

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO
SUBDIRECCIÓN DE POSTGRADO



Variables bioclimáticas y su influencia en la predicción de la densidad de
biomasa aérea viva en bosques húmedos del Amazonas

Tesis

Que presenta MARINO GARCÍA GUZMÁN

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

Saltillo, Coahuila, México

Diciembre, 2024

Variables bioclimáticas y su influencia en la predicción de la densidad de
biomasa aérea viva en bosques húmedos del Amazonas

Tesis

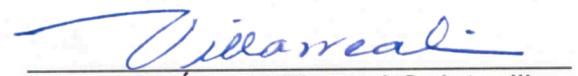
Elaborada por MARINO GARCÍA GUZMÁN como requisito parcial para obtener
el grado de Maestro en Ciencias en Ingeniería de Sistemas de Producción con
la supervisión y aprobación del Comité de Asesoría



Dr. Jorge Méndez González
Director de Tesis



Dr. Eladio Henriquez Cornejo Oviedo
Asesor



Dr. José Ángel Villarreal Quintanilla
Asesor



Dr. Antonio Flores Naveda
Subdirector de Postgrado
UAAAN

AGRADECIMIENTOS

A la *Universidad Autónoma Agraria Antonio Narro*, por la oportunidad de continuar con mi preparación profesional.

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

Al Dr. Jorge Méndez González, por su paciencia y enseñanzas en todo este proceso, las cuales siempre me acompañaran y formaran parte de mi trabajo.

Al Dr. Eladio Heriberto Cornejo Oviedo y al Dr. José Ángel Villarreal Quintanilla por su apoyo, atenciones brindadas y por sus consejos.

A mi esposa Leticia Jiménez Hernández por su compañía y apoyo en este proceso.

A mis compañeros Nestor y Carmela, por su amistad y trabajo conjunto en todo este proceso.

Al programa de Maestría en Ciencias en Ingeniería de Sistemas de Producción (ISP) por brindarme la oportunidad de formar parte de su grupo de egresados.

DEDICATORIA

A dios

A mi esposa, gracias por tu compañía

A mis padres Romeo García Martínez y Antonia Guzmán

ÍNDICE GENERAL

AGRADECIMIENTOS.....	iii
DEDICATORIA	iv
INTRODUCCIÓN	1
REVISIÓN DE LITERATURA	5
Cambio climático	5
Trayectorias de concentración representativas	6
Variables bioclimáticas	7
Importancia de los bosques.....	8
Biomasa y carbono.....	9
Proyecto Global Ecosystem Dynamics Investigation.....	11
Modelos de Circulación General	12
Modelos Lineales Generalizados	13
Estudios afines al proyecto.....	14
MATERIALES Y MÉTODOS.....	20
Descripción del área de estudio	20
Adquisición y preprocesamiento de datos	21
Optimización y Validación de Modelos Predictivos de la densidad de biomasa áerea viva.....	23
Proyecciones de la densidad de biomasa viva aérea actuales y Futuras	24
RESULTADOS Y DISCUSIÓN.....	26
Densidad de biomasa viva aérea en el área de estudio.....	26
Carbono aéreo en el área de estudio	26
Variables predictoras de la densidad de biomasa viva aérea.....	27
Importancia de las Bios de escala anual	31
Importancia de las Bios de escala interanual	32
Correlación de las variables bioclimáticas y la densidad de biomasa viva áerea	33
Predicción actual y futura de la densidad de la biomasa viva aérea	35
Proyecciones de pérdida de la densidad de biomasa viva aérea: Análisis por escenarios, RCP y estratos	36
Evaluación de las proyecciones climáticas sobre las variables de predicción	41

CONCLUSIONES	45
REFERENCIAS	46

ÍNDICE DE CUADROS

Cuadro 1. Coeficientes y estadísticos de ajuste del modelo de regresión para predecir la densidad de biomasa viva aérea en los bosques húmedos del Amazonas.....	28
Cuadro 2. Estadísticas descriptivas de la densidad de biomasa viva aérea y de las variables bioclimáticas actuales que componen el modelo de predicción en bosques húmedos del Amazonas	30
Cuadro 3. Validación de los modelos de regresión con cuatro métodos diferentes.	35
Cuadro 4. Superficie para cada rango de pérdida o ganancia (km^2), de la Densidad biomasa viva aérea de los bosques húmedos del Amazonas en escenarios climáticos al 2050 y 2070.....	40
Cuadro 5. Estadísticas descriptivas de las predicciones de la densidad de biomasa viva aérea en los bosques húmedos del Amazonas	44

ÍNDICE DE FIGURAS

Figura 1. Ubicación del área de estudio a escala mundial (izquierda) y estratos bioclimáticos generados a través del índice Calinski-Harabasz (derecha)	21
Figura 2. Proceso de manipulación de datos y validación de los modelos de predicción de la densidad de la biomasa viva aérea.....	25
Figura 3. Predicción actual de la densidad de biomasa viva aérea ($Mg\ ha^{-1}$) con los modelos bioclimáticos generados, en los bosques húmedos del Amazonas para los estratos I (a) y II (b).....	36
Figura 4. Cambios en la densidad de biomasa viva aérea en los bosques húmedos del Amazonas bajo los escenarios RCP 2.6 a 8.5 (de izquierda a derecha).para el año 2050 (a-d) y 2070 (e-h) del estrato I. Para el estrato II para el año 2050 (i-l) y 2070 (m-p), las áreas con color representan la superficie del estrato.	39
Figura 5. Prueba de Wilcoxon para comparar medianas de la variable actual con cada escenario climático, en el estrato I. Bio 5: Temperatura máxima del mes más cálido ($^{\circ}C$); Bio 12: Precipitación anual (mm). Niveles de significancia: **** (Significativo al 0.0001)	41
Figura 6. Prueba de Wilcoxon para comparar medianas de la variable actual con cada escenario climático, en el estrato II. Bio 1: Temperatura media anual ($^{\circ}C$); Bio 7: Rango de temperatura anual (Bio 5 – Bio 6, $^{\circ}C$). Niveles de significancia: **** (Significativo al 0.0001).....	42
Figura 7. RCP y años con menor y mayor Incertidumbre estimada para la densidad de la biomasa viva aérea, estrato I año 2050 RCP 4.5 año 2070 RCP 8.5 (a y b), estrato II año 2050 RCP 6.0 y año 2070 8.5 c y d).....	43

Resumen

VARIABLES BIOCLIMÁTICAS Y SU INFLUENCIA EN LA PREDICCIÓN DE LA
DENSIDAD DE BIOMASA AÉREA VIVA EN BOSQUES HÚMEDOS DEL
AMAZONAS

POR

MARINO GARCÍA GUZMÁN

MAESTRÍA EN CIENCIAS EN INGENIERÍA DE SISTEMAS DE PRODUCCIÓN

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO

DR. JORGE MÉNDEZ GONZÁLEZ

RESUMEN

El objetivo de este estudio fue evaluar el impacto del cambio climático en la densidad de biomasa viva aérea (DB_{va}) en los bosques húmedos del Amazonas mediante la creación de modelos de predicción dinámicos basados en variables bioclimáticas. Los datos de DB_{va} se obtuvieron del proyecto Global Ecosystem Dynamics Investigation (GEDI) de la NASA, y las variables bioclimáticas del repositorio de WorldClim. Se consideraron cuatro Trayectorias de Concentración Representativas (RCP) 2.6, 4.5, 6.0, y 8.5 $W\ m^{-2}$, proyectados para los años 2050 y 2070. La investigación se centró en dos estratos dentro de la cuenca del Amazonas, una región clave para el almacenamiento de carbono y la regulación climática global. Se utilizó el ajuste de Modelos Lineales Generalizados (GLM), con el que se seleccionaron las variables bioclimáticas más influyentes mediante un algoritmo de selección exhaustiva “algoritmo genético”. Se analizaron 22,944 puntos de muestreo distribuidos en ambos estratos. Los resultados indican que las variables relacionadas con la temperatura (Bio 1, Bio 5, Bio 7) fueron los predictores más significativos sobre la DB_{va} , mientras que la variable relacionada con la precipitación (Bio 12) tuvieron una menor influencia. El estrato I mostró un promedio de $173.95\ Mg\ ha^{-1}$ y el estrato II alcanzó $222.75\ Mg\ ha^{-1}$. Las proyecciones climáticas para 2050 y 2070 sugieren una reducción considerable en la DB_{va} , especialmente bajo el escenario RCP 8.5, con pérdidas de hasta $90\ Mg\ ha^{-1}$ de DB_{va} . Este trabajo resalta la importancia de integrar variables climáticas dinámicas en los modelos de estimación de biomasa y se concluye que los cambios climáticos futuros tendrán un impacto negativo considerable en la DB_{va} en el área de estudio.

Palabras clave: Cambio climático, densidad de biomasa aérea viva DB_{va} , Variables bioclimáticas y Modelos Lineales Generalizados (GLM).

Abstract

BIOCLIMATIC VARIABLES AND THEIR INFLUENCE ON THE PREDICTION
OF LIVE ABOVEGROUND BIOMASS DENSITY IN AMAZON RAINFORESTS

BY

MARINO GARCÍA GUZMÁN

MASTER OF SCIENCE IN PRODUCTION SYSTEMS ENGINEERING

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO

DR. JORGE MÉNDEZ GONZÁLEZ

ABSTRACT

The objective of this study was to assess the impact of climate change on aboveground living biomass density (DB_{va}) in the Amazon rainforests by creating dynamic prediction models based on bioclimatic variables. The DB_{va} data were obtained from NASA's Global Ecosystem Dynamics Investigation (GEDI) project, and the bioclimatic variables from the WorldClim repository. Four Representative Concentration Pathways (RCP) 2.6, 4.5, 6.0, and 8.5 $W\ m^{-2}$, projected for the years 2050 and 2070, were considered. The research focused on two strata within the Amazon basin, a key region for carbon storage and global climate regulation. Generalized Linear Modeling (GLM) fitting was used, with which the most influential bioclimatic variables were selected using an exhaustive selection algorithm "genetic algorithm". A total of 22,944 sampling points distributed in both strata were analyzed. The results indicated that temperature-related variables (Bio 1, Bio 5, Bio 7) were the most significant predictors of DB_{va} , while the precipitation-related variable (Bio 12) had the least influence. Stratum I showed an average of 173.95 $Mg\ ha^{-1}$ and stratum II reached 222.75 $Mg\ ha^{-1}$. Climate projections for 2050 and 2070 suggest a considerable reduction in DB_{va} , especially under the RCP 8.5 scenario, with losses of up to 90 $Mg\ ha^{-1}$ of DB_{va} . This work highlights the importance of integrating dynamic climate variables into biomass estimation models and it is concluded that future climate changes will have a considerable negative impact on DB_{va} in the study area.

Key words: Climate change, Aerial Biomass Density (DB_{va}), Bioclimatic variables and Generalized Linear Models (GLM).

INTRODUCCIÓN

Los bosques son cruciales para la humanidad, ya que proporcionan alimentos, medicinas, biocombustibles, protegen suelos y agua, albergan más del 75% de la biodiversidad terrestre y ayudan a mitigar el cambio climático, en una superficie de 4,060 millones de hectáreas, 31% de la superficie terrestre (FAO, 2021). En específico, las selvas cubren el 10% de la superficie del planeta y almacenan una cuarta parte del carbono terrestre (Hurtado-Torres et al., 2022). La cuenca del Amazonas, como parte de las selvas del mundo, es fundamental para los sistemas climáticos globales, ya que absorbe grandes cantidades de carbono, lo que la convierte en uno de los principales sumideros naturales del planeta (Galbraith et al., 2010).

Se estima que el carbono total de la biomasa muerta y subterránea es de 86 Pg C con un 20% de incertidumbre (Saatchi et al., 2007). Otras estimaciones indican un total de 93 ± 23 Pg C, sin embargo, si se considera la biomasa muerta y subterránea aumentaría en un 10 a 21% (Malhi et al., 2006), lo que la convierte en el sumidero de carbono más importante del planeta (CEPAL & Patrimonio Natural, 2013). Por lo anterior, a nivel mundial, destaca como la región de mayor relevancia ecológica, en la regulación climática y en la conservación de la biodiversidad (Medina P. & Carrillo Silva, s/f; Dinerstein et al., 2017).

No obstante, el cambio climático afecta a todos los ecosistemas terrestres (Guo et al., 2019; FAO & PNUMA, 2020). El cambio climático es una variación del clima, que persiste durante largos períodos, atribuible a procesos naturales o actividades humanas que alteran la composición de la atmósfera y se suma a la variabilidad natural del clima (IPCC, 2013, 2018). Según estimaciones se prevé que la temperatura media global del aire aumente entre 1.8 y 4.0 °C para finales del siglo XXI (IPPC, 2013). Con un incremento de 3 a 4 °C en la región amazónica bajo el escenario RCP 4.5 (representative concentration pathway, por sus siglas en inglés), acompañado de cambios en la precipitación que podrían variar $\pm 25\%$ (OCTA y CIIFEN, 2021).

Algunos estudios (Scholze et al., 2006; Panel Científico por la Amazonía, 2021) han demostrado que fenómenos asociados al cambio climático, como sequías extremas, inundaciones y un aumento en la frecuencia de incendios forestales en la cuenca Amazónica, han tenido un impacto profundo en los sistemas naturales y humanos, alterado considerablemente las reservas de biomasa y carbono de los bosques.

El riesgo de cambios en la forma y distribución de los ecosistemas forestales del mundo depende (y de forma no lineal) del grado de calentamiento del planeta, las regiones boreales y árticas circumpolares resultan especialmente vulnerables (Scholze et al., 2006) aunque la cuenca Amazonia no es la excepción.

Se ha demostrado que las variables climáticas (temperatura y precipitación) influyen directamente en la fisiología, crecimiento y productividad de las plantas (Grossiord et al., 2017; Marchiori et al., 2019; Damaceno et al., 2020). Por ejemplo, durante la fotosíntesis, la temperatura del aire regula la evaporación, la transpiración y otros procesos (OCTA y CIIFEN, 2021). Estudios han evidenciado que el aumento de la temperatura favorece el crecimiento de biomasa en los bosques boreales, pero en bosques tropicales, tiende a inhibir este crecimiento (Liu et al., 2013). Además, las temperaturas elevadas pueden limitar el desarrollo de las especies al modificar la pigmentación foliar, comprometer el sistema radicular, inducir estrés hídrico, en consecuencia, alterar significativamente los patrones de crecimiento de las plantas (Han et al., 2012).

Mientras que la precipitación juega un papel fundamental, desde la disponibilidad y absorción de nutrientes, conductancia estomatal, incluso influir en la misma transpiración y fotosíntesis (Bennett et al., 2020; Cysneiros Costa et al., 2021). Así mismo, la disponibilidad y variabilidad de la precipitación influyen directamente en la eficiencia del uso del agua por las plantas, lo cual tiene un impacto crucial en todo el proceso de crecimiento de estas (Gao et al., 2017; Yuan et al., 2022). Por lo tanto, está claramente documentado que existe una relación estrecha entre la productividad de biomasa y las variables climáticas.

La biomasa se ha definido como la masa seca de todos los componentes de la vegetación por encima del suelo (toda la vegetación viva y no-viva), pero se refiere casi siempre solo a la biomasa viva (Gutierrez et al., 2014), usualmente se reporta en Mega gramos (Mg). Mientras que la densidad de biomasa hace referencia a esa biomasa por unidad de área.

Algunos estudios han encontrado relaciones importantes entre la biomasa aérea y variables climáticas, por ejemplo, un estudio a escala global, indica que, en los bosques boreales, la densidad de carbono de la biomasa aérea tiene una relación positiva con la temperatura, al igual que la precipitación en los bosques templados y tropicales (Liu et al., 2013).

A nivel continental, la precipitación se relaciona de forma positiva con la biomasa aérea de los bosques templados secos y bosques tropicales, mientras que la temperatura muestra una relación negativa con la biomasa aérea en los bosques tropicales húmedos (Stegen et al., 2011). En los bosques tropicales y subtropicales, la precipitación media anual se correlaciona de forma positiva con biomasa aérea y carbono (Guo et al., 2019; Paroshay et al., 2021), mientras que la temperatura media lo hace de forma negativa (Paroshay et al., 2021).

Estas mismas relaciones parecen ocurrir a escalas más pequeñas, por ejemplo, en bosques subtropicales de China, la temperatura se correlaciona negativamente con biomasa aérea (Li et al., 2022). En plantaciones y bosques naturales de pinos (subgénero *Pinus* L.) en Eurasia, la biomasa de las agujas y las ramas aumenta a medida que aumenta la precipitación y todos los componentes cambian a diferentes ritmos con relación a los cambios de temperatura (Andreevich et al., 2020). En los bosques de *Picea*, la biomasa aérea del rodal y de árboles individuales se ve influenciada positivamente con mayor humedad y un aumento en la temperatura (Usoltsev et al., 2022).

Como se puede notar, la literatura científica ha correlacionado las variables climáticas con la biomasa aérea, pero pocos estudios han evaluado el impacto del cambio climático sobre su densidad, especialmente en la cuenca del Amazonas. Es crucial enfocarse en predictores climáticos dinámicos, como

temperatura y precipitación, ya que las variables estáticas (altura, altitud, diámetro, exposición y pendiente etc.) no capturan estos efectos (Adhikari et al., 2017; Guo et al., 2019; Ma et al., 2023).

Basado en lo anteriormente expuesto, el objetivo de este estudio fue desarrollar modelos bioclimáticos, para evaluar los efectos del clima futuro sobre los cambios en la distribución geoespacial de la densidad de la biomasa viva aérea en la cuenca del Amazonas, al considerar cuatro posibles escenarios climáticos o RCP (Representative Concentration Pathways) por sus siglas en inglés: 2.6, 4.5, 6.0 y 8.5 W m⁻² para los años 2050 y 2070. Se hipotetiza que el cambio climático futuro impactará significativamente la distribución de la biomasa aérea de la cuenca del Amazonas.

REVISIÓN DE LITERATURA

Cambio climático

El cambio climático es la variación del clima identificable que persiste durante períodos de tiempo prolongados, el cual puede deberse a procesos naturales o a forzamientos externos (IPCC, 2013). Por otro lado, se define como el fenómeno atribuido, directa o indirectamente a la actividad humana, a las actividades que alteran la composición de la atmósfera global y que se suma a la variabilidad natural del clima observada durante el tiempo (IPCC, 2018).

El detener la deforestación de los bosques podría ser una de las acciones más económicamente viables para la adaptación al cambio climático, así como mitigar sus efectos y reducir la pérdida de biodiversidad, sin embargo, esta capacidad de amortiguamiento se ve afectada por la deforestación y la degradación de los bosques a raíz del cambio climático, por lo que no existe otra forma de afrontar el exceso de CO₂ (FAO & PNUMA, 2020).

Aunado a lo anterior, los procesos de deforestación liberan grandes cantidades de carbono a la atmósfera lo que origina problemas de degradación de los recursos forestales, los suelos e incluso de pérdida de biodiversidad (Ordóñez B & Masera, 2001). Además de la consideración de los efectos del cambio climático, las actividades humanas, los fenómenos meteorológicos intensos, los incendios forestales, las plagas y las enfermedades pueden generar efectos adversos sobre los bosques y reducir los bienes y servicios que prestan, su diversidad, productividad y su salud (FAO, 2021).

Se ha reconocido que las principales amenazas a la captura de carbono y sus depósitos son principalmente el cambio climático y los eventos meteorológicos asociados a este, además de la deforestación y su efecto en la captura de carbono, lo que provoca la pérdida de la diversidad (UNESCO et al., 2023). En un estudio se determinó que el cambio climático afecta a la fotosíntesis, la respiración de las plantas y la descomposición de la materia orgánica, lo que impacta al flujo de carbono entre la tierra y la atmósfera; además se encontró que, con el aumento de la temperatura, los sumideros terrestres de carbono se

convirtan en fuentes, lo que implica un alto riesgo de pérdida de la capacidad de captura de carbono en condiciones de calentamiento extremo (Scholze et al., 2006).

En el área de la cuenca del Amazonas se ha estudiado el efecto del cambio climático, en un estudio se describen fenómenos que afectan a esta área, entre los que destacan la ocurrencia de sequías extremas, inundaciones, los cuales han tenido un impacto fuerte en los sistemas naturales y humanos, estos fenómenos han aumentado el número de incendios durante los períodos de sequía, al liberar carbono, humo y hollín a la atmósfera (Panel Científico por la Amazonía, 2021). En un estudio se indican que en la región donde se encuentra la cuenca del Amazonas existirá un mayor riesgo de sequía lo que puede generar la muerte progresiva de los bosques lo que afectará su salud y biodiversidad, lo anterior impulsado por la mayor presencia de incendios forestales; también se prevé la reducción de disponibilidad de agua por la reducción en las escorrentías (Scholze et al., 2006).

Trayectorias de concentración representativas

Las trayectorias de concentración representativas (RCP) se definen como escenarios que abarcan series temporales de emisiones y concentraciones de la gama completa de gases de efecto invernadero y aerosoles y gases químicamente activos, así como el uso del suelo y la cubierta terrestre (IPCC, 2013, 2018).

Con relación a lo anterior se menciona que las proyecciones de cambio climático utilizan modelos de diferente complejidad, desde simples hasta integrales, para simular cambios según escenarios de forzamientos antropogénicos, llamados trayectorias de concentración representativas (RCP), las cuales fueron realizadas en el marco del CMIP5 y proyectan que las concentraciones de CO₂ serán más altas para el año 2100 debido a un aumento continuo de emisiones, estas se comparan con el período 1986-2005 y muestran un aumento histórico de 0.61 °C entre 1850-1900 y el período de referencia, aunque el calentamiento ha superado estas cifras en años recientes (IPPC, 2013).

El Quinto Informe del IPCC introduce cuatro trayectorias de concentración representativas (RCP) para evaluar diferentes escenarios de emisiones y forzamiento radiativo hacia el año 2100: RCP 2.6, RCP 4.5, RCP 6.0 y RCP 8.5, cada RCP refleja un posible nivel de forzamiento y representa distintas políticas climáticas, desde mitigación hasta altas emisiones de gases de efecto invernadero, estos escenarios ofrecen datos sobre uso del suelo, emisiones por sector y concentraciones de gases de efecto invernadero, aunque no abarcan todas las posibles emisiones, especialmente aerosoles (IPPC, 2013).

Variables bioclimáticas

Se describe el desarrollo de BIOCLIM como uno de los primeros intentos del uso de la interpolación climática avanzada para crear un conjunto de variables bioclimáticas, estas variables fueron desarrolladas para capturar las limitaciones climáticas clave sobre el crecimiento de especies vegetales, con base en datos climáticos recopilados de varias estaciones meteorológicas, a través de métodos de interpolación de splines se generaron superficies climáticas que permitieron obtener datos estimados de temperatura y precipitación en puntos geoespaciales específicos, sin embargo la precisión de estos fue mejorada mediante la inclusión de la altitud como un factor de ajuste clave (Booth et al., 2014).

Los datos derivados se convirtieron en 12 variables bioclimáticas esenciales que definían el "envolvente bioclimático" para cada especie estudiada; este marco permitió a BIOCLIM proyectar distribuciones de especies y modelar sus nichos ecológicos, que proporcionan una herramienta fundamental para estudios de cambio climático, invasión de especies y conservación, las variables bioclimáticas se obtienen a partir de los valores mensuales de temperatura y precipitación, transformándolos en variables con mayor relevancia biológica, estas variables se emplean comúnmente en el modelado de la distribución de especies y otras técnicas ecológicas (Booth et al., 2014).

Las variables bioclimáticas incluyen tendencias anuales (como temperatura y precipitación media anual), estacionalidad (como el rango anual de temperatura y precipitación) y factores extremos o limitantes (como las temperaturas del mes

más frío y cálido, y las precipitaciones durante los trimestres húmedos y secos) tal y como lo indican (Fick & Himans, 2017).

En relación con lo anterior (Liu et al., 2013; Luo et al., 2013; Fu et al., 2017; Bennett et al., 2020; Paroshy et al., 2021; Li et al., 2022; Xin et al., 2022) desarrollaron estudios en los que se han utilizado a las variables bioclimáticas para la estimación de carbono y biomasa aérea, en los cuales se evaluaron diversas relaciones de estas variables con factores bióticos y abióticos.

Importancia de los bosques

Es bien sabido que los bosques tienen un gran valor a nivel mundial, en este sentido se indica que los bosques son un elemento crucial para el cumplimiento de los objetivos de la Agenda 2030 instaurada en septiembre de 2015, estos proporcionan alimento, medicinas y biocombustibles para más de 1,000 millones de personas, protegen suelos y agua, albergan más del 75% de la biodiversidad terrestre y ayudan a mitigar el cambio climático, esta vegetación cubre un área de 4,060 millones de hectáreas, lo que representa el 31% de la superficie terrestre, aunque estos no se distribuyen de forma equitativa ya que en la zona tropical se encuentra el 45% del total de los bosques a nivel mundial (FAO & PNUMA, 2020; FAO, 2021).

Los bosques tienen una gran importancia en la mitigación del cambio climático, a pesar de la disminución de su superficie entre los años 2011 y 2020 estos absorbieron más carbono del que emitieron gracias a la influencia de diversos factores, entre los que destacan la implementación de reforestaciones y un mejor proceso de manejo; por otro lado se destaca la importancia de los árboles en las áreas urbanas como las de Europa central en las que se ha detectado que estos pueden reducir la temperatura hasta 12 °C en la época de mayor incidencia de esta variable (FAO, 2022).

La UNESCO et al. (2023) indica que los bosques suscritos a esta cubren una superficie de 69 millones de hectáreas y prestan múltiples bienes y servicios en pro de la naturaleza y de las personas, además se menciona que estos han capturado alrededor de 190 millones de toneladas de CO₂ anualmente desde la

atmósfera desde el año 2020 y que los mayores sumideros de este compuesto se encuentran en las regiones tropicales y templadas.

De forma similar se indica que los bosques tropicales son cruciales para el bienestar humano, ya que brindan servicios de suministro, regulación y culturales, su biodiversidad y extensión les permiten ofrecer funciones vitales, como la regulación del clima y prevención de inundaciones, estos servicios se ven amenazadas por decisiones de manejo y la creciente demanda de alimentos por lo que acciones como la restauración y los incentivos financieros pueden ayudar a preservarlos, sin embargo, garantizar la sostenibilidad de todos estos beneficios a largo plazo es un desafío (Balvanera, 2012).

El área que conforma la cuenca del Amazonas tiene una gran importancia a nivel mundial con relación a los ciclos hidrológicos y de carbono, además de representar un punto crítico para la biodiversidad, así como ser un potencial centro para el crecimiento económico de la región, además de lo anterior esta región representa una fuente importante de evapotranspiración y de vapor de agua (Lathuillière et al., 2016; OCTA y CIIFEN, 2021).

Biomasa y carbono

La biomasa se puede definir como la masa total de los organismos vivos que se encuentran en un área determinada, así como el material muerto se puede considerar como biomasa muerta (IPCC, 2013, 2018). Por otro lado, el carbono en la vegetación corresponde a la biomasa aérea (tronco, hojas, ramas y follaje) y el que se encuentra contenido en la biomasa de las raíces (Ordóñez B & Masera, 2001).

Con relación a lo anterior (Gutierrez et al., 2014) presentan los siguientes conceptos:

Biomasa aérea (Aboveground biomass -AGB): Biomasa superficial. Masa seca de todos los componentes de la vegetación por encima del suelo (toda la vegetación viva y no-viva), pero se refiere casi siempre solo a la biomasa viva (usualmente se reporta en Mg).

Biomasa Aérea Viva (Aboveground living biomass - AGLB): Masa seca de la vegetación viva sobre la superficie del suelo (usualmente reportada en Mg).

Densidad: valor por hectárea (ej. densidad de biomasa aérea en Mg ha⁻¹).

El 99% de los bosques del mundo se encuentran en 193 países, el total de la biomasa mundial es de casi 606 gigatoneladas (Gt) o 149 toneladas por hectárea (ton ha⁻¹), las mayores existencias de esta se encuentran en las regiones con bosques tropicales de América del Sur y en África occidental y central, con valores superiores a 200 ton ha⁻¹; se estima que la biomasa muerta en los bosques del mundo es de 59.0 Gt de materia seca equivalente a 14.5 ton ha⁻¹; por otro lado, las existencias de biomasa han disminuido alrededor de 8 Gt en el periodo de 1990 al 2000, la mayoría de estas en África y América del Sur, debido principalmente a que la superficie boscosa se ha reducido; lo contrario ocurre en los bosques de Asia, Europa y América del Norte (FAO, 2021).

Se indica que el 99% del carbono del mundo se encuentra contenido en 192 países, alrededor del 44% en la biomasa viva de los bosques, cerca del 45% se encuentra contenido en la materia orgánica del suelo y el resto en la madera muerta y la hojarasca de estos; se estima que el total de existencias de carbono en los bosques es de 662 Gt, de las cuales 300 Gt se encuentran en la materia orgánica sobre el suelo, 295 Gt en la biomasa viva y 68 Gt en madera muerta y hojarasca (FAO, 2021). Para el caso de las estimaciones del carbono contenido en la biomasa, se recomienda de forma general utilizar un factor de conversión de 0.5 toneladas de carbono por tonelada de biomasa en el proceso de estimación (IPCC, 1996).

En el área que cubre la cuenca del Amazonas se han desarrollado diversos estudios (Malhi et al., 2006; Saatchi et al., 2007; Alves et al., 2010; Stegen et al., 2011; Araujo-Murakami et al., 2016) los cuales se han enfocado en la estimación de la biomasa aérea viva, sin embargo, en cada caso se han obtenido resultados diversos, tal vez por la escala a la que fueron hechos, por la forma de estimación de estos valores o por la evaluación de diversas interacciones de variables;

en los estudios referidos se ha observado que el promedio de esta variable oscila entre los 118 Mg ha⁻¹ hasta los 350 Mg ha⁻¹.

Proyecto Global Ecosystem Dynamics Investigation

El proyecto denominado *Global Ecosystem Dynamics Investigation* (GEDI), por sus siglas en inglés) de la NASA fue puesto en órbita en diciembre de 2018, este programa recopila datos entre las latitudes 51.6° N y 51.6° S, de esta forma proporciona mediciones de la densidad de biomasa aérea a escala mundial en superficies de 1 km² esta información comprende el periodo entre 2019 hasta el 2023, los productos generados por este proyecto constan de un conjunto de 10 archivos en formato GeoTiFF relacionados con la biomasa (Dubayah et al., 2023).

Los datos generados por el proyecto GEDI han sido utilizados en diversos estudios. Por ejemplo, la información generada por la primera versión de este proyecto y se utilizó para ajustar modelos de predicción de la huella de la densidad de biomasa aérea en cada estrato definido; en el proceso de ajuste fueron incluidas variables relacionadas con la métrica de altura, las cuales son sensibles a la cobertura del dosel y determina si la correlación obtenida es negativa o positiva (Duncanson et al., 2022).

Los resultados de este proyecto fueron utilizados por (Lahssini et al., 2024) en su estudio desarrollado en bosques tropicales de la isla de Mayotte en Francia, con el fin de evaluar la precisión de las observaciones de altura del dosel derivadas del GEDI, así como la influencia de estos y parámetros ambientales en las estimaciones de altura, se determinó que la penetración del haz LiDAR depende en gran parte de las características del bosque, por otro lado se identificó que la pendiente del terreno tiene un efecto significativo en las formas de onda recibidas que se devuelven a los sensores de GEDI; se indica que los modelos de regresión se pueden implementar para mejorar la precisión de estimación de la altura del dosel.

Modelos de Circulación General

Los Modelos de Circulación General (GCM) por sus siglas en inglés, se definen como una representación numérica del sistema climático, que se basa en características físicas, químicas y biológicas de sus componentes, sus interacciones y su retroalimentación, y que analiza algunas o todas de sus características conocidas; estos modelos son una herramienta para estudiar el clima y simular en particular el clima mensual, estacional e interanual (IPCC, 2013, 2018). Todos los GCM simulan el sistema climático global con diferentes alcances (atmósfera, océano, hielo marino y componentes de la superficie terrestre), a escala temporal y espacial, así como con diferente complejidad, de acuerdo con lo expresado por (Fenech et al., s/f).

En el desarrollo del presente trabajo se utilizaron diversos GCM, estos fueron MIROC-6 (la sexta versión de MIROC o Modelo para la Investigación Interdisciplinaria del Clima) el cual de acuerdo con lo descrito por (K-1 Coupled GCM (MIROC) Description K-1 model developers, s/f; MIROC AGCM document writing team, 2021) consta de cinco componentes: atmósfera, tierra, ríos, hielo marino y océano, este modelo fue desarrollado en el Centro de Investigación Atmosférica y Oceánica, la Universidad de Tokio, la Agencia Japonesa de Ciencia y Tecnología Marino-Terrestre y el Instituto Nacional de Estudios Ambientales; este modelo se desarrolló con el fin de simular la circulación general atmosférica, se utilizaron variables como el viento, la temperatura y la presión a nivel mundial.

También se utilizó el Modelo E2 del Instituto Goddard de Estudios Espaciales (GISS), este fue concebido como un modelo sobre el clima global para estimar el efecto de gases de efecto invernadero de origen antropogénico sobre la temperatura media global, además de probar el efecto de los aerosoles volcánicos, el cual ha sufrido diversas actualizaciones, una de las cuales corresponde a la versión GISS-E2, este modelo involucra representaciones de la atmósfera, el océano, el hielo marino, la superficie terrestre, así como considerar componentes radiactivamente activos y se incluye la química de aerosoles y polvos de emisiones (Schmidt et al., 2014).

El último GCM considerado fue el Modelo del Sistema Terrestre de Segunda generación, el cual fue desarrollado por el Centro Euromediterráneo sobre Cambio Climático (CMCC-ESM2), considera factores terrestres, atmosféricos, hidrológicos, oceánicos, utiliza un núcleo físico-dinámico y se tienen en cuenta retroalimentaciones del sistema terrestre, lo cual representa avances sustanciales con respecto a su predecesor CMCC-CESM, en general el componente terrestre utiliza información más amplia de los tipos de vegetación y los depósitos del carbono; este modelo tiene como fin promover la investigación sobre cómo evoluciona el clima y los ciclos biogeoquímicos a nivel mundial, mediante el estudio de la dinámica acoplada del ciclo clima-carbono (Lovato et al., 2022).

Modelos Lineales Generalizados

Los Modelos Lineales Generalizados (GLM) se han convertido en una buena alternativa para el ajuste de modelos que tienen datos no métricos, es decir que no cumplen con los supuestos estadísticos básicos de un modelo lineal clásico, estos pueden incluir ajustes de tipo logit, probit, de Poisson y modelos de regresión ordinal (López-González, 2011). Este tipo de modelos van más allá de los modelos lineales mixtos ya que las variables de respuesta no se distribuyen normalmente, son heterocedásticas y existe una relación lineal entre la variable de respuesta y las predictoras (Salinas Ruiz et al., 2023).

Esta metodología de ajuste de modelos se ha utilizado en estudios como el desarrollado por (Antúnez et al., 2017) en el que se utilizaron estos para determinar las variables ambientales que afectan de forma significativa la abundancia y observar su tipo de relación con tres especies arbóreas en los bosques templados naturales del estado de Oaxaca, en este estudio se encontró que la relación lineal fue pobre entre la abundancia de las especies y las variables predictoras, de las 18 variables ambientales estudiadas la precipitación y la temperatura tuvieron una alta correlación, de forma global los modelos GLM explicaron 8.8%, 14.08% y 11.45% de la variación existente.

Este tipo de modelos también han sido utilizados en el estudio del impacto de las variables climáticas en la producción primaria neta (PPN), en los que mediante la aplicación de estos se determinó que las variables climáticas tienen efectos significativos ($p < 0.01$) sobre la PPN en el santuario de la vida silvestre Katerniaghat en Uttar Pradesh, India, en la evaluación de estos modelos se determinó que la temperatura en el año 2001 explica más del 75% de la varianza, se menciona que la combinación de las variables utilizadas explican un máximo del 88 y 80% en este mismo año, en general se observa que la temperatura es importante en los otros años estudiados (Tripathi et al., 2019).

En un estudio realizado en los bosques de México, se empleó un modelo GLM para estimar las reservas de carbono, se utilizaron datos de 10,500 parcelas del inventario Forestal, se ajustaron dos tipos de modelos, en el primero por tipo de bosque y en el segundo se integraron los datos de todos los tipos de bosques estudiados mediante la interacción entre la precipitación, tipo de bosque, la temperatura y tipo de bosque, y talud y tipo de bosque; esta versatilidad en el uso de los GLM subraya su importancia en la investigación forestal y en la gestión de recursos naturales (Arasa-Gisbert et al., 2018).

Estudios afines al proyecto

La regresión se define como una técnica utilizada para modelar la relación entre variables, a decir de como una o varias variables dependientes se comportan respecto a una o más variables independientes (Bouza, s/f). Con base en lo anterior en el desarrollo de modelos de predicción que consideren variables climáticas, la modelación ha permitido determinar los efectos que el cambio climático tendrá en diferentes regiones del planeta y sus consecuencias en poblaciones naturales (Romero Sánchez, 2016).

En un estudio se analizó la relación de factores climáticos y del suelo con la densidad de carbono sobre y bajo del suelo en diferentes bosques a nivel mundial; en este estudio se evaluaron varias vías de concentración representativa (RCP) (2.6, 4.5 y 8.5), derivado de esto se encontró que el índice de sequedad tiene un impacto negativo sobre los factores evaluados en los

bosques tropicales, sin embargo, la precipitación media anual mostro un efecto positivo en los bosques templados lo que dependió de si los valores estaban encima o por debajo de un umbral definido; en este sentido tanto la precipitación media anual como la temperatura se identificaron como factores clave que impulsan la variación de las reservas de biomasa, sin embargo su efecto difiere de acuerdo con el tipo de bosque estudiado (Guo et al., 2019).

Por otro lado, se ha analizado la relación de la biomasa aérea (AGB) con las variables climáticas y alométricas, lo anterior con el objetivo de desarrollar un modelo de predicción de esta variable para un bosque de Pino Masson (*Pinus massoniana* Lamb.) en una subprovincia tropical de China, así como determinar el efecto de estas variables hacia el futuro, para esto se analizaron valores de las vías de concentración representativa (RCP) 2.6, 4.5 y 8.0 hacia los años 2041, 2061 y 2080; los resultados obtenidos indicaron que el diámetro a la altura el pecho junto con el promedio de la temperatura de la temporada de crecimiento, la precipitación total de la temporada de crecimiento, la temperatura media del trimestre más húmedo y la precipitación del trimestre más húmedo fueron significativos para la predicción de los valores de AGB (Fu et al., 2017).

En un estudio se utilizaron 879 sitios de bosques maduros con el fin de evaluar como los datos climáticos obtenidos de WorldClim y la edad del arbolado influyen en la densidad de carbono en la biomasa (BCD_a) de los árboles evaluados; los biomas forestales y las zonas ecológicas se clasificaron mediante distintos contextos espaciales y climáticos; los resultados obtenidos indicaron que la BCD_a es más elevada en latitudes medias en las que las temperaturas medias anuales oscilan entre los 8 a 10 °C y con una precipitación media anual que oscila entre 1,000 a 2,500 mm, además se determinó que en los bosques boreales la BCD_a aumenta con la temperatura, mientras que en los bosques tropicales la BCD_a tiende a disminuir con el aumento de esta (Liu et al., 2013).

En un estudio se analizó el efecto de variables climáticas y del suelo sobre la biomasa aérea (AGB) en los bosques de Australia, se utilizaron modelos Random Forest y se concluye que el clima es el factor más importante, explican

aproximadamente el 50% de la variación de la AGB, la variable más importante fue la temperatura media del trimestre más seco, mientras que la densidad aparente fue la variable del suelo más significativa; las mayores concentraciones de AGB se encuentran en el suroeste y sureste del país; se sugiere la inclusión de factores como el régimen de perturbaciones y la diversidad de especies que pueden influir en el poder explicativo de los modelos, se resalta la influencia del clima más que el suelo en la distribución de AGB y sugiere que futuras investigaciones se enfoquen en factores más locales (Bennett et al., 2020).

En un estudio realizado en bosques subtropicales perennifolios de la cuenca del río Xiangjiang, China, la que se encuentra representada en un 54.4% de su superficie por esta vegetación, se estimó la biomasa aérea (AGB) mediante la relación de la información del inventario nacional forestal continuo de los años 1999, 2004, 2009 y 2014 y datos de sensores remotos climáticos, se ajustó un modelo SGBoost y la interpolación Kriging, se determinó que la AGB disminuirá con el aumento de las emisiones de los gases de efecto invernadero hacia los años 2050 y 2070 lo que indica un efecto negativo en el crecimiento, la estructura y la biodiversidad de los bosques estudiados, se concluye que los planes de gestión de las áreas forestales deben considerar los efectos del cambio climático con el fin de garantizar la sostenibilidad (Li et al., 2022).

La concentración de carbono se evaluó a nivel mundial en un estudio en el cual mediante un modelo preliminar se encontró que las variables de temperatura media anual, estacionalidad de las precipitaciones, la estacionalidad de la temperatura y el rango diurno medio, tuvieron una correlación significativa, posteriormente se ajustó un modelo lineal de efectos mixtos con el criterio de información de Akaike (AIC) para determinar el conjunto de variables que influyen en el contenido de carbono; los resultados indicaron que los bosques estacionarios tropicales y templados fueron mejor evaluados y los bosques boreales estuvieron infrarrepresentados, a nivel mundial las concentraciones de carbono oscilaron entre el 30.5 y el 65.0%; se determinó que el modelo ajustado explico el 67.2% de la variación de las concentraciones de carbono al incluir los

efectos aleatorios, con cuatro variables climáticas y sus términos polinómicos como predictores (Paroshy et al., 2021).

Por otro lado, en un estudio se utilizaron variables climáticas y de biomasa en el ajuste de modelos básicos de estimación de la biomasa total del rodal y biomasa de los componentes aéreos y subterráneos (raíces, tallos, ramas y agujas), en plantaciones de tres especies de coníferas en el noreste de China, se ajustaron modelos que incluyeron 19 variables climáticas de las cuales ocho estaban relacionadas con la precipitación y 11 con la temperatura; de lo anterior se determinó que ocho variables son influyentes sobre la biomasa, entre las que destacan, la temperatura media anual, temperatura mínima y la isotermalidad, por otro lado las variables relacionadas con la precipitación fueron la media anual, del trimestre más húmedo y la del mes más seco, todas estas se consideraron como las más importantes en el desarrollo de los modelos (Xin et al., 2022).

El estudio de la dinámica de la vegetación tropical en el Amazonas en escenarios climáticos se evalúa en el trabajo desarrollado por (Galbraith et al., 2010), mediante el ajuste de modelos dinámicos de vegetación global (Hyland, Lund-Potsdam-Jena y MOSES-TRIFFID), se utilizaron datos climáticos obtenidos de la Unidad de Investigación Climática de la región para el periodo de 1983 a 2002 (temperatura, precipitación, humedad relativa, concentración de dióxido de carbono, velocidad del viento, radiación, déficit de presión de vapor y humedad del suelo), así como datos de teledetección con información de biomasa a una resolución de 1 Km, además de la humedad del suelo y propiedades hidráulicas, se determinó que hacia el futuro habrá un aumento de la temperatura y reducciones en las precipitaciones, lo que impactara de forma negativa a la biomasa amazónica.

En un estudio se incluyeron variables climáticas en el ajuste de modelos alométricos para mejorar la estimación de la altura, volumen y el grosor de la corteza de los árboles en la Mata Atlántica en el estado de Río de Janeiro, Brasil; se utilizó un análisis factorial múltiple para evaluar la relación de las variables estudiadas; el diámetro a la altura del pecho, área basal, textura del suelo,

fertilidad del suelo y la variable de precipitación media anual, temperatura media anual, fueron incluidas en el modelo final de estimación; este estudio concluye que los modelos que consideran variables climáticas tienen mejoras significativas con valores menores del Criterio de Información de Akaike y valores del coeficiente de determinación (R^2) más altos (Cysneiros Costa et al., 2021).

Las variables climáticas se han utilizado en el ajuste de modelos de estimación, tal es el caso de un estudio hecho en varios tipos de bosques y regiones climáticas en el continente americano, en este se desarrolló el ajuste de modelos con el uso la biomasa máxima individual y el déficit hídrico del ecosistema para estudiar su relación con factores climáticos como la temperatura media anual, precipitación anual, precipitación del trimestre más seco, evaporación potencial y real, así como el déficit hídrico del ecosistema; se encontró que los modelos que consideran variables climáticas a escalas geográficas amplias y en climas restringidos tienen una influencia limitada, por otro lado se indica que el déficit hídrico establece un límite máximo en el desarrollo de esta variable (Stegen et al., 2011).

En un Meta-Análisis de 40 estudios de 25 países que consideraban diferentes biomas, que incluían bosques boreales, templados estacionales, selvas tropicales y estacionales tropicales, el análisis tuvo como fin determinar la relación de las características estructurales de los rodales y la biomasa aérea (AGB), así como evaluar el efecto de las variables climáticas en desarrollo de los factores anteriores; se encontró que las características evaluadas varían según el bioma que se haya estudiado, por otro lado se indica que los factores climáticos como la precipitación media anual y la temperatura media anual desempeñan un papel crucial en la regulación de las características evaluadas; se concluye que las características estructurales y climáticas influyen significativamente en el desarrollo de la biomasa aérea (Ma et al., 2023).

En un estudio desarrollado en la península de Yucatán, México, en bosques tropicales semiperennifolios y semicaducífolios, fueron utilizados datos espectrales para el desarrollo de índices de vegetación como el índice diferencial

normalizado de vegetación (NDVI), bandas espectrales y variables climáticas, con el fin de estimar y cartografiar la biomasa, así como la incertidumbre asociada a esta; las variables climáticas estudiadas consideraron la temperatura media mensual, temperaturas mínimas y máximas, así como la media anual, también variables de precipitación como la de enero, febrero, noviembre y diciembre, además de considerar el valor anual de esta; se concluye que las variables a escala anual tienen una mayor influencia en los procesos de crecimiento de la biomasa (Ortiz-Reyes et al., 2021).

En un estudio desarrollado a nivel mundial se evaluaron los patrones de acumulación de la biomasa forestal sobre el suelo (AGB) con relación a los patrones de acumulación de esta y los gradientes climáticos donde se desarrollan diferentes tipos de bosques, las principales variables climáticas utilizadas en el ajuste de los modelos fueron la temperatura media anual y la precipitación media anual, las variables de acumulación de AGB consideradas fueron la tasa inicial de acumulación, la AGB saturada y la edad de los bosques; el modelo ajustado fue del tipo bayesiano en el que se encontró que la temperatura tuvo un efecto positivo significativo en los bosques siempreverdes y un efecto negativo en los bosques caducifolios latifoliados, por otro lado la variable de precipitación influyó de forma opuesta en los mismos tipos de bosque (Chen et al., 2023).

MATERIALES Y MÉTODOS

Descripción del área de estudio

La Cuenca Hidrográfica Internacional del Río Amazonas abarca aproximadamente siete millones de km² (Medina P. & Carrillo Silva, s/f; Panel Científico por la Amazonía, 2021), limitándose entre 5° N y 10° S de latitud y 70° W y 50° W de longitud (Blitzkow et al., 2009). La mayor parte le corresponde a Brasil (67.69%), el resto 32.31% le corresponde a Perú (13.02%), Bolivia (11.20%), Ecuador (1.67%), Colombia (5.52%), Venezuela (0.79%) y 0.08% a Guayana (Medina P. & Carrillo Silva, s/f).

La cuenca del Amazonas alberga una rica y diversa vegetación, que incluye bosques lluviosos siempre verdes, bosques estacionales, bosques inundados estacionalmente, bosques montañosos (Buscardo et al., 2016), selva tropical lluviosa, bosques tropicales secos, bosques templados cálidos y fríos, pastizales y matorrales fríos, y estepa, entre otros (Kern et al., 2022). Se estima un total de 14,003 especies comprendidas en 1,788 géneros y 188 familias, más del 52% de estas especies (7,276) son arbustos, árboles pequeños, lianas, enredaderas y hierbas (Cardoso et al., 2017). En el área de estudio, existen 227 especies hiperdominantes de flora y las más abundantes son *Euterpe oleracea* Mart, *Astrocaryum murumuru* Mart. y *Eperua leucantha* Benth. (Ter Steege et al., 2013).

La delimitación del área de estudio se basó en el shapefile de ecorregiones terrestres, ecorregión número uno “Bosques húmedos tropicales y subtropicales de hoja ancha” (Dinerstein et al., 2017). La precipitación promedio en esta cuenca es de 2,200 mm año⁻¹ (Costa & Foley, 1998; Fassoni-Andrade et al., 2021), pero, en regiones andinas (Perú, Bolivia, Ecuador y Colombia), se registran valores de hasta 6,000 mm año⁻¹, incluso en algunos lugares ocurren 250 mm año⁻¹, y esto es dependiente de la altitud y la posición de barlovento o sotavento (Espinoza Villar et al., 2008). A lo largo de la cuenca se registran temperaturas entre 26 y 28 °C (OCTA y CIIFEN, 2021). Los máximos se registran en la zona ecuatorial central, por encima de los 29 °C (Panel Científico por la Amazonía, 2021). Aunque

al oeste en los Andes se presentan temperaturas de hasta 2 °C (OCTA y CIIFEN, 2021).

En el área de estudio se han descrito suelos hidromórficos y no hidromórficos; es decir; áreas inundables y no inundables respectivamente (Damaceno et al., 2020). También al Sur de la cuenca, se han caracterizado suelos entisoles y inceptisoles (Franciscon et al., 2019).

En la Figura 1 se muestra la ubicación del área de estudio a nivel global, diferenciados por colores en el panel izquierdo. En panel derecho se observa una vista ampliada de estos estratos, donde el estrato I aparece en color mostaza y el estrato II en color verde.

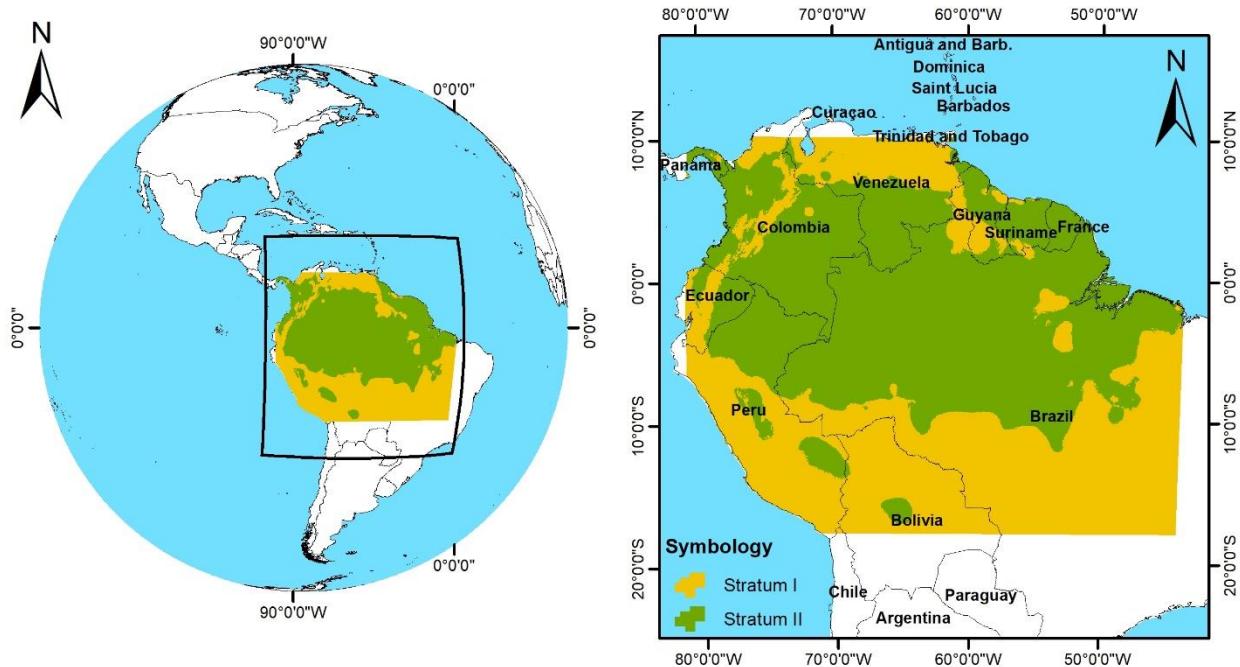


Figura 1. Ubicación del área de estudio a escala mundial (izquierda) y estratos bioclimáticos generados a través del índice Calinski-Harabasz (derecha).

Adquisición y preprocesamiento de datos

Los datos de densidad de la biomasa viva aérea de aquí en adelante DB_{va} (por sus siglas en español), se refiere al stock de biomasa por unidad de área, de biomasa viva aérea, fueron obtenidos en diciembre de 2023 de la plataforma EarthDATA (https://daac.ornl.gov/cgi-bin/dsviewer.pl?ds_id=2017) de la NASA, del proyecto Global Ecosystem Dynamics Investigation (GEDI), lanzado en 5 de

diciembre de 2018, donde se proporcionan estimaciones de DB_{va} entre las latitudes 51.6° N y 51.6° S (Dubayah et al., 2023) en formato GeoTiff (*.tif), a una resolución de 1 km² por pixel.

Para predecir la DB_{va}, se utilizaron las variables bioclimáticas obtenidas del sitio Worldclim (<https://www.worldclim.org/data/worldclim21.html>), corresponden a 19 variables en formato raster, a la misma resolución de los datos de DB_{va} (Fick & Hijmans, 2017; Fick & Himans, 2017). La información de las Bios ha sido utilizada en estudios similares para relacionarlas con biomasa y/o carbono (Saatchi et al., 2007; Stegen et al., 2011; Liu et al., 2013; Fu et al., 2017; Arasa-Gisbert et al., 2018; Guo et al., 2019; Bennett et al., 2020; Ortiz-Reyes et al., 2021; Paroshy et al., 2021; Li et al., 2022; Xin et al., 2022).

En el área de estudio, se distribuyeron sistemáticamente 45,000 puntos, a una equidistancia de 12 km entre filas y columnas, se utilizó la librería 'sp' de R (Pebesma et al., 2024). Después, a través de la librería 'raster' (Hijmans et al., 2023), a cada punto, se le extrajo el valor de cada capa (DB_{va} y Bios). La limpieza de los datos de DB_{va} consistió en: a) eliminar registros que no tuvieran valores (NA), b) registros con valor de cero, c) valores de DB_{va} ≤ percentil 5, por su probable ubicación en lugares con poca o desprovistos de vegetación, Trancoso et al. (2010) y Beuchle et al. (2021) han documentado una tasa de deforestación del 20% y un incremento del 9.5% en el periodo de 2019 a 2020 en ciertas porciones de la cuenca, d) puntos fuera de la elipse (99%) de un análisis de componentes principales, realizado con datos estandarizados de DB_{va} y 19 Bios.

Debido a la gran cobertura geográfica del área de estudio, y con el fin de mejorar las predicciones de DB_{va} se realizó una estratificación bioclimática, por lo cual se utilizaron las 19 variables bioclimáticas en formato raster, a través de la librería 'GeoStratR' (Bivand, 2022), además se empleó el índice de Calinski-Harabasz ("calinski"). Este criterio busca que la varianza entre los grupos sea lo mayor posible con relación a la varianza dentro de los grupos.

Optimización y Validación de Modelos Predictivos de la densidad de biomasa aérea viva.

Por la respuesta cuadrática de algunas Bios, con biomasa aérea (Guo et al., 2019), las Bios fueron transformadas al cuadrado, lo que comprendió un total de 38 variables. Para elegir los mejores predictores de DB_{va}, se utilizó el algoritmo genético (AG) de la librería “glmulti” (Calcagno & de Mazancourt, 2010), bajo los siguientes criterios: a) método “l”, b) criterio de información de Akaike, c) nivel de interacciones 1, d) prueba gaussiana y, e) Técnicas lm (lineal model) y GLM (General Lineal Model). Proceso realizado de forma independiente en cada estrato.

Con el conjunto de predictores derivados del proceso anterior, se usó el 70 y 80% de los datos (para los estratos I y II respectivamente), el modelo fue entrenado a través de Machine Learning (ML) con la técnica lm, con la librería ‘caret’ (Kuhn, 2008), y se verificó el cumplimiento de los supuestos: homogeneidad de varianza, autocorrelación, colinealidad y normalidad, además de evaluar la significancia estadística ($p < 0.05$) de todos los coeficientes de regresión. De no cumplir todos estos criterios, se optaría por la técnica GLM; ésta, es apropiada para el análisis de variables de respuesta continuas y positivas (Arasa-Gisbert et al., 2018; Cysneiros Costa et al., 2021).

Con el resto de los datos de cada estrato (30 y 20%), los modelos fueron validados con base en las técnicas: Validación cruzada de dejar uno fuera (VCDUF), Validación cruzada (VC; $k=10$), Validación cruzada repetida (VCR, $k=10$, rep=10) y Bootstrap (reps=100) con el uso la librería ‘caret’ (Kuhn, 2008). Las métricas calculadas fueron: raíz del cuadrado medio del error (RCME) y error medio absoluto (EMA). Para este tipo de estudios algunos autores (Fu et al., 2017; Chen et al., 2023;) han utilizado entre 20 y el 30% del conjunto de los datos para la validación de los modelos.

Proyecciones de la densidad de biomasa viva aérea actuales y Futuras

Con el modelo generado y los predictores en formato raster, se realizaron predicciones actuales de DB_{va} con la librería 'raster' de R (Hijmans et al., 2023), se aplicó el argumento type = "response", para obtener mapas raster por estrato.

Las predicciones futuras de DB_{va} se realizaron con los promedios de los predictores (raster) de tres modelos de circulación general (GCM): MIROC-6, GISS-E2 y CMCC-ESM2, derivados de predicciones futuras del clima de la fase cinco del proyecto de intercomparación de modelos acoplados (CMIP5), se consideraron cuatro RCP: 2.6, 4.5, 6.0, y 8.5 W m⁻² para los años 2050 y 2070, definidas por el Panel Intergubernamental sobre Cambio Climático (IPPC, 2013)

Similarmente, se empleó el argumento type = "response", de la librería 'raster' (Hijmans et al., 2023) para obtener mapas de las predicciones de DB_{va} en formato raster. En ambos casos, se utilizó la librería de R 'geoData' (Hijmans et al., 2024), para el acceso a las variables bioclimáticas directamente del sitio de Worldclim.

Para evaluar los cambios en DB_{va} atribuibles al cambio climático futuro en comparación con el escenario actual, se empleó álgebra de rásters mediante la expresión: DB_{va} (futuro) - DB_{va} (actual). Los resultados fueron los siguientes: 0 si los valores de los píxeles son iguales en ambos escenarios; positivo si DB_{va} es mayor en el futuro; y negativo si DB_{va} es mayor en el escenario actual. Se utilizó el Coeficiente de Variación (CV) para cuantificar la incertidumbre en las predicciones futuras de la densidad de la biomasa viva aérea (DB_{va}), por último, se empleó la prueba no paramétrica pareada de Wilcoxon para evaluar las diferencias entre los valores de los predictores en condiciones actuales y futuras. La comparación se realizó en todos los escenarios proyectados con relación a los valores actuales, desglosados por cada RCP y año.

Todos los análisis estadísticos, figuras y el procesamiento geográfico se realizaron con el software RStudio versión, 4.3.1 (R Core Team. R:, 2024).

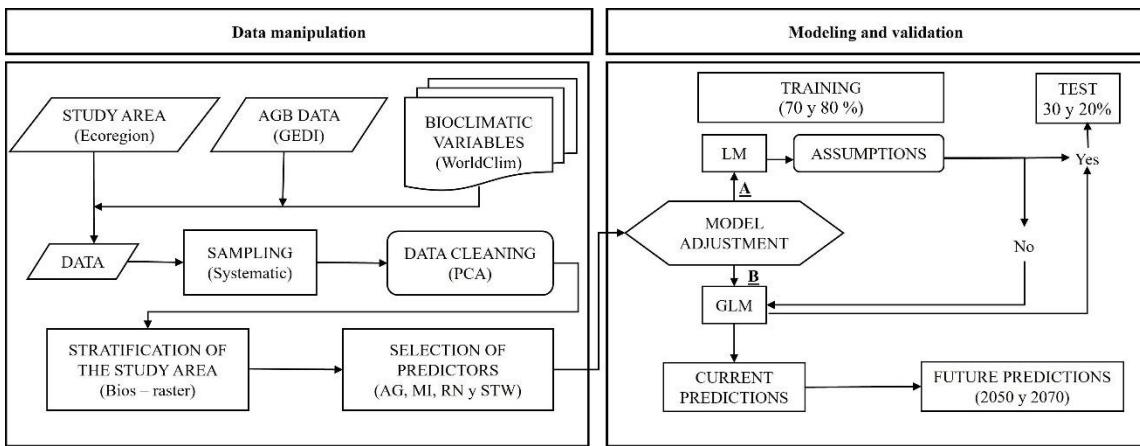


Figura 2. Proceso de manipulación de datos y validación de los modelos de predicción de la densidad de la biomasa viva aérea.

Dado que los modelos LM no cumplieron con los supuestos de heterocedasticidad, autocorrelación, colinealidad y normalidad, o solo se cumplieron parcialmente, se optó por ajustar un modelo GLM, ya que este enfoque se considera más adecuado bajo estas condiciones (Arasa-Gisbert et al., 2018). El entrenamiento del modelo se llevó a cabo con la utilización de 4,640 y 13,056 de los puntos de muestreo de los estratos I y II respectivamente, las variables que mostraron el mejor ajuste como predictoras en los modelos ajustados fueron Bio 5² y Bio 12² para el estrato I, así como Bio 1² y Bio 7² para el estrato II.

Los modelos ajustados fueron Modelos Lineales Generalizados (GLM), desarrollados para incorporar variables que no cumplen con los supuestos de un Modelo Lineal (LM) clásico, la relevancia de los GLM radica en que amplían la capacidad de los modelos para ajustar datos no métricos en comparación con los modelos LM, lo que los convierte en una herramienta esencial para analizar conjuntos de datos en procesos de modelado predictivo (López-González, 2011; Salinas Ruiz et al., 2023).

RESULTADOS Y DISCUSIÓN

Densidad de biomasa viva aérea en el área de estudio

El análisis identificó dos estratos en el área de estudio, con una superficie de 4,611,956.45 km² (estrato I) y 5,654,271.41 km² (estrato II), en los que se establecieron 6,627 y 16,317 sitios de muestreo respectivamente. El estrato I presenta una DB_{va} promedio de 173.95 Mg ha⁻¹, mientras que el estrato II registra 222.75 Mg ha⁻¹, estos valores se encuentran dentro del rango reportado por (Stegen et al., 2011) el cual se encuentra entre 118.9 hasta 250.3 Mg ha⁻¹ de AGB en inventarios forestales del estado de Rio Grande do Sul al sur de Brasil, otro estudio registró un rango de 166.3 a 283.2 Mg ha⁻¹ de AGB en la cordillera de la Serra do Mar en el sudeste del Brasil, donde se utilizaron datos obtenidos mediante LiDAR (Alves et al., 2010).

En otro estudio se reportaron hasta 268.61 Mg ha⁻¹ de AGB en bosques amazónicos del Pando Occidental en Bolivia, a través de ecuaciones alométricas y es más alto que el valor de este estudio (Araujo-Murakami et al., 2016). Se estimó que la Biomasa viva aérea (AGLB) en la parte occidental de la cuenca del Amazonas varía entre 150 a 300 Mg ha⁻¹ (Saatchi et al., 2007). Finalmente, (Malhi et al., 2006) indican un rango más alto de AGLB que varía de 250 a 350 Mg ha⁻¹ en parcelas permanentes de bosques amazónicos.

En comparación, los valores obtenidos en este estudio se encuentran dentro del rango reportado por (Saatchi et al., 2007), (Alves et al., 2010) y (Stegen et al., 2011), pero son menores que los mencionados por (Malhi et al., 2006) y (Araujo-Murakami et al., 2016). No obstante, los resultados presentados permanecen dentro de los límites establecidos para ecosistemas tropicales.

Carbono aéreo en el área de estudio

Con base en un factor de conversión de 0.5 de biomasa a carbono (IPCC, 1996), se estiman 86.98 Mg C ha⁻¹ y 111.38 Mg C ha⁻¹ para los estratos I y II respectivamente, semejante (estrato II) con lo encontrado por (Guo et al., 2019) (106.6 ± 2.6 Mg C ha⁻¹) de carbono aéreo (ACD). En su estudio (Hurtado-Torres et al., 2022) se estimó que el carbono almacenado en la biomasa aérea es de

56.3 Mg ha⁻¹ en la selva mediana subcaducifolia en el estado de Yucatán, México. En el estudio realizado en la región Madre de Dios al suroeste del área de estudio, se estimó un promedio de 127.55 Mg C ha⁻¹ (Gutierrez et al., 2014).

Variables predictoras de la densidad de biomasa viva aérea

En el estrato I fueron seleccionadas las variables Bio 5 (Temperatura máxima del mes más cálido) y Bio 12 (Precipitación anual) y para el estrato II se seleccionaron la Bio 1 (Temperatura media anual) y Bio 7 (Rango de temperatura anual).

Las variables bioclimáticas seleccionadas mediante la aplicación de la metodología de algoritmo genético fueron altamente significativas ($p < 0.0001$). En el estrato I, las variables seleccionadas fueron una relacionada con la temperatura (Bio 5) y con la precipitación (Bio 12), con pendiente negativa y positiva respectivamente. Para el estrato II, se seleccionaron dos variables que representan valores de temperatura (Bio 1 y Bio 7), ambas con una relación negativa con la DB_{va}. (Cuadro 1).

Cuadro 1. Coeficientes y estadísticos de ajuste del modelo de regresión para predecir la densidad de biomasa viva aérea en los bosques húmedos del Amazonas.

Estrato	Coeficientes	Estimadores	2.5%	97.5%	Error std	Valor-T	Pr(> t)	Desviación residual
I (n = 4,640)	β_0 (intercept)	156.40	140.60	173.10	6.227	25.11	<2e-16 ***	1,556.30
	β_1 (Bio 5 ²)	-0.0009	-0.0011	-0.0007	0.00009	-10.20	<2e-16 ***	
	β_2 (Bio 12 ²)	0.00004	0.00003	0.00004	0.000002	19.89	<2e-16 ***	
II (n = 13,056)	β_0 (intercept)	458.90	439.18	478.85	9.446	48.58	<2e-16 ***	1,005.40
	β_1 (Bio 1 ²)	-0.0031	-0.0034	-0.0029	0.0001	-24.03	<2e-16 ***	
	β_2 (Bio 7 ²)	-0.0016	-0.0017	-0.0014	0.00009	-18.01	<2e-16 ***	

Donde: n: Número de sitios; β_0 , β_1 y β_2 : Coeficientes de regresión; 2.5% y 97.5%: Intervalo de confianza de los coeficientes de regresión al 95% de confiabilidad (%); Error std.: Error estándar de los coeficientes de regresión; Pr(>|t|): Probabilidad de obtener un valor de t más extremo que el observado si la hipótesis nula es verdadera; Bio 1: Temperatura media anual °C; Bio 5: Temperatura máxima del mes más cálido (°C); Bio 7: Rango de temperatura anual (Bio 5 - Bio 6, °C); Bio 12: Precipitación anual (mm). Significancia estadística: “*** p < 0.0001”: Muy altamente significativo.

Las ecuaciones predictoras de Biomasa Aérea Viva (DB_{va}) obtenidas en el presente estudio fueron las siguientes:

$$\text{Estrato I: } DB_{va} (\text{Mg ha}^{-1}) = \beta_0 + \beta_1 * \text{Bio 5}^2 (\text{°C} \times 10) + \beta_2 * \text{Bio 12}^2 (\text{mm}) \quad \text{Ec. 1}$$

$$\text{Estrato II: } DB_{va} (\text{Mg ha}^{-1}) = \beta_0 + \beta_1 * \text{Bio 1}^2 (\text{°C} \times 10) + \beta_2 * \text{Bio 7}^2 (\text{°C} \times 10) \quad \text{Ec. 2}$$

En el estrato I, la densidad de biomasa viva aérea (DB_{va}) presenta alta variabilidad ($DE = 95.55$) y valores máximos que alcanzan $1,165.01 \text{ Mg ha}^{-1}$. El coeficiente de variación ($CV = 54.93\%$) sugiere heterogeneidad en este estrato. En contraste, el estrato II registra menor variabilidad ($DE = 65.63$) y un CV más bajo (29.46%), lo que indica mayor uniformidad en la distribución de la biomasa. El análisis de normalidad a través de las pruebas de Shapiro-Wilk y Anderson-Darling sugiere que ninguna de las variables sigue una distribución normal ($p < 0.0001$), lo que justifica el uso de análisis no paramétricos (Cuadro 2).

Cuadro 2. Estadísticas descriptivas de la densidad de biomasa viva aérea y de las variables bioclimáticas actuales que componen el modelo de predicción en bosques húmedos del Amazonas.

	n	Min	P25	Media	Mediana	P75	Max	DE	CV	Curtosis	Asimetría	Shapiro Valor-p	Anderson valor-p
Estrato I													
DBva		34.58	95.82	173.95	164.81	237.49	1,165.01	95.55	54.93	7.28	1.06	0.00	0.00
Bio 5²	4,640	11.20	31.70	31.56	32.70	33.50	35.80	3.74	11.86	8.90	-2.43	0.00	0.00
Bio 12²		379.00	1,586.00	1,695.34	1,789.00	1,918	2,504.00	336.34	19.84	4.75	-1.42	0.00	0.00
Estrato II													
DBva		116.48	175.44	222.75	216.85	260.09	1,157.18	65.63	29.46	1.80	0.006	0.00	0.00
Bio 1²	13,056	11.80	25.50	25.87	26.00	26.50	27.80	1.03	3.99	9.61	1.31	0.00	0.00
Bio 7²		8.20	11.10	12.56	11.90	13.30	22.40	2.23	17.72	5.49	1.62	0.00	0.00

Donde: DBva: Densidad de biomasa viva aérea ($Mg\ ha^{-1}$); Bio 1: Temperatura media anual ($^{\circ}C$); Bio 5: Temperatura máxima del mes más cálido ($^{\circ}C$); Bio 7: Rango de temperatura anual (Bio 5 – Bio 6, $^{\circ}C$); Bio 12: Precipitación media anual (mm); n: Número de sitios de muestreo en cada estrato; Min: Valores mínimos; Max: Valores máximos; P25 y P75: percentil 25 y 75; DE: Desviación estándar; CV: Coeficiente de Variación (%).

Importancia de las Bios de escala anual

Las variables bioclimáticas que representan escala anual (Bio 1 y Bio 12) seleccionadas por el algoritmo de selección en este estudio, han sido encontradas como buenos predictores de AGB en bosques húmedos subtropicales del sur de Brasil, entre otras como: número de meses secos, estacionalidad de las precipitaciones (Bio 15), Bio 5 y Bio 6 las cuales fueron significativas ($p < 0.001$) (Rosenfield & Souza, 2014).

En el estudio desarrollado por Ortiz-Reyes et al. (2021) en bosques semicaducifolios en Yucatán, Bio 1 y Bio 12 predijeron también eficientemente la AGB, sin embargo, el valor de importancia de estas variables fue determinada directamente por el modelo random Forest. De manera similar, en los bosques del mundo, de más de 80 años, que representan una amplia variedad de biomas forestales, como bosques tropicales y los bosques tropicales lluviosos, estas variables muestran una relación directa significativa ($p < 0.05$) con BCD_a (Liu et al., 2013).

En el estudio realizado por Ma et al. (2023) en bosques de 25 países, estas variables (Bio 1 y Bio 12) son altamente significativas ($p < 0.001$) en la estimación de AGB, junto con otros factores como la densidad arbórea, diámetro a la altura del pecho y área basal. En plantaciones de coníferas en el noreste de China, estas variables, se asocian significativamente ($p < 0.05$) con la biomasa (Xin et al., 2022). Estas mismas Bios (Bio 1 y Bio 12) fueron utilizadas por (Khan et al., 2019) para construir modelos alométricos en *Larix gmelinii* Rupr. y *Betula platyphylla* Sukaczev, demostraron que fueron buenos predictores de la biomasa con un valor de R^2 de entre 0.36 a 0.76 de las variables, respectivamente y un análisis de varianza (ANOVA) con un valor de significancia de $p < 0.05$ para este proceso.

En un estudio realizado en un bosque plantado de Yulin en la provincia de Shanxi, las especies dominantes en este son *Pinus tabuliformis* Carr., *Populus alba* L. y *Styphnolobium japonicum* (L.) Schott se consideraron las variables Bio 1 y Bio 12 y la duración total de luz, entre otras (NDVI, edad del stand, pendiente, etc.),

resultaron ser altamente significativas ($p < 0.001$) para la estimación de AGB (Peng et al., 2019). En el estudio realizado por Adhikari et al. (2017) en Kenia, se concluye que la Bio 12 es la más importante para predecir AGB en bosques tropicales afromontanos, más que variables como: elevación, pendiente, exposición entre otras, en donde se determinó la influencia de las variables con la aplicación de una regresión reforzada (BRT).

En los bosques templados y húmedos de todo el mundo, las variables Bio 1 y Bio 12 explicaron el 68.3% y el 50.0% del carbono aéreo, respectivamente (Guo et al., 2019), este estudio evidencia que, a nivel global, los predictores bioclimáticos de escala anual son altamente efectivos y significativos ($p < 0.001$) para estimar la biomasa aérea.

Por su parte Li et al. (2022) estimaron la AGB mediante un modelo de predicción, con base en valores de teledetección y variables climáticas, estas últimas correspondieron a las 19 variables bioclimáticas disponibles en el repositorio de WorldClim, este estudio se desarrolló en la cuenca del río Xiangjiang en la provincia de Hunan, China, en bosques siempre verdes subtropicales, las variables climáticas más importantes en el modelo obtenido fueron la temperatura mínima del mes más frío (Bio 6) y precipitación del mes más seco (Bio 14).

Importancia de las Bios de escala interanual

En el presente estudio se encontró que la variable de escala interanual (Bio 5) es menos relevante que las variables de escala anual (Bio 1, 7 y 12), sin embargo, es importante señalar que las variables de escala interanual tienen relevancia en la estimación de AGB, ya que han sido utilizadas en diversas investigaciones relacionadas.

En un estudio se estimó la biomasa aérea en los bosques de pino Masson (*Pinus massoniana* Lamb.) en la región subtropical de China, se utilizaron variables climáticas para ajustar modelos de predicción, estas fueron promedio a largo plazo de la temperatura de la temporada de crecimiento, precipitación total de la temporada de crecimiento, temperatura media del trimestre más húmedo (Bio 8) y la precipitación del trimestre más húmedo (Bio 16), se encontró que estas

variables fueron significativas ($p < 0.05$) en el proceso de estimación de la biomasa (Fu et al., 2017).

En el estudio de Stegen et al. (2011) se evaluó la influencia de diversas variables climáticas en bosques templados, tropicales secos y tropicales húmedos distribuidos en América del Norte, Central y Sur, entre las variables analizadas se incluyeron la temperatura media anual (Bio 1), la precipitación anual (Bio 12), la relación entre la temperatura media anual y la precipitación anual, y la precipitación del trimestre más seco (Bio 17), los resultados mostraron que la significancia de estas variables varió según el tipo de bosque, con niveles poco significativos hasta altamente significativos ($p < > 0.05$).

Por su parte Zhou et al. (2022) estudiaron el efecto del cambio climático en el potencial de secuestro de carbono en siete tipos de bosques en la provincia de Yunnan en el suroeste de China, en el análisis se consideraron datos de temperatura media anual (Bio 1), temperatura media del trimestre más cálido (Bio 10) y temperatura mínima del mes más frío (Bio 6), precipitación anual (Bio 12) y precipitación del trimestre más frío (Bio 19), los resultados mostraron que, en general la Bio 6 fue el principal factor limitante para la distribución de todos los tipos de bosques, con excepción de los bosques boreales.

El estudio de Bennett et al. (2020) se utilizaron variables climáticas y edáficas para evaluar su relevancia en la predicción de la biomasa forestal de Australia, los resultados indicaron que la variable climática más importante en este proceso fue la temperatura promedio del trimestre más seco (Bio 9), especialmente en los modelos que únicamente incluían variables climáticas para la estimación de la biomasa forestal.

Correlación de las variables bioclimáticas y la densidad de biomasa viva aérea

En el presente estudio se encontró que las variables bioclimáticas de temperatura se correlacionan negativamente con DB_{va} (Cuadro 1) de los bosques húmedos del Amazonas (Bio 1, 5 y 7), lo cual es congruente a lo encontrado por (Stegen et al., 2011; Li et al., 2022) en bosques húmedos y tropicales donde la

temperatura media anual (Bio 1) influía de forma negativa en el desarrollo de la biomasa, así como (Xin et al., 2022) en su estudio realizado en plantaciones de coníferas en China, encontraron que la Bio1 (temperatura media anual), la temperatura mínima registrada anualmente (TMIN) y la isothermalidad (Bio 3) son variables clave y que valores altos de estas afectan el contenido total de biomasa, sin embargo, estas tienen una correlación de forma negativa.

Por otro lado, Ma et al. (2023) indicaron que la temperatura media anual (Bio 1) y precipitación media anual (Bio 12) puede restringir el desarrollo de AGB a través de la estacionalidad y períodos prolongados de sequía, para el caso de los bosques húmedos templados y tropicales se encontró que la Bio 12 se correlaciona de forma positiva, en este sentido (Galbraith et al., 2010) encontraron que el aumento de la temperatura media anual es un factor clave en las pérdidas de biomasa en el ajuste de modelos predictivos.

Por otra parte Guo et al. (2019) evaluaron los cambios futuros en la densidad de carbono en cinco tipos de bosques a nivel global y determinaron que la precipitación media anual (Bio 12) tiene un efecto positivo significativo en el contenido total de carbono en las áreas estudiadas, en contraste, la temperatura media anual (Bio 1) mostró un efecto negativo en este factor para los años 2050 y 2070.

Acorde a la pseudo R² calculada con el set de validación, los modelos explican entre 8.4 y 9.1% (estrato I), así como de un 4% hasta un 4.5% de la DB_{va} en el estrato II (Cuadro 3). Lo cual es similar el estudio desarrollado por (Stegen et al., 2011) donde se encontró que los valores de R² de la relación de la biomasa con Bio 1 de 0.02 en todos los bosques estudiados y en los bosques tropicales con la misma variable el valor de R² es del orden de 0.13, para el caso de la variable de la precipitación anual y su relación con la biomasa en los bosques la R² fue de 0.03, para el caso de los bosques tropicales secos R² de 0.37 y en bosques templados de 0.39. En un estudio realizado en los diversos bosques nativos del continente australiano donde el modelo obtenido que solo contenía variables climáticas tiene una R² de hasta el 0.47 ± 0.04 de AGB (Bennett et al., 2020).

Cuadro 3. Validación de los modelos de regresión con cuatro métodos diferentes.

Estrato	Método	Conjunto	n	Pseudo R ²	RCME	EMA
I	VCDUF	Entrenamiento	4,640			
	VC	Validación	1,987	0.084	89.17	71.93
	VCR	Validación	1,987	0.091	89.08	71.89
	Bootstrap	Validación	1,987	0.084	89.58	72.21
II	LOOCV	Entrenamiento	13,056			
	CV	Validación	3,261	0.040	65.79	50.45
	RCV	Validación	3,261	0.043	65.73	50.43
	Bootstrap	Validación	3,261	0.045	65.67	50.44

Donde: VCDUF: Validación cruzada de dejar uno fuera; VC: Validación Cruzada; VCR: Validación Cruzada Repetida; n: Tamaño de muestra; R²: Coeficiente de determinación; RCME: Raíz del cuadrado medio del error; EMA: Error Medio Absoluto.

La raíz del error cuadrático medio (RCME) estimada en el estrato I asciende a casi 90 Mg ha⁻¹, mientras que en el estrato II es de poco más de 65 Mg ha⁻¹ (Cuadro 3). Estos valores superan lo reportados por (Ortiz-Reyes et al., 2021), quienes obtuvieron un RCME de 34.10 Mg ha⁻¹ en selvas medianas subperennifolias y de 26.20 Mg ha⁻¹ en selvas medianas subcaducifolias. Por su parte, (Xin et al., 2022) registraron RCME en un rango de 7.32 a 13.06 Mg ha⁻¹ en plantaciones de *Pinus koraiensis* Siebold & Zucc., *Larix olgensis* A. Henry y *Pinus sylvestris* var. mongolica Litv. Adicionalmente, Fu et al. (2017) desarrollaron un modelo en bosques de pino en China, donde se obtuvo una estimación con un RCME de 52.82 kg. Las diferencias en los valores del RCME en la predicción de AGB, entre los distintos estudios se deben principalmente a la magnitud y la variabilidad de la variable dependiente.

Predicción actual y futura de la densidad de la biomasa viva aérea

Acorde a las predicciones generadas por los modelos bioclimáticos generados en este estudio, los valores actuales de DB_{va} van desde 89.71 hasta 304.54 Mg

ha^{-1} en el estrato I (Figura 3. a) y desde 184.73 a 400.19 Mg ha^{-1} en el estrato II (Figura 3. b).

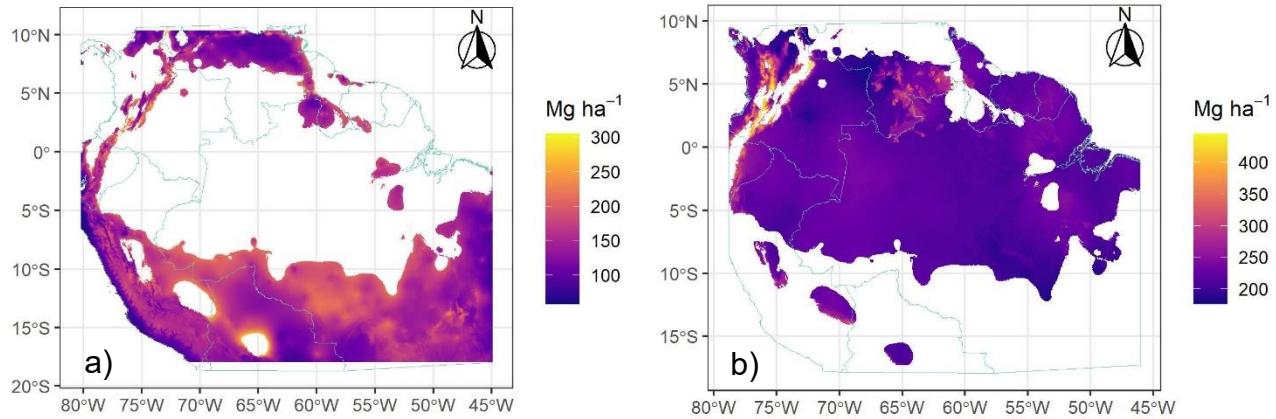


Figura 3. Predicción actual de la densidad de biomasa viva aérea (Mg ha^{-1}) con los modelos bioclimáticos generados, en los bosques húmedos del Amazonas para los estratos I (a) y II (b).

Proyecciones de pérdida de la densidad de biomasa viva aérea: Análisis por escenarios, RCP y estratos

Derivado del álgebra de ráster de las predicciones futuras de DB_{va} con el modelo bioclimático de cada estrato, menos las predicciones actuales de DB_{va} en diversos RCP y horizontes temporales (2050 y 2070), los cambios en DB_{va} debidos exclusivamente al clima y en ausencia de actividades antropogénicas, podría ser de la siguiente manera: Se proyecta una disminución de DB_{va} de entre 30 y 90 Mg ha^{-1} para los años 2050 y 2070, en todos los RCP analizados (Figura 4. a-p), con cambios esperados en ambos estratos. En el estrato I se anticipa que los mayores cambios se concentrarán principalmente en la zona este (Figura 4. a-h), mientras que en el estrato II se prevé que estos se distribuyan a lo largo de toda su superficie, con un impacto más evidente en las zonas este y central (Figura 4. i-p).

Con relación a lo anterior para el caso del estrato I las disminuciones registradas representan la proporción de afectación para el año 2050 de la siguiente manera,

0 – 30 (68.92%), -30 – -60 (28.44%) y -60 – -90 (0.93%), para el caso del año 2070 los valores de disminución representan lo siguiente 0 – 30 (49.94%), -30 – -60 (42.25%) y -60 – -90 (4.6%).

Para el caso del estrato II estos rangos de afectación registrados representan la proporción de afectación para el año 2050 de la siguiente manera, 0 – 30 (22.35%), -30 – -60 (75.24%) y -60 – -90 (2.40%), para el caso del año 2070 los valores de disminución representan lo siguiente 0 – 30 (13.66%), -30 – -60 (63.08%) y -60 – -90 (23.26%).

En el estudio realizado por (Guo et al., 2019), se evaluó el efecto de las variables climáticas en el futuro sobre cinco tipos de bosques a nivel mundial, se determinó que, en los bosques tropicales, el índice de sequedad del suelo será el más importante para el año 2070, por otro lado, en los bosques templados, la precipitación media anual (Bio 12) tendrá un impacto significativo tanto en 2050 como en 2070 en estos bosques. En los bosques boreales, se estimaron impactos bajo los escenarios RCP 4.5 ($-0.22 \pm 10.53 \text{ Mg C ha}^{-1}$) y RCP 8.5 ($-4.75 \pm 10.80 \text{ Mg C ha}^{-1}$) para el año 2070. De forma similar a este estudio, se indica que los cambios aumentaran gradualmente de los RCP 2.6 a 4.5 a 8.5 para los años 2050 y 2070 en los bosques templados, así como un patrón en 2050 para los bosques boreales.

Por otro lado Fu et al. (2017) desarrollaron una ecuación de predicción de AGB en bosques de pino masón (*Pinus massoniana* Lamb.) en china subtropical, mediante la incorporación de variables climáticas y el diámetro a la altura del pecho, con el fin de evaluar los efectos del cambio climático sobre este factor hacia los años 2041 y 2080, se encontró que en el periodo de evaluación bajo los RCP 2.6, 4.5 y 8.5 la AGB aumentara en $24.8 \text{ kg} \pm 32.7\%$, $27.0 \text{ kg} \pm 33.4\%$, y $27.7 \text{ kg} \pm 33.8\%$ respectivamente.

En su estudio Li et al. (2022) desarrollaron un modelo de estimación de AGB mediante valores de teledetección y su relación con variables climáticas, estas últimas correspondieron a las 19 variables bioclimáticas disponibles en el repositorio de WorldClim, este estudio se desarrolló en la cuenca del río

Xiangjiang en la provincia de Hunan, China en bosques siempre verdes subtropicales, con el modelo ajustado se realizaron predicciones de AGB hacia los años 2050 y 2070 se consideraron los RCP 2.6, 4.5, 6.0 y 8.5, estas estimaciones indican que para el año 2050 habrá una disminución de 207.15, 192.30, 180.24 y 176.26 Mg ha⁻¹ y para 2070 de 196.55, 191.80, 175.08 y 170.58 Mg ha⁻¹ en cada RCP, con estos valores se menciona que la AGB disminuirá de forma constante en el siguiente orden: RCP 2.6 > RCP 4.5 > RCP 6.0 > RCP 8.5.

En el presente estudio a diferencia de la mayoría, también se estiman posibles incrementos de DB_{va} en la parte noroeste del estrato I (Figura 4. a-h) de 30 a 60 Mg ha⁻¹ en la mayoría de los RCP con excepción del RCP 4.5 para el año 2050, representan una superficie promedio de 464.41 km² (Cuadro 4). En el escenario más crítico (RCP 8.5) para los años 2050, se espera una disminución de biomasa en una superficie promedio de 261,611.82 km² y para el año 2070 se tendrá una disminución de 258,337.85 km² (Figura 4. d y h). Para el caso del estrato II en este mismo RCP y años (2050 y 2070) se tendrá una disminución promedio de 364,865.55 km² y 333,832.19 km² respectivamente (Figura 4. l y p).

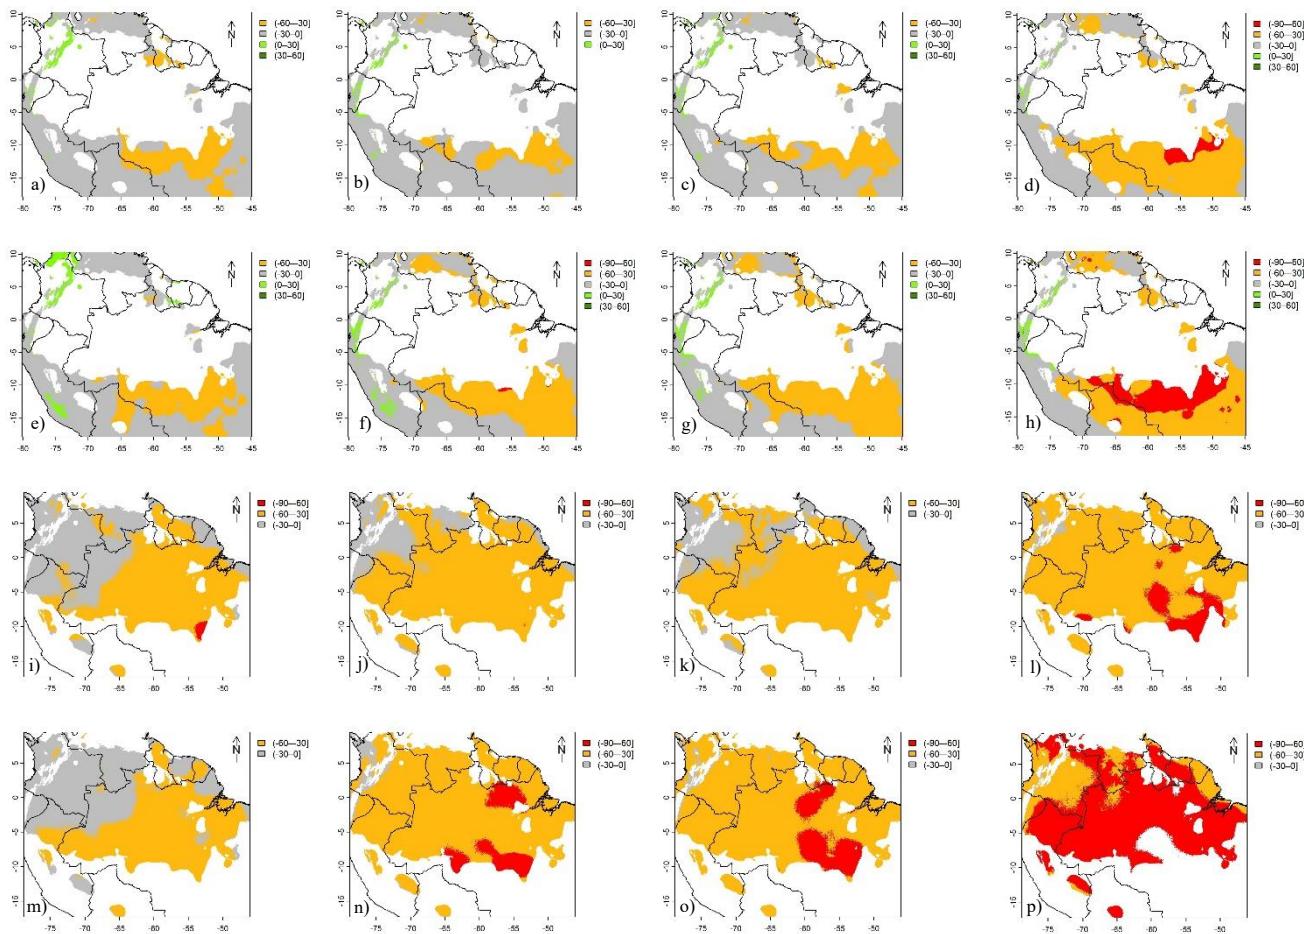


Figura 4. Cambios en la densidad de biomasa viva aérea en los bosques húmedos del Amazonas bajo los escenarios RCP 2.6 a 8.5 (de izquierda a derecha).para el año 2050 (a-d) y 2070 (e-h) del estrato I. Para el estrato II para el año 2050 (i-l) y 2070 (m-p), las áreas con color representan la superficie del estrato.

Si en el año 2070 se presenta el RCP 8.5, se verá afectada una superficie de más de 77 millones hectáreas en el estrato I y de más de 100 millones de hectáreas en el estrato II, con disminuciones de entre 30 y 90 Mg ha⁻¹ de DB_{va} (Cuadro 4). En el RCP 8.5 para ambos años y el RCP 6.0 al 2070 el rango de pérdida con mayor superficie afectada fue de 30 a 60 Mg ha⁻¹ en el estrato I, para el caso del estrato II esto ocurre en todos los RCP y años (Figura 4. d, h, g, i-h), para el estrato I se espera una reducción promedio de 279,532.38 km², mientras que en el estrato II, el promedio de reducción es de 749,722.87 km² (Cuadro 4).

Cuadro 4. Superficie para cada rango de pérdida o ganancia (km^2), de la Densidad biomasa viva aérea de los bosques húmedos del Amazonas en escenarios climáticos al 2050 y 2070.

Cambios en DB_{va}	Estrato I							
	RCP 8.5		RCP 6.0		RCP 4.5		RCP 2.6	
2050	2070	2050	2070	2050	2070	2050	2070	
(-90 – -60 ■)	29,337.65	145,172.25	0.00	0.00	0.00	2,177.90	0.00	0.00
(-60 – -30 □)	424,328.30	392,236.24	181,620.11	370,393.14	117,265.18	363,154.82	176,602.39	210,658.83
(-30 – 0 □)	331,169.52	237,605.06	594,119.40	399,837.55	659,178.94	402,164.92	595,977.02	540,333.71
(0 – 30 □)	5,209.89	14,583.42	14,711.53	20,198.99	14,433.95	23,359.09	18,213.26	39,266.33
(30 – 60 □)	832.73	1,259.77	4.27	469.74	0.00	21.35	85.41	619.21
Estrato II								
(-90 – -60 ■)	97,705.44	757,243.55	0.00	135,900.34	211.26	103,409.32	7,288.30	0.00
(-60 – -30 □)	975,258.71	241,147.58	830,042.02	940,972.02	890,587.70	952,231.91	598,612.17	568,930.84
(-30 – 0 □)	21,632.51	3,105.45	264,554.64	17,724.29	203,797.70	38,955.42	488,696.19	525,665.82
(0 – 30 □)	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
(30 – 60 □)	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00

Donde: DB_{va}: Densidad de biomasa viva aérea (Mg ha^{-1}); RCP = Vías de concentración representativas.

Evaluación de las proyecciones climáticas sobre las variables de predicción

Los resultados de la prueba de Wilcoxon para el estrato I, al comparar las medianas de los valores actuales de las Bios y cada escenario climático, arroja que la temperatura máxima del mes más cálido (Bio 5) actualmente tiene una media de 31.6 °C cuyo valor es estadísticamente diferente ($p<0.0001$) al valor estimado para el año 2050 en todos los escenarios con un valor promedio de 35.7 °C lo que representa un incremento de 4.1 °C, lo mismo ocurre para al año 2070 con un valor proyectado de 36.4 °C lo que representa un incremento de 4.8 °C sobre al valor actual (Figura 5. a, de color naranja)

De forma similar el valor de precipitación anual (Bio 12) es estadísticamente diferente ($p<0.0001$) con un valor actual de 1,788 mm a lo proyectado para el año 2050, con un valor promedio de 1,709 mm anual, lo que representa una disminución de 79 mm de precipitación, para el año 2070 el valor promedio de 1,702 mm representa una reducción de 86 mm (Figura 5. b, de color azul).

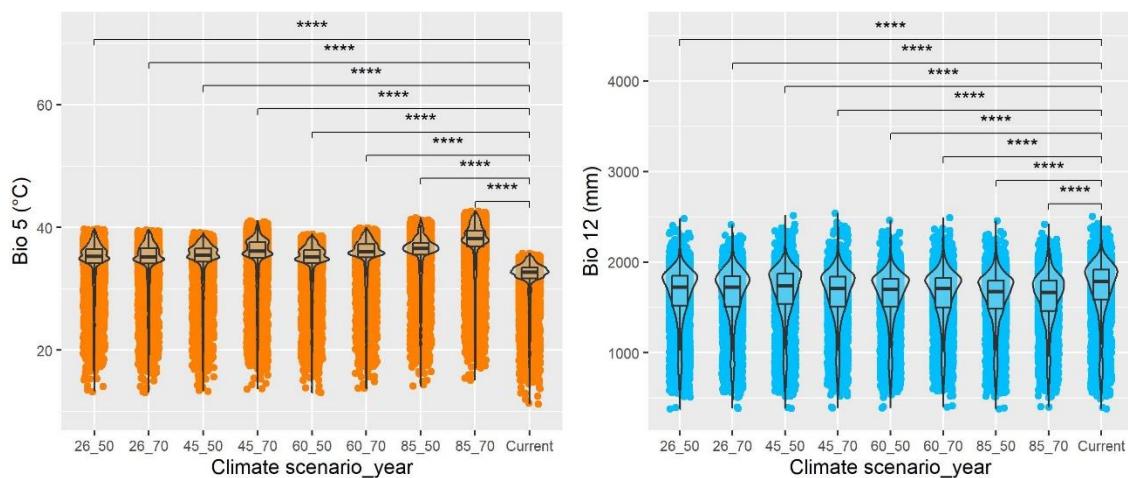


Figura 5. Prueba de Wilcoxon para comparar medianas de la variable actual con cada escenario climático, en el estrato I. Bio 5: Temperatura máxima del mes más cálido (°C); Bio 12: Precipitación anual (mm). Niveles de significancia: **** (Significativo al 0.0001)

Los resultados de la prueba de Wilcoxon para el estrato II, al contrastar las medianas de los valores actuales de las Bios y cada escenario climático, demuestra que la temperatura promedio anual (Bio 1) actualmente tiene una media de 26 °C cuyo valor es estadísticamente diferente ($p<0.0001$) el valor proyectado al año 2050 en todos los escenarios con un valor promedio de 28.1 °C lo que representa un incremento de 2.1 °C, lo mismo ocurre para al año 2070 con un valor proyectado de 28.6 °C lo que representa un incremento de 2.6 °C sobre al valor actual (Figura 6. a, de color naranja).

De forma similar el valor del rango de temperatura anual (Bio 5 - Bio 6, Bio 7) es estadísticamente diferente ($p<0.0001$) con un valor actual de 11.9 °C a lo proyectado para el año 2050, con un valor promedio proyectado de 12.8 °C, lo que representa un incremento de 0.9 °C, para el año 2070 el valor promedio de 13.2 °C representa un incremento de 1.3 °C (Figura 6. b, de color naranja).

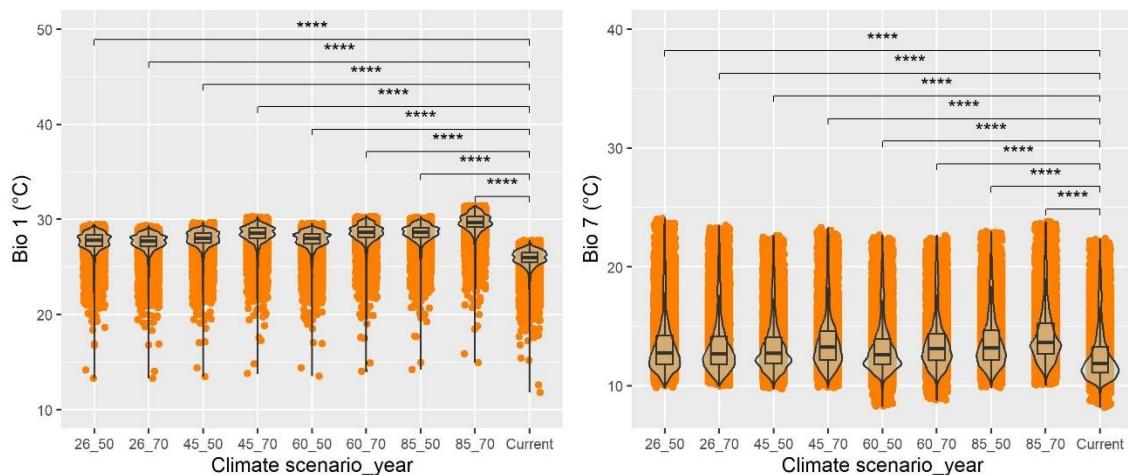


Figura 6. Prueba de Wilcoxon para comparar medianas de la variable actual con cada escenario climático, en el estrato II. Bio 1: Temperatura media anual (°C); Bio 7: Rango de temperatura anual (Bio 5 – Bio 6, °C). Niveles de significancia: **** (Significativo al 0.0001).

En el presente estudio la incertidumbre se representa con el coeficiente de variación (CV), estos valores indican que para el año 2050 y en todos los RCP se tendrá un valor promedio de 11.36% y 5.57% estrato I y II respectivamente

respecto a las predicciones realizadas, por su parte para el año 2070 esta variable representa en promedio el 15.03 y 8.18% estrato I y II (Cuadro 5).

A manera de ejemplo se muestran las predicciones con menor CV en las estimaciones (Figura 7. a y c) de los estratos I y II respectivamente, así como las que tienen mayores valores de esta variable (Figura 7. b y d), sin embargo, en las figuras citadas los rangos de variación más extremos se encuentran fuera de los estratos correspondientes.

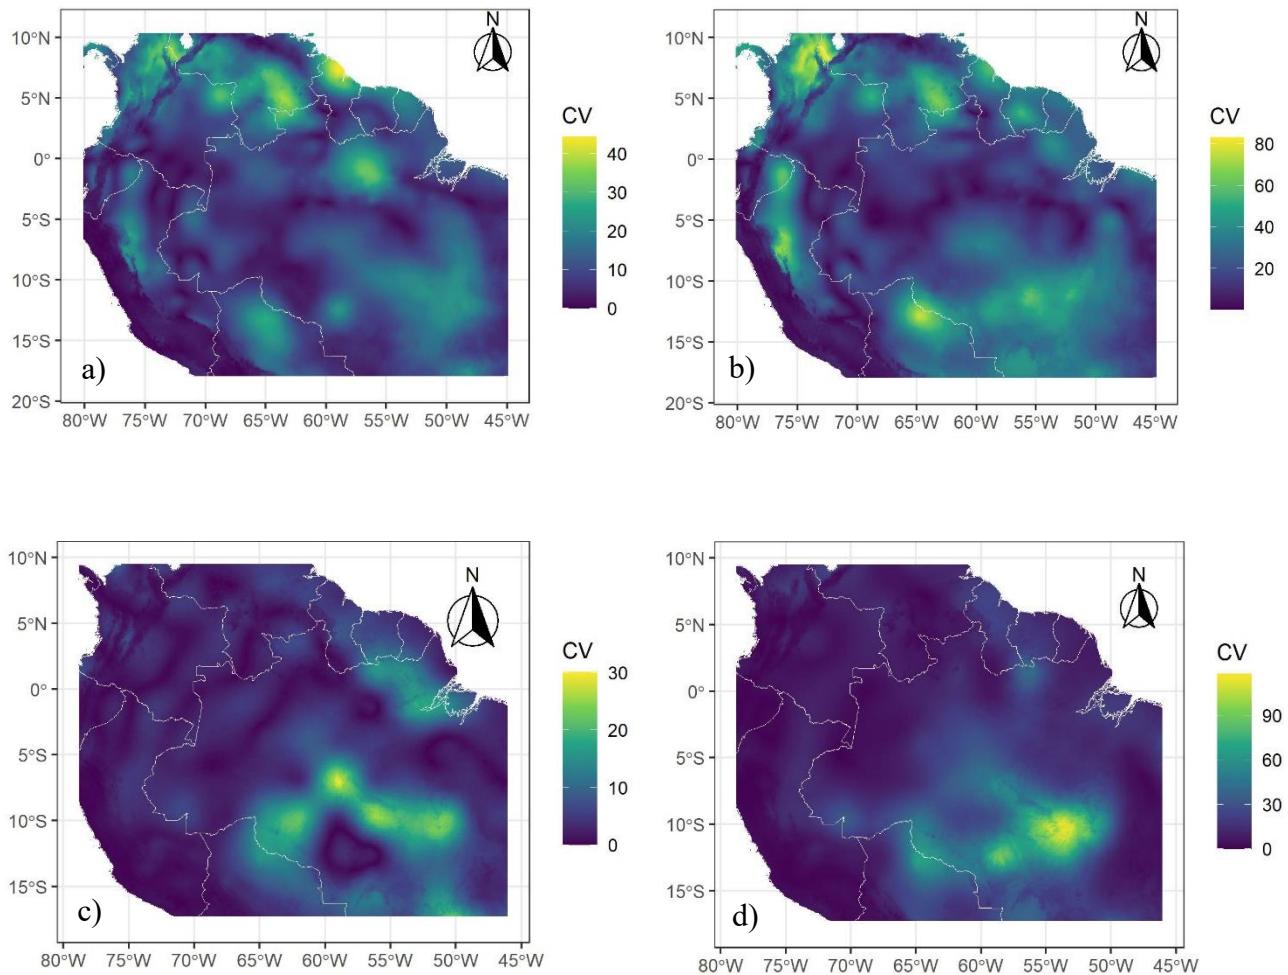


Figura 7. RCP y años con menor y mayor Incertidumbre estimada para la densidad de la biomasa viva aérea, estrato I año 2050 RCP 4.5 año 2070 RCP 8.5 (a y b), estrato II año 2050 RCP 6.0 y año 2070 8.5 c y d)

Los valores de las medias de los coeficientes de variación en los años y RCP estudiados son menores en el área que comprende al estrato II con relación a el estrato I en donde en promedio las estimaciones son del 13.20 y 6.87% respectivamente para cada estrato (Cuadro 5). Estas variaciones podrían deberse a lo que expresa (Malhi et al., 2006), que indicaron que la mayor cantidad de biomasa se encuentra en la Amazonia central y las Guayanas, que es alrededor de 15% más baja en el este y los valores más bajos se encuentran al norte y en al sur de la región.

Cuadro 5. Estadísticas descriptivas de las predicciones de la densidad de biomasa viva aérea en los bosques húmedos del Amazonas.

Estrato I									
	RCP 8.5		RCP 6.0		RCP 4.5		RCP 2.6		
	2050	2070	6050	6070	4550	4570	2650	2670	
Min	0.021	0.008	0.000	0.020	0.000	0.005	0.000	0.000	
1 st. Qu.	7.698	11.651	6.523	8.928	5.644	7.673	6.015	5.519	
Mediana	14.095	20.822	11.075	15.195	9.659	13.584	10.622	10.514	
3rd Qu.	20.401	32.218	16.704	21.809	15.009	19.334	16.439	16.987	
Max.	52.897	83.104	61.075	55.252	44.359	46.637	49.783	74.324	
Estrato II									
	2050	2070	6050	6070	4550	4570	2650	2670	
Min	0.015	0.000	0.000	0.000	0.000	0.002	0.000	0.000	
1 st. Qu.	3.841	5.948	1.950	3.051	1.880	3.220	3.039	2.652	
Median	7.129	12.303	3.606	7.335	4.038	7.319	7.279	5.765	
3rd Qu.	11.852	22.716	6.741	12.838	7.816	13.526	12.262	10.853	
Max.	40.868	117.880	30.094	40.768	34.813	64.523	54.710	43.911	

Donde: RCP: Vías de concentración representativas; 1st. Qu y 3rd Qu: Primer y tercer cuartil; Mediana: Mediana de los valores; Min: Valores mínimos, Max: Valores máximos.

CONCLUSIONES

Fueron obtenidos dos modelos de predicción de biomasa viva aérea, en los que las variables más importantes fueron las que tienen una cobertura anual Bio 1 (Temperatura media anual) y Bio 12 (Precipitación anual) con el 3.24 y 5.72% de este valor respectivamente. Los modelos desarrollados demostraron una buena capacidad predictiva en los bosques húmedos del Amazonas considerando únicamente variables bioclimáticas.

En toda la superficie del área de estudio (estrato I y II) existirán en su mayoría cambios en las existencias de biomasa viva aérea, con disminuciones desde 30 hasta 60 Mg ha⁻¹ en todos los RCP y años estudiados, la mayor disminución de la biomasa viva aérea será en la parte sureste (estrato I) y centro (estrato II) del área de estudio, en las cuales se prevé una disminución de hasta 90 Mg ha⁻¹ en el RCP 8.5 para el año 2070. Por otro lado, se proyecta un cambio positivo en la parte noroeste del estrato I, con incrementos de la biomasa viva aérea de hasta 30 Mg ha⁻¹ en todos los RCP y años, así como incrementos de hasta 60 Mg ha⁻¹ en el RCP 8.5 para ambos años.

Se proyecta que la biomasa viva aérea se reduzca en una superficie promedio de 257,222.21 de Km² en el estrato I y en una superficie promedio de 360,986.38 Km² en el estrato II, sin embargo, en el estrato I se proyecta que en una superficie promedio de 9,605.73 Km² existirán incrementos desde 30 hasta 60 Mg ha⁻¹, lo que no ocurrirá en el estrato II.

La prueba de Wilcoxon indica que el cambio climático tendrá efectos negativos significativos sobre la biomasa viva aérea, al determinar un incremento de temperatura media anual de hasta 2.1 °C para el año 2050 y de 2.6 °C para el 2070 y una disminución de la precipitación de hasta 79 mm para el año 2050 y 86 mm para el 2070.

REFERENCIAS

- Adhikari, H., Heiskanen, J., Siljander, M., Maeda, E., Heikinheimo, V., & Pellikka, P. K. E. (2017). Determinants of aboveground biomass across an afromontane landscape Mosaic in Kenya. En *Remote Sensing* (Vol. 9, Número 8). MDPI. <https://doi.org/10.3390/rs9080827>
- Alves, L. F., Vieira, S. A., Scaranello, M. A., Camargo, P. B., Santos, F. A. M., Joly, C. A., & Martinelli, L. A. (2010). Forest structure and live aboveground biomass variation along an elevational gradient of tropical Atlantic moist forest (Brazil). *Forest Ecology and Management*, 260(5), 679–691. <https://doi.org/10.1016/j.foreco.2010.05.023>
- Andreevich, U. V., Reza, S. S. O., Stepanovich, T. I., Amirhossein, A., Meng, Z., Anees, S. A., & Petrovich, C. V. (2020). Are There Differences in the Response of Natural Stand and Plantation Biomass to Changes in Temperature and Precipitation? A Case for Two-Needled Pines in Eurasia. *Journal of Resources and Ecology*, 11(4), 331–341. <https://doi.org/10.5814/j.issn.1674-764x.2020.04.001>
- Antúnez, 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), 14. <https://doi.org/10.3390/f8030059>
- Arasa-Gisbert, R., Vayreda, J., Román-Cuesta, R. M., Villela, S. A., Mayorga, R., & Retana, J. (2018). Forest diversity plays a key role in determining the stand carbon stocks of Mexican forests. *Forest Ecology and Management*, 415–416, 160–171. <https://doi.org/10.1016/j.foreco.2018.02.023>
- Araujo-Murakami, A., Milliken, W., Klitgaard, B. B., Carrion-Cuellar, A. M., Vargas-Lucindo, S., & Parada-Arias, R. (2016). BIOMASS AND CARBON IN THE VÁRZEA AND TERRA FIRME AMAZON FOREST IN WESTERN PANDO BIOMASS AND CARBON IN THE VÁRZEA AND TERRA FIRME AMAZON FOREST IN WESTERN PANDO. *Kempffiana*, 12, 3–19.
- Balvanera, P. (2012). Los servicios ecosistémicos que ofrecen los bosques tropicales. *ecosistemas*, 21, 136–147. <http://www.revistaecosistemas.net/articulo.asp?Id=709>
- Bennett, A. C., Penman, T. D., Arndt, S. K., Roxburgh, S. H., & Bennett, L. T. (2020). Climate more important than soils for predicting forest biomass at the continental scale. *Ecography*, 43(11), 1692–1705. <https://doi.org/10.1111/ecog.05180>
- Beuchle, R., Archard, F., Bourgoin, C., Vancutsem, C., Eva, H. D., & Follador, M. (2021). *Deforestation and Forest Degradation in the Amazon-Status and trends up to year 2020*. <https://doi.org/10.2760/61682>

- Bivand, R. , G.-R. V. , & P. E. (2022). *GeoStratR: Tools for simple stratification of spatial patterns.*
- Blitzkow, D., De Matos, A. C. O. C., Campos, I. O., Ellmann, A., Vaníček, P., & Santos, M. C. (2009). *An Attempt for an Amazon Geoid Model Using Helmert Gravity Anomaly.*
- Booth, T. H., Nix, H. A., Busby, J. R., & Hutchinson, M. F. (2014). Bioclim: The first species distribution modelling package, its early applications and relevance to most current MaxEnt studies. En *Diversity and Distributions* (Vol. 20, Número 1, pp. 1–9). <https://doi.org/10.1111/ddi.12144>
- Bouza, C. N. (s/f). *MODELOS DE REGRESIÓN Y SUS APLICACIONES.* <https://www.researchgate.net/publication/323227561>
- Buscardo, E., Nardoto, G., Luizão, F., Piedade, M. T. F., Schöngart, J., Wittmann, F., Doughty, C. E., Quesada, C. A., & Nagy, L. (2016). The Biogeochemistry of the Main Forest Vegetation Types in Amazonia. En *Interactions Between Biosphere, Atmosphere and Human Land Use in the Amazon Basin* (pp. 225–266). https://doi.org/10.1007/978-3-662-49902-3_11
- Calcagno, V., & de Mazancourt, C. (2010). glmulti: An R Package for Easy Automated Model Selection with (Generalized) Linear Models. *Journal of Statistical Software*, 34(12), 29. <http://www.jstatsoft.org/>
- Cardoso, D., Särkinen, T., Alexander, S., Amorim, A. M., Bitrich, V., Celis, M., Daly, D. C., Fiaschi, P., Funk, V. A., Giacomin, L. L., Goldenberg, R., Heiden, G., Iganci, J., Kelloff, C. L., Knapp, S., De Lima, H. C., Machado, A. F. P., Dos Santos, R. M., Mello-Silva, R., ... Forzza, R. C. (2017). Amazon plant diversity revealed by a taxonomically verified species list. *Proceedings of the National Academy of Sciences of the United States of America*, 114(40), 10695–10700. <https://doi.org/10.1073/pnas.1706756114>
- CEPAL, & Patrimonio Natural. (2013). *Amazonia posible y sostenible* (M. Giraldo, Ed.).
- Chen, X., Luo, M., & Larjavaara, M. (2023). Effects of climate and plant functional types on forest above-ground biomass accumulation. *Carbon Balance and Management*, 18(1), 11. <https://doi.org/10.1186/s13021-023-00225-1>
- Costa, M. H., & Foley, J. A. (1998). A comparison of precipitation datasets for the Amazon basin. *Geophysical Research Letters*, 25(2), 155–158. <https://doi.org/10.1029/97GL03502>
- Cysneiros Costa, V., Coelho de Souza, F., Dias Gaui, T., Libanio Pelissari, A., Angostini Orso, G., do Amaral Machado Sebastião, Costa de Carvalho, D., & Borges Silveira-Filho, T. (2021). Integrating climate, soil and stand structure into allometric models: An approach of site-effects on tree allometry in

- Atlantic Forest. *Ecological Indicators*, 127.
<https://doi.org/10.1016/j.ecolind.2021.107794>
- Damaceno, J. B. D., Silva, W. G. da, Lima, H. N., Falcão, N. P. de S., Padilha, F. de J., Junior, A. B. da C., Martins, J. K. D., Caniato, M. M., Souza, F. R. de, Brito, W. B. M., & Tucci, C. A. F. (2020). Physical, Chemical, Morphological and Mineralogical Characterization Surface and Subsurface in Hydromorphic and Non-hydromorphic Soil of the Central Amazon. *Journal of Agricultural Science*, 12(4), 245–261. <https://doi.org/10.5539/jas.v12n4p245>
- Dinerstein, E., Olson, D., Joshi, A., Vynne, C., Burgess, N. D., Wikramanayake, E., Hahn, N., Palminteri, S., Hedao, P., Noss, R., Hansen, M., Locke, H., Ellis, E. C., Jones, B., Barber, C. V., Hayes, R., Kormos, C., Martin, V., Crist, E., ... Saleem, M. (2017). An Ecoregion-Based Approach to Protecting Half the Terrestrial Realm. *BioScience*, 67(6), 534–545. <https://doi.org/10.1093/biosci/bix014>
- Dubayah, R. O., Armston J., Healey S.P., Yang Z., Patterson P.L., Saarela S., Stahl G., Duncanson Kellner J.R., Bruening J., & Pascual A.. (2023). GEDI L4B Gridded Aboveground Biomass Density, Version 2.1. ORNL DAAC, 7.
<https://doi.org/10.3334/ORNLDaac/2299>
- Duncanson, L., Kellner, J. R., Armston, J., Dubayah, R., Minor, D. M., Hancock, S., Healey, S. P., Patterson, P. L., Saarela, S., Marselis, S., Silva, C. E., Bruening, J., Goetz, S. J., Tang, H., Hofton, M., Blair, B., Luthcke, S., Fatoyinbo, L., Abernethy, K., ... Zgraggen, C. (2022). Aboveground biomass density models for NASA's Global Ecosystem Dynamics Investigation (GEDI) lidar mission. *Remote Sensing of Environment*, 270.
<https://doi.org/10.1016/j.rse.2021.112845>
- Espinoza Villar, J. C., Ronchail, J., Loup Guyot, J., Cochonneau, G., Naziano, F., Lavado, W., De Oliveira, E., Pombosa, R., & Vauchel, P. (2008). Spatio-temporal rainfall variability in the Amazon basin countries (Brazil, Peru, Bolivia, Colombia, and Ecuador). *International Journal of Climatology*, 29(11), 1574–1594. <https://doi.org/10.1002/joc.1791>
- FAO. (2021). Evaluación de los recursos forestales mundiales 2020 Informe principal. En *Evaluación de los recursos forestales mundiales 2020*. FAO.
<https://doi.org/10.4060/ca9825es>
- FAO. (2022). El estado de los bosques del mundo 2022 - Vías forestales hacia la recuperación verde y la creación de economías inclusivas, resilientes y sostenibles. En *El estado de los bosques del mundo 2022*. FAO.
<https://doi.org/10.4060/cb9360es>
- FAO, & PNUMA. (2020). El estado de los bosques del mundo 2020 - Los bosques, la biodiversidad y las personas. En *El estado de los bosques del mundo 2020*. FAO and UNEP. <https://doi.org/10.4060/ca8642es>

- Fassoni-Andrade, A. C., Fleischmann, A. S., Papa, F., Cauduro Días de Paiva, R., Wongchuig, S., M. Melack, J., Aparecida Moreira, A., Paris, A., Ruhoff, A., Barbosa, C., Andrade Maciel, D., Novo, E., Durand, F., Frappart, F., Aires, F., Medeiros Abrahão, G., Ferreira-Ferreira, J., Carlo Espinoza, J., Laipelt, L., ... Pellet, V. (2021). Amazon Hydrology From Space: Scientific Advances and Future Challenges. *Reviews of Geophysics*, 59. <https://doi.org/10.1029/2020RG000728>
- Fenech, A., Comer, N., & Gough, B. (s/f). Paper 5: Selecting a Global Climate Model for Understanding Future Projections of Climate Change. 133–145. Recuperado el 11 de noviembre de 2024, de https://projects.upei.ca/climate/files/2012/10/Book-1_Paper-5.pdf
- 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>
- Fick, S. E., & Hijmans, R. J. (2017). Historical climate data — WorldClim 1 documentation. <https://www.worldclim.org/data/worldclim21.html>
- Franciscon, U., Campos, M. C. C., Mantovanelli, B. C., dos Santos, L. A. C., da Cunha, J. M., Chechi, L., & de Oliveira, I. A. (2019). Soils characterization and classification in clean field, dirty field and forest areas in amazonian environments. *Bioscience Journal*, 35(4), 1083–1098. <https://doi.org/10.14393/BJ-v35n4a2019-42130>
- 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). <https://doi.org/10.1007/s13595-017-0636-z>
- Galbraith, D., Levy, P. E., Sitch, S., Huntingford, C., Cox, P., Williams, M., & Meir, P. (2010). Multiple mechanisms of Amazonian forest biomass losses in three dynamic global vegetation models under climate change. *New Phytologist*, 187, 647–665. <https://doi.org/10.1111/j.1469-8137.2010.03350.x>
- Gao, J., Zhao, P., Shen, W., Rao, X., & Hu, Y. (2017). Physiological homeostasis and morphological plasticity of two tree species subjected to precipitation seasonal distribution changes. *Perspectives in Plant Ecology, Evolution and Systematics*, 25, 1–19. <https://doi.org/10.1016/j.ppees.2017.01.002>
- Grossiord, C., Sevanto, S., Adams, H. D., Collins, A. D., Dickman, L. T., McBranch, N., Michaletz, S. T., Stockton, E. A., Vigil, M., & McDowell, N. G. (2017). Precipitation, not air temperature, drives functional responses of trees in semi-arid ecosystems. *Journal of Ecology*, 105, 163–175. <https://doi.org/10.1111/1365-2745.12662>

- Guo, Y., Peng, C., Trancoso, R., Zhu, Q., & Zhou, X. (2019). Stand carbon density drivers and changes under future climate scenarios across global forests. *Forest Ecology and Management*, 449, 11. <https://doi.org/10.1016/j.foreco.2019.117463>
- Gutierrez, N., Alvarez, C., Riveros, J. C., & Aguilar-Amuchastegui, N. (2014). *Estimación del Carbono en la Biomasa aérea de los bosques de la Región de Madre de Dios*.
- Han, S.-H., Kim, D.-H., Kim, G.-N., Lee, J.-C., & Yun, C.-W. (2012). Changes on Initial Growth and Physiological Characteristics of Larix kaempferi and Betula costata Seedlings under Elevated Temperature. *Korean Journal of Agricultural and Forest Meteorology*, 14(2), 63–70. <https://doi.org/10.5532/kjafm.2012.14.2.063>
- Hijmans, R. J., Barbosa, M., Ghosh, A., & Mandel, A. (2024). *Title Download Geographic Data*. <https://github.com/rspatial/geodata/issues/>
- Hijmans, R. J., van Etten, J., Sumner, M., Cheng, J., Baston, D., Bevan, A., Bivand, R., Busetto, L., Canty, M., Fasoli, B., Forrest, D., Ghosh, A., Golicher, D., Gray, J., Greenberg, J. A., Hiemstra, P., Hingee, K., Ilich, A., Institute for Mathematics Applied Geosciences, ... Wueest, R. (2023). *Geographic Data Analysis and Modeling*. <https://github.com/rspatial/raster/issues/>
- Hurtado-Torres, M. C., Dupuy-Rada, J. M., Montañez-Escalante, P., & Jiménez-Osornio, J. (2022). Tree diversity and carbon stored in communally managed tropical forests in Yucatan, Mexico. *Madera y Bosques*, 28(3), 16. <https://doi.org/10.21829/myb.2022.2832499>
- IPCC. (1996). LAND-USE CHANGE & FORESTRY. En *Guidelines for National Greenhouse Gas Inventories: Reference Manual* (pp. 5-5.19).
- IPCC. (2013). Glosario. En S. T.F., D. Qin, P. G.-K., M. Tignor, A. S.K., B. J., N. A., X. Y., B. V., & M. P.M. (Eds.), *Cambio Climático 2013. Bases físicas. Contribución del Grupo de trabajo I al Quinto Informe de Evaluación del Grupo Intergubernamental de Expertos sobre el Cambio Climático* (pp. 184–204). Cambridge University.
- IPCC. (2018). Annex I: Glossary. En Mustafa Babiker, Heleen de Coninck, Sarah Connors, Renée van Diemen, Riyanti Djalante, Kristie L. Ebi, Neville Ellis, Andreas Fischlin, Tania Guillén Bolaños, Kiane de Kleijne, Valérie Masson-Delmotte, Richard Millar, Elvira S. Poloczanska, Hans-Otto Pörtner, Andy Reisinger, Joeri Rogelj, Sona I. Seneviratne, Chandni Singh, Petra Tschakert, & Nora M. Weyer (Eds.), *Global Warming of 1.5°C* (pp. 541–562). Cambridge University Press. <https://doi.org/10.1017/9781009157940.008>
- IPPC. (2013). *Climate change 2013 : the physical science basis : Working Group I contribution to the Fifth assessment report of the Intergovernmental Panel on*

Climate Change (T. Stocker, Q. Dahe, G.-K. Plattner, M. Tignor, S. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex, & P. Midgley, Eds.; p. 1535). Cambridge University.

K-1 Coupled GCM (MIROC) Description K-1 model developers. (s/f).

Kern, A. K., Akabane, T. K., Ferreira, J. Q., Chiessi, C. M., Willard, D. A., Ferreira, F., Sanders, A. O., Silva, C. G., Rigsby, C., Cruz, F. W., Dwyer, G. S., Fritz, S. C., & Baker, P. A. (2022). A 1.8 million year history of Amazon vegetation. *Quaternary Science Reviews*, 299, 18. <https://doi.org/10.1016/j.quascirev.2022.107867>

Khan, D., Muneer, M. A., Nisa, Z. U., Shah, S., Amir, M., Saeed, S., Uddin, S., Munir, M. Z., Lushuang, G., & Huang, H. (2019). Effect of Climatic Factors on Stem Biomass and Carbon Stock of Larix gmelinii and Betula platyphylla in Daxing'anling Mountain of Inner Mongolia, China. *Advances in Meteorology*, 2019, 10. <https://doi.org/10.1155/2019/5692574>

Kuhn, M. (2008). Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28(5). <http://www.jstatsoft.org/>

Lahssini, K., Baghdadi, N., Le Maire, G., Dupuy, S., & Fayad, I. (2024). Use of GEDI Signal and Environmental Parameters to Improve Canopy Height Estimation over Tropical Forest Ecosystems in Mayotte Island. *Canadian Journal of Remote Sensing*, 50, 21. <https://doi.org/10.1080/07038992.2024.2351004>

Lathuillière, M. J., Coe, M. T., & Johnson, M. S. (2016). A review of green-and blue-water resources and their trade-offs for future agricultural production in the Amazon Basin: What could irrigated agriculture mean for Amazonia? En *Hydrology and Earth System Sciences* (Vol. 20, Número 6, pp. 2179–2194). Copernicus GmbH. <https://doi.org/10.5194/hess-20-2179-2016>

Li, Y., Li, M., & Wang, Y. (2022). Forest Aboveground Biomass Estimation and Response to Climate Change Based on Remote Sensing Data. *Sustainability (Switzerland)*, 14(21), 27. <https://doi.org/10.3390/su142114222>

Liu, Y., Yu, G., Wang, Q., & Zhang, Y. (2013). How temperature, precipitation and stand age control the biomass carbon density of global mature forests. *Global Ecology and Biogeography*, 23(3), 11. <https://doi.org/10.1111/geb.12113>

López-González, E. (2011). Análisis De Datos Con El Modelo Lineal Generalizado- Una aplicación con R. *Revista española de pedagogía*, 248, 59–80.

Lovato, T., Peano, D., Butenschön, M., Materia, S., Iovino, D., Scoccimarro, E., Fogli, P. G., Cherchi, A., Bellucci, A., Gualdi, S., Masina, S., & Navarra, A. (2022). CMIP6 Simulations With the CMCC Earth System Model (CMCC-ESM2). *Journal of Advances in Modeling Earth Systems*, 14(3). <https://doi.org/10.1029/2021MS002814>

- Luo, Y., Wang, X., Zhang, X., Ren, Y., & Poorter, H. (2013). Variation in biomass expansion factors for China's forests in relation to forest type, climate, and stand development. *Annals of Forest Science*, 70(6), 589–599.
<https://doi.org/10.1007/s13595-013-0296-6>
- Ma, Y., Eziz, A., Halik, Ü., Abliz, A., & Kurban, A. (2023). Precipitation and Temperature Influence the Relationship between Stand Structural Characteristics and Aboveground Biomass of Forests—A Meta-Analysis. *En Forests* (Vol. 14, Número 5). MDPI. <https://doi.org/10.3390/f14050896>
- Malhi, Y., Wood, D., Baker, T. R., Wright, J., Phillips, O. L., Cochrane, T., Meir, P., Chave, J., Almeida, S., Arroyo, L., Higuchi, N., Killeen, T. J., Laurance, S. G., Laurance, W. F., Lewis, S. L., Monteagudo, A., Neill, D. A., Vargas, P. N., Pitman, N. C. A., ... Vinceti, B. (2006). The regional variation of aboveground live biomass in old-growth Amazonian forests. *Global Change Biology*, 12(7), 1107–1138. <https://doi.org/10.1111/j.1365-2486.2006.01120.x>
- Marchiori, N. M., da Silva, J. G., Dos Santos, F. C., Domingues, L. M., de Freitas, H. C., da Rocha, H. R., de Camargo, P. B., & Aidar, M. P. M. (2019). Effects of seasonal air temperatures and light on leaf traits at atlantic montane forest, Brazilian southeast. *Cerne*, 25(3), 263–272.
<https://doi.org/10.1590/01047760201925032625>
- Medina P., M. E., & Carrillo Silva, G. (s/f). *LA CUENCA AMAZONICA Y SU IMPORTANCIA ESTRATEGICA EN EL CASO DE LA AMAZONA VENZOLANA*.
- MIROC AGCM document writing team. (2021). *Description of MIROC6 AGCM*.
<https://doi.org/10.15083/0002000180>
- OCTA y CIIFEN. (2021). *Atlas de Vulnerabilidad Hidroclimática de la Región Amazónica*. Organización del Tratado de Cooperación Amazónica y Centro Internacional para la Investigación del Fenómeno de El Niño.
- Ordóñez B, J. A., & Masera, O. (2001). Captura de carbono ante el cambio climático. *Madera y Bosques*, 7(1), 3–12.
- 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>
- Panel Científico por la Amazonía. (2021). *Informe de evaluación de Amazonía 2021, Capítulo 5: El Sistema Físico Hidroclimático de la Amazonía* (C. Nobre, A. Encalada, E. Anderson, F. H. Roca Alcazar, M. Bustamante, C. Mena, M. Peña-Claros, G. Poveda, J. P. Rodriguez, S. Saleska, S. Trumbore, A. L. Val, L. Villa Nova, R. Abramovay, A. Alencar, A. C. Rodríguez Alzza, D. Armenteras, P.

- Artaxo, S. Athayde, ... G. Zapata-Ríos, Eds.).
<https://doi.org/10.55161/FAAQ6494>
- Paroshy, N. J., Doraisami, M., Kish, R., & Martin, A. R. (2021). Carbon concentration in the world's trees across climatic gradients. *New Phytologist*, 232(1), 123–133. <https://doi.org/10.1111/nph.17587>
- Pebesma, E., Bivard, R., Rowlingson, B., Gomez-Rubio, V., Hijmans, R., Sumner, M., MacQueen, D., Lemon, J., Lindgren, F., O'Brien, J., O'Rourke, J., & Hausmann, P. (2024). *Classes and Methods for Spatial Data*. <https://github.com/edzer/sp> /<https://edzer.github.io/sp/>
- Peng, D., Zhang, H., Liu, L., Huang, W., Huete, A. R., Zhang, X., Wang, F., Yu, L., Xie, Q., Wang, C., Luo, S., Li, C., & Zhang, B. (2019). Estimating the Aboveground Biomass for Planted Forests Based on Stand Age and Environmental Variables. *Remote Sensing*, 11(19), 18. <https://doi.org/10.3390/rs11192270>
- R Core Team. R: (2024). *A Language and Environment for Statistical Computing; R Foundation for Statistical Computing*.
- Romero Sánchez, M. E. (2016). *Escenarios de Cambio Climático en el sector forestal*. 7, 4. <http://www.ipcc.ch/pdf/>
- Rosenfield, M. F., & Souza, A. F. (2014). Forest biomass variation in Southernmost Brazil: the impact of Araucaria trees. En *Rev. Biol. Trop. (Int. J. Trop. Biol.) ISSN* (Vol. 62, Número 1).
- Saatchi, S., Houghton, R. A., Dos Santos Alvalá, R. C., Soares, J. V., & Yu, Y. (2007). Distribution of aboveground live biomass in the Amazon basin. *Global Change Biology*, 13(4), 816–837. <https://doi.org/10.1111/j.1365-2486.2007.01323.x>
- Salinas Ruiz, J., Montesinos López, O. A., Hernández Ramírez, G., & Crossa Hiriart, J. (2023). Chapter 2 Generalized Linear Models. En *Generalized Linear Mixed Models with Applications in Agriculture and Biology* (pp. 43–84). Springer International Publishing. https://doi.org/10.1007/978-3-031-32800-8_2
- Schmidt, G. A., Kelley, M., Nazarenko, L., Ruedy, R., Russell, G. L., Aleinov, I., Bauer, M., Bauer, S. E., Bhat, M. K., Bleck, R., Canuto, V., Chen, Y. H., Cheng, Y., Clune, T. L., Del Genio, A., De Fainchtein, R., Faluvegi, G., Hansen, J. E., Healy, R. J., ... Zhang, J. (2014). Configuration and assessment of the GISS ModelE2 contributions to the CMIP5 archive. *Journal of Advances in Modeling Earth Systems*, 6(1), 141–184. <https://doi.org/10.1002/2013MS000265>
- Scholze, M., Knorr, W., Arnell, N. W., & Prentice, I. C. (2006). *A climate-change risk analysis for world ecosystems*. <https://doi.org/10.1073/pnas.0601816103>
- Stegen, J. C., Swenson, N. G., Enquist, B. J., White, E. P., Phillips, O. L., Jørgensen, P. M., Weiser, M. D., Monteagudo Mendoza, A., & Núñez Vargas, P. (2011). Variation in above-ground forest biomass across broad climatic gradients.

- Global Ecology and Biogeography*, 20(5), 744–754.
<https://doi.org/10.1111/j.1466-8238.2010.00645.x>
- Ter Steege, H., Pitman, N. C. A., Sabatier, D., Baraloto, C., Salomão, R. P., Guevara, J. E., Phillips, O. L., Castilho, C. V., Magnusson, W. E., Molino, J. F., Monteagudo, A., Vargas, P. N., Montero, J. C., Feldpausch, T. R., Coronado, E. N. H., Killeen, T. J., Mostacedo, B., Vasquez, R., Assis, R. L., ... Silman, M. R. (2013). Hyperdominance in the Amazonian Tree Flora. *Science*, 342(6156), 10. <https://doi.org/10.1126/science.1243092>
- Trancoso, R., Carneiro Filho, A., Tomasella, J., Schietti, J., Rider Forsberg, B., & Pritchard Miller, R. (2010). Deforestation and conservation in major watersheds of the Brazilian Amazon. *Environmental Conservation*, 36(4), 277–288. <https://doi.org/10.1017/S0376892909990373>
- Tripathi, P., Behera, M. D., Behera, S. K., & Sahu, N. (2019). Investigating the contribution of climate variables to estimates of net primary productivity in a tropical deciduous forest in India. *Environmental Monitoring and Assessment*, 191, 15. <https://doi.org/10.1007/s10661-019-7684-9>
- UNESCO, WRI, & IUCN. (2023). *Bosques del Patrimonio Mundial: sumideros de carbono bajo presión*. <https://doi.org/10.58337/SSFY9797>
- Usoltsev, V. A., Merganičová, K., Konôpka, B., & Tseporedy, I. S. (2022). The principle of space-for-time substitution in predicting *Picea* spp. biomass change under climate shifts. *Central European Forestry Journal*, 68, 16. <https://doi.org/10.2478/forj-2022-0004>
- 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), 21. <https://doi.org/10.3390/f13122022>
- Yuan, J., Yan, Q., Wang, J., Xie, J., & Li, R. (2022). Different responses of growth and physiology to warming and reduced precipitation of two co-existing seedlings in a temperate secondary forest. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.946141>
- Zhou, R., Zhang, Y., Peng, M., Jin, Y., & Song, Q. (2022). Effects of Climate Change on the Carbon Sequestration Potential of Forest Vegetation in Yunnan Province, Southwest China. *Forests*, 13(2), 12. <https://doi.org/10.3390/f13020306>