

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO
DIVISIÓN DE AGRONOMÍA
PROGRAMA DOCENTE DE LA CARRERA DE
INGENIERO FORESTAL



Cambios proyectados en la densidad de carbono de la biomasa viva aérea en el sur del Desierto Chihuahuense bajo escenarios de cambio climático

Por:

ALEXA MONSERRAT ROMERO MONTAÑO

TESIS

Presentada como requisito parcial para obtener el título de:

INGENIERO FORESTAL

Saltillo, Coahuila de Zaragoza, México
Junio 2026

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO
DIVISIÓN DE AGRONOMÍA
PROGRAMA DOCENTE DE LA CARRERA DE
INGENIERO FORESTAL

Cambios proyectados en la densidad de carbono de la biomasa viva aérea en el sur
del Desierto Chihuahuense bajo escenarios de cambio climático

Por:

ALEXA MONSERRAT ROMERO MONTAÑO

TESIS


Presentada como requisito parcial para obtener el título de:

INGENIERO FORESTAL

Aprobada por el Comité Asesor:


DR. JORGE MENDEZ GONZALEZ
Asesor Principal


LIBRADO SOSA DIAZ
Asesor Principal Externo


DR. CELESTINO FLORES LOPEZ
Coasesor


DR. GENARO ESTEBAN GARCIA MOSQUEDA
Coasesor


DR ALBERTO SANDOVAL RANGEL
Coordinador de la División de Agronomía



Derechos de autor y declaración de no plagio


Todo material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor de los Estados Unidos Mexicanos, y pertenece al autor principal quien es el responsable directo y jura bajo protesta de decir verdad que no se incurrió en plagio o conducta académica incorrecta en los siguientes aspectos: Reproducción de fragmentos o textos sin citar la fuente o autor original (corta y pega); reproducir un texto propio publicado anteriormente sin hacer referencia al documento original (auto plagio); comprar, robar o pedir prestados los datos o la tesis para presentarla como propia; omitir referencias bibliográficas o citar textualmente sin usar comillas; utilizar ideas o razonamientos de un autor sin citarlo; utilizar material digital como imágenes, videos, ilustraciones, gráficas, mapas o datos sin citar al autor original y/o fuente. Asimismo, tengo conocimiento de que cualquier uso distinto de estos materiales, como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los derechos de autor. Por lo anterior nos responsabilizamos de las consecuencias de cualquier tipo de plagio en caso de existir y declaramos que este trabajo no ha sido previamente presentado en ninguna otra institución educativa, organización, medio público o privado.

Autor principal



Alexa Monserrat Romero Montaña

Asesor Principal



Dr. Jorge Méndez González

DEDICATORIA

A Dios, por darme una nueva oportunidad de vida y por enseñarme, a través de cada experiencia, la fortaleza, valentía y capacidad que habitan en mí. Gracias por acompañarme en cada paso de este camino y por permitirme superar las adversidades que se presentaron durante este proceso.

A mis padres Yamilet M. Montaña González y Alejandro Romero De la Peña, por su amor y por su apoyo incondicional, por su esfuerzo constante y la confianza que depositaron en mí durante cada etapa de mi formación académica. Por nunca dejarme sola y confiar en mis decisiones. Gracias por impulsarme a perseguir mis sueños, por sus enseñanzas y por los valores que me han convertido en la persona que soy hoy. Este logro también les pertenece, porque sin ustedes nada de esto habría sido posible.

A mis padres, A pesar de la distancia, siempre encontraron la manera de hacerme sentir su cercanía, su amor y su respaldo en todo momento.

A mí, Alexa Monserrat Romero Montaña, por mantener la fe en mis capacidades y por demostrarme que la perseverancia, el esfuerzo y la determinación pueden llevarme más lejos de lo que alguna vez imaginé. Gracias por creer en mí, por enfrentar cada desafío y por conservar una actitud positiva ante las adversidades. Este trabajo es el reflejo del esfuerzo, la constancia y el crecimiento alcanzados a lo largo de este camino.

AGRADECIMIENTOS

A mi mamá, Yamilet M. Montaña, por su amor incondicional, su fortaleza y su apoyo constante a lo largo de toda mi vida. Gracias por cada palabra de aliento, por escucharme en los momentos de incertidumbre y por enseñarme, con tu ejemplo, el valor de la perseverancia y el trabajo honesto. Aun en la distancia, siempre encontraste la manera de hacerme sentir acompañada, querida y segura. Tu confianza en mí fue una de las principales razones por las que nunca dejé de avanzar.

A mi papá, Alejandro Romero De la Peña, por cada sacrificio realizado para brindarme la oportunidad de alcanzar mis metas. Gracias por creer en mí, por impulsarme a superarme cada día y por enseñarme que los sueños se alcanzan con esfuerzo, disciplina y determinación. Tu apoyo incondicional y tu confianza en mis capacidades me dieron la fuerza necesaria para enfrentar los retos de esta etapa y llegar hasta aquí. Este logro es también el resultado de todo lo que has hecho por mí.

A Dios por ser mi guía y fortaleza a lo largo de este camino. Gracias por protegerme, brindarme valor y coraje para seguir adelante en los momentos más difíciles, y por iluminar mis pensamientos y mis palabras cuando más lo necesité.

A mi hermano, Alexis G. Romero Montaña, gracias por estar al lado de nuestros padres mientras yo me encontraba lejos de casa, por asumir responsabilidades y brindarles compañía cuando más lo necesitaban. Agradezco profundamente tu esfuerzo y tu manera de protegerme de las preocupaciones del hogar para que pudiera enfocarme en mis estudios y perseguir este sueño con tranquilidad. Tu apoyo, tu cariño y tu confianza significaron más de lo que las palabras pueden expresar.

A mi familia, por el apoyo incondicional, por sus palabras de aliento y sobre todo por su confianza.

A mi asesor principal de Tesis, Dr. Jorge Méndez González, por brindarme los conocimientos y herramientas necesarias para desarrollar este proyecto, por ser mi psicólogo cuando lo necesite, por enseñarme que la constancia puede más que el miedo y que incluso los procesos más difíciles terminan convirtiéndose en aprendizaje. Por ser un gran maestro, en la escuela y en la vida.

A mis amigos, por las aventuras y experiencias compartidas, por acompañarme a lo largo de esta etapa tan importante de mi vida.

A mi mejor amigo, Bernardo F. López García, gracias por siempre escucharme, por brindarme tu apoyo incondicional y por compartir conmigo tu forma de ver la vida, por enseñarme a encontrar valor y belleza incluso en los detalles más simples. Gracias por acompañarme en algunos de los momentos más difíciles de mi vida, por ayudarme a seguir adelante cuando más lo necesitaba. Tu amistad ha sido un regalo invaluable y una fuente constante de aprendizaje y alegría a lo largo de este camino.

A mi Luna, tu apoyo silencioso y tu compañía fue muy importante durante esta etapa de mi vida.

ÍNDICE DE CONTENIDO

1. INTRODUCCIÓN	1
1.1 Objetivo e hipótesis	4
1.1.1 Objetivo general	4
1.1.2 Objetivos específicos	4
1.2 Hipótesis	5
2. REVISIÓN DE LITERATURA	6
2.1 El Desierto Chihuahuense	6
2.2 Cambio Climático.....	7
2.3 Influencia del clima en la $cdAGB$.....	9
2.4 Densidad de carbono de la biomasa viva aérea $cdAGB$	10
2.5 Variables bioclimáticas	11
2.6 Modelos GLM.....	12
2.7 Estudios similares.....	14
3. MATERIALES Y MÉTODOS.....	17
3.1 Descripción del área de estudio.....	17
3.2. Obtención de datos de biomasa y variables ambientales	18
3.3. Selección de predictores y control de multicolinealidad	20
3.4. Generación y validación del modelo	21
3.5. Predicción espacial y escenarios de cambio climático.....	21
4. RESULTADOS Y DISCUSIÓN.....	23
4.1 Generalidades de la información	23
4.2 Selección de variables bioclimáticas	25
4.3 Modelo para predecir la $cdAGB$	28
4.4 Validación del modelo de predicción de la $cdAGB$.....	30
4.5 Predicción actual de $cdAGB$	32
4.6 Predicción futura de la densidad de carbono de la biomasa viva aérea ($cdAGB$).....	33
5. CONCLUSIONES	41
6. LITERATURA CITADA.....	42
7. ANEXOS	50

ÍNDICE DE CUADROS

Cuadro 1. Estadísticos descriptivos de las variables utilizadas en los conjuntos de entrenamiento (n = 608) y validación (n = 151) para la predicción de la densidad de carbono de la biomasa viva aérea (c_dAGB), y sus predictores en el sur de la provincia del Desierto Chihuahuense.	24
Cuadro 2. Coeficientes de regresión para la predicción de la densidad de carbono de la biomasa viva aérea (c_dAGB) en el sur de la provincia del Desierto Chihuahuense en territorio mexicano.	26
Cuadro 3. Clasificación de Superficie (km^2) por intervalos de cambio en la c_dAGB en el sur de la provincia del desierto Chihuahuense bajo distintos escenarios SSP y horizontes temporales.....	38

ÍNDICE DE FIGURAS

Figura 1. Área de estudio en el contexto global (izquierda) y en el contexto regional (derecha). Los puntos verdes representan los sitios (conglomerados) utilizados para en análisis de la $_{cd}AGB$ en el sur de la provincia del Desierto Chihuahuense.	18
Figura 2. Predicción actual de la densidad de carbono de la biomasa viva aérea ($Mg\ C\ ha^{-1}$) en base al modelo generado para el sur de la provincia del Desierto Chihuahuense. El tamaño del círculo y el gradiente de color indican los valores de $_{cd}AGB$	33
Figura 3. Cambios en la densidad de carbono de la biomasa viva aérea en la provincia del Desierto Chihuahuense bajo los escenarios SSP1-2.6 (superior izquierdo), SSP2-4.5 (superior derecho), SSP3-7.0 (inferior izquierdo) y SSP5-8.5 (inferior derecho) para el año 2030.	34
Figura 4. Cambios en la densidad de carbono de la biomasa viva aérea en la provincia del Desierto Chihuahuense bajo los escenarios SSP1-2.6 (superior izquierdo), SSP2-4.5 (superior derecho), SSP3-7.0 (inferior izquierdo) y SSP5-8.5 (inferior derecho) para el año 2050.	35
Figura 5. Cambios en la densidad de carbono de la biomasa viva aérea en la provincia del Desierto Chihuahuense bajo los escenarios SSP1-2.6 (superior izquierdo), SSP2-4.5 (superior derecho), SSP3-7.0 (inferior izquierdo) y SSP5-8.5 (inferior derecho) para el año 2070.	36

RESUMEN

El cambio climático se ha intensificado de manera significativa durante las últimas décadas, generando alteraciones importantes en los almacenes de carbono de los ecosistemas forestales. El objetivo de esta investigación fue modelar la distribución espacial de la densidad de carbono de la biomasa viva aérea ($_{cd}AGB$) en el sur del Desierto Chihuahuense para los horizontes 2030, 2050 y 2070. Para ello, se utilizó información de $_{cd}AGB$ proveniente del Inventario Nacional Forestal y de Suelos 2015–2020, así como variables bioclimáticas empleadas como predictores, cuya selección se realizó mediante el algoritmo Random Forest, verificando además la ausencia de multicolinealidad entre variables. La modelación se desarrolló mediante modelos lineales generalizados (GLM), utilizando el 80% de los datos para el entrenamiento y el 20% restante para la validación. Las proyecciones futuras se generaron a partir de cinco modelos de circulación general bajo cuatro escenarios de Trayectorias Socioeconómicas Compartidas (SSP1-2.6, SSP2-4.5, SSP3-7.0 y SSP5-8.5). Los resultados mostraron un promedio de $9.69 \text{ Mg C ha}^{-1}$ de $_{cd}AGB$. El modelo final incorporó la precipitación del trimestre más húmedo (BIO 16), con relación positiva, y la temperatura máxima del mes más cálido (BIO 5), con relación negativa, variables que permitieron explicar el 13.5% de la varianza observada. Las proyecciones evidenciaron una tendencia consistente hacia la disminución de $_{cd}AGB$ en la región. Para 2030, el 76% del área de estudio presentará reducciones de 0 a -1 Mg C ha^{-1} ; hacia 2050, las pérdidas de -1 a -3 Mg C ha^{-1} se expandirán hasta afectar el 43% de la región; mientras que para 2070 cerca del 70% de la superficie registrará disminuciones dentro de ese mismo intervalo. Estos resultados evidencian la elevada vulnerabilidad ecológica del Desierto Chihuahuense frente a las tendencias actuales de calentamiento global. En conclusión, es prioritario diseñar e implementar políticas de mitigación a escala local orientadas tanto a la conservación de las zonas con mayor acumulación de biomasa como a la restauración de ecosistemas degradados, con el fin de fortalecer la capacidad de almacenamiento de carbono y reducir los efectos del cambio climático en la región.

Palabras clave: Carbono, biomasa, desierto, vulnerabilidad, modelación, proyecciones.

SUMMARY

Climate change has intensified markedly over recent decades, resulting in substantial alterations to the carbon stocks of forest ecosystems. The objective of this study was to model the spatial distribution of aboveground living biomass carbon density ($_{cd}AGB$) in the southern Chihuahuan Desert for the 2030, 2050, and 2070 projection horizons. To this end, $_{cd}AGB$ data obtained from the 2015–2020 National Forest and Soils Inventory were combined with bioclimatic variables used as predictors. Variable selection was conducted using the Random Forest algorithm, while the absence of multicollinearity among predictors was simultaneously verified. Modeling was performed using generalized linear models (GLMs), allocating 80% of the dataset for model calibration and the remaining 20% for validation. Future projections were generated using five general circulation models under four Shared Socioeconomic Pathway scenarios (SSP1-2.6, SSP2-4.5, SSP3-7.0, and SSP5-8.5). The results revealed a mean $_{cd}AGB$ of $9.69 \text{ Mg C ha}^{-1}$. The final model incorporated precipitation during the wettest quarter (BIO16), which exhibited a positive association, and maximum temperature during the warmest month (BIO 5), which showed a negative association; together, these variables accounted for 13.5% of the observed variance. The projections demonstrated a consistent regional decline in $_{cd}AGB$. By 2030, approximately 76% of the study area is projected to experience reductions ranging from 0 to -1 Mg C ha^{-1} . By 2050, losses between -1 and -3 Mg C ha^{-1} are expected to expand across 43% of the region, whereas by 2070, nearly 70% of the total area is projected to exhibit declines within the same interval. These findings underscore the high ecological vulnerability of the Chihuahuan Desert in response to ongoing global warming trends. In conclusion, the development and implementation of local-scale mitigation strategies should be considered a priority, particularly those aimed at conserving areas with high biomass accumulation and restoring degraded ecosystems, in order to enhance carbon storage capacity and mitigate the impacts of climate change throughout the region.

Key words: Carbon, biomass, desert, vulnerability, modeling, projections.

1. INTRODUCCIÓN

Las emisiones de gases de efecto invernadero (GEI) derivadas de las actividades humanas continúan incrementándose de manera considerable. De acuerdo con el IPCC (2023), estas emisiones representan la principal causa del cambio climático (CC), ya que han contribuido al aumento de aproximadamente 1.1 °C en la temperatura superficial global durante el periodo 2011–2020 respecto a 1850–1900. El mismo organismo señala que, entre 2010 y 2019, las emisiones siguieron aumentando como consecuencia del uso insostenible de la energía, el cambio de uso del suelo, así como de los patrones de consumo y producción predominantes (IPCC, 2023). Actualmente, el cambio climático afecta la intensidad y frecuencia de fenómenos meteorológicos extremos en distintas regiones del mundo, generando impactos importantes sobre la salud humana y fuertes afectaciones en los ecosistemas forestales. Además, se considera uno de los principales impulsores de la pérdida de biodiversidad, afectando la seguridad alimentaria y la disponibilidad de agua a escala global (IPCC, 2023).

Los ecosistemas proporcionan servicios ambientales fundamentales para el bienestar humano, entre ellos la purificación del aire y del agua, la formación y conservación de los suelos, el reciclaje de nutrientes, la protección contra la erosión hídrica y eólica, así como la regulación del clima y la mitigación de eventos meteorológicos extremos (Semarnat, 2016). Dentro de estos ecosistemas, las zonas áridas poseen una relevancia particular, ya que cubren más del 35 % de la superficie terrestre y aproximadamente el 60 % del territorio nacional (Pointing y Belnap, 2012), lo que resalta la importancia de su estudio y conservación.

El Desierto Chihuahuense (DC), considerado el desierto más grande de Norteamérica (Granados-Sánchez et al., 2011), posee una superficie de 874,360.89 km² (Sandoval-Mata et al., 2024) y uno de los más diversos biológicamente a nivel mundial, ocupando el tercer lugar en riqueza de especies (Camargo-Sanabria y Hernández, 2020). En esta región se han registrado alrededor de 826 especies endémicas (Tecoatlapeuh Nelly, 2024), mientras que

cerca de 258 especies de cactáceas se encuentran bajo alguna categoría de riesgo de acuerdo con la Norma Oficial Mexicana NOM-059-ECOL-2001 (Granados-Sánchez et al., 2011). Además de su importancia ecológica, el desierto alberga especies vegetales con relevancia económica y potencial productivo, entre ellas el guayule, la candelilla, los izotes y la lechuguilla (Granados-Sánchez et al., 2011).

La densidad de carbono de la biomasa viva aérea (c_{dAGB}) comprende el almacén de carbono por unidad de área contenido en la vegetación viva presente sobre la superficie del suelo, incluyendo troncos, ramas y hojas (IPCC, 2003). Aproximadamente el 50 % de su composición corresponde a carbono fijado mediante el proceso de fotosíntesis (Rodríguez-Veiga et al., 2017). Este componente representa uno de los reservorios de carbono más visibles y dinámicos de los ecosistemas terrestres, aunque también es uno de los más vulnerables ante perturbaciones ambientales, lo que puede ocasionar que se convierta en una fuente emisora de carbono (Kumar y Mutanga, 2017). Generalmente, la densidad de carbono aéreo se estima aplicando factores de conversión que oscilan entre 0.44 y 0.51 sobre las estimaciones de biomasa (Cartus et al., 2014). No obstante, algunos estudios han reportado valores superiores, entre 55 y 57 %, en especies de bosques secos (Abich et al., 2018). A pesar de la aparente escasez de vegetación en las zonas áridas, estos ecosistemas almacenan aproximadamente el 36 % del carbono presente en los ecosistemas terrestres globales (Montaño et al., 2016).

Algunos estudios, como el realizado por Briones et al. (2018), demostraron que la biomasa aérea aumenta significativamente conforme se incrementan la precipitación y la temperatura en regiones áridas mexicanas; dicho autor reportó que estas zonas almacenan en promedio 10.3 Mg ha^{-1} de carbono, valor superior al promedio registrado en otros desiertos del mundo. Asimismo, se ha documentado que la densidad de carbono presenta correlación positiva con la precipitación media anual (MAP) y negativa con la temperatura media anual (MAT), lo que sugiere que los climas más húmedos y frescos favorecen una mayor acumulación de carbono en biomasa aérea (Balima et al., 2021).

Las proyecciones climáticas para México indican escenarios preocupantes. Se espera que la temperatura aumente alrededor de $0.82 \text{ }^{\circ}\text{C}$ entre 2020 y 2039, alcanzando $1.63 \text{ }^{\circ}\text{C}$ hacia mediados de siglo (2040–2059) y hasta $3.55 \text{ }^{\circ}\text{C}$ para finales del siglo XXI (World Bank

Group, 2023). Asimismo, se prevé un incremento de hasta 15 % en la frecuencia de sequías hidrológicas, junto con una disminución en la precipitación de -1.90 % para el periodo 2020–2039, de -4.65 % para 2040–2059 y de hasta -9.61 % hacia finales de siglo, mientras que se espera un aumento en la intensidad de las precipitaciones, favoreciendo la ocurrencia de eventos extremos (World Bank Group, 2023). En regiones áridas mexicanas, la disponibilidad de agua constituye el principal factor regulador de la biomasa y de la productividad primaria (Briones et al., 2018).

En el ámbito ambiental, los modelos estadísticos GLM han demostrado ser herramientas útiles para predecir la distribución espacial de especies y comunidades, así como para analizar procesos ecológicos y comprender la respuesta de los sistemas biológicos frente a un conjunto reducido de variables predictoras seleccionadas estadísticamente (Guisan et al., 2002). De igual manera, el uso combinado de enfoques paramétricos y no paramétricos, como Random Forest, ha permitido mapear la biomasa aérea a grandes escalas espaciales con resultados satisfactorios (Rodríguez-Veiga et al., 2017).

Por otro lado, la base de datos WorldClim 2 representa una herramienta ampliamente utilizada en estudios ambientales debido a que proporciona superficies climáticas globales de alta resolución espacial, aproximadamente de 1 km². Estas superficies se generan a partir de datos mensuales de variables climáticas básicas y sirven como base para derivar las variables bioclimáticas BIO 1–BIO 19, las cuales son fundamentales en múltiples aplicaciones científicas (Hijmans, 2017). Esta base de datos ha sido empleada en investigaciones relacionadas con la proyección de densidad de carbono en biomasa aérea viva dentro de ecosistemas forestales (Sandoval-García et al., 2024).

Los modelos de circulación general (GCM) constituyen representaciones del sistema climático que integran simplificaciones, parametrizaciones y aproximaciones numéricas de componentes como la atmósfera, los océanos y la biosfera, permitiendo realizar simulaciones climáticas a largo plazo (Wang et al., 2020). Estos modelos son considerados herramientas fundamentales en la evaluación de impactos del cambio climático debido a su capacidad para proyectar variables climáticas futuras y analizar la respuesta del sistema climático bajo diferentes escenarios de emisiones (Deb, 2018). Deb (2018) señala que las incertidumbres asociadas a estos modelos pueden reducirse significativamente mediante el uso de ensambles

multimodelo, obteniendo resultados más robustos que aquellos derivados de un único modelo climático.

En el presente estudio se desarrolló una proyección geoespacial orientada a analizar los posibles cambios en la densidad de carbono en la biomasa aérea viva ($cdAGB$) para los años 2030, 2050 y 2070. Para ello, se empleó un modelo GLM construido a partir de variables bioclimáticas estadísticamente significativas, seleccionadas mediante un enfoque no paramétrico basado en Random Forest. Asimismo, se construyó un ensamble de cinco modelos GCM (ACCESS-ESM1-5, MIROC6, GISS-E2-1-G, GISS-E2-1-H y UKESM1-0-LL) con el fin de generar proyecciones de cuatro escenarios de Trayectorias Socioeconómicas Compartidas: SSP1-2.6, SSP2-4.5, SSP3-7.0 y SSP5-8.5 (W/m^2). A partir de ello, se mapearon los cambios proyectados en la distribución de la $cdAGB$ respecto a las condiciones climáticas actuales.

1.1 Objetivo e hipótesis

1.1.1 Objetivo general

Modelar la distribución espacial de la densidad de carbono de la biomasa viva aérea en el sur del Desierto Chihuahuense, mediante datos del Inventario Nacional Forestal y de Suelos (2015–2020) y variables bioclimáticas, bajo diferentes escenarios climáticos proyectados para 2030, 2050 y 2070.

1.1.2 Objetivos específicos

Desarrollar modelos bioclimáticos para predecir la distribución espacial de la densidad de carbono de la biomasa viva aérea en el sur del Desierto Chihuahuense, mediante variables bioclimáticas actuales.

Predecir la distribución espacial futura de la densidad de carbono de la biomasa viva aérea para los años 2030, 2050 y 2070, empleando cuatro escenarios de Trayectorias Socioeconómicas Compartidas (SSP1-2.6, SSP2-4.5, SSP3-7.0 y SSP5-8.5) y un ensamble de cinco modelos de circulación general: ACCESS-ESM1-5, MIROC6, GISS-E2-1-G, GISS-E2-1-H y UKESM1-0-LL.

Determinar los cambios espaciales en la densidad de carbono de la biomasa viva aérea en el sur del Desierto Chihuahuense para los horizontes 2030, 2050 y 2070, mediante la comparación entre las condiciones climáticas actuales y las proyecciones generadas bajo cuatro escenarios de Trayectorias Socioeconómicas Compartidas (SSP1-2.6, SSP2-4.5, SSP3-7.0 y SSP5-8.5), utilizando un ensamble de cinco modelos de circulación general.

1.2 Hipótesis

Con base en las evidencias actuales del incremento de la temperatura asociado al cambio climático, se espera que la temperatura sea el principal predictor de la densidad de carbono de la biomasa viva aérea en el sur del Desierto Chihuahuense y el principal impulsor de los cambios proyectados en su distribución y acumulación bajo escenarios climáticos futuros.

2. REVISIÓN DE LITERATURA

2.1 El Desierto Chihuahuense

El Desierto Chihuahuense (DC) es considerado el desierto más grande de Norteamérica (Granados-Sánchez et al., 2011), con una superficie de 874,360.89 km²; su extensión abarca parte del sur de Estados Unidos, principalmente en Texas, Nuevo México y Arizona Nuevo México y Texas, y se extiende ampliamente por México en los estados de Chihuahua, Coahuila, Durango, Zacatecas, San Luis Potosí, Nuevo León, Sonora, Aguascalientes, Guanajuato, Querétaro, Hidalgo, Estado de México, Tamaulipas, Jalisco y Michoacán (Sandoval-Mata et al., 2024). La región se encuentra rodeada por importantes sistemas montañosos que limitan el paso de la humedad proveniente de los vientos costeros; entre ellos destacan la Sierra Madre Oriental, la Sierra Madre Occidental y la Faja Volcánica Transmexicana en México, así como las Montañas Rocallosas en Estados Unidos (Granados-Sánchez et al., 2011).

El DC es reconocido además como el tercer desierto con mayor riqueza de especies a nivel mundial (Camargo-Sanabria y Hernández, 2020). Dentro de esta región existen numerosas plantas con importancia económica o potencial productivo, entre las que destacan el guayule, la candelilla, los izotes y la lechuguilla (Granados-Sánchez et al., 2011). Asimismo, los abanicos aluviales y las cuencas del desierto desempeñan un papel fundamental en la recarga de acuíferos que abastecen de agua a numerosas poblaciones humanas localizadas en la zona fronteriza (Ruhlman et al., 2012).

En cuanto a la vegetación, predominan asociaciones de matorral desértico micrófilo, donde abundan especies como la gobernadora (*Larrea tridentata* (DC.) Coville) y el hojazén (*Flourensia cernua* DC.) (Granados-Sánchez et al., 2011). También se presentan comunidades de matorral desértico rosetófilo, caracterizadas por especies con hojas en roseta, como la lechuguilla (*Agave lechuguilla* Torr.), el sotol (*Dasyllirion palmeri* S. Watson) y la palma o izote (*Yucca carnerosana* (Trel.) McKelvey). Además, son comunes los

pastizales dominados por *Hilaria mutica* (Buckley) Benth. y *Bouteloua* Lag. spp., los mezquitales de *Prosopis glandulosa* Torr., extensas áreas de matorral crassicaule con nopaleras de *Opuntia* Mill. spp., así como bosques de pino-encino en las zonas montañosas de mayor altitud (Granados-Sánchez et al., 2011). De las 3,382 especies de flora registradas en el DC, aproximadamente 826 son endémicas (Tecoatlapeuh Nelly, 2024).

La fauna característica del Desierto Chihuahuense incluye especies como el venado bura (*Odocoileus hemionus* Rafinesque), el coyote (*Canis latrans* Say), el berrendo (*Antilocapra americana* Ord), el puma (*Puma concolor* Linnaeus), el lince (*Lynx rufus* Schreber) y el pecarí de collar (*Pecari tajacu* Linnaeus), también destacan pequeños mamíferos como las ratas canguro (*Dipodomys* Gray spp.), los ratones espinosos (*Chaetodipus* Merriam spp.), los conejos (*Sylvilagus* Gray spp.), las liebres (*Lepus* Linnaeus spp.) y los perros de la pradera (*Cynomys* Rafinesque spp.) (Camargo-Sanabria y Hernández, 2020). Entre las aves sobresalen las águilas (*Aquila* Brisson), los halcones (*Buteo* Lacépède) y diversas especies de búhos y lechuzas (*Bubo* Duméril, *Asio* Brisson y *Tyto* Billberg); en cuanto a los reptiles, son frecuentes las serpientes de cascabel (*Crotalus* Linnaeus) y las serpientes cincuate (*Pituophis* Holbrook y *Elaphe* Fitzinger) (Camargo-Sanabria y Hernández, 2020).

Las condiciones climáticas del DC se caracterizan por precipitaciones anuales que oscilan entre 80 y 400 mm, concentrándose principalmente entre junio y septiembre (Sandoval-Mata et al., 2024). Durante el verano predominan temperaturas diurnas elevadas que van de 5.5 a 11 °C, aunque generalmente menores que las registradas en el Desierto de Sonora; mientras que en invierno son comunes las heladas moderadas e incluso severas en altitudes mayores a los 1700 m s. n. m. (Granados-Sánchez et al., 2011).

2.2 Cambio Climático

El Cambio Climático (CC) constituye actualmente una de las principales problemáticas ambientales a nivel global debido a los efectos que genera sobre los sistemas climáticos, ecológicos e hidrológicos del planeta, siendo la actividad humana identificada como la principal responsable del calentamiento global a causa de las elevadas emisiones de gases de efecto invernadero derivadas de actividades industriales, energéticas y del cambio de uso del suelo, las cuales han provocado, desde mediados del siglo XIX, una acumulación progresiva

de dióxido de carbono y otros gases en la atmósfera, contribuyendo directamente al incremento de la temperatura global (IPCC, 2023).

De acuerdo con el IPCC (2023), durante el periodo 2011–2020 la temperatura media global registró un aumento aproximado de 1.1 °C respecto a los niveles preindustriales, con un rango estimado entre 0.95 y 1.20 °C; asimismo, datos actualizados hasta 2022 indican que el calentamiento global se aproxima a 1.15 °C, lo que refleja la rapidez con la que continúan intensificándose los cambios climáticos a escala planetaria.

Entre los principales gases responsables del calentamiento destacan el dióxido de carbono (CO₂) y el metano (CH₄). Se estima que, durante el periodo 2010–2019, el CO₂ contribuyó aproximadamente con 0.8 °C del calentamiento observado, mientras que el CH₄ aportó cerca de 0.5 °C, consolidándose ambos como compuestos con una influencia significativa sobre el balance energético de la Tierra (IPCC, 2023).

Las proyecciones climáticas indican además que el umbral de 1.5 °C podría alcanzarse durante la primera mitad de la década de 2030 bajo la mayoría de las Trayectorias Socioeconómicas Compartidas (SSP). No obstante, el IPCC señala que incluso en escenarios de emisiones muy bajas, existe la posibilidad de que la temperatura global supere temporalmente dicho umbral antes de disminuir nuevamente hacia finales de siglo, siempre y cuando se logren emisiones netas negativas (IPCC, 2023).

El incremento continuo de la temperatura global trae consigo diversas consecuencias ambientales. Cada fracción adicional de calentamiento incrementa la frecuencia e intensidad de fenómenos extremos, particularmente las olas de calor. Asimismo, fortalece el ciclo hidrológico, favoreciendo eventos de precipitación extrema más intensos y periodos de sequía cada vez más severos y recurrentes (IPCC, 2023).

Estas alteraciones representan una amenaza importante para los ecosistemas áridos y semiáridos, debido a su elevada sensibilidad frente a los cambios de temperatura y a la disponibilidad de agua (IPCC, 2023). En este contexto, Huang et al. (2016) señala que durante las últimas décadas se ha registrado una expansión acelerada de las zonas áridas a nivel global; las proyecciones climáticas sugieren que, hacia finales del presente siglo, las

tierras secas podrían abarcar entre el 50 % y el 56 % de la superficie terrestre mundial bajo distintos escenarios de emisiones.

La vegetación presente en las tierras secas suele caracterizarse por una distribución dispersa y una productividad naturalmente limitada, condiciones que incrementan su fragilidad ante el aumento de temperatura y la reducción de la disponibilidad hídrica, de modo que la disminución de la productividad vegetal afecta directamente la capacidad de secuestro de carbono, permitiendo que mayores concentraciones de CO₂ permanezcan en la atmósfera, por lo que diversos estudios destacan la necesidad de implementar estrategias orientadas a reducir la vulnerabilidad de las tierras secas y frenar los procesos de desertificación, entre las cuales sobresalen la restauración de la cobertura vegetal y la recuperación de ecosistemas degradados debido a su papel fundamental en la regulación climática, la conservación del suelo y el mantenimiento de la capacidad de captura de carbono (Huang et al., 2016).

2.3 Influencia del clima en la ρ_d AGB

Aunque la literatura internacional proporciona múltiples evidencias de la sensibilidad de la biomasa aérea al clima, los estudios específicos para zonas áridas mexicanas, y particularmente para el Desierto Chihuahuense, son limitados; se ha encontrado que, en regiones áridas y semiáridas, el incremento de la temperatura genera efectos negativos sobre la biomasa aérea debido al aumento del estrés hídrico y la limitación de los procesos fisiológicos de las plantas; un ejemplo claro es el estudio de Aguirre Gutiérrez (2022) reportó que las regiones caracterizadas por elevada aridez y altas temperaturas presentan las mayores reducciones en sus sumideros netos de carbono, llegando incluso a convertirse en emisores netos de CO₂ hacia la atmósfera. En las sabanas africanas también se han identificado tendencias preocupantes, ya que para el año 2070 se proyecta una disminución considerable en la capacidad de almacenamiento de carbono en Burkina Faso debido al incremento de la aridez climática (Dimobe et al. 2018).

Por otra parte, diversos estudios han demostrado que el efecto de la temperatura sobre la biomasa no es uniforme a nivel global y puede variar dependiendo de las condiciones climáticas regionales, por ejemplo, en ecosistemas fríos o boreales el aumento de la temperatura puede generar efectos positivos sobre el crecimiento vegetal al prolongar las temporadas de crecimiento, como en el estudio de Paquette et al. (2017), quienes reportaron

que, en regiones frías de Quebec, Canadá, el incremento de temperatura favoreció la productividad forestal debido a la extensión del periodo de crecimiento. Del mismo modo, Nadezhda M. Devi et al. (2020) encontraron que los cambios recientes de temperatura estimularon el crecimiento y la acumulación de biomasa en el límite arbóreo de los Montes Urales polares en Rusia. Fu et al. (2017) también documentaron que temporadas de crecimiento más cálidas favorecieron significativamente la acumulación de biomasa aérea en *Pinus massoniana* Lamb. en China.

La precipitación también ha sido reconocida como un factor fundamental para el mantenimiento de la biomasa y la productividad vegetal. Ortiz-Reyes et al. (2021) encontraron que, en las selvas de la Península de Yucatán, la precipitación anual fue la variable más influyente para predecir la biomasa aérea, ejerciendo un control más importante sobre su densidad que otras variables ambientales. Resultados semejantes fueron obtenidos por Nolan et al. (2019), quienes señalaron que el riesgo de que la vegetación se transforme en una fuente neta de carbono en Australia está fuertemente relacionado con la escasez de lluvia. De igual forma, Gao et al. (2019) observaron en especies de alerce que la biomasa aumenta con mayores niveles de precipitación anual, aunque disminuye bajo condiciones de isothermalidad elevada y menor precipitación durante la temporada de crecimiento.

2.4 Densidad de carbono de la biomasa viva aérea $_{cdAGB}$

En ecosistemas forestales, la biomasa aérea concentra entre el 70 y el 90 % de la biomasa total del bosque, por lo que constituye una de las reservas de carbono más importantes a nivel terrestre (Kumar y Mutanga, 2017). De hecho, se estima que alrededor del 45 % del carbono terrestre del planeta se encuentra almacenado en los bosques, principalmente en forma de biomasa aérea generada a través de la fotosíntesis (Pedro Rodríguez, 2017). Esta visión más amplia ha incrementado notablemente el interés por su estudio en las últimas décadas, sobre todo por la creciente preocupación relacionada con el calentamiento global y con la función que desempeñan los ecosistemas terrestres en el almacenamiento de carbono y la regulación de gases de efecto invernadero (Kumar y Mutanga, 2017).

Según Kumar y Mutanga (2017) la biomasa aérea viva representa uno de los depósitos de carbono más visibles y dinámicos dentro de los ecosistemas terrestres. Por ello, su monitoreo constante resulta esencial para evaluar reservas de carbono, fortalecer mercados de bonos de

carbono y apoyar estrategias dirigidas a la prevención de incendios forestales. Asimismo, los autores señalan que una adecuada cuantificación y representación espacial de la biomasa permite comprender con mayor precisión los efectos del cambio climático, además de respaldar actividades asociadas con bioenergía, manejo forestal y aprovechamiento maderable. La biomasa, expresada en peso seco, contiene aproximadamente un 50 % de carbono. Por ello, las estimaciones de biomasa viva aérea son ampliamente utilizadas tanto en inventarios de carbono como en investigaciones enfocadas en la captura de carbono atmosférico (Kumar y Mutanga, 2017). En este contexto, las técnicas de teledetección espacial, combinadas con mediciones de campo, se han consolidado como herramientas eficientes para el monitoreo de biomasa a gran escala, ya que facilitan el análisis de su distribución espacial en regiones extensas, tanto a nivel nacional como global (Pedro Rodríguez, 2017).

La complejidad estructural y ambiental característica de numerosos ecosistemas ha impulsado el desarrollo y uso de algoritmos de modelación espacial más robustos, entre los más utilizados destacan métodos no paramétricos como Random Forest y MaxEnt, los cuales suelen presentar un mejor desempeño que los enfoques tradicionales al extrapolar la distribución espacial de la biomasa a través del paisaje (Pedro Rodríguez, 2017).

2.5 Variables bioclimáticas

WorldClim, particularmente en su versión 2, corresponde a una base de datos climática compuesta por registros mensuales interpolados espacialmente para las áreas terrestres del planeta. Su resolución espacial es de 30 segundos de arco, equivalente aproximadamente a 1 km² (0.86 km² en el Ecuador), lo que permite representar con mayor precisión las variaciones climáticas entre distintas regiones y favorece su aplicación en estudios ecológicos, ambientales y de cambio climático (Hijmans, 2017).

A partir de los datos mensuales de temperatura y precipitación proporcionados por WorldClim se generan las variables bioclimáticas conocidas como BIOCLIM. Estas variables son ampliamente utilizadas para describir patrones ecológicos asociados con la estacionalidad, la variabilidad climática y los eventos extremos del clima (Hijmans, 2005; Hijmans, 2017). Debido a ello, han sido empleadas de manera frecuente en investigaciones orientadas al análisis de zonas bioclimáticas y procesos ambientales a escala global (Hijmans,

2017). Además, las superficies climáticas derivadas de WorldClim 2 son consideradas actualmente una referencia de alta resolución para el desarrollo, evaluación y comparación de modelos ambientales y escenarios de cambio climático (Hijmans, 2017).

En el estudio realizado por Sandoval-García et al. (2024), se utilizaron las 19 variables bioclimáticas de WorldClim versión 2 con el propósito de identificar los principales predictores de la densidad de carbono en biomasa aérea viva ($_{cd}AGB$). Para ello, los autores aplicaron técnicas de aprendizaje automático mediante la librería “*caret*” (Kuhn, 2024) de R (R Core Team, 2026), incorporando validación cruzada de 10 pliegues y un procedimiento de selección hacia atrás (*backward selection*). Los resultados indicaron que las variables bioclimáticas lograron explicar entre el 20 y el 22 % de la varianza total de la densidad de carbono a escala de ecorregión. Asimismo, estimaron que el aumento proyectado de la temperatura, que podría alcanzar hasta 3.36 °C hacia el año 2070, ocasionaría pérdidas de biomasa en todos los escenarios climáticos evaluados, con reducciones estimadas de entre 15 y 20 Mg C ha⁻¹ en la región central del país.

La relevancia de incorporar variables bioclimáticas también ha sido señalada en estudios enfocados en la densidad potencial de biomasa aérea (AGB). Un ejemplo de ello es la investigación desarrollada por Bengochea Paz et al. (2024), quienes emplearon el algoritmo de aprendizaje automático XGBoost en combinación con un método de selección de predictores basado en el algoritmo evolutivo NSGA-II, el análisis se realizó a partir de un conjunto inicial de 20 variables bioclimáticas derivadas de CHELSA-BIOCLIM+, con la finalidad de identificar aquellas con mayor influencia sobre la AGB. Entre las variables que mostraron mayor capacidad predictiva destacaron la temperatura media anual del aire, la temperatura máxima del mes más cálido, la precipitación anual total y el rango anual de temperatura del aire. Los autores concluyeron que un número relativamente reducido de factores climáticos puede explicar gran parte de los patrones espaciales de biomasa observados a gran escala.

2.6 Modelos GLM

Según Antúñez et al. (2017), los Modelos Lineales Generalizados (GLM) constituyen herramientas estadísticas ampliamente utilizadas en ecología moderna debido a su capacidad para modelar la respuesta de los organismos frente a diferentes factores ambientales. De

acuerdo con Guisan et al. (2002), estos modelos representan una extensión de los modelos lineales tradicionales, ya que permiten analizar relaciones no lineales y trabajar con datos cuya varianza no permanece constante, evitando así la necesidad de transformar la información a escalas poco naturales. Además, los GLM establecen la relación entre las variables predictoras y la variable respuesta mediante una función de enlace, lo que facilita interpretar el efecto de las variables independientes sobre el fenómeno estudiado.

Desde el punto de vista estructural, un Modelo Lineal Generalizado se integra por tres componentes principales: el componente aleatorio, el componente sistemático y la función de enlace. El componente aleatorio describe el comportamiento estadístico de la variable respuesta; el sistemático corresponde a la combinación lineal de las variables predictoras; mientras que la función de enlace conecta ambos componentes, permitiendo representar la influencia de las variables explicativas sobre la variable de interés dentro del modelo (Antúñez et al. (2017).

En ecología, los modelos GLM han sido utilizados ampliamente para predecir la distribución espacial de especies y comunidades, incluyendo árboles, arbustos, aves e invertebrados acuáticos. Una de sus principales ventajas es que pueden trabajar con distintas familias de distribuciones de probabilidad, entre ellas la gamma, la cual se ajusta bien a datos con estructuras de error no normales, permitiendo manejar la no-linealidad y varianzas no constantes sin forzar los datos a escalas antinaturales (Guisan et al., 2002), como es el caso de este estudio.

Diversos estudios han señalado la utilidad de este tipo de modelos debido a su capacidad explicativa y relativa simplicidad, un ejemplo de ello es el trabajo desarrollado por Paquette et al. (2017), quienes modelaron cdAGB en bosques de coníferas de México, los autores generaron modelos GLM capaces de explicar entre el 52 y el 72 % de la varianza observada ($p < 0.05$), dependiendo del tipo de clima evaluado, posteriormente compararon el modelo GLM original con modelos de mínimos cuadrados generalizados (GLS) para incorporar la correlación espacial de los errores, sin embargo, observaron que los coeficientes obtenidos no presentaban diferencias significativas, por lo que optaron por conservar el modelo GLM debido a su mayor simplicidad y facilidad de interpretación.

2.7 Estudios similares

Sandoval-García et al. (2024) desarrollaron modelos predictivos para estimar la densidad de carbono de la biomasa viva aérea (cdAGB) en los bosques de coníferas de México, considerando especies de los géneros *Pinus*, *Abies*, *Cupressus* y *Juniperus*. El estudio se llevó a cabo a escala nacional y distinguió tres regiones biogeográficas o estratos, con el propósito de analizar cómo diferentes condiciones ambientales influyen en el almacenamiento de carbono. Para ello, se emplearon modelos lineales generalizados (GLM) construidos a partir de variables bioclimáticas relacionadas principalmente con la temperatura y la precipitación. En el estrato I, la cdAGB estuvo asociada con la temperatura máxima del mes más cálido (Bio5) y la precipitación del trimestre más cálido (Bio18); en el estrato II, la variación observada se relacionó con la temperatura máxima del mes más cálido (Bio5) y la precipitación anual (Bio12), mientras que en el estrato III destacaron la temperatura media del trimestre más cálido (Bio10) y la precipitación del mes más húmedo (Bio13).

Si bien los modelos mostraron valores de R^2 relativamente bajos, entre 0.10 y 0.32, con un promedio de 0.19, los resultados permitieron identificar patrones espaciales relevantes en la distribución del carbono almacenado. Las estimaciones de cdAGB registradas en los sitios de inventario oscilaron entre 7.48 y 71.29 Mg C ha⁻¹. Los autores observaron que las variables relacionadas con la temperatura ejercieron una influencia más marcada que aquellas asociadas con la precipitación. Bajo escenarios futuros de cambio climático, las proyecciones estimaron pérdidas potenciales de hasta 15 Mg C ha⁻¹ hacia el año 2070, lo que evidencia la susceptibilidad de los bosques de coníferas mexicanos frente a las alteraciones climáticas previstas y sus posibles efectos sobre la capacidad de captura y almacenamiento de carbono.

Briones et al. (2018) estudiaron la biomasa aérea y el carbono almacenado en la vegetación de las principales regiones áridas de México, incluyendo las zonas Sonorense, Chihuahuense, Tamaulipeca, Hidalguense y Poblana. El análisis se basó en información obtenida de 23 sitios representativos de matorrales xerófilos y pastizales. Los resultados mostraron una relación positiva de la biomasa aérea tanto con la precipitación como con la temperatura. Sin embargo, la temperatura presentó una capacidad explicativa ligeramente superior ($R^2 = 0.27$) en comparación con la precipitación ($R^2 = 0.23$), sugiriendo una influencia relevante de las condiciones térmicas sobre la dinámica de la vegetación en las zonas áridas. Además, los autores estimaron una biomasa aérea promedio de 23.2 ± 4.15 Mg ha⁻¹ y un almacenamiento m

edio de carbono de 10.3 Mg ha^{-1} . Uno de los hallazgos más importantes fue que la disponibilidad de agua se identificó como el principal factor asociado con la producción de biomasa en estos ecosistemas.

Bengochea Paz et al. (2024) desarrollaron un modelo de variables climáticas para estimar la densidad potencial de biomasa aérea a escala global utilizando información obtenida de parcelas forestales distribuidas en diversos biomas. El estudio se basó únicamente en cuatro variables bioclimáticas: temperatura media anual, temperatura máxima del mes más cálido, precipitación anual y rango anual de temperatura. El modelo alcanzó un desempeño comparable al de enfoques mucho más complejos que incorporaban hasta 190 variables ambientales, registrando un error absoluto medio (MAE) de 42 Mg ha^{-1} .

Las predicciones mostraron diferencias notables entre regiones; en el norte de la Amazonía se estimaron valores cercanos a 169 Mg ha^{-1} de biomasa aérea potencial, mientras que, en ambientes más secos, como el Chaco Seco, los valores se aproximaron a 40 Mg ha^{-1} , estos contrastes refuerzan la influencia del clima sobre la distribución de la biomasa forestal a escala global. Los autores mencionan que la simplicidad del modelo no solo favorece una interpretación ecológica más clara de los patrones observados, sino que también facilita su aplicación en evaluaciones prospectivas relacionadas con los efectos del cambio climático sobre la biomasa y el almacenamiento de carbono.

Balima et al. (2021) investigaron los factores climáticos relacionados con el almacenamiento de carbono aéreo en ecosistemas forestales de Burkina Faso, África Occidental, a partir de información recopilada en cuatro áreas protegidas representativas de las sabanas sudanesas. Los resultados indicaron que las mayores densidades de carbono se registraron en las zonas con mayor disponibilidad de precipitación, mientras que los valores tendieron a disminuir conforme aumentó la temperatura media anual. En conjunto, las estimaciones de carbono almacenado oscilaron entre 47.82 y $67.95 \text{ Mg C ha}^{-1}$, reflejando diferencias asociadas a las condiciones ambientales predominantes en cada sitio evaluado. Aunque la precipitación y la temperatura mostraron efectos estadísticamente significativos, su capacidad para explicar la variación observada fue relativamente limitada, con valores de R^2 ajustado de 3.35% y 2.62% , respectivamente.

Chen et al. (2024) estudiaron la distribución espacial de la biomasa aérea y subterránea en distintos ecosistemas terrestres de China, entre ellos bosques, pastizales, matorrales, desiertos, praderas y humedales. Para ello, emplearon una base de datos integrada por 4,485 sitios de muestreo distribuidos a nivel nacional, lo que permitió evaluar cómo varía la biomasa bajo una amplia gama de condiciones ambientales. A partir de modelos de Random Forest y ecuaciones estructurales, identificaron a la elevación, la radiación solar y la temperatura media anual como los factores más influyentes en la distribución de la biomasa aérea. Las variables climáticas, las propiedades del suelo y la disponibilidad de nutrientes explicaron el 53 % de la variación observada ($R^2 = 0.53$), resaltando la importancia de la interacción entre estos componentes en el funcionamiento de los ecosistemas terrestres.

Los autores observaron que tanto la radiación solar como la precipitación media anual favorecieron la acumulación de biomasa, mientras que la temperatura media anual mostró una relación negativa. Este comportamiento fue atribuido a un incremento en la evaporación del suelo y a una menor eficiencia en el uso del agua, especialmente en ambientes áridos y semiáridos. Los autores consideraron la elevación como el predictor más importante debido a su capacidad para modificar indirectamente las condiciones climáticas y la disponibilidad de nutrientes. En conjunto, estos hallazgos indican que la distribución de la biomasa responde a una interacción compleja entre factores topográficos y climáticos.

3. MATERIALES Y MÉTODOS

3.1 Descripción del área de estudio

El Desierto Chihuahuense es uno de los desiertos más extensos de América del Norte (Granados-Sánchez et al., 2011), con una superficie aproximada de 874,360.89 km². Su extensión abarca parte del sur de Estados Unidos, principalmente en Texas, Nuevo México y Arizona Nuevo México y Texas, y se extiende ampliamente por México en los estados de Chihuahua, Coahuila, Durango, Zacatecas, San Luis Potosí, Nuevo León, Sonora, Aguascalientes, Guanajuato, Querétaro, Hidalgo, Estado de México, Tamaulipas, Jalisco y Michoacán (Sandoval-Mata et al., 2024). Se localiza en una planicie delimitada por sistemas montañosos como la Sierra Madre Oriental y Occidental (Granados-Sánchez et al. 2011), con un rango altitudinal que va aproximadamente de 1000 a más de 3000 m.s.n.m. (Sandoval-Mata et al., 2024). El clima es predominantemente árido a semiárido con temperaturas que oscilan entre 16 y 22 °C, caracterizado por inviernos fríos y secos y veranos cálidos (Sandoval-Mata et al., 2024). La precipitación es limitada y altamente variable, generalmente entre poco menos de 80 mm y 400 mm anuales (Sandoval-Mata et al., 2024), concentrándose mayormente entre el 65 y 80 % durante el verano (junio a septiembre), mientras que el resto del año presenta condiciones marcadamente secas (Granados-Sánchez et al., 2011). Esta estacionalidad, junto con la ocurrencia de sequías prolongadas, convierte a la disponibilidad de agua en el principal factor limitante de la productividad vegetal (Granados-Sánchez et al., 2011)

Los suelos son predominantemente de origen calcáreo, incluyendo aridisoles (Granados-Sánchez et al., 2011) y leptosoles, caracterizados por ser someros, con contenidos reducidos de materia orgánica (Campuzano et al., 2021) y baja capacidad de retención de agua (Flores-Márgez et al., 2025); Sin embargo, la materia orgánica tiende a concentrarse en microambientes bajo la cobertura de arbustos, formando “islas de fertilidad” que generan una distribución espacial heterogénea de los recursos (Granados-Sánchez et al., 2011).

La vegetación dominante corresponde al matorral xerófilo en sus distintas variantes, acompañado por pastizales en zonas más bajas y comunidades arbóreas en áreas montañosas (Granados- Sánchez et al., 2011.) Esta cobertura vegetal es generalmente discontinua (Sandoval-Mata et al., 2024) y responde a la disponibilidad de agua, la cual, junto con la temperatura y la topografía, controla la productividad del ecosistema (Campuzano et al., 2021).

El área de estudio se delimitó cartográficamente con base en la regionalización biogeográfica que proponen Morrone, J. J., Escalante, T., & Rodríguez-Tapia, G. (2017) (Figura 1). Se seleccionó la superficie correspondiente a la Provincia del Desierto Chihuahuense, restringiendo el análisis exclusivamente a la porción comprendida dentro del territorio mexicano.




Figura 1. Área de estudio en el contexto global (izquierda) y en el contexto regional (derecha). Los puntos verdes representan los sitios(conglomerados) utilizados para en análisis de la $_{cd}AGB$ en el sur de la provincia del Desierto Chihuahuense.

3.2. Obtención de datos de biomasa y variables ambientales

Los datos dasométricos para el cálculo de la densidad de carbono de la biomasa viva aérea ($_{cd}AGB$), se obtuvieron del Inventario Nacional Forestal y de Suelos (INFyS) 2015-2020 (CONAFOR, 2026). Dicho inventario emplea un esquema de muestreo sistemático con una

equidistancia de 5×5 km entre unidades de muestreo denominadas «conglomerados» (Cglm). Cada Cglm está diseñado con cuatro sitios circulares de 400 m² para el registro del estrato arbóreo; no obstante, debido a la operatividad del inventario, el número de sitios efectivos por conglomerado puede variar. La base de datos del inventario incluye de manera directa los valores estimados de biomasa viva aérea y densidad de carbono para cada sitio de muestreo, por lo que no fue necesario realizar cálculos adicionales para su determinación.

Para el desarrollo de este estudio se emplearon las variables coordenadas geográficas X (longitud) y Y (latitud), altura total de los árboles (m), diámetro normal (cm), área basal (m²), volumen (m³), carbono sobre el suelo (t ha⁻¹) y biomasa individual (kg). La biomasa total por conglomerado se obtuvo mediante la suma de la biomasa individual de los árboles registrados en cada conglomerado, posteriormente extrapolada a toneladas por hectárea con base en la superficie efectiva muestreada.

Del conjunto total de datos disponibles, se seleccionaron exclusivamente los sitios de muestreo localizados dentro de la provincia del Desierto Chihuahuense en México. A partir de este proceso se integró una base de 759 conglomerados, cuya distribución espacial permitió representar adecuadamente la heterogeneidad existente en el área de estudio. Estos conglomerados constituyeron la unidad de análisis utilizada para desarrollar los modelos orientados a estimar la densidad de carbono asociada a la biomasa viva aérea.

Para asegurar la calidad de la información de la base de datos, se realizó un proceso de depuración. Este consistió en la exclusión de registros (conglomerados) con información incompleta (especies no identificadas) y la eliminación de valores atípicos (*outliers*) en las variables utilizadas, garantizando así la consistencia estadística de los análisis posteriores.

Para predecir la c_dAGB , se emplearon 19 variables bioclimáticas (Anexo 1) obtenidas de WorldClim (v2.1) en formato raster (SpatRaster) mediante la paquetería “*geodata*” (Hijmans, 2026) del software R (R Core Team, 2026), correspondientes a promedios climáticos del periodo 1970-2000 con una resolución de 30 segundos de arco (~1 km) (Fick y Hijmans, 2017). Las variables representan las condiciones de temperatura y precipitación que determinan la productividad primaria neta (Gao et al., 2019; Wang et al., 2024).

3.3. Selección de predictores y control de multicolinealidad

El conjunto de datos de $cdAGB$ se dividió de manera aleatoria mediante una proporción de 80/20 con la función “createDataPartition” de la librería “*caret*” (Kuhn, 2024) en RStudio (R Core Team, 2026). El 80 % de los datos se utilizó para el entrenamiento y ajuste de parámetros del modelo, mientras que el 20 % restante se reservó estrictamente para la validación externa y la evaluación del desempeño general del modelo. Este procedimiento ha sido ampliamente utilizado en estudios de modelación ecológica y predicción de biomasa, donde la partición de los datos permite evaluar la capacidad predictiva de los modelos en datos independientes (Dimobe et al., 2018; Chen, H., et al., 2024); Sandoval-García et al., 2024).

Con el fin de asegurar la robustez del modelo, se llevó a cabo un proceso de selección de los mejores predictores (Anexo 1). Se empleó el método Random Forest para la elección de las variables que describen mejor el comportamiento del modelo (para identificar las variables con mayor capacidad explicativa sobre la $cdAGB$), ya que ha demostrado ser eficiente en el ajuste de relación entre condiciones ambientales y crecimiento vegetal, siendo superior a otros algoritmos de aprendizaje automático (Chen, H., et al. 2024). El enfoque Random Forest ha sido utilizado en varios estudios de predicción de biomasa en diferentes ecosistemas (He et al., 2022; Chen, Y., et al. 2024; Dimobe et al., 2018).

Posteriormente, se verificó la ausencia de multicolinealidad mediante el cálculo del Factor de Inflación de la Varianza (VIF), utilizando los parámetros $VIF < 5$ “No existe colinealidad”, VIF entre 5 y 10 “Colinealidad moderada”, $Vif > 10$ “Existe colinealidad Alta”. Este proceso ha sido usado para verificar la multicolinealidad entre las variables predictoras en modelación de biomasa aérea. (Feyisa et al., 2016).

La importancia de las variables se evaluó mediante el método de permutación (permutation importance), utilizando como criterio el incremento porcentual del error cuadrático medio (%IncMSE). Este procedimiento consiste en permutar aleatoriamente los valores de cada variable predictora en las observaciones Out-Of-Bag (OOB) y medir el aumento del error de predicción resultante. De esta manera, las variables cuya alteración produce un mayor incremento en el error son consideradas más importantes para el modelo.

$$\%IncMSE = \frac{MSE_{perm} - MSE_{original}}{MSE_{original}} \times 100$$

Donde: $MSE_{original}$: Corresponde al error cuadrático medio obtenido con los datos originales. MSE_{perm} : Representa el error cuadrático medio calculado después de permutar aleatoriamente los valores de una variable. $\%IncMSE$: Indica la contribución de la variable a la capacidad predictiva del modelo.

Las variables con los mayores valores de $\%IncMSE$ fueron seleccionadas para la construcción del Modelo Lineal Generalizado (GLM).

3.4. Generación y validación del modelo

Para predecir la $cdAGB$, se utilizó un Modelo Lineal Generalizado (GLM) empleando una función de distribución de la familia Gamma y función de enlace logarítmica. Sandoval-García et al. (2024) y Paquette et al. (2017) proponen que dicho enfoque es reconocido por su eficacia para modelar variables continuas en contextos ecológicos y climáticos. Para el GLM se utilizó como variable respuesta la $cdAGB$ y como variables explicativas las variables bioclimáticas (Anexo 1) seleccionadas por Random Forest.

Con el fin de evaluar la precisión del modelo generado se aplicaron cuatro técnicas de validación utilizando el paquete “caret” (Kuhn, 2024) de R (R Core Team, 2026), incluyendo el método LOOCV (Leave-One-Out Cross-Validation): Validación Cruzada de Dejar-Uno-Fuera; CV: Validación Cruzada; boot: remuestreo tipo bootstrap; repeatedcv: validación cruzada repetida.

3.5. Predicción espacial y escenarios de cambio climático

La predicción espacial actual de la $cdAGB$ se realizó con el modelo GLM sobre las variables bioclimáticas mejor ajustadas, utilizando la función “predict” del paquete “terra” en R (Hijmans et al., 2026). Posteriormente se generó un mapa raster de predicción actual de $cdAGB$ con la librería “raster” (Hijmans et al., 2025) del software R (R Core Team, 2026).

Para la predicción futura de $cdAGB$, con el propósito de incorporar la variabilidad, se seleccionaron los modelos de circulación general (GCM): ACCESS-ESM1-5, MIROC6, GISS-E2-1-G, GISS-E2-1-H y UKESM1-0-LL, de los cuales, únicamente se eligieron los

predictores bioclimáticos de $_{cd}AGB$ seleccionados anteriormente (los seleccionados por Random Forest). Estos modelos pertenecen al Proyecto de Intercomparación de modelos acoplados fase 6 (CMIP6), y se obtuvieron mediante la librería “*geodata*” en R (Hijmans et al., 2026). Se seleccionaron cinco modelos con el propósito de incorporar la variabilidad, utilizando el promedio de estos (ensemble) para las predicciones futuras, lo cual permite reducir la incertidumbre inherente a las simulaciones climáticas.

Para las proyecciones futuras de $_{cd}AGB$ se consideraron los escenarios de trayectorias socioeconómicas compartidas (SSP): SSP1-2.6, SSP2-4.5, SSP3-7.0 y SSP5-8.5, los cuales representan diferentes trayectorias de desarrollo socioeconómico y niveles de emisiones de gases de efecto invernadero (Riahi et al., 2017). Dichos escenarios forman parte del marco de proyecciones climáticas del Panel Intergubernamental sobre el Cambio Climático (IPCC), ampliamente utilizado para evaluar posibles condiciones futuras bajo distintos contextos de cambio climático (Riahi et al., 2017). Se generaron proyecciones de $_{cd}AGB$ para tres horizontes temporales futuros: 2021–2040, 2041–2060 y 2061–2080, los cuales fueron representados por los años de referencia 2030, 2050 y 2070, respectivamente.

Mediante álgebra de mapas, se promediaron las 5 capas ráster correspondientes a cada GCM, SSP y año, utilizando dicho promedio para predecir la $_{cd}AGB$ del área de estudio. Este proceso se ejecutó con la librería “*raster*” (Hijmans et al., 2025) en R (R Core Team, 2026), empleando el argumento `type = "response"` para generar las cartografías de predicción. Finalmente, el cambio en la biomasa se determinó mediante la diferencia entre el escenario actual y futuro con la expresión: $_{cd}AGB \text{ (futura)} - _{cd}AGB \text{ (actual)}$; de esta forma, valores de 0 indican que los valores de los píxeles son igual en ambos escenarios (sin cambios), valores positivos señalan un incremento de la $_{cd}AGB$ en el futuro y valores negativos representan una disminución respecto a la actualidad.

4. RESULTADOS Y DISCUSIÓN

4.1 Generalidades de la información

A partir de los sitios del INFyS (2015-2020) se obtuvieron los datos utilizados para el desarrollo y validación de los modelos de predicción de densidad de carbono de la biomasa viva aérea (c_dAGB). Del total de sitios, 608 sitios (80 %) fueron destinados al conjunto de entrenamiento y 151 sitios (20 %) al conjunto de validación o prueba. La distribución espacial de los puntos de muestreo presentó una cobertura amplia a lo largo de la región de estudio, abarcando principalmente los estados de Chihuahua, Coahuila, Durango, Zacatecas, San Luis Potosí y Nuevo León, donde se observó la mayor concentración de sitios de muestreo (Figura 1).

La superficie total del área de estudio tiene una extensión de 578001.5 km² delimitada mediante el polígono de la provincia del Desierto Chihuahuense que proponen Morrone, J. J., Escalante, T., & Rodríguez-Tapia, G. (2017). Esta amplitud territorial permitió incorporar una alta variabilidad ambiental y estructural de la vegetación, incluyendo diferencias en precipitación, temperatura y atributos dasométricos.

Los estadísticos descriptivos de las variables utilizadas se presentan en la Tabla 1. En términos generales, se observó que los conjuntos de entrenamiento y validación mostraron distribuciones similares para todas las variables analizadas, lo que indica una partición balanceada y representativa de los datos originales. El algoritmo de Random Forest eligió entre otras a la BIO 16 (la precipitación del trimestre más húmedo) y a BIO 5 (la temperatura máxima del mes más cálido) como mejores predictores de c_dAGB , dicho esto, la BIO 16 presentó valores promedio de 326.72 mm en el conjunto de entrenamiento y 346.23 mm en el conjunto de prueba, con amplitudes que oscilaron entre 100 y 737 mm para entrenamiento y entre 152 y 603 mm para validación.

Por su parte, la BIO 5 mostró menor variabilidad relativa, con medias cercanas a 30 °C en ambos conjuntos y valores máximos de 40.3 °C y 39.6 °C para entrenamiento y prueba, respectivamente.

Respecto a las variables estructurales de la vegetación, la densidad de carbono de la biomasa viva aérea (c_{dAGB}) registró medias de 9.69 Mg C ha⁻¹ en entrenamiento y 10.42 Mg C ha⁻¹ en validación, aunque con desviaciones estándar relativamente altas (10.50 y 11.12, respectivamente), lo cual indica una marcada heterogeneidad espacial de c_{dAGB} . Asimismo, los valores máximos alcanzaron 80.14 Mg C ha⁻¹ en entrenamiento y 65.65 Mg C ha⁻¹ en prueba, reflejando la presencia de sitios con alta acumulación de c_{dAGB} .

El diámetro normal (DBH) presentó promedios de 14.43 cm y 14.94 cm para entrenamiento y validación, respectivamente, mientras que la altura total de los individuos (m) mostró medias cercanas a 4.6–4.7 m. En general, las variables exhibieron valores relativamente consistentes entre conjuntos, lo que confirma que el proceso de partición mantuvo adecuadamente la estructura dasométrica de los datos.

Cuadro 1. Estadísticos descriptivos de las variables utilizadas en los conjuntos de entrenamiento (n = 608) y validación (n = 151) para la predicción de la densidad de carbono de la biomasa viva aérea (c_{dAGB}), y sus predictores en el sur de la provincia del Desierto Chihuahuense.

Grupo	Variable	Media	DE	Min.	Mediana	Max.	Hist.
Entrenamiento	BIO 16	326.722	92.920	100.000	331.000	737.000	
	BIO 5	30.369	2.949	23.100	30.200	40.300	
	c_{dAGB}	9.688	10.497	0.100	6.279	80.144	
	D	14.433	4.279	7.700	13.412	34.850	
	Altura	4.609	1.329	1.614	4.339	12.449	
Prueba	BIO 16	346.225	107.688	152.000	338.000	603.000	
	BIO 5	30.329	2.716	23.700	30.200	39.600	
	c_{dAGB}	10.419	11.122	0.143	6.175	65.649	
	D	14.940	4.507	8.300	14.016	33.900	
	Altura	4.739	1.428	1.178	4.451	10.707	

Donde. DE: Desviación estándar; Min.: Valor Mínimo; Max.: Valor máximo; BIO 16: precipitación del trimestre más húmedo (mm); BIO 5: temperatura máxima del mes más cálido; $_{cd}AGB$: Densidad de carbono de la biomasa viva aérea ($Mg\ C\ ha^{-1}$); D: Diámetro normal medido a 1.30 m del suelo (cm).

Autores como Sandoval-García et al. (2024) y Cartus et al. (2014) confirman que el uso de una base de datos nacional estandarizada como lo es el Inventario Nacional Forestal y de Suelos (INFiS), permite generar estimaciones consistentes de la densidad de carbono de la biomasa viva aérea ($_{cd}AGB$), así como desarrollar modelos espaciales confiables. Como señala He et al. (2022), la relevancia de los inventarios nacionales para el manejo forestal y la mitigación climática se potencia al incorporar variables climáticas; esta combinación no solo optimiza la certidumbre de los modelos de biomasa, sino que resulta esencial para el mapeo efectivo de las existencias de carbono a gran escala.

4.2 Selección de variables bioclimáticas

Las variables predictoras de $_{cd}AGB$ integrados en el modelo GLM comprendieron la temperatura máxima del mes más cálido (BIO 5), que mostró una relación negativa con la $_{cd}AGB$ con un valor de -0.0847 ($p = 5.32e-08$), lo que indica que temperaturas máximas más elevadas se asocian con una reducción en la $_{cd}AGB$. Por el contrario, la precipitación del trimestre más húmedo (BIO 16) mostró una relación positiva con la $_{cd}AGB$ con un valor de 0.0025 ($p = 2.57e-07$), lo que indica el aumento en la precipitación del trimestre más húmedo, está asociada a un aumento en la $_{cd}AGB$. Cabe destacar que, dentro de la estructura del modelo, las variables BIO 16 y BIO 5 presentaron los mayores valores de %IncMSE (Cuadro 2), por lo que fueron seleccionadas para la construcción del Modelo Lineal Generalizado (GLM).

Cuadro 2. Coeficientes de regresión para la predicción de la densidad de carbono de la biomasa viva aérea ($_{cd}AGB$) en el sur de la provincia del Desierto Chihuahuense en territorio mexicano.

Coef.	Est.	2.5	97.5	Std.	T	Pr	Var.	VIF	Imp. (%)
				Err	Value	(> t)	Exp.		
β_0 (Int.)	3.9349	2.8667	5.0129	0.5320	7.396	4.71e-13 ***			
β_1 (BIO 16)	0.0025	0.0016	0.0035	0.0005	5.212	2.57e-07 ***	13.5	1.07	11.86
β_2 (BIO 5)	-0.0847	-0.1157	-0.0537	0.0154	-5.510	5.32e-08 ***		1.07	10.33

Donde: β_0 , β_1 , y β_2 : son los coeficientes de regresión. Est.: Valor estimado. 2.5 y 97.5: intervalos de confianza del 95 % de los coeficientes de regresión. Std. Err: error estándar de los coeficientes de regresión. Pr (> |t|): la probabilidad de obtener un valor T más extremo que el observado, asumiendo que la hipótesis nula es verdadera. Var. Exp.: Varianza explicada. VIF: factor de inflación de la varianza. Imp = valor de importancia de las variables. BIO 16 (Precipitación del trimestre más lluvioso (mm). BIO 5: Temperatura máxima del mes más cálido (°C). Significación estadística: * ($p < 0.05$): Significativo; ** ($p < 0.01$): Altamente significativo; *** ($p < 0.001$): Muy altamente significativo.

Se ha demostrado que las variables bioclimáticas (Anexo 1) derivadas de WorldClim tienen gran capacidad predictiva de biomasa aérea en zonas áridas, como lo menciona el estudio de Gao et al. (2019) en una zona semiárida de China, donde generaron y compararon modelos sensibles al clima para predecir biomasa aérea (AGB) y el crecimiento del diámetro a la altura del pecho (DBH). Los autores encontraron que dos de las variables predictoras mejor ajustadas para su modelo fueron variables climáticas incluyendo el incremento en la precipitación anual (BIO 12) con un valor de 4.9833, y la isothermalidad (BIO 3) con un valor de -0.2715, ambas variables estadísticamente significativas ($p < 0.05$). De igual manera, (Chen, Y., et al. (2024) realizaron modelación de biomasa aérea y subterránea en bosques, pastizales, matorrales, desiertos y humedales (China), encontrando que dos de las variables predictoras de densidad de la biomasa aérea (AGB) fueron parámetros bioclimáticos que incluyeron la BIO 1 con un valor estimado de -0.15 ($p < 0.05$) y BIO 12 con un valor estimado de 0.23 ($p < 0.001$).

Al contrastar la literatura con los hallazgos de esta tesis, se observa que, en los ecosistemas semiáridos, la disponibilidad hídrica (variables de precipitación) mantiene una correlación positiva con la biomasa aérea. Por el contrario, las variables térmicas tienden a presentar una relación negativa, sugiriendo que el incremento en las temperaturas y la variabilidad térmica pueden exacerbar el estrés hídrico y, en consecuencia, reducir la capacidad de almacenar carbono de las plantas.

Investigaciones como las de Xin et al. (2022) y Mahardika et al. (2023) coinciden en que la inclusión de variables bioclimáticas en modelos de predicción de biomasa total y de sus componentes (raíces, tallos, ramas y acículas), permite capturar la respuesta de este fenómeno ante variaciones ambientales y escenarios de cambio climático. Estos autores han desarrollado modelos de biomasa “sensibles al clima” utilizando datos de WorldClim, argumentando que los modelos tradicionales basados únicamente en variables dasométricas (diámetro, altura) tienden a ignorar la influencia del clima.

Una de las principales fortalezas de WorldClim, como señalan Fernández-Martínez et al. (2014) y Xin et al. (2022), radica en que proporciona datos mensuales derivados de series temporales extensas (1950–2000) con alta resolución espacial ($\sim 1 \text{ km}^2$), además de variables bioclimáticas derivadas como la estacionalidad y la amplitud térmica, las cuales son útiles para explicar el funcionamiento de los ecosistemas. Esta característica resulta particularmente relevante en zonas áridas y semiáridas como el Desierto Chihuahuense, donde la variabilidad climática juega un papel clave en la productividad primaria (Huenneke et al. 2001).

Por otro lado, Narváez Ortiz et al. (2026) destacan que, a pesar de su alta resolución, los datos de WorldClim presentan limitaciones asociadas a su naturaleza interpolada, lo que puede generar incertidumbre en regiones con baja densidad de estaciones meteorológicas. Sin embargo, los mismos autores reconocen que esta herramienta es fundamental para compensar la falta de instrumentación en tierra y la escasez de datos históricos en muchas regiones, lo cual justifica su uso en estudios como el presente.

4.3 Modelo para predecir la $_{cd}AGB$

A partir del proceso de selección de variables, las variables bioclimáticas que cumplieron con los criterios de significancia estadística y ausencia de multicolinealidad, se generó una ecuación con la siguiente estructura:

$$_{cd}AGB = e^{\beta_0 + \beta_1(BIO\ 16) + \beta_2(BIO\ 5)}$$
$$_{cd}AGB = e^{3.9349 + 0.0025*(BIO\ 16) - 0.0847*(BIO\ 5)}$$

Donde:

$_{cd}AGB$ = Densidad de carbono de biomasa vegetal aérea ($Mg\ C\ ha^{-1}$), BIO 16= precipitación del trimestre más húmedo (mm), BIO 5 = temperatura máxima del mes más cálido ($^{\circ}C$), β_0 = intercepto del modelo. β_1 y β_2 = coeficientes de regresión asociados a las variables predictoras.

Las variables bioclimáticas fueron ordenadas de acuerdo con su importancia relativa dentro del modelo (Cuadro 2), identificándose BIO 16 y BIO 5 como las variables con mayor contribución explicativa sobre la variación de $_{cd}AGB$. De manera similar, Chen, Y., et al. (2024), al modelar biomasa aérea en ecosistemas áridos de China, incluyendo desiertos y pastizales, reportaron que la precipitación media anual (BIO 12) tuvo un efecto positivo de 0.23 ($p < 0.001$). Resultados semejantes fueron documentados por Noulèkoun et al. (2018), en plantaciones de *Moringa oleifera* y *Jatropha curcas* en el Benín semiárido, encontrando que la precipitación total anual en días húmedos (ATWP) presentó coeficientes positivos de 0.46 y 0.45, respectivamente, lo que refleja una influencia significativa de la precipitación sobre el crecimiento de ambas especies.

A partir de los hallazgos anteriores y su contraste con lo observado en esta investigación, es posible discernir que en ambientes con limitaciones hídricas la precipitación constituye uno de los factores más importantes para la acumulación de biomasa y por ende del carbono, lo cual coincide con los resultados obtenidos en el presente estudio para el sur del Desierto Chihuahuense.

La relevancia de las variables de precipitación también ha sido ampliamente documentada en ecosistemas forestales templados y de coníferas. Por ejemplo, Sandoval-García et al.

(2024), al modelar la densidad de carbono de biomasa viva aérea en bosques de coníferas de México, identificaron que la precipitación del trimestre más cálido (BIO 18) fue una variable predictora significativa en el estrato árido del noroeste del país, con un coeficiente de 0.0586 ($p < 0.001$), mientras que la precipitación anual (BIO 12) mostró un coeficiente positivo de 0.0190 ($p < 0.001$) en el estrato centro-sur. En ecosistemas tropicales y humedales, Quinto Mosquera (2010), encontró una correlación positiva significativa entre la precipitación y la biomasa aérea total ($r = 0.73$; $p = 0.02$), en el Pacífico y los Andes colombianos. De igual manera, Wang et al. (2021), en marismas de la meseta tibetana, reportaron una correlación positiva entre la precipitación anual y la biomasa, con un coeficiente de Pearson de 0.543 ($p < 0.05$).

En estrecha concordancia con los hallazgos del presente estudio, algunas investigaciones sostienen que las variables de temperatura ejercen una influencia negativa sobre la biomasa en ecosistemas áridos. Por ejemplo, Gao et al. (2019), al modelar la biomasa aérea en zonas semiáridas, identificaron a la isotermidad (BIO 3) como una variable predictora clave con un coeficiente de -0.2715 ($p < 0.05$). De manera similar, en el noroeste de China, Chen, Y., et al. (2024) determinaron que la temperatura media anual (MAT) es un factor determinante para predecir AGB en los ecosistemas terrestres de China, reportando un valor estimado de -0.15 ($p < 0.05$) para dicha región caracterizada por su aridez.

La variable de temperatura también ha mostrado tener relación negativa en otro tipo de ecosistemas, como lo muestra Sandoval-García et al. (2024), quienes al modelar la densidad de carbono de la biomasa aérea en bosques de coníferas de México, encontraron que la temperatura máxima del mes más cálido (BIO 5) presentó coeficientes negativos en el Estrato I del noroeste (-0.1897) y en el Estrato II del centro-sur (-0.2572), mientras que en la Sierra Madre Occidental la temperatura media del trimestre más cálido (BIO 10) también mostró un efecto negativo (-0.0959), siendo todas las variables estadísticamente significativas ($p < 0.05$).

En contraste, otros estudios muestran que no siempre la relación de la temperatura con la biomasa es negativa. En ecosistemas forestales de regiones templadas y frías, diversos autores reportan relaciones positivas entre la temperatura y la acumulación de biomasa. Por ejemplo, en bosques boreales y templados de Canadá y en bosques mediterráneos húmedos

de España, Paquette et al. (2017) encontraron que la temperatura media anual presentó efectos positivos significativos sobre la productividad, con coeficientes de 17.3, 10.7 y 12.3, respectivamente ($p < 0.001$). Resultados similares fueron documentados por Fu et al. (2017) en bosques subtropicales de *Pinus massoniana* en China, donde la temperatura media de la temporada de crecimiento (MGST) mostró un efecto positivo significativo sobre la biomasa aérea ($\beta_3 = 12.062$; $p < 0.05$), indicando que temperaturas más cálidas favorecen el crecimiento y acumulación de biomasa.

Con base en las evidencias anteriores, es posible establecer que la relación de las variables térmicas con la biomasa puede ser positivo o negativo depende del contexto ecológico y climático del área de interés, es decir es altamente variable.

4.4 Validación del modelo de predicción de la $_{cd}AGB$.

Según los métodos de validación aplicados para del modelo de predicción de $_{cd}AGB$ (Tabla 3), el método REPEATEDCV obtuvo el mejor ajuste, con un valor de Pseudo R^2 de 0.155 y los errores más bajos (RMSE = 10.374 y MAE = 7.877). En contraste, el método LOOCV presentó el desempeño más bajo con un valor de Pseudo R^2 de 0.067. Se observaron comportamientos similares entre los métodos REPEATEDCV y CV, así como entre LOOCV y BOOT, aunque estos últimos mostraron una mayor fluctuación en el valor de Pseudo R^2 .

Cuadro 3. Métodos de validación del modelo de regresión bioclimática para predecir la densidad de carbono de la biomasa viva aérea($_{cd}AGB$) en la provincia del sur del Desierto Chihuahuense.

Método	Set	<i>n</i>	Pseudo R^2	RMSE	MAE
	Entrenamiento	608			
REPEATEDCV	Validación	151	0.155	10.374	7.877
LOOCV	Validación	151	0.067	10.733	7.925
CV	Validación	151	0.15	10.441	7.876
BOOT	Validación	151	0.089	10.725	7.95

Donde: LOOCV: Validación Cruzada de Dejar-Uno-Fuera; CV: Validación Cruzada; BOOT: remuestreo tipo bootstrap; REPEATEDCV: validación cruzada repetida; Set: Conjunto de datos utilizado; *n*: tamaño de la muestra; Pseudo R^2 : Coeficiente de Determinación; RMSE: Raíz del Error Cuadrático Medio; MAE: Error Absoluto Medio.

En general, los resultados evidencian similitud entre los valores de Pseudo R^2 que presentan los métodos de validación evaluados y el del modelo, lo que sugiere que el modelo presenta una estabilidad adecuada y un buen desempeño predictivo en la estimación de la $_{cd}AGB$.

La baja capacidad explicativa observada en los diferentes métodos de validación sugiere que la densidad de carbono de la biomasa aérea viva está influenciada por múltiples factores que no fueron completamente capturados en el modelo. Sin embargo, se observa que, en estudios de predicción de biomasa aérea y almacenamiento de carbono en biomasa aérea, donde se utilizan estrictamente variables bioclimáticas como predictoras del modelo, la capacidad predictiva es generalmente baja, como el de Sandoval-García et al. (2024), quienes hicieron modelos de predicción de densidad de carbono en la biomasa aérea en bosques de coníferas en México y mostraron que sus modelos bioclimáticos logran explicar alrededor de 20 % de la varianza. O bien el estudio de Chen, Y., et al. (2024), quienes basándose en todos los ecosistemas de china (Incluyendo bosques, pastizales, matorrales, desiertos y praderas) identificaron el efecto directo del clima sobre la biomasa contribuyó con un 21.7 % a la variación del modelo.

En contraste, los estudios que incorporan múltiples fuentes de información suelen presentar desempeños predictivos considerablemente superiores. Por ejemplo, Ortiz-Reyes et al. (2021) estimaron y mapearon la biomasa aérea (AGB) mediante la integración de variables

climáticas, espectrales y datos LiDAR usando modelos Random Forest, obteniendo un R^2 del 50 % en selvas de la península de Yucatán. Asimismo, Dimobe et al. (2018) registraron valores excepcionalmente altos (R^2 entre 98.40 y 98.92 %) en sabanas semiáridas de Burkina Faso al emplear variables espectrales, topográficas y climáticas para predecir el stock de carbono tanto en biomasa aérea como en el suelo.

Estos antecedentes sugieren que la incorporación de variables estructurales y de percepción remota puede mejorar de manera importante la capacidad predictiva de los modelos empleados para estimar la $cdAGB$.

4.5 Predicción actual de $cdAGB$

El mapa generado bajo condiciones actuales (Figura 2) revela la variación espacial en los niveles de $cdAGB$, donde los mayores almacenes de $cdAGB$ se localizan principalmente hacia el sur y oeste del área de estudio, con almacenes moderados en el este, mientras que los valores más reducidos se distribuyen en las porciones centro y norte del área de estudio.

Los resultados evidencian que los mayores almacenes de carbono se encuentran en regiones montañosas y zonas con mayor cobertura vegetal, mientras que las áreas con menor densidad de carbono se localizaron principalmente en regiones áridas y con vegetación dispersa.




Figura 2. Predicción actual de la densidad de carbono de la biomasa viva aérea (Mg C ha^{-1}) en base al modelo generado para el sur de la provincia del Desierto Chihuahuense. El tamaño del círculo y el gradiente de color indican los valores de cdAGB .

En el presente estudio, los valores medios de cdAGB van desde 9.5 a 10.5, similar a lo que reporta Briones et al. (2018), quienes encontraron que la densidad de carbono promedio almacenado en la vegetación (biomasa aérea) de las zonas áridas de México es de 10.3 Mg ha^{-1} ; en ese estudio también encontraron que, en promedio, el 44.6 % del peso seco de la biomasa de las especies de zonas áridas corresponde a carbono.

4.6 Predicción futura de la densidad de carbono de la biomasa viva aérea (cdAGB).

Las Figuras 3, 4 y 5 muestran los cambios proyectados en la densidad de carbono de la biomasa viva aérea (cdAGB) bajo cuatro diferentes escenarios climáticos para los años 2030, 2050 y 2070 en la provincia del Desierto Chihuahuense. De manera general, se observa que una tendencia consistente hacia la disminución de la cdAGB en la región de estudio, independientemente del escenario y periodo analizado.

Para el año 2030, se observa que una extensión cerca del 76.8 y 82.5 % (según el SSP) del área de estudio, presenta disminuciones de 0 a -1 Mg C ha^{-1} , intensificándose el gradiente de pérdida hacia el sur del área de estudio. En esta región, se identificaron rangos de entre -1 y -3 Mg C ha^{-1} que cubren entre el 18.5 y 23.7 % (según el SSP) de la superficie, detectándose además núcleos aislados (entre 0.9 y 1.5 % del área de estudio) donde la pérdida de biomasa supera los -3 Mg C ha^{-1} (Figura 2).




Figura 3. Cambios en la densidad de carbono de la biomasa viva aérea en la provincia del Desierto Chihuahuense bajo los escenarios SSP1-2.6 (superior izquierdo), SSP2-4.5 (superior derecho), SSP3-7.0 (inferior izquierdo) y SSP5-8.5 (inferior derecho) para el año 2030.

En el periodo correspondiente al año 2050, se observa una intensificación de las pérdidas de cdAGB , con una mayor extensión de las áreas que presentan disminuciones de entre -1 y -3 Mg C ha^{-1} cubriendo aproximadamente entre 33.1 y 43.3 % (según el SSP) aunque la superficie de pérdida de 0 a -1 Mg C ha^{-1} disminuyó sigue cubriendo entre el 52 y 67.4 % (según el SSP) del área de estudio. Las pérdidas mayores a -3 Mg C ha^{-1} aumentaron considerablemente alcanzando entre el 1.6 y 6.8 % (según el SSP) del área de estudio.




Figura 4. Cambios en la densidad de carbono de la biomasa viva aérea en la provincia del Desierto Chihuahuense bajo los escenarios SSP1-2.6 (superior izquierdo), SSP2-4.5 (superior derecho), SSP3-7.0 (inferior izquierdo) y SSP5-8.5 (inferior derecho) para el año 2050.

Para el año 2070, los resultados muestran que la superficie correspondiente con disminución de cd_{AGB} , crece notablemente, cubriendo hasta un 68.9 % (según el SSP) de la superficie pérdidas de entre -1 y -3 $Mg\ C\ ha^{-1}$ de la cd_{AGB} (Figura 5).




Figura 5. Cambios en la densidad de carbono de la biomasa viva aérea en la provincia del Desierto Chihuahuense bajo los escenarios SSP1-2.6 (superior izquierdo), SSP2-4.5 (superior derecho), SSP3-7.0 (inferior izquierdo) y SSP5-8.5 (inferior derecho) para el año 2070.

Los resultados muestran una alta disminución de la $cdAGB$ en prácticamente toda la región a medida que pasa el tiempo. Las áreas con pérdidas más severas se expanden hacia el norte, evidenciando la reducción de la $cdAGB$.

Si bien los resultados muestran que la pérdida de $cdAGB$ en el área de estudio cada vez cubrirá mayor extensión, es posible detectar que también existen tendencias de ganancia Cuadro 3, aunque en pequeñas superficies.

Las categorías asociadas con incrementos positivos de $cdAGB$ muestran una representación espacial muy reducida en todos los escenarios. La clase $(0 - 1]$ apenas supera el 0.4 % (según

el SSP) en 2030 y disminuye progresivamente hasta valores cercanos a cero hacia 2070, especialmente en SSP3-7.0 y SSP5-8.5. Por su parte, la categoría (1 – 3] prácticamente desaparece en los escenarios de mayor calentamiento, indicando que las áreas con incrementos importantes en biomasa aérea serán extremadamente limitadas bajo condiciones climáticas futuras.

Las figuras 3, 4 y 5 evidencian una tendencia espacial clara hacia el incremento de las pérdidas en la $cdAGB$ dentro de la provincia del Desierto Chihuahuense, conforme avanzan los horizontes temporales y aumentan los niveles de emisiones considerados en los escenarios SSP. En términos generales, las categorías que predominan a lo largo del análisis corresponden a pérdidas ligeras (-1 – 0) y pérdidas moderadas (-3 – -1). Sin embargo, en los escenarios más severos y hacia finales del periodo de proyección se aprecia una expansión considerable de las pérdidas severas de $cdAGB$, particularmente en la porción sur y sureste de la provincia.

Para el año 2030 (Figura 3), gran parte del territorio todavía se concentra dentro de la categoría de pérdidas ligeras (-1 – 0). Estas superficies se distribuyen principalmente en regiones de Chihuahua, Coahuila y parte del norte de Durango. Las pérdidas moderadas (-3 – -1) comienzan a presentarse con mayor frecuencia en áreas de Zacatecas, San Luis Potosí y el sur de Nuevo León. Las pérdidas severas (Inf. – -3), aunque todavía limitadas espacialmente, aparecen sobre todo en algunas zonas de San Luis Potosí y sectores de Tamaulipas.

Hacia el año 2050 (Figura 4), las pérdidas moderadas adquieren una mayor relevancia espacial y comienzan a dominar extensas áreas del territorio. La categoría (-3 – -1) se expande desde el sur hacia la parte central de la provincia, abarcando amplias superficies de Coahuila, Nuevo León, Zacatecas y San Luis Potosí. Al mismo tiempo, las pérdidas ligeras (-1 – 0) reducen notablemente su extensión y permanecen principalmente en el norte de Chihuahua y algunas regiones de Durango. Dentro de este periodo, San Luis Potosí destaca como uno de los estados más afectados, mientras que el sur de Coahuila y el norte de Zacatecas muestran un incremento importante en la intensidad de disminución del carbono.

Para 2070 (Figura 5), las tendencias observadas en los periodos anteriores se intensifican de manera evidente. Las pérdidas moderadas (-3 – -1) pasan a dominar gran parte de la provincia

en todos los escenarios analizados, mientras que las pérdidas severas (Inf. – -3) incrementan significativamente su cobertura espacial. El escenario SSP5-8.5 representa la condición más crítica de todo el estudio, ya que las pérdidas severas abarcan extensas áreas del sureste de la provincia, afectando principalmente a San Luis Potosí, Zacatecas, Nuevo León y el sur de Coahuila (Figura 5).

De manera adicional, el comportamiento espacial de las categorías más críticas sugiere un patrón latitudinal, donde las afectaciones comienzan principalmente en el sur y sureste del Desierto Chihuahuense y posteriormente avanzan hacia la parte central de la provincia conforme aumenta tanto el horizonte temporal como la severidad de las emisiones.

Cuadro 3. Clasificación de Superficie (km²) por intervalos de cambio en la $_{cd}AGB$ en el sur de la provincia del desierto Chihuahuense bajo distintos escenarios SSP y horizontes temporales.

SSP	Año	$_{cd}AGB$				
		(Inf. – -3 ■)	(-3 – -1 ■)	(-1 – 0 ■)	(0 – 1 ■)	(1 – 3 ■)
SSP1-2.6	2030	5314.954	107251.573	476874.016	2333.432	46.237
	2050	9582.639	191649.689	389834.991	745.188	7.706
	2070	12292.133	201177.613	377624.544	720.528	5.394
SSP2-4.5	2030	6893.951	119257.806	463413.627	2227.087	27.742
	2050	22194.578	236020.349	333325.551	276.652	3.082
	2070	36818.601	305793.671	249164.786	43.155	0.000
SSP3-7.0	2030	8660.979	137120.738	443919.295	2105.329	13.871
	2050	34690.153	248900.463	308060.830	167.224	1.541
	2070	67053.040	326870.852	197877.826	18.495	0.000
SSP5-8.5	2030	8946.878	136159.777	444871.009	1827.907	14.642
	2050	39861.002	250800.808	300995.031	161.830	1.541
	2070	86900.314	398302.545	106614.271	3.082	0.000

Los resultados muestran una tendencia clara hacia la disminución de la densidad de carbono de la biomasa aérea viva ($_{cd}AGB$) a medida que aumentan tanto la intensidad de los escenarios de emisiones como el horizonte temporal de proyección.

Los resultados obtenidos en este estudio muestran que tanto la temperatura como la precipitación desempeñan un papel importante en la estimación de la $_{cd}AGB$ en proyecciones a largo plazo, lo cual coincide con lo reportado en diversos estudios que integran variables bioclimáticas en modelos de biomasa, como el de Dimobe et al. (2018), quienes en las

sabanas semiáridas de Dano, al suroeste de Burkina Faso, realizaron modelos de predicción de distribución espacial del stock de carbono total integrando tanto el carbono de la biomasa leñosa como el carbono orgánico del suelo (SOC) en las sabanas semiáridas de África Occidental, definiendo las variables bioclimáticas BIO 1 y BIO 12 como variables predictoras para predecir la distribución espacial del stock de carbono total y encontró que los resultados de este modelado indicaron que el cambio climático podría reducir significativamente la capacidad de almacenamiento de carbono en la región para el año 2070, principalmente debido a un desplazamiento hacia un clima más árido.

Diversos estudios, al igual que la presente investigación, han reportado tendencias de disminución en la densidad de carbono de la biomasa viva aérea ($_{cd}AGB$) bajo distintos escenarios ambientales y climáticos. Un ejemplo de ello es el trabajo desarrollado por Sandoval-García et al., quienes mediante modelos bioclimáticos construidos con técnicas de aprendizaje automático (*Machine Learning*), proyectaron pérdidas importantes de $_{cd}AGB$ en bosques de coníferas de México, alcanzando reducciones de hasta -20 Mg C ha^{-1} hacia el año 2070.

Además de las proyecciones futuras, existen evidencias históricas que muestran una disminución progresiva del carbono almacenado en la vegetación. Por ejemplo, Li et al. (2015), por ejemplo, analizaron los cambios ocurridos entre 1979 y 2011 utilizando el Modelo de Ecosistema Árido (AEM), un modelo basado en procesos que simula la dinámica del carbono y del agua en ecosistemas áridos. Sus resultados mostraron pérdidas severas en la densidad de carbono de la vegetación (incluyendo tanto biomasa aérea viva como biomasa radical) con una disminución estimada de 0.3 kg C m^{-2} durante ese periodo.

Resultados semejantes fueron reportados por Ma et al. (2012) en bosques boreales de Canadá. A partir de modelos lineales de efectos mixtos construidos con datos de parcelas permanentes de muestreo correspondientes al periodo 1963–2008, los autores identificaron una reducción neta en el sumidero de carbono de $0.0237 \pm 0.0102 \text{ t C ha}^{-1} \text{ año}^{-1}$, así como una tendencia decreciente significativa en el cambio de biomasa, con una pendiente de $-0.0694 \text{ t ha}^{-1} \text{ año}^{-1}$.

De manera similar, en sabanas y bosques secos de Senegal, Liu et al. (2004), documentaron una reducción aproximada del 46 % del stock de carbono de la biomasa viva a lo largo del siglo XX. De acuerdo con sus resultados, el carbono almacenado pasó de 97 Mg C ha^{-1} en

1900 a 74 Mg C ha^{-1} en 1980, evidenciando una pérdida importante de carbono en estos ecosistemas secos.

Por otro lado, Safari y Sohrabi (2019), en Irán, emplearon modelos de regresión estocástica de aumento de gradiente utilizando series temporales de imágenes Landsat (TM, ETM+ y OLI) junto con datos de campo. Los autores observaron una disminución de la densidad de carbono aéreo entre 2010 y 2015, con valores que descendieron de 7.5 t ha^{-1} a 6.9 t ha^{-1} . Según los investigadores, esta reducción estuvo relacionada con procesos de muerte regresiva (*dieback*) ocasionados por tormentas de polvo, presencia de plagas y efectos asociados al cambio climático.

En términos ecológicos, los resultados destacan la importancia de conservar las áreas con mayor acumulación de biomasa dentro de ecosistemas áridos y semiáridos, ya que estas funcionan como reservorios relevantes de carbono y contribuyen a la mitigación del cambio climático. Además, el uso de modelos predictivos basados en variables bioclimáticas representa una herramienta útil para identificar patrones espaciales de almacenamiento de carbono y apoyar estrategias de manejo y conservación forestal.

5. CONCLUSIONES

El sur del Desierto Chihuahuense constituye la región con mayor vulnerabilidad frente al cambio climático. Este comportamiento se relaciona principalmente con el incremento sostenido de la temperatura y, sobre todo, con la disminución progresiva de la precipitación, factores que reducirán de manera importante la densidad de carbono en biomasa aérea viva (cdAGB). A lo largo de todos los escenarios climáticos analizados se identificó una tendencia claramente decreciente en la cdAGB. En los escenarios iniciales predominan pérdidas comprendidas entre 0 y -1 Mg ha^{-1} ; sin embargo, conforme avanzan las proyecciones hacia finales del siglo, las pérdidas más frecuentes alcanzan valores de hasta -3 Mg C ha^{-1} , evidenciando un deterioro cada vez más severo en la capacidad de almacenamiento de carbono de estos ecosistemas. El escenario SSP585 mostró las condiciones más críticas, registrando principalmente pérdidas de $3.082 \text{ Mg C ha}^{-1}$, lo que refleja un panorama particularmente alarmante bajo condiciones de altas emisiones. Bajo este contexto, amplias zonas podrían experimentar una reducción acelerada de biomasa aérea, comprometiendo no solo la captura de carbono, sino también la estabilidad ecológica y funcional de la región. Las afectaciones más intensas se concentran en los estados de San Luis Potosí, Zacatecas, Nuevo León y el sur de Coahuila, áreas donde el incremento de la aridez podría intensificar aún más los procesos de degradación ambiental. Asimismo, las variables climáticas explicaron en conjunto el 13.5% de la variación de la cdAGB. Se observó una relación positiva con la precipitación y negativa con la temperatura, lo que sugiere que la disminución de las lluvias representa el principal factor asociado a la pérdida de biomasa y carbono en el Desierto Chihuahuense. En términos ecológicos, esta reducción de precipitación podría convertirse en uno de los mecanismos más determinantes en la disminución futura de la capacidad de secuestro de carbono en los ecosistemas áridos de la región.

6. LITERATURA CITADA

Abich, A., Mucheye, T., Tebikew, M., Gebremariam, Y., & Alemu, A. (2018). Species-specific allometric equations for improving aboveground biomass estimates of dry deciduous woodland ecosystems. *Journal of Forestry Research*. <https://doi.org/10.1007/s11676-018-0707-5>

Antúñez, P., Hernández-Díaz, J. C., Wehenkel, C., y Clark-Tapia, R. (2017). Generalized models: An application to identify environmental variables that significantly affect the abundance of three tree species. *Forests*, 8(3), 59. <https://doi.org/10.3390/f8030059>

Bengochea Paz, D., Marquez-Torres, A., Pompeu, J., Martin-Ducup, O., Villa, F., Köhler, C., & Balbi, S. (2024). A climate envelope model for the projection of forest carbon storage on a global scale.

Aguirre-Gutiérrez, J., Berenguer, E., Oliveras Menor, I., Bauman, D., Corral-Rivas, J. J., Nava-Miranda, M. G., Both, S., Ndong, J. E., Ondo, F. E., Bengone, N. N., Mihinhou, V., Dalling, J. W., Heineman, K., Figueiredo, A., González-M, R., Norden, N., Hurtado-M, A. B., González, D., Salgado-Negret, B., ... Malhi, Y. (2022). Functional susceptibility of tropical forests to climate change. *Nature Ecology and Evolution*, 6(7), 878–889. <https://doi.org/10.1038/s41559-022-01747-6>

Paquette, A., Vayreda, J., Coll, L., Messier, C., & Retana, J. (2017). Climate change could negate positive tree diversity effects on forest productivity: A study across five climate types in Spain and Canada. *Ecosystems*, 21(1), 181–194. <https://doi.org/10.1007/s10021-017-0196-y>

Antúñez, P., Hernández-Díaz, J. C., Wehenkel, C., & Clark-Tapia, R. (2017). Generalized Models: An Application to Identify Environmental Variables That Significantly Affect the Abundance of Three Tree Species. *Forests*, 8(3), Artículo 59. <https://doi.org/10.3390/f8030059>

Balima, L. H., Kouamé, F. N., Bayen, P., Ganamé, M., Nacoulma, B. M. I., Thiombiano, A., & Soro, D. (2021). Influence of climate and forest attributes on aboveground carbon storage in Burkina Faso, West Africa. *Environmental Challenges*, 4, 100123. <https://doi.org/10.1016/j.envc.2021.100123>

Briones, O., Búrquez, A., Martínez-Yrizar, A., Pavón, N., y Perroni, Y. (2018). Biomasa y productividad en las zonas áridas mexicanas. *Madera y Bosques*, 24(Número especial), Artículo e2401898. <https://doi.org/10.21829/myb.2018.2401898>

Camargo-Sanabria, A. A., y Hernández, J. A. (2020). El Desierto Chihuahuense, un escenario de múltiples interacciones entre especies. Facultad de Zootecnia y Ecología, Universidad Autónoma de Chihuahua.

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>

Chen, H., Zhao, W., He, Z., Zhang, Y., Wu, W., & Chen, T. (2024). Quantifying nonlinear responses of vegetation to hydro-climatic changes in mountainous Southwest China. *Frontiers in Forests and Global Change*, 7, Artículo 1417737. <https://doi.org/10.3389/ffgc.2024.1417737>

Chen, Y., Zhang, S., & Wang, Y. (2024). Spatial distribution patterns and drivers of above- and below- biomass in Chinese terrestrial ecosystems. *Science of the Total Environment*, 944, Artículo 173922. <https://doi.org/10.1016/j.scitotenv.2024.173922>

CONAFOR (2020). Inventario Nacional Forestal y de Suelo (INFyS). Comisión Nacional Forestal. <https://snif.cnf.gob.mx/datos-abiertos> (Fecha de consulta: enero 2026)

Deb, P. (2018). Multi-GCMs approach for assessing climate change impact on water resources in Thailand. *Modeling Earth Systems and Environment*, 4(2), 825–839. <https://doi.org/10.1007/s40808-018-0442-4>

Dimobe, K., Kouakou, J. L. N., Tondoh, J. E., Zoungrana, B. J.-B., Forkuor, G., & Ouédraogo, K. (2018). Predicting the potential impact of climate change on carbon stock in semi-arid West African savannas. *Land*, 7(4), Artículo 124. <https://doi.org/10.3390/land7040124>

Fernández-Martínez, M., Vicca, S., Janssens, I. A., Luyssaert, S., Campioli, M., Sardans, J., Estiarte, M., & Peñuelas, J. (2014). Spatial variability and controls over biomass stocks, carbon fluxes, and resource-use efficiencies across forest ecosystems. *Trees*, 28(2), 597–611. <https://doi.org/10.1007/s00468-013-0975-9>

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>

Florent Noulèkoun et al. (2018) Noulèkoun, F., Khamzina, A., Naab, J. B., Khasanah, N., van Noordwijk, M., & Lamers, J. P. A. (2018). Climate change sensitivity of multi-species afforestation in semi-arid Benin. *Sustainability*, 10(6), 1931. <https://doi.org/10.3390/su10061931>

Guisan, A., Edwards, T. C., Jr., y Hastie, T. (2002). Generalized linear and generalized additive models in studies of species distributions: setting the scene. *Ecological Modelling*, 157(2–3), 89–100. [https://doi.org/10.1016/S0304-3800\(02\)00204-1](https://doi.org/10.1016/S0304-3800(02)00204-1)

Granados-Sánchez, D., Sánchez-González, A., Granados Victorino, R. L., y Borja de la Rosa, A. (2011). Ecología de la vegetación del desierto chihuahuense. *Revista Chapingo Serie Ciencias Forestales y del Ambiente*, 17(Edición Especial), 111–130. <https://doi.org/10.5154/r.rchscfa.2010.10.102>

Quinto Mosquera, H. (2010). Dinámica de la biomasa aérea en bosques primarios de Colombia y su relación con la precipitación y la altitud [Tesis de maestría, Universidad Nacional de Colombia sede Medellín]. Repositorio Institucional UN.

- He, X., Lei, X., Zeng, W., Feng, L., Zhou, C., & Wu, B. (2022). Quantifying the effects of stand and climate variables on biomass of larch plantations using random forests and national forest inventory data in north and northeast China. *Sustainability*, 14(9), Artículo 5580. <https://doi.org/10.3390/su14095580>
- Hijmans, R. J. (2025). *raster: Geographic Data Analysis and Modeling* [Data set]. CRAN: Contributed Packages. The R Foundation. <https://doi.org/10.32614/CRAN.package.raster>
- Hijmans, R. J. (2026). *geodata: Access Geographic Data* [Data set]. En CRAN: Contributed Packages. The R Foundation. <https://doi.org/10.32614/CRAN.package.geodata>
- Hijmans, R. J. (2026). *terra: Spatial Data Analysis* [Data set]. CRAN: Contributed Packages. The R Foundation. <https://doi.org/10.32614/CRAN.package.terra>
- Huang, J., Yu, H., Guan, X., Wang, G., & Guo, R. (2016). Accelerated dryland expansion under climate change. *Nature Climate Change*, 6, 166–171. <https://doi.org/10.1038/nclimate2837>.
- Huenneke et al. (2001) Huenneke, L. F., Clason, D., & Muldavin, E. (2001). Spatial heterogeneity in Chihuahuan Desert vegetation: Implications for sampling methods in semi-arid ecosystems. *Journal of Arid Environments*, 47(3), 257–270. <https://doi.org/10.1006/jare.2000.0678>
- Kuhn, M. (2024). *caret: Classification and Regression Training* [Data set]. En CRAN: Contributed Packages. The R Foundation. <https://CRAN.R-project.org/package=caret>
- Kumar, L., & Mutanga, O. (2017). Remote sensing of above-ground biomass. *Remote Sensing*, 9(9), 935. <https://doi.org/10.3390/rs9090935>
- Li, C., Zhang, C., Luo, G., Chen, X., Maisupova, B., Madaminov, A. A., Han, Q., & Djenbaev, B. M. (2015). Carbon stock and its responses to climate change in Central Asia. *Global Change Biology*, 21(5), 1951–1967. <https://doi.org/10.1111/gcb.12846>

- Liu, S., Kairé, M., Wood, E., Diallo, O., & Tieszen, L. L. (2004). Impacts of land use and climate change on carbon dynamics in south-central Senegal. *Journal of Arid Environments*, 59(3), 583–604. <https://doi.org/10.1016/j.jaridenv.2004.03.019>
- Fu, L., Lei, X., Hu, Z., Zeng, W., Tang, S., Marshall, P., Cao, L., Song, X., Yu, L., & Liang, J. (2017). Integrating regional climate change into allometric equations for estimating tree aboveground biomass of Masson pine in China. *Annals of Forest Science*, 74(2), Artículo 42. <https://doi.org/10.1007/s13595-017-0636-z>
- Ma, Z., Peng, C., Zhu, Q., Chen, H., Yu, G., Li, W., Zhou, X., Wang, W., & Zhang, W. (2012). Regional drought-induced reduction in the biomass carbon sink of Canada's boreal forests. *Proceedings of the National Academy of Sciences*, 109(7), 2423–2427. <https://doi.org/10.1073/pnas.1111576109>
- Mahardika, S. B., Xin, S., Wang, W., & Jiang, L. (2023). Effects of climate on stand-level biomass for larch plantations in Heilongjiang province, northeast China. *Forests*, 14(4), Artículo 820. <https://doi.org/10.3390/f14040820>
- Montaño, N. M., Ayala, F., Bullock, S. H., Briones, O., García Oliva, F., García Sánchez, R., Maya, Y., Perroni, Y., Siebe, C., Tapia Torres, Y., Troyo, E., y Yépez, E. (2016). Almacenes y flujos de carbono en ecosistemas áridos y semiáridos de México: Síntesis y perspectivas. *Terra Latinoamericana*, 34(1), 39–59.
- Morrone, J. J., Escalante, T., & Rodríguez-Tapia, G. (2017). Mexican biogeographic provinces: Map and shapefiles. *Zootaxa*, 4277(2), 277–279. <https://doi.org/10.11646/zootaxa.4277.2.8>
- Nadezhda M. Devi et al. (2020) Devi, N. M., Kukarskih, V. V., Galimova, A. A., Mazepa, V. S., & Grigoriev, A. A. (2020). Climate change evidence in tree growth and stand productivity at the upper treeline ecotone in the Polar Ural Mountains. *Forest Ecosystems*, 7(1), Artículo 20. <https://doi.org/10.1186/s40663-020-0216-9>

Narváez-Ortiz, I., Ortiz-Paz, R. A., & Hernández-Vásquez, C. C. (2026). Análisis espaciotemporal de estimaciones de precipitación y temperaturas de Chirps y Worldclim en la cuenca del río Sonora, México. *Revista de Investigación Agraria y Ambiental*, 17(1), 319–343. <https://doi.org/10.22490/21456453.8484>

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>

IPCC. (2021). Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report. Cambridge University Press. <https://doi.org/10.1017/9781009157896>

Pedro Rodríguez (2017): Rodríguez-Veiga, P., Wheeler, J., & Balzter, H. (2017). Quantifying forest biomass carbon stocks from space. *Current Forestry Reports*, 3(1), 1–18. <https://doi.org/10.1007/s40725-017-0052-8>

Pointing, S. B., & Belnap, J. (2012). Microbial colonization and controls in dryland systems. *Nature Reviews Microbiology*, 10, 551–562. <https://doi.org/10.1038/nrmicro2831>

Nolan, R. H., Sinclair, J., Waters, C. M., Mitchell, P. J., Eldridge, D. J., Paul, K. I., Roxburgh, S., Butler, D. W., & Ramp, D. (2019). Risks to carbon dynamics in semi-arid woodlands of eastern Australia under current and future climates. *Journal of Environmental Management*, 235, 500–510. <https://doi.org/10.1016/j.jenvman.2019.01.076>

Riahi, K., van Vuuren, D. P., Kriegler, E., Edmonds, J., O'Neill, B. C., Fujimori, S., Bauer, N., Calvin, K., Dellink, R., Fricko, O., Lutz, W., Popp, A., Crespo Cuaresma, J., KC, S., Leimbach, M., Jiang, L., Kram, T., Rao, S., Emmerling, J., . . . Tavoni, M. (2017). The Shared Socioeconomic Pathways and their energy, land use, and greenhouse gas emissions

implications: An overview. *Global Environmental Change*, 42, 153–168.
<https://doi.org/10.1016/j.gloenvcha.2016.05.009>

Rodríguez-Veiga, P., Wheeler, J., Louis, V., Tansey, K., y Balzter, H. (2017). Quantifying forest biomass carbon stocks from space. *Current Forestry Reports*, 3(1), 1–18.
<https://doi.org/10.1007/s40725-017-0052-5>

Ruhlman, J., Gass, L., y Middleton, B. (2012). Chihuahuan Deserts Ecoregion. En B. M. Sleeter, T. S. Wilson, y W. Acevedo (Eds.), *Status and Trends of Land Change in the Western United States—1973 to 2000* (U.S. Geological Survey Professional Paper 1794–A, pp. 275–284). U.S. Geological Survey.

Safari, A., & Sohrabi, H. (2019). Effect of climate change and local management on aboveground carbon dynamics (1987–2015) in Zagros oak forests using Landsat time-series imagery. *Applied Geography*, 110, Artículo 102048.
<https://doi.org/10.1016/j.apgeog.2019.102048>

Sandoval-García, C., Méndez-González, J., Andrés, F., Villavicencio-Gutiérrez, E. E., Paz-Pellat, F., Flores-López, C., Cornejo-Oviedo, E. H., Zermeño-González, A., Sosa-Díaz, L., García-Guzmán, M., & Villarreal-Quintanilla, J. Á. (2024). Mapping the future: Climate-induced changes in aboveground live-biomass carbon density across Mexico's coniferous forests. *Forests*, 15(11), Artículo 2032. <https://doi.org/10.3390/f15112032>

Sandoval-Mata, T. N., Hernández-Sandoval, L., Munguía-Lino, G., Steinmann, V. W., & Delgado-Salinas, A. (2024). Regionalización de la provincia del desierto chihuahuense con base en la distribución de especies de *Dalea* (Fabaceae). *Botanical Sciences*, 102(3), 975–994. <https://doi.org/10.17129/botsci.3462>.

Secretaría de Medio Ambiente y Recursos Naturales. (2016). Ecosistemas terrestres. En *Informe de la situación del medio ambiente en México: Compendio de estadísticas ambientales*. Edición 2015 (pp. 61–152). SEMARNAT.

Wang, H.-M., Chen, J., Xu, C.-Y., Zhang, J., y Chen, H. (2020). A framework to quantify the uncertainty contribution of GCMs over multiple sources in hydrological impacts of climate change. *Earth's Future*, 8(9), Artículo e2020EF001602. <https://doi.org/10.1029/2020EF001602>

Wang, Y., Shen, X., Jiang, M., Tong, S., & Lu, X. (2021). Spatiotemporal change of aboveground biomass and its response to climate change in marshes of the Tibetan Plateau. *International Journal of Applied Earth Observations and Geoinformation*, 102, Artículo 102385. <https://doi.org/10.1016/j.jag.2021.102385>

World Bank Group. (2023). Climate risk profile: Mexico. <https://climateknowledgeportal.worldbank.org/>.

World Bank Group. (2023). *Climate risk profile: Mexico*. World Bank. <https://climateknowledgeportal.worldbank.org/>

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), Artículo 2022. <https://doi.org/10.3390/f13122022>

Zhigang Gao et al. (2019) Gao, Z., Wang, Q., Hu, Z., Luo, P., Duan, G., Sharma, R. P., Ye, Q., Gao, W., Song, X., & Fu, L. (2019). Comparing independent climate-sensitive models of aboveground biomass and diameter growth with their compatible simultaneous model system for three larch species in China. *International Journal of Biomathematics*, 12(07), 1950053. <https://doi.org/10.1142/S1793524519500530>

7. ANEXOS

Anexo 1. Variables Bioclimáticas

Variable	Descripción
BIO 1	Temperatura media anual (°C)
BIO 2	Intervalo medio diurno (°C)
BIO 3	Isotermalidad (BIO 2 / BIO 7) (*100)
BIO 4	Estacionalidad de la temperatura (Desviación estándar *100)
BIO 5	Temperatura máxima del mes más cálido (°C)
BIO 6	Temperatura mínima del mes más frío (°C)
BIO 7	Rango anual de temperatura (BIO 5 – BIO 6 °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 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)