiento		48			
	LOOCV	Validación	12	0.031	38.319	30.806
	CV	Validación	12	0.177	29.908	29.379
	RCV	Validación	12	0.177	31.949	31.272
Bootstrap		Validación	12	0.316	42.426	34.457
II	Entrenamiento		360			
	LOOCV	Validación	90	0.128	29.938	21.789
	CV	Validación	90	0.249	28.493	21.720
	RCV	Validación	90	0.246	28.620	21.685
Bootstrap		Validación	90	0.150	30.107	22.302
III	Entrenamiento		370			
	LOOCV	Validación	92	0.153	13.887	10.699
	CV	Validación	92	0.231	13.181	10.543
	RCV	Validación	92	0.238	13.330	10.600
Bootstrap		Validación	92	0.192	14.175	10.986

Donde: LOOCV: validación cruzada por omisión CV: validación cruzada, RCV: validación cruzada repetida; n: tamaño de muestra; R<sup>2</sup>: coeficiente de determinación; RMSE: raíz del error cuadrático medio; error medio absoluto.

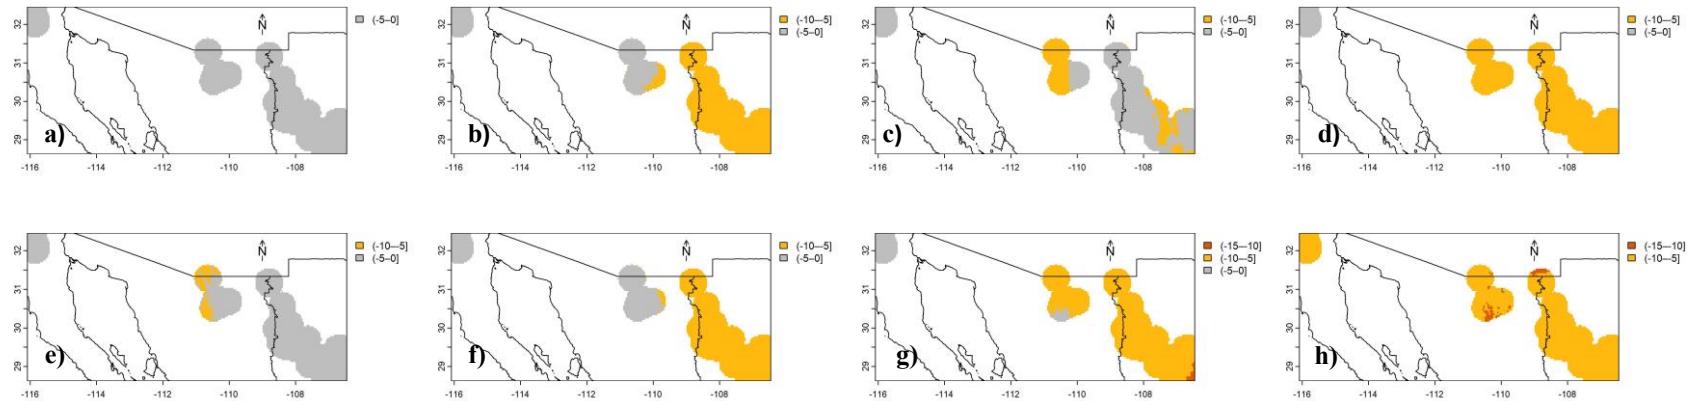
### **Predicción actual y futura de la densidad de carbono de biomasa viva aérea**

Usando los modelos generados aquí, en los sitios del INFyS, se predicen desde 7.48 hasta 34.79 Mg C ha<sup>-1</sup>; desde 16.68 hasta 71.29 Mg C ha<sup>-1</sup> y desde 10.98 hasta 41.91 Mg C ha<sup>-1</sup>, para los estratos I, II y III respectivamente (Figura 2a-2c). La mayor DCBVA se observa/predice en estrato II (Figura 2b) en el centro del país. Las diferencias más altas entre DCBVA observada – estimada, son de -19 y +30; -52 y +124; -29 y +56 Mg C ha<sup>-1</sup>, respectivamente.

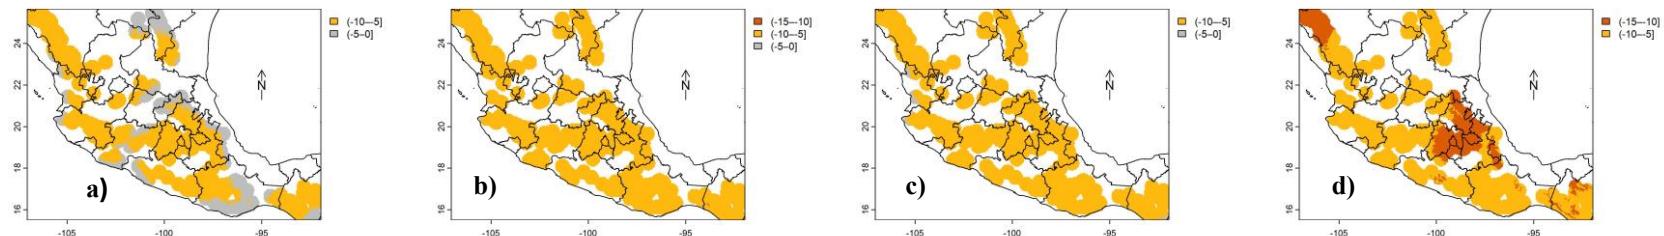


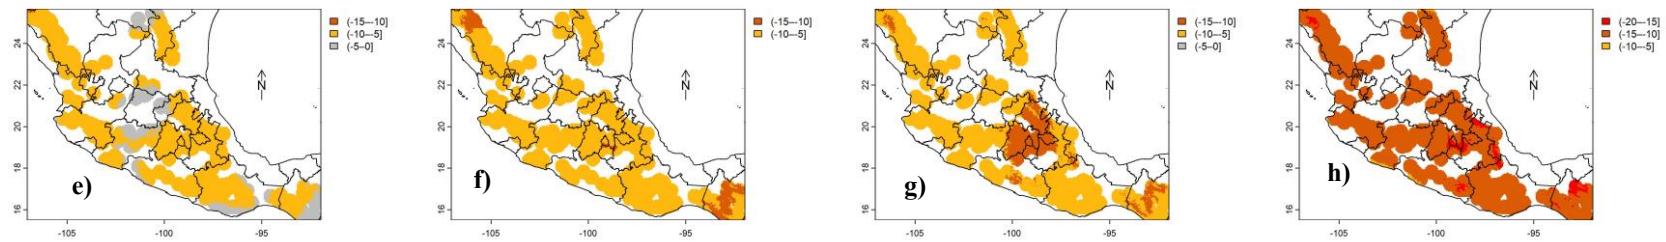
**Figura 2.** Predicción actual de la densidad de carbono de la biomasa viva aérea, en bosques de coníferas México, a través de modelos bioclimáticos: estrato I (a), estrato II (b), estrato III (c). Tamaño de los círculos y color de la rampa, indican los valores de la densidad de carbono de la biomasa viva área ( $Mg\ C\ ha^{-1}$ ).

Acorde a las predicciones futuras al 2050 y 2070 (Figs. 3-5) con el modelo bioclimático de cada estrato (ecuaciones 1-3), ante cualquier escenario climático (RCP), solo se esperan pérdidas de  $DCBVA$ . Los bosques ubicados en estrato II (Fig. 4a - 4h, centro y sur del país), serían los más afectados, con disminuciones de entre -5 y -10  $Mg\ C\ ha^{-1}$ , incluso de hasta -20  $Mg\ C\ ha^{-1}$  al 2070, mientras que los menos afectados serían los del estrato III (Figs. 5a – 5h. SMO) con pérdidas entre 0 y -5  $Mg\ C\ ha^{-1}$ . Las pérdidas de  $DCBVA$  más significativas ocurrirían en el RCP8.5 y se espera sean más en 2070.

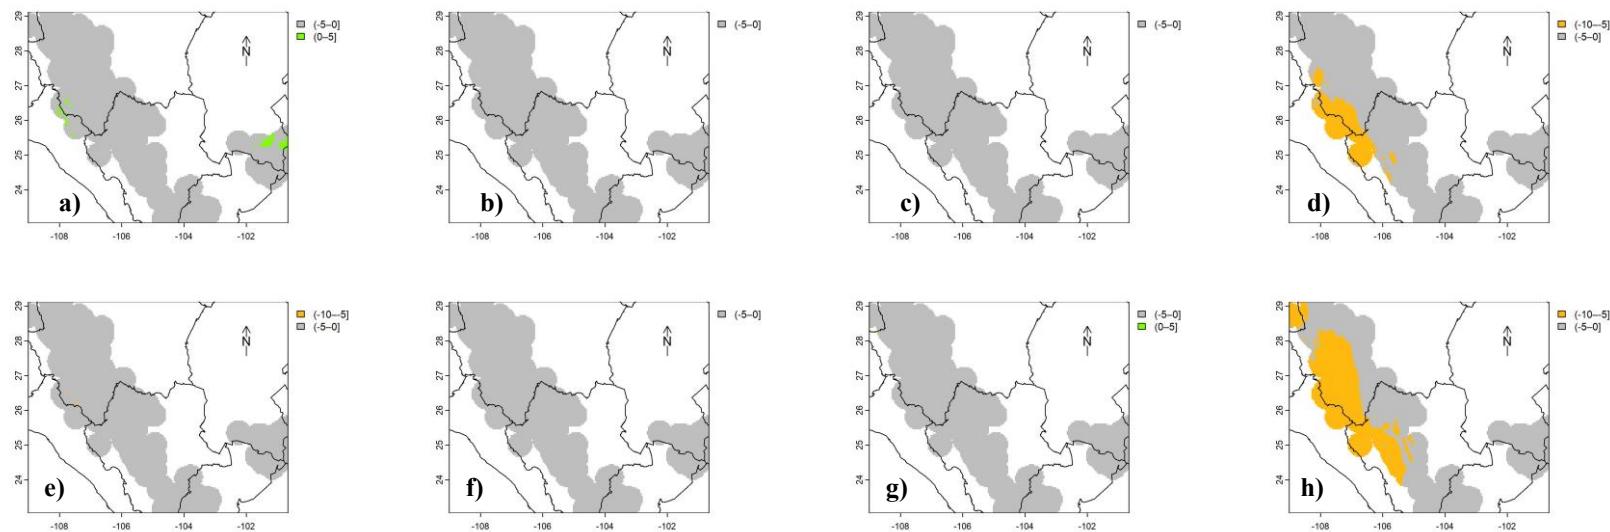


**Figura 3.** Cambios en la densidad carbono de biomasa viva aérea en bosques de coníferas de México, bajo los escenarios RCP 2.6 al 8.5 (de izquierda a derecha), para los años 2050 (arriba) y 2070 (abajo), en el estrato I. Áreas coloreadas representan buffers de 40 km de radio alrededor de cada sitio del INFyS; áreas sin relleno de color, corresponden a zonas no boscosas.





**Figura 4.** Lo mismo que figura 3, pero para el estrato II.



**Figura 5.** Lo mismo que figura 3, pero para el estrato III.

**Tabla 4.** Número de pixeles contenidos en el buffer de 40 km de radio alrededor de cada sitio de muestreo del INFyS para diferenciar cambios en la densidad de la biomasa viva aérea en los bosques de coníferas de México, ante escenarios climáticos futuros. Cada píxel mide 0.98 x 0.98 km de cada lado.

<b>Estrato</b>	<b>Cambios en</b>	<b>RCP26</b>		<b>RCP45</b>		<b>RCP60</b>		<b>RCP85</b>	
	<i>DCBVa</i>	<b>2050</b>	<b>2070</b>	<b>2050</b>	<b>2070</b>	<b>2050</b>	<b>2070</b>	<b>2050</b>	<b>2070</b>
I	(-20 --15	0	0	0	0	0	0	0	0
	(-15 --10	0	0	0	0	0	35	0	107
	(-10 --5	0	240	2361	2280	906	2885	3011	3180
	(-5 --0	3287	3047	926	1007	2381	367	276	0
	(0 --5	0	0	0	0	0	0	0	0
II	(-20 --15	0	0	0	0	0	0	0	1148
	(-15 --10	0	30	6	1526	0	3928	4796	22466
	(-10 --5	17750	19473	23821	22317	23571	19912	19047	229
	(-5 --0	6093	4340	16	0	272	3	0	0
	(0 --5	0	0	0	0	0	0	0	0
III	(-20 --15	0	0	0	0	0	0	0	0
	(-15 --10	0	0	0	0	0	0	0	0
	(-10 --5	0	6	0	0	0	0	1290	3281
	(-5 --0	9680	9819	9825	9825	9825	9822	8535	6544
	(0 --5	145	0	0	0	0	3	0	0

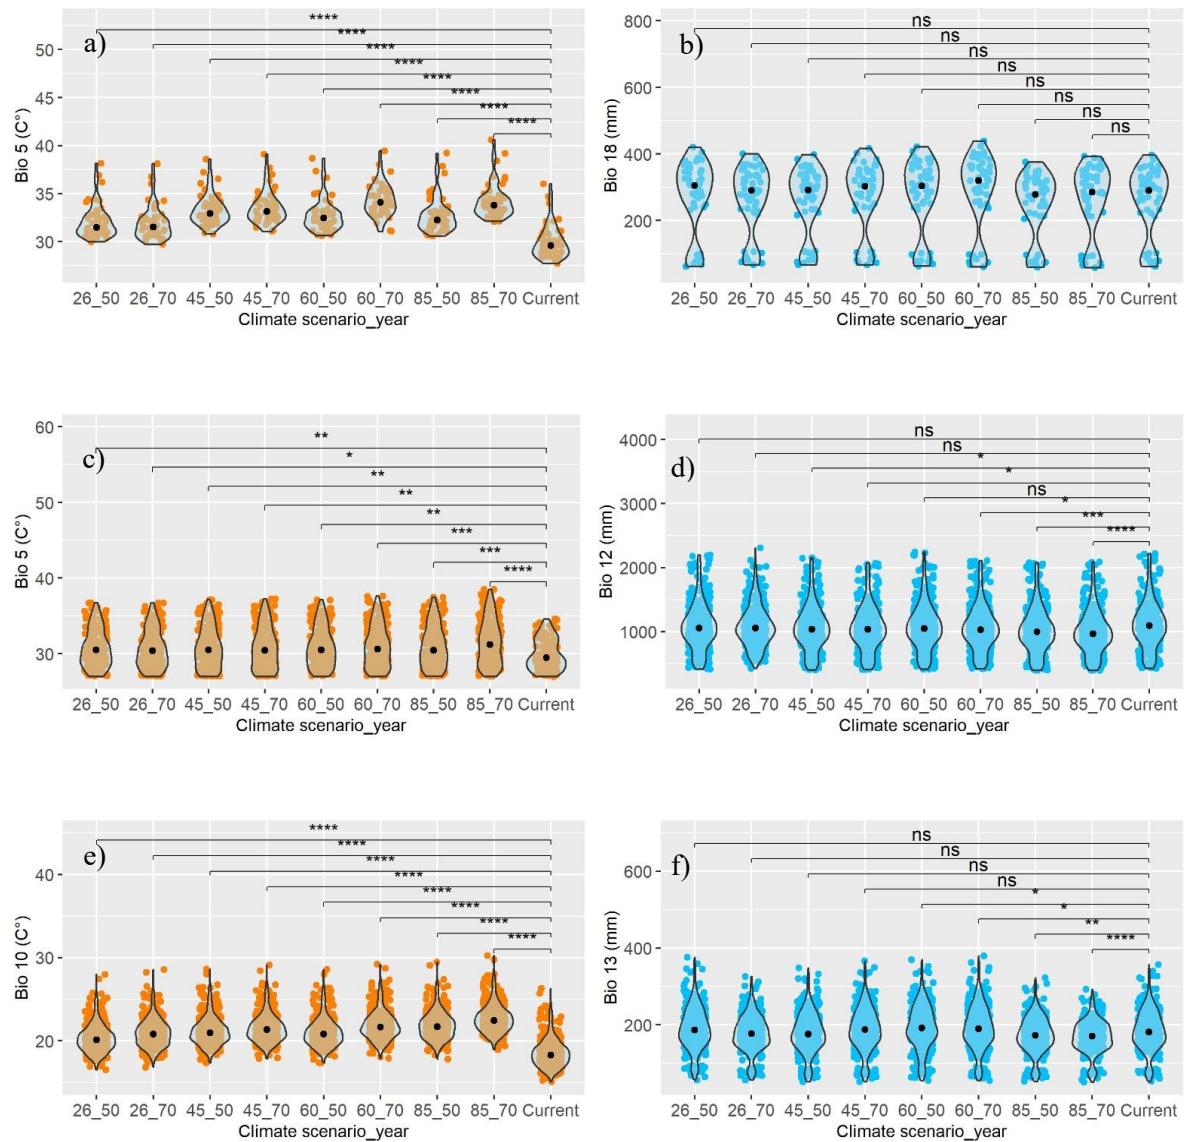
Donde: Densidad de Carbono de Biomasa Viva Aérea observada ( $\text{Mg C ha}^{-1}$ ); RCP = rutas representativas de concentración. Color del cuadro en columna dos, corresponde al color del píxel de las figuras 3-5.

### Evaluación de proyecciones climáticas en variables que predicen DCBVa en bosques de coníferas de México

La prueba de Wilcoxon mostró evidencias suficientes ( $p<0.0001$ ) para rechazar la  $H_0$  de igual de medianas entre la Bio actual y la misma Bio ante un escenario climático futuro. En todos los casos, la mediana de las Bios de temperatura estimada al 2050 y 2070 por tres MCG, en cualquier escenario climático, RCP (izq. Fig. 6), será mayor a la actual (Tabla 2). De manera general, se espera que la temperatura sea  $2.66^{\circ}\text{C}$  (2050) y  $3.36^{\circ}\text{C}$

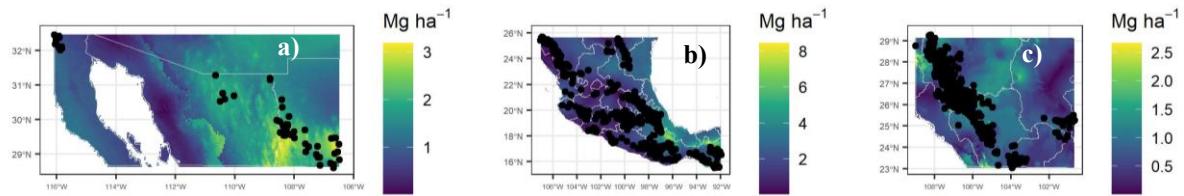
(2070) más que la actual (Figs. 6a, 6c y 6e). Las áreas del estrato II, serían las vulnerables al mostrar +2.7 °C al 2050, y menos vulnerables las áreas del estrato III (+2.5 °C). Al 2070, la temperatura incrementa así: estrato I > estrato II > estrato III, desde 3.55 hasta 3.25 °C.

La prueba demostró que, en los bosques de México, de forma general la precipitación al 2050 y 2070 podría ser igual en el estrato I (Fig. 6b), disminuir ( $p < 0.0001$ ) entre 5.3 % (2050) y 6.4 % (2070) en el estrato II (Fig. 6d), y aumentar/disminuir en el estrato III (Fig. 6f). De forma individual (Actual vs Bio-RCP-Año), existen también diferencias únicamente en el caso de variables de precipitación (der. Fig. 6), no así de temperatura (izq. Fig 6).



**Figura 6.** Prueba Wilcoxon para la comparación de las medianas de la variable actual con cada escenario climático, en el estrato I (a-b), II (b-c) y III (e-f). Bio 05: temperatura máxima del mes más cálido ( $^{\circ}\text{C}$ ); Bio 10: temperatura media del trimestre más cálido ( $^{\circ}\text{C}$ ); Bio 12: precipitación anual (mm); Bio 13: precipitación del mes más lluvioso (mm); Bio 18: precipitación del trimestre más cálido (mm). Significancia estadística: "\*\*  $p < 0.05$ ": Significativo; "\*\*\*  $p < 0.01$ ": Altamente significativo; \*\*\*\*  $p < 0.001$ ": Muy altamente significativo. Significancia estadística: "ns": No significativo; \*  $p < 0.05$ ": Significativo; \*\*  $p < 0.01$ ": Altamente significativo; \*\*\*  $p < 0.001$ ": Muy altamente significativo; \*\*\*\*\*  $p < 0.0001$ ": Extremadamente altamente significativo.

La incertidumbre (representada por el error estándar) estimada para *DCBVA* mostrada aquí (Figura 7), para el escenario más crítico (RCP85 | 2070), muestra que el error estándar oscila desde 2.5 Mg C ha<sup>-1</sup> (estrato III) hasta 8 Mg C ha<sup>-1</sup> (estrato II), muy por debajo del RMSE (Tabla 3) estimado con datos independientes. Esta incertidumbre, es similar en escenarios climáticos menos críticos (RCP26 | 2050; Figuras no mostradas).



**Figura 7.** Incertidumbre (error estándar) estimada de la densidad de carbono de biomasa viva aérea, en bosques de coníferas de México, para los estratos I (a), II (b) y III (c) para el RCP85 y para el año 2070.

La selección de predictores de la AGB mediante algoritmos automatizados (stepwise, Machine Learning, redes neuronales etc.) en general es eficiente, estos han sido probados en bosques naturales (Luo *et al.*, 2021; Björk *et al.*, 2021) selvas (Ortiz-Reyes *et al.*, 2021) inclusive en plantaciones (He *et al.*, 2022). Aunque las variables seleccionadas por estos algoritmos son estadísticamente significativas,  $p < 0.05$  (Li *et al.*, 2022), los modelos generados aquí, presentaron efectos de multicolinealidad ( $VIF > 10$ ), por lo que tuvieron que ser evaluados para evitar este efecto y mejorar las predicciones.

Algunos autores (Zhang *et al.*, 2022), han utilizado procedimientos lineales (lm) para la predicción de PPN (Producción Primaria Neta) en pastizales, con resultados favorables. Nosotros probamos esta técnica; sin embargo, quedó demostrado que, en este tipo de estudios, es difícil satisfacer todos los supuestos de un modelo de regresión ( $\varepsilon_i \sim N(\mathbf{0}, \sigma^2)$ ), por lo que finalmente se empleó el procedimiento ‘glm’, como se ha hecho en este tipo de estudios (Arasa-Gisbert *et al.*, 2018; Cysneiros *et al.*, 2021). Además de estos procedimientos, también se ha utilizado Random Forest (Cartus *et al.*, 2014; Bennett *et*

*al.*, 2020; Yan *et al.*, 2023) y modelos bayesianos (Chen *et al.*, 2023) para la predicción de AGB a partir de variables de temperatura y precipitación.

### Variables predictoras de biomasa aérea

En este estudio los algoritmos utilizados eligieron tanto variables de temperatura (Bio 5 y Bio 10) como de precipitación (Bio 12, Bio 13 y Bio 18) como mejores predictores de *DCBVa*. Las variables de temperatura fueron las de mayor importancia en el modelo (de 8 a 10% de la pseudo R<sup>2</sup>), en el estrato I y II (Tabla 1, Fig. 1a y 1b) no así para el estrato III. Según algunos autores (Dai *et al.*, 2016; Zhang *et al.*, 2022), a escala global, las variables de precipitación y temperatura son las que mejor explican la predicción de AGB. En particular, la temperatura media anual (Bio 1) y temperatura del trimestre más cálido (Bio 10) son variables climáticas que se asocian a la distribución de la biomasa a escalas amplias, las métricas demuestran que temperaturas parecen ser más importantes que variables de precipitación (Reich *et al.*, 2014).

Se ha demostrado que variables bioclimáticas de temperatura (Bio 1 y Bio 5) y de precipitación (Bio 12) están asociadas con la acumulación del AGB de los bosques (Chen *et al.*, 2023), en ecosistemas boreales (He *et al.*, 2022), estacionales templados (Keith *et al.*, 2009), selvas tropicales (Chen *et al.*, 2018), y estacionales tropicales (Guo *et al.*, 2019; Ma *et al.*, 2023). Como puede notarse, Bio 5 y Bio 12 (Appendix B), son buenos predictores de AGB en diferentes tipos de ecosistemas. Por ejemplo, un estudio realizado en la SMO (estrato II de este mismo estudio) menciona que la temperatura promedio (Bio 1) es la más importante para predecir AGB en bosques templados (López-Serrano *et al.*, 2020).

En bosques de Australia, abarcando 15 tipos de bosques dominados especialmente con eucaliptos (Bennett *et al.*, 2020), demuestran que las variables climáticas, son mejores predictores de AGB, que variables del suelo, siendo Bio 9 (Temperatura media del trimestre más seco) la variable más importante. Independientemente de las métricas, al

igual que en nuestro estudio, las variables de temperatura parecen ser las más importantes para predecir AGB (Tabla 1).

No obstante, la relación de las variables bioclimáticas con AGB, es completamente dependiente del tipo de ecosistema, de la especie, pero también de la región del mundo, por esta razón otros autores enfatizan que la precipitación media anual (MAP), posee una importancia relativa mayor (0.19 %) que MAT (0.05 %) para la predicción de AGB en plantaciones de *Larix* del norte y noreste de China, incluso, su importancia también es dependiente de la estructura del modelo (He *et al.*, 2022).

Continuando con la narrativa anterior, la relación entre precipitación y AGB puede ser compleja, ya que se pueden observar diferentes respuestas según el tipo de bosque y condiciones climáticas. Esta variable influye significativamente en la acumulación de los diferentes componentes de biomasa aérea (ramas, tallos, raíces y acículas) en plantaciones de coníferas, por ello es importante considerarla en modelos de predicción y en la evaluación de la relación clima-bosques (Xin *et al.*, 2022), pero en conjunto, variables climáticas de temperatura y precipitación pueden mejorar las estimaciones de AGB (Dai *et al.*, 2019). Por ejemplo, en bosques tropicales (Adhikari *et al.*, 2017), utilizaron 13 variables predictoras de AGB, incluyendo: geográficas, topográficas, hidrológicas, de suelo, incluso de la especie (cobertura), etc., encontrando que la influencia relativa de MAP sobre AGB es de 37.6 % siendo la más importante, mientras que MAT, posee una influencia relativa menor al 1 %.

### **Correlación entre variables bioclimáticas y densidad de carbono**

La correlación de *DCBVa* con variables de temperatura (Bio 5 y Bio 10) en bosques templados de México es negativa, pero positiva con las variables de precipitación (Tabla 1). Algo similar encontraron (Khan *et al.*, 2019), una correlación negativa ( $-0.46 > r < -0.63$ ;  $-0.43 > r < -0.60$ ) entre biomasa de fuste de *Larix gmelinii* y *Betula platyphylla* con MAT. De la misma forma, en otros estudios se demuestra que MAT se correlaciona

negativamente con AGB, ya sea a nivel especie (Xin *et al.*, 2022) o a nivel rodal (Li *et al.*, 2022).

Similar a este estudio, en bosques templados y bosques secos, se observa una correlación positiva entre DCBVa y MAP (Stegen *et al.*, 2011) y esta misma relación se observa en otros estudios por ejemplo (Khan *et al.*, 2019) encontraron que MAP se correlaciona positivamente con biomasa de fuste de *Larix gmelinii* ( $0.84 > r < 0.92$ ) y *Betula platyphylla* ( $0.76 > r < 0.88$ ), mientras que (Xin *et al.*, 2022) observaron que MAP se correlaciona positivamente y significativamente ( $p < 0.05$ ) con AGB de *Pinus koraiensis* Siebold & Zucc., *Larix olgensis* A. Henry y *Pinus sylvestris* var. mongolica Litv.

Por otro lado, el estudio realizado por Reich *et al.*, (2014), revela que a escala global ( $> 6200$  bosques y 61 países), MAT se correlaciona positivamente con la biomasa del follaje, aunque los patrones geográficos de correlación no son consistentes. (Liu *et al.*, 2013) encontraron que mientras en los bosques boreales la temperatura se correlaciona positivamente, en bosques tropicales ocurre lo contrario. Estudios realizados por Guo *et al.*, (2019) en bosques boreales, demuestran que MAT puede explicar ( $R^2$ ) desde 26 hasta 45 % de la densidad de carbono y se correlaciona de forma positiva; mientras que MAP puede explicar desde 28 hasta 67 % de la densidad de carbono (áerea y subterránea); sin embargo, la correlación es positiva entre estas dos variables cuando la precipitación es desde 0 a 1000 mm, y negativa cuando es mayor a 1000 mm.

Contrario a este estudio, en bosques boreales y templados, se ha encontrado una relación positiva entre DCBVa y MAT (Keith *et al.*, 2009) , pero negativa en regiones húmedas (Stegen *et al.*, 2011).

### **Capacidad predictiva de los modelos**

La validación de un modelo es crucial para evaluar la capacidad predictiva que posee un modelo, en base con nuevos datos. En realidad, en esta temática (relación AGB - predictores climáticos), son pocos los estudios que realizan este proceso (Cartus *et al.*,

2014; Opelele *et al.*, 2021; He *et al.*, 2022; Zhang *et al.*, 2022). Como es conocido, al generar un modelo con el procedimiento ‘glm’, no se calculan estadísticos como:  $R^2$ , RMSE, MAE etc.; al realizar la validación de nuestros modelos, fue posible calcular estas métricas y evaluar, la capacidad predictiva de cada modelo. Observamos que las variables bioclimáticas pueden explicar hasta 22 % de la *DCBVA*, en este tipo de bosques (Tabla 3), un valor considerable razonable cuando se trata de modelos a nivel de eco-región (Guo *et al.*, 2019), no así a nivel especie (Khan *et al.*, 2019; Xin *et al.*, 2022) ya que, a esta escala, las variables pueden explicar hasta 84 % de AGB.

En general la técnica de ‘validación cruzada’, ha sido la más utilizada para validar modelos para estimar AGB (Opelele *et al.*, 2021; Li et al. 2022; He *et al.*, 2022; Wang *et al.*, 2023); en este estudio nosotros la utilizamos además de otras tres técnicas (Tabla 3). Resaltar que, cuando se trata de predictores climáticos, estos pueden explicar alrededor de 20 % (Tabla 3), mientras que cuando se predice AGB a partir de predictores derivados de índices de vegetación, e. g. índice de vegetación de diferencia normalizada, NDVI, información aspectral (Opelele *et al.*, 2021), o imágenes ópticas de satélite y vehículos aéreos no tripulados (Wang *et al.*, 2023), se puede explicar ( $R^2$ ) hasta 80 % de AGB. La inclusión de diferentes variables predictoras como MAP, MAT, contenido de arcilla, pH, índice de sequedad y edad del rodal, pueden explicar hasta 44.4 % de *DCBVA* en bosques templados (Guo *et al.*, 2019).

Sin embargo, predictores exclusivos del rodal (diámetro a la altura del pecho, edad, densidad del rodal), pueden explicar hasta 98 % de la varianza de ABG (He *et al.*, 2022). La métrica RMSE, es completamente dependiente de las unidades y de la escala de las variables dependientes, por eso se observan diferencias tan distantes entre estudios.

### **Proyección actual y futura de la densidad de carbono de biomasa viva aérea**

Ante cualquier escenario climático (RCP - año), nuestros modelos predicen pérdidas de *DCBVA*, desde 5 Mg C ha<sup>-1</sup> (2050) hasta 20 Mg C ha<sup>-1</sup> al 2070 (Figs. 3-5) en los bosques de coníferas de México. A escala global, en bosques templados, se predicen cambios

positivos en la densidad de carbono total (TCD), con un promedio de 2.23 Mg C ha<sup>-1</sup> (RCP26, 45 y 85; 2050) y de 1.99 Mg C ha<sup>-1</sup> al 2070; exclusivamente en México, estos autores (Guo *et al.*, 2019), predicen cambios de  $\pm 20$  Mg C ha<sup>-1</sup>; sin omitir que, para el país, se tuvieron solo dos plots, a diferencia de este estudio, se hizo a escala más fina, generando los modelos con n= 48 hasta n=370 (Tabla 2).

Un estudio realizado (Zhou *et al.*, 2022) bajo diferentes escenarios de simulación, incrementando/disminuyendo temperatura y precipitación, en la provincia de Yunnan, China, sugiere que los efectos combinados de estas variables son más complejos de lo esperado; se pueden tener tanto ganancias como pérdidas (como en este estudio) de secuestro de carbono en diferentes tipos de bosques y es debido a la disminución de precipitación y al aumento de la temperatura. En nuestro estudio se observa disminución de DCB<sub>Va</sub> y en general es debido a incremento desde 1 hasta 3 °C y disminución de precipitación de alrededor de 10 %. Desde hace casi tres décadas (Villers-Ruiz y Trejo-Vazquez, 1997), se evaluó la vulnerabilidad de los bosques de México al cambio climático, encontrando que bajo las estas condiciones (+ 2 °C y -10 % precipitación), bosques templados húmedos y secos se reducirían significativamente (a menos de la mitad de su tamaño).

En una investigación realizada en los bosques atlánticos brasileños (AF) (Ferreira *et al.*, 2023), encontraron que, en 34.7 % de los fragmentos de bosque existentes, la AGB podría aumentar, mientras que en el 2.6 % podría disminuir para el año 2100; los modelos predicen un incremento de 8.5 % de total carbón existente, además, 76.9 % de AF sería idóneo a un posible incremento de AGB al 2100 bajo un rcp de 4.5, debido meramente al cambio climático: Lo anterior se contrapone a lo encontrado aquí, posiblemente por el tipo de bosques y ubicación geográfica, pero es similar a lo que encontraron (Li *et al.*, 2022), en subtropical de los bosques siempre verde de China, un decremento de AGB al 2050 2070, variando según los diferentes escenarios climáticos (rcp 2.6 > rcp 4.5 > rcp 6.0 > rcp 8.5).

## CONCLUSIONES

Las relaciones entre *DCBVa* y el clima son más complejas de lo que parece. Las variables bioclimáticas, especialmente las relacionadas con la temperatura, demostraron ser predictores significativos de la *DCBVa* en los modelos desarrollados y pueden explicar hasta 19 % de la *DCBVa*. Bio 5 (Temperatura máxima del mes más cálido) destacó como el predictor más robusto. Los modelos desarrollados mostraron una buena capacidad predictiva con datos independientes, para predecir la *DCBVa* en bosques de coníferas de México. Las predicciones con los modelos bioclimáticos indican que todos los estratos de bosques de coníferas del país, bajo cualquier escenario climático (RCP - Año), experimentarán pérdidas en la *DCBVa* hacia el 2050 y 2070, especialmente bajo el escenario RCP8.5. Se prevé que los bosques del estrato II sean los más afectados, con reducciones significativas que podrían alcanzar hasta -20 Mg C ha<sup>-1</sup> para el año 2070. La temperatura proyectada por los MCG's al 2050 y 2070 será significativamente mayor a la actual, con aumentos de hasta 3.55 °C en el estrato I al 2070. La precipitación podría permanecer igual en el estrato I, disminuir (-10 %) en el estrato II y variar ( $\pm 10\%$ ) en el estrato III. Estas proyecciones climáticas futuras, serían las responsables de la redistribución de la *DCBVa* de los bosques de México. Las conclusiones sugieren la necesidad urgente de estrategias de adaptación y mitigación frente al cambio climático para conservar la biodiversidad y los servicios ecosistémicos proporcionados por los bosques de coníferas en México. La gestión forestal debe considerar no solo la conservación de la biodiversidad, sino también la capacidad de almacenamiento de carbono en estos ecosistemas.

## REFERENCIAS

- Adhikari, H., Heiskanen, J., Siljander, M., Maeda, E., Heikinheimo, V., & Pellikka, P. K. E. (2017). Determinants of aboveground biomass across an afromontane landscape Mosaic in Kenya. In *Remote Sensing* (Vol. 9, Issue 8). MDPI. <https://doi.org/10.3390/rs9080827>
- Arasa-Gisbert, R., Vayreda, J., Román-Cuesta, R. M., Villela, S. A., Mayorga, R., & Retana, J. (2018). Forest diversity plays a key role in determining the stand carbon stocks of Mexican forests. *Forest Ecology and Management*, 415–416, 160–171. <https://doi.org/10.1016/j.foreco.2018.02.023>
- Barreras, A., Alanís de la Rosa, J., Mayorga, R., Cuenca, R., Moreno-G, C., Godinez, C., Delgado, C., de los, M., Soriano-Luna, A., George, S., Aldrete Leal, M., Medina, S., Romero, J., Villela, S., Lister, A., Sheridan, R., Flores, R., Crowther, T., Guevara, M., Crowther, T. W. (2009). Spatial predictions of tree density and tree height across Mexicos forests using ensemble learning and forest inventory data Title: Spatial predictions of tree density and tree height across Mexicos forests using ensemble learning and forest inventory data. <https://doi.org/10.22541/au.166512787.73882380/v1>
- 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>
- Bivand, R., G.-R. V., & P. E. (2022). GeoStratR: Tools for simple stratification of spatial patterns.
- Busby, J. (1991). BIOCLIM - a bioclimate analysis and prediction system. *Plant protection quarterly*, 6, 8-9.
- Björk, S., Anfinsen, S. N., Næsset, E., Gobakken, T., & Zahabu, E. (2021). On the potential of sequential and non-sequential regression models for Sentinel-1-based biomass prediction in Tanzanian miombo forests. <http://arxiv.org/abs/2106.15020>
- Cartus, O., Kellndorfer, J., Walker, W., Franco, C., Bishop, J., Santos, L., & Fuentes, J. M. M. (2014). A national, detailed map of forest aboveground carbon stocks in Mexico. *Remote Sensing*, 6(6), 5559–5588. <https://doi.org/10.3390/rs6065559>
- Challenger, A. (1998). Utilización y conservación de los ecosistemas terrestres de México: Pasado, presente y futuro.
- Chen, L., Ren, C., Zhang, B., Wang, Z., & Xi, Y. (2018). Estimation of forest above-ground biomass by geographically weighted regression and machine learning with sentinel imagery. *Forests*, 9(10). <https://doi.org/10.3390/f9100582>

- Chen, N., Tsendbazar, N. E., Requena Suarez, D., Verbesselt, J., & Herold, M. (2023). Characterizing aboveground biomass and tree cover of regrowing forests in Brazil using multi-source remote sensing data. *Remote Sensing in Ecology and Conservation*, 9(4), 553–567. <https://doi.org/10.1002/rse2.328>
- Chen, X., Luo, M., & Larjavaara, M. (2023). Effects of climate and plant functional types on forest above-ground biomass accumulation. *Carbon Balance and Management*, 18(1). <https://doi.org/10.1186/s13021-023-00225-1>
- Cysneiros, V. C., Coelho de Souza, F., Gaudi, T. D., Pelissari, A. L., Orso, G. A., Machado, S. do A., de Carvalho, D. C., & Silveira-Filho, T. B. (2021). Integrating climate, soil and stand structure into allometric models: An approach of site-effects on tree allometry in Atlantic Forest. *Ecological Indicators*, 127. <https://doi.org/10.1016/j.ecolind.2021.107794>
- Dai, L., Ke, X., Guo, X., Du, Y., Zhang, F., Li, Y., Li, Q., Lin, L., Peng, C., Shu, K., & Cao, G. (2019). Responses of biomass allocation across two vegetation types to climate fluctuations in the northern Qinghai–Tibet Plateau. *Ecology and Evolution*, 9(10), 6105–6115. <https://doi.org/10.1002/ece3.5194>
- Devi, V., Kaur, A., Sethi, M., & Avinash, G. (2023). Perspective Chapter: Effect of Low-Temperature Stress on Plant Performance and Adaptation to Temperature Change. [www.intechopen.com](http://www.intechopen.com)
- Eamus, D. (2003). How does ecosystem water balance affect net primary productivity of woody ecosystems? *Functional Plant Biology*, 30(2), 187–205. <https://doi.org/10.1071/FP02084>
- Fang, J., Shi, J., Zhang, P., Shao, M., Zhou, N., Wang, Y., & Xu, X. (2024). Potential Distribution Projections for *Senegalia senegal* (L.) Britton under Climate Change Scenarios. *Forests*, 15(2). <https://doi.org/10.3390/f15020379>
- FAO. (2022). El estado de los bosques del mundo 2022. FAO. <https://doi.org/10.4060/cb9360es>
- Ferreira, I. J. M., Campanharo, W. A., Fonseca, M. G., Escada, M. I. S., Nascimento, M. T., Villela, D. M., Brancalion, P., Magnago, L. F. S., Anderson, L. O., Nagy, L., & Aragão, L. E. O. C. (2023). Potential aboveground biomass increase in Brazilian Atlantic Forest fragments with climate change. *Global Change Biology*, 29(11), 3098–3113. <https://doi.org/10.1111/gcb.16670>
- 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>
- Gao, J., Zhao, P., Shen, W., Rao, X., & Hu, Y. (2017). Physiological homeostasis and morphological plasticity of two tree species subjected to precipitation seasonal

- distribution changes. *Perspectives in Plant Ecology, Evolution and Systematics*, 25, 1–19. <https://doi.org/10.1016/j.ppees.2017.01.002>
- Gernandt, D. S., & Pérez-De La Rosa, J. A. (2014). Biodiversity of Pinophyta (conifers) in Mexico. *Revista Mexicana de Biodiversidad*, 85(SUPPL.). <https://doi.org/10.7550/rmb.32195>
- Girón-Gutiérrez, D., Méndez-González, J., Osorno-Sánchez, T. G., Cerano-Paredes, J., Soto-Correa, J. C., & Cambrón-Sandoval, V. H. (2024). Climate as a Driver of Aboveground Biomass Density Variation: A Study of Ten Pine Species in Mexico. *Forests*, 15(7), 1160. <https://doi.org/10.3390/f1507116>
- Granados-Sánchez, D., López-Ríos, G. F., & Hernández-García, M. A. (2007). Ecología y silvicultura en bosques templados. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 13(1), 67-83. <http://www.redalyc.org/articulo.oa?id=62913110>
- Grömping, U. (2006). Relative Importance for Linear Regression in R: The Package relaimpo. In *JSS Journal of Statistical Software* (Vol. 17). <http://www.jstatsoft.org/>
- Guo, Y., Peng, C., Trancoso, R., Zhu, Q., & Zhou, X. (2019). Stand carbon density drivers and changes under future climate scenarios across global forests. *Forest Ecology and Management*, 449. <https://doi.org/10.1016/j.foreco.2019.117463>
- 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* (Switzerland), 14(9). <https://doi.org/10.3390/su14095580>
- Heiderman, R. R., & Kimsey, M. J. (2023). Pacific Northwest conifer forest stand carrying capacity under future climate scenarios. *Natural Resource Modeling*, 36(4). <https://doi.org/10.1111/nrm.12381>
- Hijmans, R. J. (2010). raster: Geographic Data Analysis and Modeling [Data set]. En CRAN: Contributed Pa ckages. The R Foundation.
- IPCC. (2013). Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change [Stocker, T.F., D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex and P.M. Midgley (eds.)].
- IPCC. (2021). In *Climate Change 2021 – The Physical Science Basis* (pp. 3–32). Cambridge University Press. <https://doi.org/10.1017/9781009157896.001>
- Keith, H., Mackey, B. G., & Lindenmayer, D. B. (2009). Re-evaluation of forest biomass carbon stocks and lessons from the world's most carbon-dense forests. *Proceedings of the National Academy of Sciences of the United States of America*, 106(28), 11635–11640. <https://doi.org/10.1073/pnas.0901970106>

- 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. <https://doi.org/10.1155/2019/5692574>
- Kuhn, M. (2008). Journal of Statistical Software Building Predictive Models in R Using the caret Package. <http://www.jstatsoft.org/>
- Lê, S., J. J. & H. F. (2008). FactoMineR: An R Package for Multivariate Analysis. *Journal of Statistical Software*. *Journal of Statistical Software*.
- Li, Y., Li, M., & Wang, Y. (2022). Forest Aboveground Biomass Estimation and Response to Climate Change Based on Remote Sensing Data. *Sustainability* (Switzerland), 14(21). <https://doi.org/10.3390/su142114222>
- Liu, Y., Yu, G., Wang, Q., & Zhang, Y. (2014). 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-Serrano, P. M., Domínguez, J. L. C., Corral-Rivas, J. J., Jiménez, E., López-Sánchez, C. A., & Vega-Nieva, D. J. (2020). Modeling of aboveground biomass with landsat 8 oli and machine learning in temperate forests. *Forests*, 11(1). <https://doi.org/10.3390/f11010011>
- Luo, M., Wang, Y., Xie, Y., Zhou, L., Qiao, J., Qiu, S., & Sun, Y. (2021). Combination of feature selection and catboost for prediction: The first application to the estimation of aboveground biomass. *Forests*, 12(2), 1–22. <https://doi.org/10.3390/f12020216>
- Luo, Y., Wang, X., Zhang, X., Ren, Y., & Poorter, H. (2013). Variation in biomass expansion factors for China's forests in relation to forest type, climate, and stand development. *Annals of Forest Science*, 70(6), 589–599. <https://doi.org/10.1007/s13595-013-0296-6>
- Ma, Y., Eziz, A., Halik, Ü., Abлиз, А., & Kurban, А. (2023). Precipitation and Temperature Influence the Relationship between Stand Structural Characteristics and Aboveground Biomass of Forests—A Meta-Analysis. In *Forests* (Vol. 14, Issue 5). MDPI. <https://doi.org/10.3390/f14050896>
- MEXICO CLIMATE RISK COUNTRY PROFILE. (2024). [www.worldbank.org](http://www.worldbank.org)
- Opelele, O. M., Yu, Y., Fan, W., Chen, C., & Kachaka, S. K. (2021). Biomass estimation based on multilinear regression and machine learning algorithms in the mayombe tropical forest, in the democratic republic of congo. *Applied Ecology and Environmental Research*, 19(1), 359–377. [https://doi.org/10.15666/aeer/1901\\_359377](https://doi.org/10.15666/aeer/1901_359377)

- Ortiz-Reyes, A. D., Valdez-Lazalde, J. R., Ángeles-Pérez, G., de los Santos-Posadas, H. M., Schneider, L., Aguirre-Salado, C. A., & Peduzzi, A. (2021). Synergy of Landsat, climate and LiDAR data for aboveground biomass mapping in medium-stature tropical forests of the Yucatan Peninsula, Mexico. *Revista Chapingo, Serie Ciencias Forestales y Del Ambiente*, 27(3), 383–400. <https://doi.org/10.5154/R.RCHSCFA.2020.08.050>
- Pan, Y., Birdsey, R. A., Phillips, O. L., & Jackson, R. B. (2013). The structure, distribution, and biomass of the world's forests. In *Annual Review of Ecology, Evolution, and Systematics* (Vol. 44, pp. 593–622). Annual Reviews Inc. <https://doi.org/10.1146/annurev-ecolsys-110512-135914>
- Peng, D., Zhang, H., Liu, L., Huang, W., Huete, A. R., Zhang, X., Wang, F., Yu, L., Xie, Q., Wang, C., Luo, S., Li, C., & Zhang, B. (2019). Estimating the aboveground biomass for planted forests based on stand age and environmental variables. *Remote Sensing*, 11(19). <https://doi.org/10.3390/rs11192270>
- Penman, J., Carruthers, I., & López, C. (2021). Capítulo 1: Panorama general AUTORES Y EDITORES REVISORES Autores principales coordinadores Editores revisores.
- Reich, P. B., Luo, Y., Bradford, J. B., Poorter, H., Perry, C. H., & Oleksyn, J. (2014). Temperature drives global patterns in forest biomass distribution in leaves, stems, and roots. *Proceedings of the National Academy of Sciences of the United States of America*, 111(38), 13721–13726. <https://doi.org/10.1073/pnas.1216053111>
- Rodríguez-Veiga, P., Saatchi, S., Tansey, K., & Balzter, H. (2016). Magnitude, spatial distribution and uncertainty of forest biomass stocks in Mexico. *Remote Sensing of Environment*, 183, 265–281. <https://doi.org/10.1016/j.rse.2016.06.004>
- Rzedowski, J., & Huerta, L. (2006). Vegetación de México (Edición Digital). Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. <https://www.biodiversidad.gob.mx/publicaciones/librosDig/pdf/VegetacionMxPort.pdf>
- Han, S.-H., Kim, D.-H., Kim, G. N., Lee, J.-C., & Yun, C.-W. (2012). Changes on initial growth and physiological characteristics of *Larix kaempferi* and *Betula costata* seedlings under elevated temperature. *Korean Journal of Agricultural and Forest Meteorology*, 14(2), 63–70. <https://doi.org/10.5532/KJAFM.2012.14.2.063>
- Solberg, S., Bollandsås, O. M., Gobakken, T., Næsset, E., Basak, P., & Duncanson, L. I. (2024). Biomass Change Estimated by TanDEM-X Interferometry and GEDI in a Tanzanian Forest. *Remote Sensing*, 16(5). <https://doi.org/10.3390/rs16050861>
- Stegen, J. C., Swenson, N. G., Enquist, B. J., White, E. P., Phillips, O. L., Jørgensen, P. M., Weiser, M. D., Monteagudo Mendoza, A., & Núñez Vargas, P. (2011). Variation in above-ground forest biomass across broad climatic gradients. *Global Ecology and Biogeography*, 20(5), 744–754. <https://doi.org/10.1111/j.1466-8238.2010.00645.x>

- Usoltsev, V. A., Chen, B., Omid, S., Shobairi, R., Tsepordey, I. S., & Anees, S. A. (2020). Changes in foliage's biomass of two-needed pine subgenus (*Pinus* spp.) and genus *Betula* spp. along the gradients of winter temperature and precipitation: inter-genera paradox in the forests of Eurasia. <https://doi.org/10.21203/rs.3.rs-71384/v1>
- Villers-Ruiz, L., & Trejo-Vazquez, I. (1997). CLIMATE RESEARCH Clim Res Assessment of the vulnerability of forest ecosystems to climate change in Mexico (Vol. 9).
- Wang, Z., Yi, L., Xu, W., Zheng, X., Xiong, S., & Bao, A. (2023). Integration of UAV and GF-2 Optical Data for Estimating Aboveground Biomass in Spruce Plantations in Qinghai, China. Sustainability (Switzerland), 15(12). <https://doi.org/10.3390/su15129700>
- Li, W., Peng, M., Higa, M., & et al. (2016). Effects of climate change on potential habitats of the cold temperate coniferous forest in Yunnan province, southwestern China. Journal of Mountain Science, 13, 1411–1422. <https://doi.org/10.1007/s11629-016-3846-1>
- Xin, S., Wang, J., Mahardika, S. B., & Jiang, L. (2022). Sensitivity of Stand-Level Biomass to Climate for Three Conifer Plantations in Northeast China. Forests, 13(12). <https://doi.org/10.3390/f13122022>
- Yuan, J., Yan, Q., Wang, J., Xie, J., & Li, R. (2022). Different responses of growth and physiology to warming and reduced precipitation of two co-existing seedlings in a temperate secondary forest. Frontiers in Plant Science, 13. <https://doi.org/10.3389/fpls.2022.946141>
- Zhang, H., Feng, Z., Shen, C., Li, Y., Feng, Z., Zeng, W., & Huang, G. (2022). Relationship between the geographical environment and the forest carbon sink capacity in China based on an individual-tree growth-rate model. Ecological Indicators, 138. <https://doi.org/10.1016/j.ecolind.2022.108814>
- Zhang, Y., Li, Q., Ge, Y., Du, X., & Wang, H. (2022). Growing prevalence of heat over cold extremes with overall milder extremes and multiple successive events. Communications Earth and Environment, 3(1). <https://doi.org/10.1038/s43247-022-00404-x>
- Zhou, R., Zhang, Y., Peng, M., Jin, Y., & Song, Q. (2022). Effects of Climate Change on the Carbon Sequestration Potential of Forest Vegetation in Yunnan Province, Southwest China. Forests, 13(2). <https://doi.org/10.3390/f13020306>

## ANEXOS

### Variables Bioclimáticas

Variable	Descripción
Bio 1	Temperatura Media Anual (°C)
Bio 2	Intervalo medio diurno (°C)
Bio 3	Isotermalidad (Bio2 / Bio7) (*100)
Bio 4	Estacionalidad de la temperatura (Desviación estándar *100)
Bio 05	Temperatura máxima del mes más cálido (°C)
Bio 06	Temperatura mínima del mes más frío (°C)
Bio 07	Rango anual de temperatura (Bio5 – Bio6 °C)
Bio 08	Temperatura media del trimestre más húmedo (°C)
Bio 09	Temperatura media del trimestre más seco (°C)
Bio 10	Temperatura media 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 cálido (mm)
Bio 15	Estacionalidad de la precipitación (Coeficiente de variación, %)
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)