



CONAHCYT
CONSEJO NACIONAL DE HUMANIDADES
CIENCIAS Y TECNOLOGÍAS



Centro de Investigación Científica de Yucatán
Posgrado en Ciencias Biológicas

Estimación de la biomasa aérea y su incremento en
bosques tropical secos usando datos de campo y de
LiDAR aéreo y terrestre

Tesis que presenta

JUAN ANDRÉS MAURICIO

En opción al título de

MAESTRO EN CIENCIAS

(Ciencias biológicas: **OPCIÓN RECURSOS NATURALES**)

Mérida Yucatán, México

2023

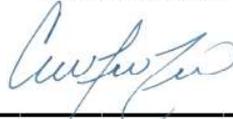
CENTRO DE INVESTIGACIÓN CIENTÍFICA DE YUCATÁN, A. C.
POSGRADO EN CIENCIAS BIOLÓGICAS



RECONOCIMIENTO

Por medio de la presente, hago constar que el trabajo de tesis de **Juan Andrés Mauricio** titulado “**Estimación de la biomasa aérea y su incremento en bosques tropical secos usando datos de campo y de LiDAR aéreo y terrestre**”, fue realizado en la Unidad de Recursos Naturales, en la línea de investigación cambio global en ecosistemas neo-tropicales, en el laboratorio de Sistemas de Información Geográfica y Percepción Remota del Centro de Investigación Científica de Yucatán, A.C. bajo la dirección del **Dr. José Luis Hernández Stefanoni** , dentro de la opción de Recursos Naturales, perteneciente al Programa de Posgrado en Ciencias Biológicas de este Centro.

Atentamente



Dra. Cecilia Hernández Zepeda
Directora de Docencia

Mérida, Yucatán, México, a 12 de septiembre de 2023

DECLARACIÓN DE PROPIEDAD

Declaro que la información contenida en las secciones de: Materiales y Métodos, Resultados y Discusión de este documento, proviene de las actividades de investigación realizadas durante el período que se me asignó para desarrollar mi trabajo de tesis, en las Unidades y Laboratorios del Centro de Investigación Científica de Yucatán, A.C., y que, a razón de lo anterior, y en contraprestación de los servicios educativos o de apoyo que me fueron brindados, dicha información, en términos de la Ley Federal del Derecho de Autor y la Ley Federal de Protección a la Propiedad Industrial, le pertenece patrimonialmente a dicho Centro de Investigación. Por otra parte, en virtud de lo ya manifestado, reconozco que de igual manera los productos intelectuales o desarrollos tecnológicos que deriven o pudieran derivar de lo correspondiente a dicha información, le pertenecen patrimonialmente al Centro de Investigación Científica de Yucatán, A.C., y se registrarán, en todo caso, por lo dispuesto por la Ley Federal del Derecho de Autor y la Ley Federal de Protección a la Propiedad Industrial, en el tenor de lo expuesto en la presente Declaración.

Firma: _____



Juan Andrés Mauricio

Este trabajo se llevó a cabo en la Unidad de **Recursos Naturales** del Centro de Investigación Científica de Yucatán, A.C., bajo la dirección del **Dr. José Luis Hernández Stefanoni**.

AGRADECIMIENTOS

Al consejo Nacional de Humanidades, Ciencia y Tecnología por la beca otorgada con el numero 791247

Al Centro de Investigación Científica de Yucatán (CICY) y especialmente a la Unidad de Recursos Naturales en donde fue posible realizar este trabajo.

Al Dr. José Luis Hernández Stefanoni por la confianza y el inmenso apoyo que me ha otorgado a lo largo de mi estancia en el CICY, tanto en lo académico como en lo personal. Gracias por invitarme a formar parte de sus proyectos y compartir su motivación por la investigación, pero también agradezco su amistad y de toda su familia.

Al Dr. Juan Manuel Dupuy, Dr. Geoffrey Parker por sus valiosas aportaciones en este trabajo. Gracias por toda su colaboración, por su paciencia y todos sus valiosos comentarios para que pudiera culminar este trabajo. Gracias por aportar mucho a mi formación profesional.

Un agradecimiento especial al Dr. Geoffrey Parker por compartir los datos recolectados por su equipo PCL, gracias a estos datos pudimos realizar este trabajo.

A los revisores de este trabajo; Dr. Rodrigo Duno, Dra. Helena Huechacona, agradezco mucho su tiempo para revisar y hacer de este un mejor trabajo.

A todo el equipo del Laboratorio de Sistemas de Información geográfica y Percepción Remota de la Unidad de Recursos Naturales del CICY. Gracias a Fernando Tun por prestar siempre su tiempo para resolver dudas y acompañar en toda mi estancia en este laboratorio, gracias a todos los compañeros que me han prestado su atención, compartido sus experiencias y su amistad en todo momento; Gabriela Reyes Palomeque, Stephanie G Chacon, Helena, Carla Ocaño, Víctor Alexis, Luis Hernández y Eric.

A los técnicos de Recursos Naturales; Fernando Tun, Francisco Chi y todos los que han ido a muestrear en campo, especialmente en Kaxil Kiuc de donde se obtuvieron los datos para realizar este trabajo.

A Karina Elizabeth, compañera durante toda esta etapa de mi vida, por motivarme a empezar en este reto y por seguir acompañándome en todo hasta este momento. Gracias a ti y a tu familia por recibirme, aceptarme y motivarme a seguir adelante.

A todos mis amigos quien han hecho más ameno mi estancia en CICY; a Roger, Pedro, Carla, Gaby, Steph, Clau, Lisandro, me siento orgulloso de haberlos conocido.

A mi familia; mi papa, a mi mama, a mi hermana Lupita, a mis hermanos Fredi, Migue y Gabriel por su confianza siempre. Estoy orgulloso de ser parte de esta gran familia.

DEDICATORIAS

Dedico este trabajo a todos los que han sido parte de mi camino hasta llegar aquí.

A mi mamá, a mi papá, a mi hermana, a mis hermanos y también a los más pequeños de la familia.

ÍNDICE

LISTADO DE TABLAS	III
LISTADO DE FIGURAS	IV
LISTADO DE ABREVIATURAS	VI
RESUMEN	VII
INTRODUCCION	1
CAPITULO I	3
1.1. ANTECEDENTES	3
1.1.1. Cambio climático.....	3
1.1.2. El papel de los bosques en el ciclo del carbono.....	5
1.1.3. Bosques tropicales secos	6
1.1.4. Sucesión secundaria.....	8
1.1.5. Biomasa aérea.....	10
1.1.6. Incremento de la biomasa aérea.....	12
1.1.7. Percepción remota.....	12
1.1.8. LiDAR	13
1.2. PLANTEAMIENTO DEL PROBLEMA	16
1.3. OBJETIVOS	17
1.3.1. Objetivo general.....	17
1.3.2. Objetivos específicos	17
1.4. PREGUNTAS DE INVESTIGACIÓN	18
1.5. HIPÓTESIS	18
CAPITULO II	19
2.1. MATERIALES Y MÉTODOS	19
2.1.1. Área de estudio.....	19
2.1.2. Muestreo en campo	20
2.1.3. Cálculo de la biomasa aérea.....	21
2.1.4. Datos LiDAR.....	22
2.1.5. Análisis de los datos LiDAR	23
2.1.6. Evaluación de la superficie de muestreo de datos LiDAR aéreo	24
2.1.7. Análisis de datos.....	25

2.1.8.	Modelos para la estimación de la biomasa aérea.....	27
2.1.9.	Modelos para la estimación del incremento de la biomasa aérea	28
CAPITULO III.....		30
3.1. RESULTADOS.....		30
3.1.1.	Cuantificación de la biomasa aérea y su incremento en el año 2013 al 2021.....	30
3.1.2.	Estimación de la biomasa aérea usando LiDAR aéreo	32
3.1.3.	Validación de los modelos para estimar la biomasa aérea mediante datos de LiDAR aéreo.....	34
3.1.4.	Estimación biomasa aérea usando métricas de LiDAR terrestre.....	35
3.1.5.	Validación de los modelos para estimar la biomasa aérea mediante datos de LiDAR terrestre	36
3.1.6.	Estimación del incremento de la biomasa aérea usando métricas de datos LiDAR (2013 – 2021).....	37
3.1.7.	Método indirecto para la estimación del incremento de la biomasa aérea.....	37
3.1.8.	Métodos directos para la estimación del incremento de la biomasa aérea.....	39
3.1.9.	Validación de los modelos para estimar el incremento de la biomasa aérea mediante método directos	40
CAPITULO IV		43
4.1. DISCUSIÓN		43
4.1.1.	Biomasa aérea y su incremento del año 2013 a 2021.....	43
4.1.2.	Modelos para la estimación de la biomasa aérea con datos LiDAR	44
4.1.3.	Modelos para estimar el incremento de la biomasa aérea con datos LiDAR.....	47
CAPITULO V		51
5.1. CONCLUSIONES.....		51
5.2. PERSPECTIVAS.....		53
ANEXOS.....		66

LISTADO DE TABLAS

Tabla 2.1. Ecuaciones alométricas utilizadas para la estimación de la biomasa aérea con datos de campo.....	22
Tabla 2.2. Descripción de las métricas de los datos LiDAR aéreo y terrestre.....	24
Tabla 3.1. Biomasa aérea estimada con datos de campo y edad de los conglomerados en Kaxil Kiuic, estado de Yucatán, México.....	30
Tabla 3.2. Resumen del modelo lineal para la estimación de la biomasa aérea a nivel de conglomerado en 2013 usando datos de LiDAR aéreo en Kaxil Kiuic, estado de Yucatán, México.....	34
Tabla 3.3. Resumen del modelo obtenido para la estimación de la biomasa aérea a nivel de conglomerado usando datos LiDAR terrestre en el año 2021 en Kaxil Kiuic, estado de Yucatán, México.....	36
Tabla 3.4. Resumen de los modelos obtenidos para la estimación del incremento de la biomasa aérea a nivel de conglomerado usando métricas LiDAR en Kaxil Kiuic, estado de Yucatán, México.....	40
Tabla 1a. Lista de valores de la densidad de la madera por especies.....	66

LISTADO DE FIGURAS

- Figura 1.1. Comparación de los datos LiDAR obtenidos mediante una plataforma aérea (ALS) y terrestre (PCL). Los histogramas representan la densidad de puntos a lo largo de las diferentes alturas del dosel (LaRue et al., 2020).....14
- Figura 2.1. Localización geográfica del área de estudio. Los puntos azules representan los conglomerados usados para obtener datos de campo. En el polígono con contorno rojo, se representa el área que abarca la Reserva Biocultural Kaxil Kiuic, estado de Yucatán, México.20
- Figura 2.2. Diseño de los conglomerados usados para la obtención de datos en campo.....21
- Figura 2.3. Tipos de extracción de datos LiDAR aéreo 2013. a) En una superficie de 0.16 que abarca las parcelas de campo dentro del conglomerado. b) En una superficie de 0.02 ha en forma de transectos de 1 m de ancho.25
- Figura 3.1. Biomasa aérea (ton/ha) por edad de cada conglomerado (años) en el año 2013 (triángulos negros) y su línea de tendencia estimada (línea negra). Los triángulos azules representan la biomasa aérea en el 2021 y su línea de tendencia estimada por la línea azul. Las líneas punteadas representan la trayectoria real de los cambios de biomasa aérea en cada conglomerado de Kaxil Kiuic, estado de Yucatán, México.....31
- Figura 3.2. Relación entre el incremento de la biomasa aérea (del 2013 hasta 2021) y la edad de los conglomerados mediante datos de campo en Kaxil Kiuic, estado de Yucatán, México. a) Tasa del incremento de la biomasa aérea por año. b) Incremento relativo de la biomasa aérea respecto a la biomasa inicial el tiempo 1 (2013). Dónde: y es Porcentaje del incremento de la biomasa, x es la edad en años.32
- Figura 3.3. Comparación de métricas de LiDAR aéreo obtenidas en transectos de 1 m de ancho por 200 m de longitud aproximadamente (0.02 ha) y en una superficie igual a las parcelas del conglomerado (0.16 ha) en Kaxil Kiuic, estado de Yucatán, México.....33
- Figura 3.4. Resultados de la validación cruzada para evaluar la precisión de la estimación de la biomasa aérea a nivel de conglomerado usando datos de LiDAR aéreo. a) Modelo con intercepto igual a 0. b) Modelo con intercepto estimado. Los puntos representan la biomasa estimada en función de la biomasa observada, la línea roja representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una relación 1 a 1 en Kaxil Kiuic, estado de Yucatán, México...35
- Figura 3.5. Resultados de la validación cruzada para evaluar la precisión de la estimación de la biomasa aérea a nivel de conglomerado usando datos de LiDAR terrestre. a) Modelo con intercepto igual a 0. b) Modelo con intercepto estimado. Los puntos representan la biomasa estimada en función de la biomasa observada, la línea roja representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una relación 1 a 1 en Kaxil Kiuic, estado de Yucatán, México.37
- Figura 3.6. Resultados de la estimación de la biomasa aérea a nivel de conglomerado, usando estimaciones de cada año por separado (2013 y 2021) en Kaxil Kiuic, estado de Yucatán, México. a)

Validación de los modelos con intercepto igual a 0. b) Validación de los modelos con intercepto estimado. Los puntos representan la biomasa estimada en función de la biomasa observada, la línea roja representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una regresión 1 a 1.....39

Figura 3.7. Resultados de la validación cruzada para evaluar la precisión de la estimación del incremento de la biomasa aérea a nivel de conglomerado usando métricas de datos LiDAR aéreo y terrestre (2013 y 2021) en Kaxil Kiuic, estado de Yucatán, México. a) Modelo con intercepto a 0. b) Modelo con intercepto estimado. Los puntos representan la biomasa aérea estimada en función de la biomasa aérea observada, la línea azul representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una regresión 1 a 1.41

Figura 3.8. Resultados de la validación cruzada para evaluar la precisión de la estimación del incremento de la biomasa aérea a nivel de conglomerado usando diferencias de métricas de datos LiDAR aéreo y terrestre (2013 y 2021) en Kaxil Kiuic, estado de Yucatán, México. a) Modelo con intercepto igual a 0. b) Modelo con intercepto estimado. Los puntos representan la biomasa aérea estimada en función de la biomasa aérea observada, la línea azul representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una regresión 1 a 1.....42

LISTADO DE ABREVIATURAS

CO ₂	Dióxido de carbono
Gt	Gigatoneladas
C	Carbono
Ppm	Partes por millón
ppb	Partes por billón
LiDAR	Light Detection and Ranging
CAI	Canopy Area Index
Hmax	Altura máxima
Hbar	Altura media
sd	Desviación estándar
RMSE	Root Mean Square Error
IPCC	Intergovernmental Panel on Climate Change
FAO	Food and Agriculture Organisation
R ²	Coefficiente de determinación R cuadrada
AGB	Aboveground Biomass
PCL	Portable Canopy LiDAR
ton	Toneladas
ha	Hectáreas
GPS	Global Positioning System
GEI	Gases de Efecto Invernadero

*Es importante destacar que las abreviaturas utilizadas en este estudio, aunque se presentan en inglés, son ampliamente reconocidas internacionalmente en la comunidad científica.

RESUMEN

Las estimaciones de los almacenes de carbono a nivel regional y global son sumamente importantes para la implementación de medidas de mitigación del cambio climático. Los bosques tropicales son grandes reservorios de carbono y albergan una gran diversidad de especies, esto los posiciona en un lugar central en este contexto. Sin embargo, estos bosques también están propensos a grandes fenómenos de disturbios naturales o antropogénicos, los cuales aceleran la liberación de carbono a la atmósfera y reducen su capacidad de captura y almacenamiento. Dada a la dinámica constante en la estructura y composición de los bosques tropicales, las variaciones en su biomasa no solo son indicadores de su resiliencia, sino también de la eficiencia en las estrategias para contrarrestar el cambio climático. Las cuantificaciones de los reservorios de biomasa aérea y las tasas de incremento son una tarea importante para la definición de áreas prioritarias para la conservación o la recuperación de los almacenes de carbono. Sin embargo, la cuantificación precisa de la biomasa aérea es una tarea difícil de realizar, para ello, las herramientas de percepción remota y sistemas de información geográfica enriquecen las estimaciones de los atributos de los bosques a niveles locales e incluso a niveles globales.

Este trabajo se realizó en un bosque tropical seco de la Península de Yucatán, localizada en el extremo sureste de México, esta región es considerada como una región geográfica importante para los bosques tropicales. Se realizó la estimación de la biomasa aérea y su incremento durante un periodo de 8 años (2013 – 2021) e integró datos de campo con datos de sensores LiDAR usando dos mediciones (una por cada año). Los datos LiDAR se obtuvieron de una plataforma aérea y una terrestre, lo que permite realizar la comparación de la precisión de las estimaciones en la biomasa para cada plataforma. También se diseñaron conjuntos de datos LiDAR, de ambas plataformas, para obtener un modelo de la estimación de la tasa de incremento de la biomasa dentro del bosque tropical seco.

Se encontró que LiDAR, en ambas plataformas, tiene una alta capacidad de capturar la estructura de la vegetación del bosque tropical seco, por lo tanto, la precisión de las estimaciones cumple las expectativas esperadas en este estudio con valores de R^2 de al menos 0.89 de los modelos con los mejores ajustes. Por otro lado, la validación de los modelos obtenidos para la estimación de la biomasa aérea abarca errores desde 24 % hasta el 29 %. En cuanto a los modelos para la estimación de los incrementos de la biomasa aérea, se obtuvieron precisiones de hasta 0.92 en la R^2 , mientras que en la validación de estos modelos se obtuvieron errores menores al 27%

cuando se usan las diferencias de las métricas como variables explicativas en los modelos. Los resultados de este estudio demuestran la factibilidad y la importancia de la integración de datos de campo y datos de percepción remota, como los del sensor LiDAR en la estimación de la biomasa aérea y sus incrementos en los bosques tropicales secos.

INTRODUCCION

Los bosques tropicales albergan una gran proporción de la biodiversidad terrestre, cuentan con aproximadamente el 10% de la superficie terrestre y representa el 50% de la biodiversidad a nivel mundial (Locatelli et al., 2009; Murphy & Lugo, 1986). Dentro de este tipo de ecosistemas se encuentran los bosques tropicales secos que representan aproximadamente el 42% de todos los bosques tropicales en el mundo (Miles et al., 2006; Quesada et al., 2009). Sin embargo, es uno de los tipos de vegetación más amenazados actualmente, ya que han sido preferidos como zonas de establecimientos humanas, por lo tanto permanecen expuestos a varias amenazas derivadas de las actividades humanas (Murphy & Lugo, 1986; Quesada et al., 2009).

Los bosques tropicales secos además de proveer productos y servicios a las poblaciones humanas también almacenan grandes cantidades de carbono (Houghton et al., 2015). Se estima que entre todos los tipos bosques tropicales almacenan el 25% del carbono terrestre (Bonan, 2008). Además de contribuir en la mitigación del cambio climático, también proveen otros numerosos servicios ecosistémicos, como la protección de suelos, y hábitat para la biodiversidad (Balvanera, 2012; Bonan, 2008). En particular, los bosques tropicales secos contienen más del 18% de carbono almacenado de todos los bosques tropicales (Keith et al., 2009).

Debido a las constantes perturbaciones y su impacto en la biodiversidad en estos bosques, varios investigadores han realizado estudios para estimar la distribución espacial de la biomasa aérea y el almacenamiento de carbono (Cartus et al., 2014; Hernández-Stefanoni et al., 2020, 2021; Urbazaev et al., 2018), existe la preocupación

Que por el ritmo de la degradación de los bosques primarios en diferentes partes del mundo, dirija a los bosques tropicales secundarios como los bosques del futuro, (Quesada et al., 2009). Ante ello, es importante hacer cuantificaciones, con la mayor precisión posible, del carbono contenido en la biomasa en los bosques tropicales. Actualmente, también sigue habiendo una incertidumbre considerable sobre la tasa de recuperación de la biomasa después del abandono de usos agrícolas o ganaderos a través de la sucesión secundaria (Poorter et al., 2016). Durante la sucesión secundaria, los bosques pasan por diferentes etapas de desarrollo y la biomasa es un indicador importante en estas etapas. Comprender la sucesión de los bosques tropicales es fundamental para el desarrollo de estrategias de conservación, restauración y aprovechamiento en los bosques tropicales secos del mundo.

INTRODUCCIÓN

Los estudios enfocados en la estimación de la biomasa aérea a escalas regionales y globales han usado datos de percepción remota de diferentes tipos, tanto de sensores pasivos como activos por separado o bien en conjunto (Cartus et al., 2014; Hernández-Stefanoni et al., 2021; Hernández-Stefanoni & Dupuy, 2007; Reyes-Palomeque et al., 2019; Rodríguez-Veiga et al., 2019). La biomasa generalmente está influenciada por los atributos estructurales de la vegetación, como la altura y el diámetro de los árboles, por lo que la variación de estos atributos influye en las variaciones de la biomasa aérea (Poorter et al., 2015).

Con la información obtenida de los sensores remotos es posible detectar con mucha precisión diferentes atributos de la vegetación en los bosques tropicales, como el diámetro y altura promedio de los árboles, el área basal, la densidad de biomasa, la diversidad de especies, entre otros (Almeida et al., 2019; Andres-Mauricio et al., 2021; Reyes-Palomeque et al., 2019). Uno de los sensores de mayor éxito es LiDAR (Light Detection and Ranging), este es un sensor activo, que ha enriquecido la estimación de la biomasa aérea y ha ampliado el rango de propiedades estructurales detectables de la vegetación obteniendo una mayor precisión en la estimación de la estructura de la vegetación debido a que los rayos láser penetran hacia la superficie (Rodríguez-Veiga et al., 2019; Wang & Gamon, 2019). Si bien muchos estudios se enfocan en realizar estimaciones en un tiempo específico, también es necesario desarrollar estudios enfocados a determinar los cambios de la biomasa aérea a través del tiempo (Puliti et al., 2021). Es decir, no solamente se requiere conocer la cantidad de carbono almacenado en la biomasa forestal, si no también cuantificar los cambios en la biomasa para poder estimar el crecimiento de los bosques y la cantidad de carbono atmosférico que capturan.

Debido a la importancia que representan los bosques en cuanto al almacenamiento del carbono, así como en la mitigación de los efectos de cambio climático, los estudios para las estimaciones de la biomasa aérea y los cambios de la biomasa aérea a través del tiempo son importantes para la gestión y el manejo sostenible de los bosques y poder garantizar que los bosques sigan siendo grandes sumideros de carbono y proporcionando múltiples beneficios al medio ambiente y a la humanidad. Por lo que, en este estudio se tiene como objetivo principal estimar la biomasa aérea forestal, así como su incremento en un periodo de tiempo de 2013 a 2021. Se usaron datos de campo y percepción remota obtenidos mediante un sensor LiDAR. Se comparó la precisión de las estimaciones de la biomasa aérea en el periodo de estudio y el incremento por año mediante dos plataformas LiDAR, una aérea (adquirida en 2013) y otra terrestre (adquirida en 2021), en un bosque tropical seco de la Península de Yucatán, México.

CAPITULO I

1.1. ANTECEDENTES

1.1.1. Cambio climático

Uno de los desafíos inevitables que enfrenta la humanidad es el cambio climático, existe evidencia de los incrementos sustanciales de la temperatura de la Tierra tanto en la atmosfera como en los océanos. A medida que la temperatura aumenta, los efectos del cambio climático se vuelven más evidentes, desde fenómenos meteorológicos extremos hasta impactos en los ecosistemas como la reducción de glaciares (IPCC, 2018b, 2023b).

De acuerdo con el Panel Intergubernamental sobre el Cambio Climático (IPCC) (2023), el cambio climático se refiere a un cambio en el estado del clima identificado con fundamentos estadísticos como la variación media de las propiedades climáticas, y su persistencia durante periodos largos de tiempo. Estas variaciones pueden atribuirse a procesos naturales o a fenómenos antropogénicos persistentes en la Tierra. La Convención Marco de las Naciones Unidas sobre el Cambio Climático (CMNUCC) atribuye el cambio a la actividad humana directa e indirectamente. El cambio climático ha causado cambios importantes en los ecosistemas terrestres y acuáticos, mayormente involucra la pérdida de especies por mortalidad masiva impulsada por aumentos en las temperaturas extremas. Algunos eventos son irreversibles como los retrocesos de los glaciares o el deshielo del permafrost en los ecosistemas árticos (IPCC, 2023a).

El calentamiento global es un aspecto clave del cambio climático, se estima que la temperatura global ha aumentado aproximadamente 1.1 °C desde la era preindustrial (1850 - 1900) hasta los promedios registrados en el año 2011 a 2022 (IPCC, 2023a). El aumento de la temperatura tiene implicaciones significativas para el clima y los sistemas naturales de todo el mundo. Las actividades humanas, principalmente a través de las emisiones de Gases de Efecto Invernadero (GEI), han provocado el aumento de la temperatura media de la superficie de la Tierra. Estos gases son sustancias que atrapan radiación en la atmosfera provocando el efecto invernadero. Entre los principales GEI está el vapor de agua (H₂O), el ozono (O₃), el óxido nitroso (N₂O), el dióxido de carbono (CO₂) y el metano (CH₄) (IPCC, 2018b), los últimos son los más importantes a niveles globales emitidos por el ser humano (EPA, 2023). El papel del carbono es esencial para comprender el cambio climático, según la organización de las Naciones Unidas para la

CAPÍTULO I

Alimentación y la Agricultura (FAO), el carbono es un elemento clave en la regulación del clima y la temperatura de la Tierra.

Las emisiones globales de GEI han aumentado considerablemente derivadas del uso de energías no renovables, el cambio de uso de la tierra y patrones de consumo y producción en todo el mundo, pero principalmente por la quema de combustibles fósiles (IPCC, 2023b). A partir de la revolución industrial en el 1850 las emisiones netas acumuladas hasta el 2019 de CO₂ fueron aproximadamente 2400 GtCO₂ (giga toneladas de dióxido de carbono). Se estima que solamente durante el 2019 fueron 59 GtCO₂ por emisiones antropogénicas, esto representa un aumento de 12 % en comparación con el año 2010. En general, para este año se alcanzaron concentraciones atmosféricas de CO₂ de 410 ppm (partes por millón), 1866 ppb (partes por billón) para CH₄ y para el N₂O hasta 332 ppm, estas concentraciones representan un aumento del 23 %, 156 %, y 23 % respectivamente desde el año 1750 (IPCC, 2023a).

En el periodo 2010 al 2019, las emisiones medias anuales fueron las más altas que cualquier década anterior, presentaron una tasa de crecimiento de 1.3% por año, aunque la tasa de incremento fue mayor entre 2000 a 2009 con 2.1% por año. Estos crecimientos de las emisiones son mayormente procedentes de los combustibles fósiles y de las industrias (IPCC, 2023a).

En 2021, las emisiones fósiles de CO₂ fueron de 36.3 GtCO₂ y las emisiones antropogénicas de 40.2 GtCO₂ al año, se alcanzó una concentración atmosférica de CO₂ de 414.71 ppm aproximadamente. En este año, también se alcanzó una acumulación de CO₂, a partir del año 1850, de 2,455 GtCO₂ derivado de emisiones antropogénicas, el 33 % de esta acumulación, corresponde a partir del año 2000 hasta el 2021. Con estas cifras es evidente que las emisiones han alcanzado crecimientos más grandes en los últimos 60 años, desde 1850 a 2021, el 30 % de las emisiones son derivadas del cambio de uso de suelo y el 70 % de la quema de combustibles fósiles (Friedlingstein et al., 2022).

Con las tasas de emisiones de GEI, existe una probabilidad que el calentamiento global presente una variación de 1.5 °C entre 2030 y 2052, los riesgos relacionados con el clima serían mayores a ese aumento de la temperatura. Estos riesgos también dependerán de la magnitud y el ritmo del calentamiento, la ubicación geográfica, así como de las opciones de adaptación y mitigación que se elijan y de su implementación (IPCC, 2018a).

Los ecosistemas terrestres y oceánicos han absorbido una proporción casi constante (a nivel mundial, alrededor del 56 % por año) de las emisiones de CO₂ por las actividades humanas durante las últimas seis décadas (IPCC, 2023a).

1.1.2. El papel de los bosques en el ciclo del carbono

Los ecosistemas terrestres son importantes en la mitigación del aumento de las concentraciones atmosféricas de CO₂. Un ecosistema actúa como sumidero de carbono cuando es capaz de absorber más rápidamente el CO₂ por medio de la fotosíntesis que la emite por medio de la respiración tanto de organismos autótrofos y heterótrofos. En cambio, cuando la captura de carbono es superada por la respiración, el ecosistema se convierte en fuente de carbono (Begon et al., 2006). Las tasas de captura de los ecosistemas terrestres ascendieron a 3.1 Gt de carbono por año durante el periodo de 2011 a 2020, lo cual representa el 29% del total de las emisiones de CO₂ (Friedlingstein et al., 2022). Acciones como la conservación, la gestión sustentable y la restauración de los bosques y otros ecosistemas representan las mejores opciones basadas en la naturaleza para la mitigación de cambio climático y los efectos del calentamiento global (IPCC, 2023b).

En especial, los bosques desempeñan un papel importante ante el cambio climático, ya que estos actúan como grandes sumideros de carbono, capturando y almacenando CO₂ de la atmósfera mediante la fotosíntesis, aunque existen aún grandes incertidumbres sobre las cantidades netas de captura, debido a la alta variabilidad en composición y estructura que hay en estos ecosistemas. Los bosques almacenan el carbono en la biomasa de los árboles y estos almacenes aumentan conforme crecen o emergen nuevos individuos. Sin embargo, los bosques al ser un importante reservorio de carbono, cualquier tipo de degradación antropogénica de los bosques da lugar a la liberación del carbono y por lo tanto a la contribución total de las emisiones a la atmósfera (EPA, 2023; IPCC, 2023a). El carbono también está involucrado en otros procesos biogeoquímicos de los bosques como la respiración, descomposición y perturbaciones por incendios o plagas. (EPA, 2023). Esto se debe a que el intercambio de energía y materia en los ecosistemas ocurre a través de compuestos orgánicos y energía almacenada en moléculas de carbono (Reichle, 2020).

La liberación de carbono almacenada en los bosques involucra procesos biológicos como la respiración y descomposición, sin embargo, por perturbaciones antropogénicas se acelera la

liberación de carbono, algunos de estas involucran la extracción de materia orgánica como la madera. En este contexto, la liberación del carbono a la atmosfera no es inmediato, ya que suele estar almacenado en los productos derivados durante un periodo de tiempo hasta llegar a un proceso de descomposición o combustión. Por el contrario, cuando la materia orgánica es involucrada directamente con la combustión, por incendios o por uso de materia orgánica como combustible, el carbono se incorpora directamente en la atmosfera (EPA, 2023).

1.1.3. Bosques tropicales secos

Los bosques tropicales secos (BTS) se encuentran en regiones tropicales y están caracterizados por una marcada estacionalidad de lluvias, con un periodo de sequías de 4 a 6 meses (Mooney et al., 1995; Murphy & Lugo, 1995). Estos bosques generalmente presentan una mayor evapotranspiración que precipitación. Se presentan temperaturas medias anuales cercanas a 25°C y el rango de las precipitaciones van desde 250 a 2000 mm anuales (Murphy & Lugo, 1986), durante los meses secos raramente supera los 10 mm mensuales, esto crea condiciones tan secas que los árboles tiran sus hojas para reducir la pérdida de humedad (Espinosa, 2006; Maass & Burgos, 2011). En estos bosques el porcentaje de árboles deciduos puede variar entre el 50 al 100% a lo largo del gradiente de precipitación y los tipos de bosques tropicales secos presentes (Griscom & Ashton, 2011).

Dentro de estos ecosistemas es resaltable también una gran diversidad y un alto valor de especies endémicas (Ceballos & Garcia, 1995). Además, estos bosques presentan típicamente uno o dos estratos y una menor diversidad de especies que los bosques tropicales húmedos, por lo que son considerados de menor complejidad estructural que otros bosques tropicales (Murphy & Lugo, 1995).

Debido a la relativa simplicidad estructural, los bosques tropicales secos son preferidos para las actividades humanas: Por ello, actualmente se encuentran amenazados por una alta deforestación derivado de actividades como el desarrollo de turismo, ganadería y agricultura (Ceballos & Garcia, 1995) y se consideran los bosques más amenazados de todos los tipos de bosques a nivel mundial (Miles et al., 2006). Los procesos antrópicos generan la disminución de grandes extensiones de los bosques, lo que repercute en la disminución de la biomasa contenida, en la liberación del carbono almacenado a la atmosfera, en la pérdida de biodiversidad y en la

degradación de los ecosistemas donde las poblaciones humanas se benefician de los productos y servicios que estos proveen (Pimentel et al., 1997).

Los bosques tropicales secos representan el mayor porcentaje de los bosques tropicales, los otros tipos se distribuyen en 33% para bosques húmedos y 25% para bosques lluviosos (Murphy & Lugo, 1995). En el neotrópico los bosques tropicales secos presentan altos grados de fragmentación, la extensión más grande se encuentra en México con el 38% de todo el continente, seguidos de países como Bolivia (25%), Brasil (17%), Colombia (6.5%) y Venezuela (6.2%) (Portillo-Quintero & Sánchez-Azofeifa, 2010). En México, una gran parte de estos bosques se encuentran en la Península de Yucatán (Duran & Méndez, 2010; Portillo-Quintero & Sánchez-Azofeifa, 2010), integrada por los estados de Campeche, Quintana Roo y Yucatán. Los bosques tropicales con mayor extensión en la Península de Yucatán son: el bosque tropical caducifolio, el bosque tropical subcaducifolio y el bosque tropical subperennifolio (Duran & Méndez, 2010). Estos bosques están distribuidos a lo largo de un marcado gradiente de humedad y estacionalidad pluvial (Toledo et al., 2008).

Actualmente, los bosques tropicales secos de la Península de Yucatán presentan parches de diferentes usos de suelo, como ganadería, agricultura y asentamientos humano (viviendas e industrias). Entre las actividades antropogénicas más frecuente en estos bosques, se encuentra el establecimiento de milpas con prácticas de roza-tumba-quema, esta actividad involucra un descanso temporal de la tierra, sin embargo la reducción de estos tiempos de descanso compromete la fertilidad del suelo (Lara Ponce et al., 2012). Otras actividades que se realizan son la apicultura y meliponicultura y la extracción de una gran diversidad de recursos forestales (Toledo et al., 2008). Estos bosques han representado una fuente primordial para la subsistencia de los habitantes de esta región desde hace miles de años (Lara Ponce et al., 2012).

1.1.3.1. Bosque tropical subcaducifolio

Este tipo de bosque, también conocido como selva mediana subcaducifolia (Rzedowski, 2006), presenta temperaturas medias entre 25 a 26 °C y precipitación media anual de 1078 y 1220 mm (Flores-Guido et al., 2010). En la península de Yucatán se presentan en suelos rocosos derivados de piedras calizas con una delgada capa de materia orgánica. El estrato arbóreo se caracteriza por presentar alturas entre 10 a 18 m. Además, estos bosques tienen una marcada estacionalidad entre meses secos y lluviosos, en los meses más secos, el 50 hasta el 75% de los árboles pierden sus hojas casi en su totalidad (Flores-Guido et al., 2010; Gómez-Pompa,

1965). Las especies más comunes de árboles son *Vachellia pennatula* (Schltdl. & Cham.) Seigler & Ebinger, , *Bursera simaruba* (L.) Sarg., *Cochlospermum vitifolium* (Willd.) Spreng., *Caesalpinia gaumeri* Greenm., *Gymnopodium floribundum* Rolfe entre otras (Flores-Guido et al., 2010). Su distribución se restringe en las vertientes del Pacífico y del Atlántico, con manchones desde el centro de Sinaloa hasta las costas de Chiapas, del otro lado, hay presencias aisladas en Veracruz y Tamaulipas, pero su mayor extensión se presenta en la Península de Yucatán (Miranda & Hernández-X., 2016).

Las actividades que se realizan en estos bosques son principalmente de tipo agrícola y ganadero. Estas diversas actividades dan como resultado la reducción de la cubierta vegetal original de los bosques tropicales secos, su distribución actual representa solamente una fracción de su cobertura original (Lebrija-Trejos et al., 2008). Después del abandono del terreno, en muchas áreas, se permite el desarrollo de fragmentos heterogéneos de vegetación secundaria, estos fragmentos de vegetación difieren en las edades de abandono (Dupuy et al., 2012) y en su distribución espacial a lo largo de los bosques.

1.1.4. Sucesión secundaria

La sucesión secundaria es el proceso de cambios en una comunidad en un nuevo hábitat o también tras un disturbio que remueve la vegetación, este proceso involucra el remplazo gradual de especies (Chazdon, 2014). La gran mayoría de los bosques tropicales, están bajo una intensa alteración producida por diferentes actividades humanas como el sobrepastoreo por ganado. Esto promueve que se pierda rápidamente su estructura y composición florística causando fragmentación y degradación de los bosques (Quesada et al., 2009; Trejo & Dirzo, 2000), posteriormente se convierten en asociaciones secundarias, que limitan la regeneración del bosque original (Trejo & Dirzo, 2000). Las tasas actuales de cambios de usos de suelo y el abandono después de las perturbaciones de los bosques tropicales dejan un paisaje complejo que consiste en una matriz de campos agrícolas, ganaderos y fragmentos de bosques bajo diferentes edades sucesionales (Quesada et al., 2009).

Una de las consecuencias más preocupantes de la degradación de los bosques tropicales, además de la pérdida de biodiversidad, son los reservorios de carbono que se ven afectados por estos procesos antrópicos (Poorter et al., 2016). En un estudio con un amplio conjunto de datos se evaluó la resiliencia de los bosques tropicales secundarios, donde se recuperan en promedio

el 78% de los atributos forestales de los bosques primarios en aproximadamente 20 años. Sin embargo, la recuperación de la acumulación de la biomasa suele ser muy lenta y tardar más de 120 años para recuperar el 90% de su estado original (Poorter et al., 2021). Estos datos deben ser foco de interés y de alerta ante la degradación de los bosques, para hacer énfasis en las medidas de conservación, protección y restauración de estos bosques.

Gran parte de la degradación de los bosques tropicales secos son causados mayormente por la deforestación, la deforestación propicia la pérdida de la biodiversidad, cambios en la estructura y composición, alteración de ciclos biogeoquímicos, interrupción de las interacciones dentro estos bosques y la degradación del suelo. Como resultado de estos disturbios, el potencial de estos bosques como sumideros de carbono se ve severamente reducido (Siyum, 2020).

Los bosques ya no cumplen eficazmente su función de capturar carbono de la atmósfera debido a la pérdida de la cobertura vegetal. Incluso algunos estudios mencionan que los bosques se están convirtiendo en fuentes de carbono a la atmósfera, emitiendo dióxido de carbono tanto por factores naturales como la respiración autótrofa y heterótrofa y por causas antropogénicas como la deforestación y el cambio de uso de suelo, así como la extracción de recursos (Siyum, 2020).

Los patrones de la estructura de la comunidad se relacionan fuertemente con la edad sucesional, aunque la forma y la fuerza de las relaciones pueden diferir entre los atributos de la vegetación (Dupuy et al., 2012). Las tasas de recuperación de algunos atributos de la vegetación difieren entre las edades sucesionales, por ejemplo, la cobertura del dosel ha llegado a alcanzar el 75% de los valores de un bosque maduro en ocho años y el área basal ha tardado hasta 23 años en alcanzar ese mismo nivel (Quesada et al., 2009).

Comprender el desarrollo de la vegetación secundaria es fundamental para lograr los objetivos de las políticas y medidas para la conservación, restauración y aprovechamiento de los bosques secundarios (Lebrija-Trejos et al., 2008), así como reforzar las medidas para la mitigación del cambio climático. Además, conocer las tasas de recuperación de algunos atributos de la vegetación, como la biomasa aérea, ayudan a identificar áreas que requieran una mayor atención en la implementación de las medidas de mitigación a corto o largo plazo.

1.1.5. Biomasa aérea

La biomasa vegetal es una de las propiedades clave de los ecosistemas, se refiere a la cantidad de materia orgánica viva o muerta de las plantas. La cuantificación de la biomasa, expresada en kilogramos o toneladas por hectárea (kg/ha o ton/ha), ayuda a comprender un atributo de los ecosistemas sobre la capacidad de almacenaje de carbono atmosférico (Keeling y Phillips, 2007). La biomasa aérea incluye componentes de árboles como tallos, ramas hojas y estructuras reproductivas, así como partes aéreas de otras formas de vida como palmas, lianas y arbustos (Álvarez *et al.*, 1992).

Además, las tasas de generación de materia orgánica durante un periodo de tiempo determinado, forma parte de la productividad de un ecosistema (Molles, 2006). Esta productividad se divide en dos componentes: la productividad primaria bruta y la productividad primaria neta (Holmes & Likens, 2016). La primera se refiere a la cantidad de materia orgánica sintetizada por las plantas por unidad de superficie en un tiempo definido, sin considerar la cantidad que se utiliza para la respiración. Mientras que, la productividad neta se refiere a la cantidad de la materia orgánica disponible, después de que las plantas han utilizado parte de la energía para mantener sus propios procesos metabólicos como la respiración. Este componente constituye la energía disponible de los ecosistemas (Molles & Laursen, 2020).

La producción en un ecosistema a través de la fotosíntesis de las plantas, productores primarios o autótrofos conforma la producción primaria de los ecosistemas, contrariamente a la producción secundaria que es dada por organismos consumidores (heterótrofos) (Molles & Laursen, 2020). Los bosques son importantes en términos de producción de energía y materia ya que albergan especies vegetales encargadas de la producción primaria. Además, también son importantes para la mitigación del cambio climático porque actúan como grandes sumideros de carbono y ayudan a regular la temperatura global. En términos de productividad ecosistémica, un ecosistema funciona como sumidero de carbono cuando el balance entre la producción neta en el ecosistema es mayor que la salida de carbono dada por la respiración de los organismos tanto autótrofos como heterótrofos (Begon *et al.*, 2006).

Existen diferentes métodos de cuantificación y estimación de la biomasa aérea: el método directo requiere de la destrucción del árbol para poder obtener los valores de la biomasa basada en el peso real de los individuos. Este método no es factible para realizar estimaciones de la biomasa en el ecosistema debido a los altos costes ecológicos y económicos que representa. Sin

embargo, sirve para desarrollar un segundo método de estimación que no precisa de más destrucciones de los individuos. El segundo método es mediante ecuaciones alométricas, calibradas a partir de métodos destructivos (Anaya, 2008).

Las ecuaciones alométricas consideran la biomasa aérea como una variable de respuesta y usa atributos estructurales de la vegetación como variables explicativas, entre ellas el diámetro de los tallos, el área basal, la altura de los individuos y la densidad de la madera (Francis, 2000).

La estructura de la vegetación es factor clave en la cantidad de biomasa aérea dentro de los bosques. Por lo tanto, cuantificar características del dosel arbóreo puede aportar variables importantes en las estimaciones de la biomasa aérea. El dosel arbóreo es la disposición espacial de los órganos de las plantas por encima del suelo. Las hojas y demás órganos presentes en el dosel sirven como receptores de energía solar necesaria para la realización de los procesos fotosintéticos, además, sirven como medios de interacción de la planta con el medio ambiente. Por lo tanto, el dosel es clave para identificar y caracterizar procesos fisiológicos y ecológicos de la vegetación (Campbell & Norman, 1989).

La estructura del dosel tanto verticalmente como horizontalmente tiene un papel importante en la ecología forestal, en la productividad, así como en la biodiversidad misma. La estructura vertical del dosel puede variar en función de la edad de los bosques y la estructura horizontal abarca la heterogeneidad espacial mediante la distribución de especies, aberturas y diferentes alturas del dosel (Frolking et al., 2009). Los bosques tropicales secos, generalmente tienen una estructura heterogénea en el dosel con espacios abiertos (Hernández-Stefanoni et al., 2020).

Las estimaciones de la biomasa aérea, típicamente, se realizan con datos de campo obtenidos mediante inventarios basados en muestreo en los bosques. En estos inventarios se obtiene información de variables dasométricas de los individuos o atributos relacionados con la estructura de la vegetación como la altura y el diámetro de los tallos (DAP, diámetro a 1.30 m de altura), para posteriormente realizar estimaciones mediante el uso de ecuaciones alométricas. Adicionalmente, en estos inventarios es posible obtener parámetros como la ubicación geográfica de las mediciones, así como características de factores abióticos en los sitios como la orografía, topografía, fisiografía, edafología, entre otros. Para obtener observaciones dinámicas de la vegetación como el crecimiento, salud y desarrollo de las comunidades, se recurre al monitoreo de los sitios mediante mediciones en intervalos de tiempo dentro de una misma área.

1.1.6. Incremento de la biomasa aérea

Los bosques son sistemas dinámicos en el espacio y el tiempo, el resultado de esta dinámica dentro de los ecosistemas es la variación de la materia orgánica contenida dentro de los organismos. La variación puede presentarse por el crecimiento de los organismos, y está influenciada por una serie de factores como: la cantidad de lluvia, la temperatura, la disponibilidad de nutrientes y la cantidad de luz solar, así como la composición y diversidad de las especies (Noguchi et al., 2022). También puede verse afectada por factores antropogénicos que pueden modificar el flujo natural de esta dinámica. Además, la dinámica de la biomasa también es derivada de los procesos de reclutamiento, crecimiento y mortalidad de los árboles. Los cambios en la acumulación de la biomasa aérea en un tiempo dado, se deben mayormente al crecimiento de los árboles existentes más el reclutamiento de nuevos árboles menos la mortalidad. Estos procesos varían según las especies y etapas sucesionales de los bosques (Aryal et al., 2014).

Las estimaciones de los cambios de la biomasa aérea son importantes para entender la dinámica de los bosques y para poder estimar el crecimiento de los bosques y la cantidad de carbono atmosférico que capturan. También es importante para la planificación o la toma de decisiones en la conservación y protección de los bosques, así como la evaluación de la gestión de los bosques frente a las medidas para mantener los sumideros de carbono y la mitigación del cambio climático (McRoberts et al., 2015; Puliti et al., 2021).

Mediante las mediciones repetidas a lo largo del tiempo, es posible evaluar los cambios de la biomasa, aunque si bien es el método más preciso y eficiente, puede representar altos costes económicos, por lo que existe la posibilidad de realizar estimaciones mediante datos de percepción remota que recopilen información de la estructura de los árboles en diferentes tiempos (McRoberts et al., 2015; Puliti et al., 2021) y a diferentes escalas espaciales.

1.1.7. Percepción remota

Otro método del estudio de la vegetación, y en particular de la biomasa aérea, consiste en la observación de la superficie terrestre y la obtención de datos sobre ella, esto se realiza mediante la percepción remota. La percepción remota es la ciencia de obtener información de un objeto o fenómeno a través de un dispositivo distante al mismo, estos dispositivos pueden estar equipados en plataformas terrestres, aéreas, satelitales y sistemas de navegación automáticos. (Pettorelli et al., 2017) El objetivo de la percepción remota es maximizar información sobre un

objetivo, inclusive aquella que no pudiera obtenerse mediante mediciones tradicionales con un sistema de muestro (Pettorelli et al., 2017; Turner et al., 2003).

El componente principal de la percepción remota son los sensores electromagnéticos, estos pueden proveer imágenes y datos con una gran variedad de composiciones y resoluciones espaciales y temporales. Los sensores se clasifican en activos y pasivos en función del sistema operacional empleado en el dispositivo (Toth & Józków, 2015; Turner et al., 2003).

La diferencia entre ambos sensores se basa principalmente en el tipo de fuente de energía para capturar información del objetivo: Los sensores pasivos se caracterizan por usar la información de la energía solar reflejada por la superficie de la Tierra, mientras que por el contrario, los señores activos emiten su propia energía y capturan el retorno de esta energía como son la tecnología de Radar de Apertura Sintética (SAR) o tecnología láser como LiDAR (Light Detection and Ranging) que provee información tridimensional de los objetos (Toth & Józków, 2015; Turner et al., 2003).

1.1.8. LiDAR

LiDAR es una herramienta de percepción remota utilizada para generar información tridimensional de puntos que interceptan los objetos de la superficie terrestre. Utiliza luz en forma de pulsos láser para detectar y medir rangos de distancia de los objetos. Esta técnica permite hacer mediciones del bosque y ofrece una alternativa para estudiar variables estructurales del dosel (Dubayah & Drake, 2000).

La complejidad de los bosques es un reto para su estudio utilizando herramientas de percepción remota con sensores pasivos que obtienen información de la reflectancia de la vegetación, en cambio LiDAR utiliza los retornos que generan una nube de puntos que representan alturas de dosel y estructura o acomodo de las hojas y ramas, así como las elevaciones del terreno y la cobertura de la vegetación (Turner et al., 2003), estas variables se emplean para la caracterización de la estructura del bosque (Hudak et al., 2009). Estudios locales han utilizado métricas de los datos LiDAR para producir estimaciones tanto de biomasa aérea (precisiones entre 59 % a 78 %) (Hernández-Stefanoni et al., 2014), así como de la diversidad en bosques tropicales secos con precisiones entre 62 % y 74 % (George-Chacón et al., 2019). El uso de LiDAR para la caracterización de la estructura vegetal, también permite observar relaciones

estrechas entre las edades sucesionales de la vegetación y métricas de datos LiDAR (Parker & Russ, 2004).

LiDAR es una herramienta útil para la caracterización multidimensional de la estructura del bosque que tiene plataformas de obtención de datos tanto terrestres como aéreas. Estas plataformas pueden llegar a ser versátiles y pueden abarcar múltiples extensiones a diferentes resoluciones espaciales. Ambas plataformas pueden ser igual de eficaces para cuantificar los componentes estructurales de la vegetación, sin embargo, cada una tiene características particulares (LaRue et al., 2020).

El LiDAR aéreo y terrestre obtienen información del dosel desde ángulos opuestos, por lo que, la calidad y cantidad de datos capturados del dosel puede ser interferido por la propia obstrucción del dosel desde la posición del instrumento. Es decir, la parte del dosel más distante al instrumento tendrá menores puntos representados por el sensor. Las plataformas terrestres capturan la estructura desde dentro, por lo tanto, la estructura interna del dosel tendrá una mayor resolución que la representación del dosel exterior de los árboles. Por otro lado, las plataformas aéreas proporcionan mejor detalle de la estructura exterior del dosel y este se reduce a medida que aumenta la profundidad del dosel (Figura 1.1) (LaRue et al., 2020).

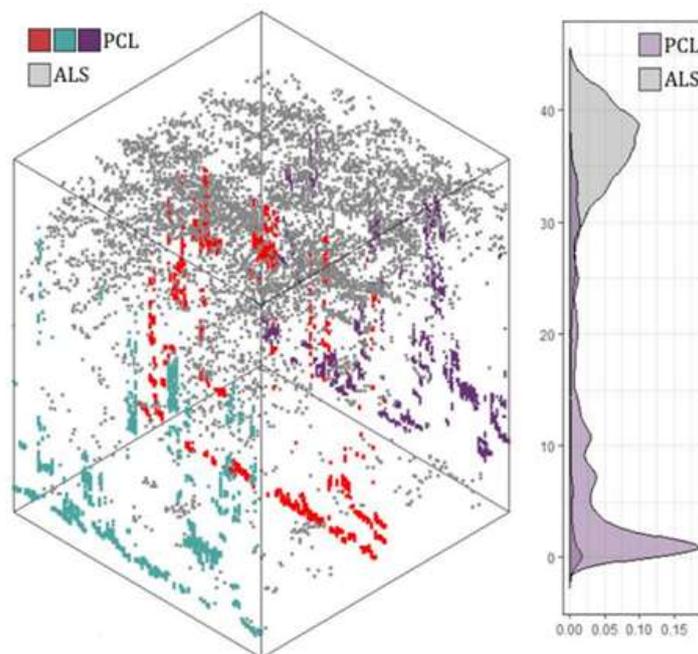


Figura 1.1. Comparación de los datos LiDAR obtenidos mediante una plataforma aérea (ALS) y terrestre (PCL). Los histogramas representan la densidad de puntos a lo largo de las diferentes alturas del dosel (LaRue et al., 2020).

Con esta condición, las plataformas están destinadas a resolver aspectos distintos sobre la estructura de los bosques, sin embargo, algunos estudios han encontrado una estrecha correlación de las estimaciones de plataformas aéreas y terrestres sobre la estructura de los bosques (Hilker et al., 2012; LaRue et al., 2020), es importante considerar que estas relaciones aún pueden ser diferentes bajo un dosel con características diferentes a las presentadas en estos estudios.

1.2. PLANTEAMIENTO DEL PROBLEMA

La estimación de la distribución espacial de la biomasa en los bosques tropicales ha tomado relevancia a niveles globales, regionales y locales. Además, ha habido una reducción de la incertidumbre en estas estimaciones con el uso del sensor LiDAR. Sin embargo, la estimación de la distribución espacial de los incrementos de la biomasa aérea de los bosques es menos frecuente debido a los retos que representa la obtención de datos tanto de campo como de los sensores en diferentes periodos de tiempo.

Las herramientas de percepción remota representan una oportunidad eficaz y eficiente para fortalecer los estudios sobre la dinámica en los bosques. Existen diferentes sensores que pueden emplearse, por ejemplo, imágenes de satélite ópticas, las cuales pueden capturar la energía reflejada por la superficie de la Tierra de medianas a altas resoluciones espaciales y temporales. Dada la amplia disponibilidad de sensores y a que existe un acervo de imágenes disponible para muchos años, estas herramientas son prometedoras para calcular la dinámica de los bosques a través del tiempo (Puliti et al., 2021).

En relación con las precisiones obtenidas en las estimaciones de la distribución espacial de la biomasa, los sensores que mejor capturan la estructura de los bosques son los de LiDAR (Duncanson et al., 2021). A pesar de que los datos LiDAR son poco accesibles en cuanto a distribución espacial y temporal, existen áreas con diferentes mediciones en el tiempo, que posibilitan que esta herramienta también pueda detectar los cambios de la estructura de la vegetación. Los datos LiDAR pueden estimar los cambios en biomasa con una mayor resolución que las imágenes ópticas, las imágenes están restringidas a recopilar información solo del dosel exterior de los bosques. Además, los datos de los sensores pasivos son generalmente insensibles a los aumentos lentos en las alturas y tienden a una saturación de la energía que puede ser captada por el sensor (Duncanson et al., 2021).

Las estimaciones de la biomasa en un tiempo puntual proveen información sobre las cantidades almacenadas de carbono, pero aún existe un gran vacío en las estimaciones de las tasas de captura en los bosques tropicales secos. Las estimaciones de los incrementos de la biomasa en el tiempo pueden ofrecer datos importantes para estudiar la dinámica de los bosques. Además, pueden ayudar a la correcta gestión de los bosques en la mitigación de los efectos del cambio climático con la conservación y protección de los bosques tropicales secos como grandes sumideros de carbono.

Por otro lado, obtener estimaciones precisas de los incrementos de las masas forestales nos ayuda a entender la dinámica de los bosques en la sucesión secundaria como un proceso natural dada por la mortalidad, crecimiento y reclutamiento de nuevos individuos. De igual manera, también nos permite conocer la recuperación de los bosques ante la presencia de disturbios naturales o antropogénicos, y nos permite evaluar los impactos de estos disturbios a lo largo del tiempo. Por último, obtener estimaciones precisas nos permite evaluar el resultado de las acciones ejecutadas de mitigación ante el cambio climático.

1.3. OBJETIVOS

1.3.1. Objetivo general

El objetivo general de este estudio es evaluar la precisión de la estimación de la biomasa aérea y su incremento usando datos LiDAR de dos plataformas diferentes (aérea y terrestre), en una selva mediana subcaducifolia dentro de la Península de Yucatán.

1.3.2. Objetivos específicos

Comparar métricas de LiDAR aéreo de 2013 en dos disposiciones de datos, la primera en forma de transecto dentro de la parcela de campo (0.02 ha) y la segunda en un área correspondiente a la parcela en campo (0.16 ha).

Estimar la biomasa aérea mediante datos de campo y ecuaciones alométricas en dos tiempos, el primero en el año 2013 y el segundo en el año 2021.

Ajustar y evaluar la precisión de modelos para la estimación de la biomasa aérea en 2013 y 2021 usando métricas de datos LiDAR obtenidas en 2013 (aéreo) y 2021 (terrestre) respectivamente.

Ajustar y evaluar la precisión de modelos para la estimación del incremento de la biomasa aérea entre el año 2013 y el 2021 usando conjuntos de métricas de datos LiDAR de 2013 y 2021 de forma conjunta.

Ajustar y evaluar la precisión de los modelos para la estimación del incremento de la biomasa aérea entre 2013 y 2021 mediante variables predictoras obtenidas de las diferencias de métricas de datos LiDAR 2013 y 2021.

1.4. PREGUNTAS DE INVESTIGACIÓN

- ¿Cuál es la precisión de la estimación de la biomasa aérea que puede ser obtenida usando métricas de datos LiDAR aéreo y terrestre en el año 2013 y 2021 respectivamente?
- ¿Cuál es la precisión de la estimación del incremento de la biomasa aérea usando métricas de datos LiDAR aéreo y terrestre de forma separada y conjunta?

1.5. HIPÓTESIS

Debido a que los atributos estructurales del bosque como la altura y cobertura del dosel están estrechamente relacionados con la biomasa aérea y que los datos LiDAR tienen la capacidad de capturar la estructura del dosel de la vegetación, se espera que las métricas de LiDAR aéreo, así como del terrestre, tengan una alta capacidad de modelar la cantidad de la biomasa aérea que hay en bosques tropicales secos con una alta precisión.

Las nubes de puntos en tres dimensiones de LiDAR capturan de manera precisa los atributos estructurales de la vegetación, así como su variación a lo largo del tiempo, por lo tanto, obtener datos en tiempos diferentes representaría los cambios estructurales del dosel de los bosques. Por consiguiente, se espera que las métricas de datos LiDAR, obtenidas en dos años diferentes y usados como variable explicativa de forma conjunta o bien por sí solos, tengan la capacidad de estimar los incrementos de la biomasa aérea en un bosque tropical seco con una alta precisión.

CAPITULO II

2.1. MATERIALES Y MÉTODOS

2.1.1. Área de estudio

El área de estudio se localiza dentro de la Península de Yucatán, México y corresponde a un bosque tropical subcaducifolio (Rzedowski, 2006). El sitio está localizado parcialmente dentro de la Reserva Biocultural Kaxil Kiuic entre las coordenadas 20° 5' y 20° 7' de latitud Norte y 89° 32' y 89° 34' de longitud Oeste. Tiene una extensión de aproximadamente 1800 ha (Hernández-Stefanoni et al., 2014) y corresponde a la parte sur del Estado de Yucatán (Figura 2.1).

En Kaxil Kiuic el clima predominante es de tipo cálido subhúmedo con lluvias en verano (García, 1973). Se presenta una temperatura media anual de 26 °C y una precipitación media anual que varía entre 1000 a 1100 mm. Su fisiografía consiste en colinas de piedra caliza con pendientes moderadas y áreas planas. Presenta una elevación máxima de 180 m s.n.m. y mínima de 60 m s.n.m. (Flores & Espejel, 1994). Dentro del sitio existe una marcada estacionalidad en la vegetación, donde hasta el 75% de los árboles tiran sus hojas en su totalidad durante la temporada de sequía (Miranda & Hernández-X., 1963). En general, las especies arbóreas tienen porte bajo, con alturas dominantes entre 15 a 18 m y promedios de 8 a 9 m (Flores & Espejel, 1994).

El paisaje está compuesto por un mosaico de vegetación en diferentes etapas sucesionales como resultado de algunos usos predominantes de la tierra como es la ganadería y la agricultura tradicional de roza-tumba y quema (Hernández-Stefanoni et al., 2014). Las especies arbóreas que tienen mayor abundancia en este sitio son *Neomillspaughia emarginata* (H. Gross) S.F Blake, *Gymnopodium floribundum* Rolfe, *Bursera simaruba* (L.) Sarg., *Piscidia piscipula* (L.) Sarg. y *Lysiloma latisiliquum* (L.) Benth. (Hernández-Stefanoni et al., 2014).

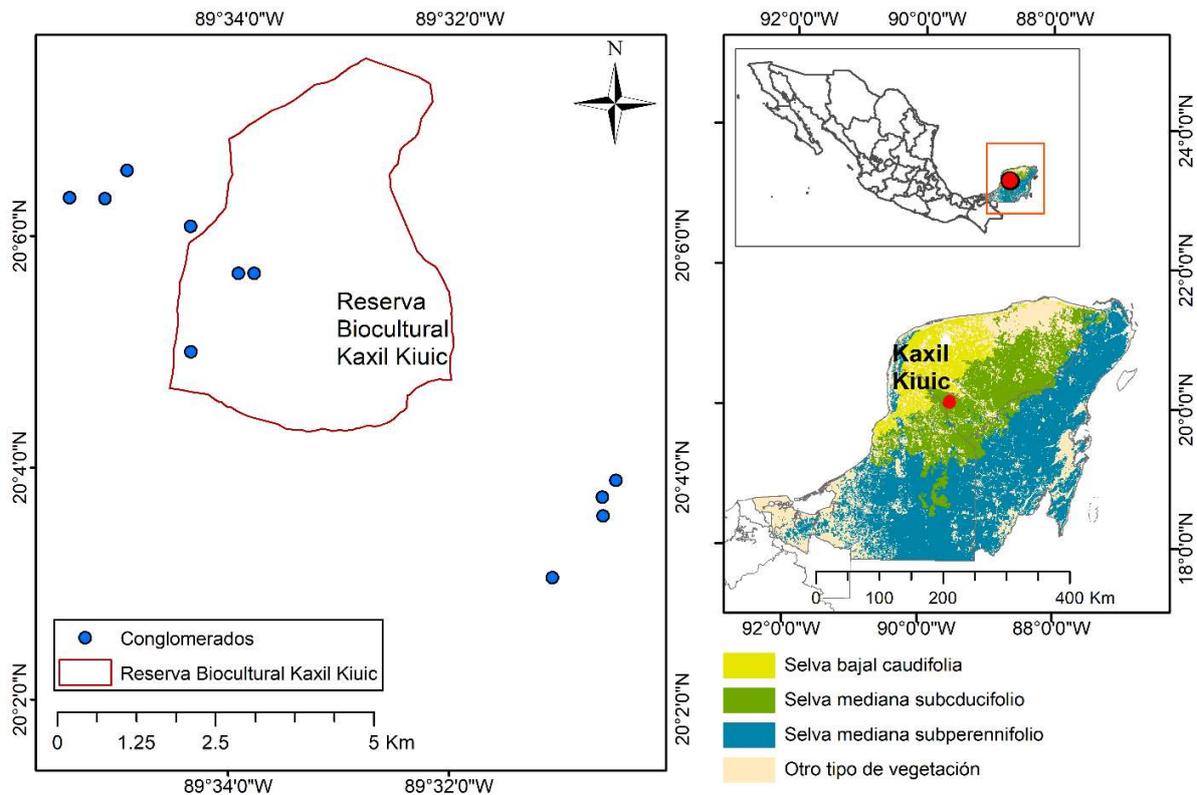


Figura 2.1. Localización geográfica del área de estudio. Los puntos azules representan los conglomerados usados para obtener datos de campo. En el polígono con contorno rojo, se representa el área que abarca la Reserva Biocultural Kaxil Kiuic, estado de Yucatán, México.

2.1.2. Muestreo en campo

Los datos de campo fueron obtenidos a partir de un levantamiento aleatorio en la temporada de lluvias del año 2013 y 2021. Se emplearon 12 conglomerados distribuidos en diferentes edades de la vegetación.

El diseño de las unidades de medición se basó en los conglomerados del Inventario Nacional Forestal y de Suelos (INFyS) de México (CONAFOR & SEMARNAT, 2012). Cada conglomerado consta de 4 parcelas de 400 m² (0.04 ha) cada una, las cuales están distribuidas dentro un área de 1 ha (56.42 m de radio). Una parcela está ubicada en el centro y las demás están ubicadas a azimut de 0°, 120° y 240° desde el centro del conglomerado. Las ubicaciones de las parcelas se registraron con coordenadas obtenidas mediante un instrumento de GPS portátil, con errores de posicionamiento registrados de menos de 3 m.

En las parcelas se muestrearon todas las plantas leñosas con DAP (diámetro a 1.3 m de altura en el tallo) mayores a 7.5 cm. Se registraron diámetros (DAP) y las alturas (Alt) de todos los individuos, así como su forma de crecimiento (árbol, liana y palma), especie y la densidad de la madera (d). Adicionalmente, se incluyeron subparcelas de 80 m² (0.008 ha) (Figura 2.2) para medir las especies con DAP menores a 7.5 y mayores a 2.5, con la finalidad de integrar a los individuos más pequeños en las estimaciones de la biomasa.

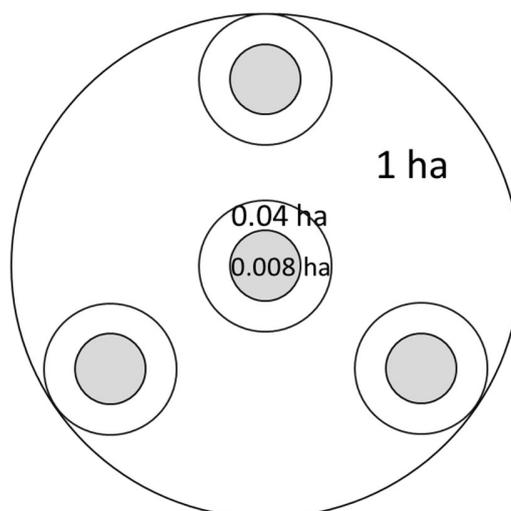


Figura 2.2. Diseño de los conglomerados usados para la obtención de datos en campo.

2.1.3. Cálculo de la biomasa aérea

Para la estimación de la biomasa aérea con datos obtenidos en campo, se aplicaron ecuaciones alométricas para árboles, palmas y lianas a partir de diámetros, alturas y la densidad de la madera de los individuos. Las ecuaciones alométricas para los árboles fueron desarrolladas para áreas con el mismo tipo de vegetación que el área de estudio: una para árboles con diámetros menores a 10 cm (Ramírez et al., 2019) y otra para diámetros mayores o iguales a 10 cm (Chave et al., 2005). Las ecuaciones alométricas para lianas (Chave et al., 2003) y palmas (Frangi & Lugo, 1985) se usaron indiferentemente del tamaño de diámetro, inclusive, en el caso de las palmas, se considera solamente la altura para la estimación de la biomasa (Tabla 2.1). Se obtuvieron las densidades de la madera a partir de estudios locales y a través de la literatura (Anexo I). Para las especies sin valores de la densidad de madera, se asignaron valores promedio del género o los promedios de las especies por unidad de muestreo.

CAPÍTULO II

Los valores de la biomasa se obtuvieron en kg y posteriormente fueron transformados a unidades estandarizadas por superficie, en toneladas por una hectárea (ton/ha). Las 4 subparcelas de 400 m² constituyen una superficie total de 1600 m² dentro del conglomerado de 1 ha.

Tabla 2.1. Ecuaciones alométricas utilizadas para la estimación de la biomasa aérea con datos de campo.

Forma biológica	Clase de tamaño	Ecuación alométricas (kg)	Autor
Palmas	Indiferente	$= 4.5 + 7.7Alt$	Frangi y Lugo 1985
Lianas	Indiferente	$= \exp(0.0499 + 2.053 \ln(DAP))$	Chave <i>et al.</i> 2003
Arboles	DAP < 10	$= \exp(-4.1392 + 0.99 \ln(DAP^2 Alt) + 1.2268d)$	Ramírez <i>et al</i> 2019
	DAP ≥ 10	$= d(\exp(-0.667 + 1.784 \ln(DAP) + 0.207(\ln(DAP))^2 - 0.0281(\ln(DAP))^3))$	Chave <i>et al.</i> 2005

*Ecuaciones alométricas de biomasa aérea en kg. DAP: diámetro (cm) a altura de 1.3 m, Alt: altura total (m), *d*: densidad de la madera por especie (g cm⁻³).

2.1.4. Datos LiDAR

2.1.4.1. LiDAR aéreo

La adquisición de los datos LiDAR aéreo fue en agosto de 2012 y enero 2013, por la empresa Carto Data. La plataforma usada para el sensor fue un avión Cessna T202 equipado con escáner láser aéreo RIEGL-QV-480 LiDAR, un sistema de posicionamiento GPS NovAtel y una cámara nadir RGB de 16 megapíxeles, con altura de operación promedio de 396.2m, 30° de ángulo de visión y una frecuencia de repetición de 200 kHz, a una velocidad entre 80 a 90 kmph. Los vuelos incluyeron una sobreposición de 50% en las líneas de vuelo adyacente. El sistema contó con 5 pulsos por metro cuadrado y cada pulso con 5 retornos discretos.

2.1.4.2. LiDAR terrestre

Los datos fueron obtenidos en octubre de 2021 mediante un sistema de LiDAR portátil terrestre llamado Portable Canopy LIDAR (PCL) (Parker et al., 2004). En este sistema un telémetro laser (RIEGL LD90-3100VHS-FLP) es orientado verticalmente hacia arriba, montado en un marco portátil, este realiza mediciones de distancias de alta frecuencia aproximadamente de 2000 pulsos/seg. El sistema PCL recoge datos a lo largo de transectos en el bosque y obtiene métricas por columnas verticales compuestas por voxeles, las dimensiones de los voxeles son de 1m x 1m x 1m. En este estudio se usaron transectos con promedios de 200 m de longitud dentro de un conglomerado de 1 ha.

La salida primaria del sistema PCL es una estimación de la densidad del área de superficie del dosel (SAD m^2/m^3) en cada vóxel, dentro de las columnas verticales. En los bosques altamente foliados, la mayoría de las mediciones que registra el instrumento laser, está dada por los componentes foliares. Sin embargo, en la densidad estimada con el sistema PCL también influyen otros elementos aéreos de la vegetación, como ramas y tallos, por ello Parker *et al*, (2004) sugieren el uso del término densidad de área de superficie en lugar de densidad de área foliar.

2.1.5. Análisis de los datos LiDAR

Los levantamientos LiDAR aerotransportados generaron un conjunto de datos tridimensionales en toda la superficie muestreada, mientras que los levantamientos LiDAR terrestres generan métricas del dosel en columnas verticales a lo largo de transectos. Un estudio previo, demostró que las estimaciones de LiDAR aéreo y terrestre de la diversidad estructural del bosque estaban correlacionadas dentro de un bosque de un número reducido de especies (LaRue et al., 2020), sin embargo, los bosques varían sustancialmente en estructura a escalas locales y regionales.

En este estudio se obtuvieron métricas de datos de LiDAR terrestre definidas por el sistema PCL, mientras que para los datos LiDAR aéreo, se usaron los paquetes de *lidr* y *RLiDAR* en la interfaz *RStudio* del lenguaje de programación *R* (R Core Team, 2019) para obtener las métricas de diversidad estructural.

En ambos tipos de LiDAR, se obtuvieron las mismas métricas para homogeneizar las variables explicativas en los modelos para la estimación de la biomasa aérea, así como su incremento. La

CAPÍTULO II

primera medida que se obtuvo es el Índice de Área del Dosel o CAI por sus siglas en inglés. CAI (m^2/m^3) estima la cantidad total de área de dosel en una columna vertical dentro del transecto o la muestra (Parker et al., 2004). Otras medidas que se pueden obtener dentro de cada columna vertical son la media de las alturas (H_{bar}) dentro de los voxeles, así como las alturas máximas (H_{max}) de cada vóxel. Las métricas se resumen por cada transecto o parcela mediante valores medios y su desviación estándar (**Tabla 2.2**).

Tabla 2.2. Descripción de las métricas de los datos LiDAR aéreo y terrestre.

Métricas LiDAR	Descripción
mCAI	Media del índice del área del dosel (CAI) dentro de cada columna vertical de la muestra.
sdCAI	Desviación estándar del índice del área del dosel (CAI).
xHmax	Altura máxima dentro de la muestra.
mHmax	Media de la altura máxima dentro de la muestra.
sdHmax	Desviación estándar de la altura máxima dentro de la muestra.
mHbar	Media de las alturas medias de las columnas verticales.
sdHbar	Desviación estándar de la media de alturas dentro de columnas verticales.

2.1.6. Evaluación de la superficie de muestreo de datos LiDAR aéreo

Los datos aéreos abarcan en su totalidad el área de los conglomerados en campo, mientras que los datos del sistema PCL (LiDAR terrestre) realizan la obtención de los datos en transectos dentro de los conglomerados. Los datos obtenidos en el segundo sistema se resumen en columnas verticales de voxeles cúbicos de $1 m^3$. La longitud de los transectos define la superficie muestreada con este sistema.

En este estudio se utilizaron transectos de aproximadamente 200 m de longitud. Por lo que la superficie aproximada de muestreo es de 0.02 ha. Esto supone una gran diferencia entre la superficie de datos obtenidos en el sistema aéreo y el terrestre y podría representar una fuente importante de sesgo en la comparación de la precisión en la estimación de la biomasa aérea mediante las métricas LiDAR.

Para evaluar el efecto de la superficie de muestreo de los datos LiDAR, se realizaron recortes de LiDAR aéreo en transectos similares a los transectos realizados con el sistema PCL de 1 m de ancho. Las métricas obtenidas en forma de transectos se compararon con las métricas obtenidas con una superficie de 0.16 ha, la cual abarca la totalidad de las parcelas dentro del conglomerado (Figura 2.3).

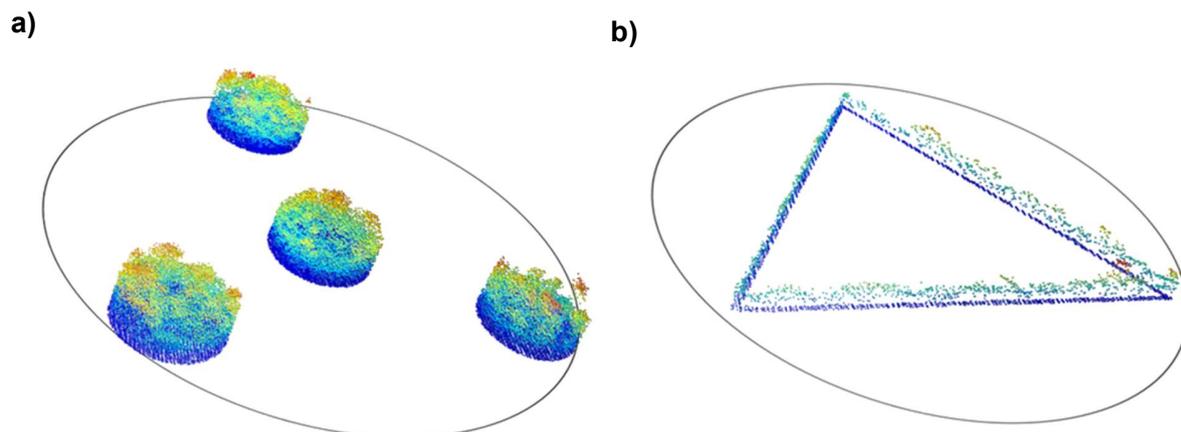


Figura 2.3. Tipos de extracción de datos LiDAR aéreo 2013. a) En una superficie de 0.16 que abarca las parcelas de campo dentro del conglomerado. b) En una superficie de 0.02 ha en forma de transectos de 1 m de ancho.

2.1.7. Análisis de datos

Se realizaron pruebas de normalidad de las variables dependientes (biomasa aérea 2013, biomasa aérea 2021 e incremento de la biomasa aérea 2013-2021). La prueba de la hipótesis de normalidad se realizó con la prueba de Shaphiro-Wilk en el programa de lenguaje de R (R Core Team, 2019).

Si las variables evaluadas en este trabajo no tenían una distribución normal, se utilizó una transformación logarítmica, esta transformación es una de las más empleadas en las ciencias biológicas (Pérez Pelea, 2018).

Para obtener los modelos de regresión para la estimación de la biomasa aérea en el año 2013 y 2021, se usaron una serie de funciones del lenguaje de programación R (R Core Team, 2019). El método que se empleó para la selección de variables predictoras es la que se denomina *forward selection*, este método comienza con un modelo sin predictores y luego agrega

CAPÍTULO II

predictores uno a la vez hasta que todos los predictores estén en el modelo. La variable que es agregada al modelo es aquella que aporte una mejora en el ajuste del modelo, y por lo tanto presente un coeficiente significativamente diferente de 0.

Posteriormente, los modelos se evalúan con el análisis de Factor de Inflación de la Varianza (VIF) para descartar multicolinealidad de las variables independientes (métricas) para cada modelo obtenido.

El VIF se define así:

$$VIF = \frac{1}{1 - R_k^2},$$

Siendo R_k^2 el coeficiente de determinación de la regresión auxiliar de la variable X_k sobre el resto de las variables explicativas.

El VIF toma valores entre 1 hasta infinito, sin embargo, valores mayores a 5 indican que los coeficientes asociados de regresión pueden estar sobreestimados debido al efecto de la multicolinealidad. Si hay uno o más valores de VIF grandes, se dice que hay multicolinealidad (Montgomery et al., 2006).

Por último, el desafío de los modelos estadísticos es que funcionen con precisión en datos que no fueron usados para calibrar los modelos. Para conocer la precisión con que del modelo se realizó una prueba de validación, mediante el método de validación cruzada. Este método consiste en evaluar los modelos mediante iteraciones, donde se removi6 una observaci6n y se calibr6 el modelo con las observaciones restantes, posteriormente se estim6 el valor de la observaci6n removida; el proceso se realiz6 n veces, siendo n el n6mero de observaciones usado en la calibraci6n del modelo a evaluar.

El resultado de esta validaci6n gener6 una matriz de datos estimados de cada observaci6n, los estadísticos que se usaron para evaluar la precisi6n son la Raíz del Error Medio Cuadrático (RMSE por sus siglas en ingles) y el coeficiente de determinaci6n R^2 entre los valores observados y predichos.

El valor de RMSE disminuye a medida que la precisi6n del modelo aumenta, mientras que la R^2 representa el porcentaje de varianza de la variable dependiente explicada por las variables

independientes en el modelo. Adicionalmente, se calculó el porcentaje de RMSE en función de la media de los valores observados de la variable dependiente, un porcentaje más bajo indica una mayor precisión en la estimación del modelo.

2.1.8. Modelos para la estimación de la biomasa aérea

Para cada año de estimación de la biomasa aérea (2013 y 2021), se usó el conjunto de métricas correspondientes al año de estimación como variables explicativas y como variables dependientes la biomasa estimada mediante datos de campo en el mismo tiempo.

Se evaluaron dos tipos de modelos para la estimación de la biomasa aérea; en el primero incluyo un ajuste del modelo sin intercepto, es decir, con valor 0 en el intercepto. El intercepto 0 indica un punto de origen del modelo con relación 0-0 en biomasa observada-predicha. La forma del modelo corresponde a la siguiente ecuación:

$$AGB_t = 0 + \beta_1 X_{1,t} + \dots + \beta_n X_{i,t}$$

dónde: AGB_t es la biomasa aérea en año t ($t = 2013, 2021$): $X_{i,t}$ es la métrica i del año t ; β_n es el coeficiente de cada métrica $X_{i,t}$.

Otros autores han realizado el ajuste del modelo con intercepto 0 para estudios ecológicos, como en la estimación del cambio de la riqueza de especies en función del tiempo transcurrido, donde en el tiempo 0 se descarta cualquier cambio en la riqueza de especies (Vellend et al., 2017). Además, en la estimación de la biomasa aérea usando un modelo de la altura del dosel, donde la altura del dosel igual a cero correspondería a una biomasa igual a cero (Schlund et al., 2020).

El segundo tipo de modelo corresponde al ajuste del modelo con intercepto, el coeficiente del Intercepto del modelo es estimado al igual que los demás coeficientes de las variables explicativas. El objetivo de integrar un intercepto en los modelos lineales, es mejorar el ajuste de este dentro del rango de datos que se usan para calibrar el modelo. Esto permite un mejor ajuste dentro del rango comprendido de las observaciones. Aunque los errores pueden ser mayores cuando el rango de observaciones tenga una distribución más restringida. Por otro lado, esta condición también puede estar influenciada por la relación natural entre los valores a predecir y las variables predictoras.

La ecuación que corresponde a este tipo de modelo es:

$$AGB_t = \beta_0 + \beta_1 X_{1,t} + \dots + \beta_n X_{i,t}$$

dónde: β_0 corresponde al intercepto estimado del modelo.

2.1.9. Modelos para la estimación del incremento de la biomasa aérea

Los modelos para estimar el incremento de la biomasa aérea del año 2013 al 2021 utilizaron métricas de datos LiDAR calculadas de la misma forma para ambos años. Se utilizaron dos enfoques para la estimación. En el primer método, se usó una estimación indirecta, donde, el incremento se estimó como la diferencia entre las estimaciones individuales de la biomasa aérea por cada año. Las estimaciones de biomasa aérea se obtuvieron a partir de los modelos de cada año con el conjunto de métricas LiDAR correspondientes.

Por lo tanto, la estimación se define de la siguiente forma:

$$\Delta AGB = AGB_{2021} - AGB_{2013}$$

dónde: ΔAGB es el incremento de la biomasa aérea; AGB_{2013} es la biomasa aérea estimada en el año 2013; AGB_{2021} es la biomasa aérea estimada en el año 2021.

Para el enfoque directo de la estimación del incremento de la biomasa aérea se usaron dos diseños de los conjuntos de métricas LiDAR, en el primer conjunto se usaron como variables independientes todas las métricas obtenidas en el año 2013 y 2021 como un solo conjunto de variables para el ajuste del modelo. En el segundo diseño de las variables predictoras, se usaron las diferencias de las métricas del año 2021 al 2013 entre los años comprendidos, es decir, las variables explicativas representan los incrementos de las métricas por año. Además, se realizó el ajuste de los modelos con intercepto igual a cero e intercepto estimado para ambos conjuntos de variables independientes.

Los modelos para el primer diseño del conjunto de variables independientes son:

$$\Delta AGB_t = 0 + \beta_1 X_{1,2013} + \beta_2 X_{1,2021} + \dots + \beta_n X_{i,t} \dots \dots \dots \text{con intercepto igual a cero}$$

$$\Delta AGB_t = \beta_0 + \beta_1 X_{1,2013} + \beta_2 X_{1,2021} + \dots + \beta_n X_{i,t} \dots \dots \dots \text{con intercepto estimado}$$

donde: $X_{i,t}$ es la métrica i ($i = 1, 2, 3, \dots, n$ métrica) del año t ($t = 2013, 2021$); β_n son los coeficientes estimados del modelo

Para el segundo diseño del conjunto de variables son:

$$\Delta AGB_t = 0 + \beta_1 \Delta X_1 + \dots + \beta_n \Delta X_i \dots \dots \dots \text{con intercepto igual a cero}$$

$$\Delta AGB_t = \beta_0 + \beta_1 \Delta X_1 + \dots + \beta_n \Delta X_i \dots \dots \dots \text{con intercepto estimado}$$

donde: ΔX_i es la diferencia de la métrica i ($i = 1, 2, 3, \dots, n$ métrica); β_n son los coeficientes estimados del modelo

CAPITULO III

3.1. RESULTADOS

3.1.1. Cuantificación de la biomasa aérea y su incremento en el año 2013 al 2021

El promedio de la biomasa aérea estimada a nivel de conglomerado fue de 109.919 ton/ha en el año 2013, mientras que en el año 2021 fue de 132.233 ton/ha. El error estándar de la media fue similar para ambos años; 23.461 y 23.220 para el año 2013 y 2021 respectivamente. El promedio de la diferencia de la biomasa en 8 años, desde 2013 a 2021 fue de 2.789 ton/ha/año con un error estándar de 0.266 (Tabla 3.1).

Tabla 3.1. Biomasa aérea estimada con datos de campo y edad de los conglomerados en Kaxil Kiuic, estado de Yucatán, México.

Conglomerados	Edad 2013	Edad 2021	AGB 2013	AGB 2021 (ton/ha)	Diferencia AGB (ton/ha/año)
1	65	73	191.32	204.90	1.70
8	80	88	195.86	218.48	2.83
10	100	108	212.28	230.61	2.29
18	100	108	147.39	180.93	4.19
20	100	108	214.23	232.86	2.33
21	3	11	2.132	19.16	2.13
22	4	12	9.20	27.85	2.33
24	3.6	11.6	32.05	50.37	2.29
25	10	18	62.40	83.31	2.61
26	17	25	33.82	73.29	4.93
28	16	24	110.77	136.16	3.17
29	18	26	107.57	128.86	2.66
Promedio			109.92	132.23	2.79
Desviación estándar			81.27	80.44	0.92
Error estándar			23.46	23.22	0.27

En este estudio, se encontró una estrecha relación entre la biomasa aérea y la edad del bosque tropical seco de Kaxil Kiuic. La edad de los conglomerados usados en este estudio abarca de los 11 hasta 108 años en el 2021. Sin embargo, los conglomerados están notablemente agrupados en dos rangos de edades: el primer grupo de conglomerados usados tienen una edad menor a 30 años, los valores de biomasa aérea en este grupo no sobrepasaron los 150 ton/ha, mientras que otro grupo de parcelas son las que tienen una edad mayor a 60 años. Este segundo grupo de parcelas tiene cantidades de biomasa aérea mayores a 150 ton/ha.

Las tendencias generales de la biomasa aérea en función de la edad se asemejan a una línea de crecimiento logarítmico. Sin embargo, la línea que representa la trayectoria real de la biomasa aérea en los conglomerados indica que los incrementos pueden ser de igual magnitud en cualquier edad. Una línea más prolongada y con mayor pendiente, indicaría que hay un mayor incremento de la biomasa aérea durante el periodo de tiempo comprendido (**¡Error! No se encuentra el origen de la referencia.3.1**).

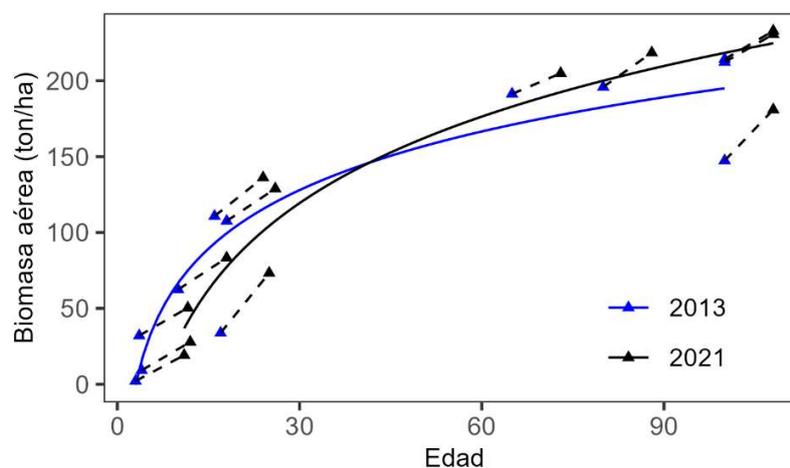


Figura 3.1. Biomasa aérea (ton/ha) por edad de cada conglomerado (años) en el año 2013 (triángulos negros) y su línea de tendencia estimada (línea negra). Los triángulos azules representan la biomasa aérea en el 2021 y su línea de tendencia estimada por la línea azul. Las líneas punteadas representan la trayectoria real de los cambios de biomasa aérea en cada conglomerado de Kaxil Kiuic, estado de Yucatán, México.

La diferencia de la biomasa aérea entre el año 2013 y el 2021 muestra incrementos desde 1.698 hasta 4.934 ton/ha/año. No se encontró una asociación significativa entre la tasa de incremento de la biomasa aérea y la edad, la variabilidad es amplia para los conglomerados jóvenes y de más edad por igual (**¡Error! No se encuentra el origen de la referencia.3.2**). Por otro lado, al

incorporar los incrementos como un porcentaje del incremento con base a la cantidad inicial de biomasa aérea en el tiempo 1 (2013), es decir el incremento relativo, se encontró una asociación significativa con valor de R^2 igual a 0.51. El mejor modelo matemático que corresponde a esta relación está basado en un exponencial de los coeficientes, por lo tanto, la mejor relación entre la edad y el incremento de la biomasa aérea corresponde a una relación potencial en lugar de la relación lineal. (¡Error! No se encuentra el origen de la referencia.3.2). Se encontró una relación negativa del incremento relativo de la biomasa y la edad, a mayor edad menor aumento relativo de la biomasa aérea con un coeficiente negativo de 0.025.

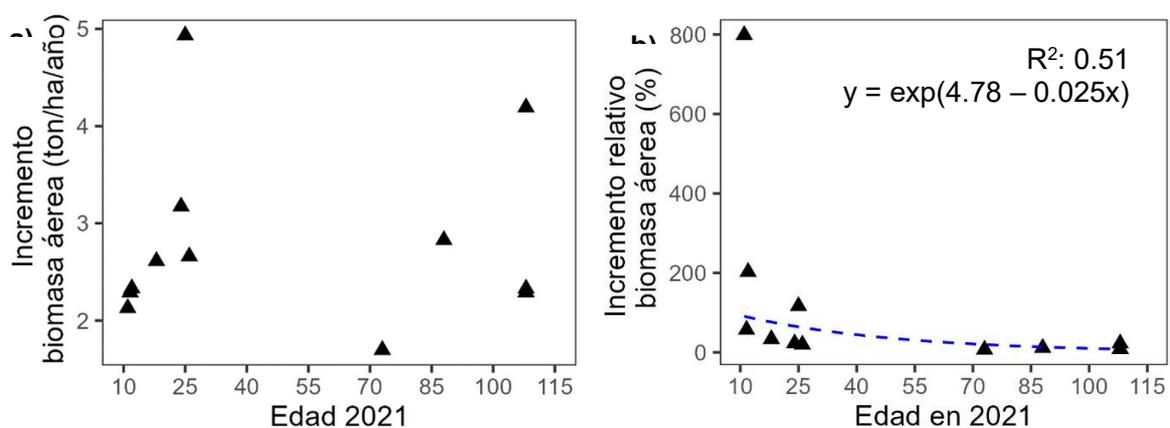


Figura 3.2. Relación entre el incremento de la biomasa aérea (del 2013 hasta 2021) y la edad de los conglomerados mediante datos de campo en Kaxil Kiuic, estado de Yucatán, México. a) Tasa del incremento de la biomasa aérea por año. b) Incremento relativo de la biomasa aérea respecto a la biomasa inicial el tiempo 1 (2013). Dónde: y es Porcentaje del incremento de la biomasa, x es la edad en años.

3.1.2. Estimación de la biomasa aérea usando LiDAR aéreo

3.1.2.1. Comparación de métricas obtenidas en dos tamaños de superficie

Las métricas obtenidas a partir de datos LiDAR en un transecto de 1 m de ancho a lo largo del conglomerado, no presentaron diferencias con las métricas obtenidas en la superficie igual a las parcelas muestreadas en campo (0.16 ha). Únicamente, la métrica sdCAI (desviación estándar de CAI) muestra una distribución con valores más bajos en los transectos (Figura 3.3; ¡Error! No se encuentra el origen de la referencia.), sin embargo, no presenta diferencias significativas. Al no encontrar diferencias significativas entre los dos grupos de métricas, se optó por usar las métricas de datos LiDAR aéreo de 0.16 ha, ya que se espera que sean más representativos de

la estructura de la vegetación dentro de los conglomerados. Así mismo, implica omitir un subproceso de recorte y ajuste de datos dentro de las parcelas en forma de transectos, el cual puede generar errores o pérdida de información por el borde de los recortes.

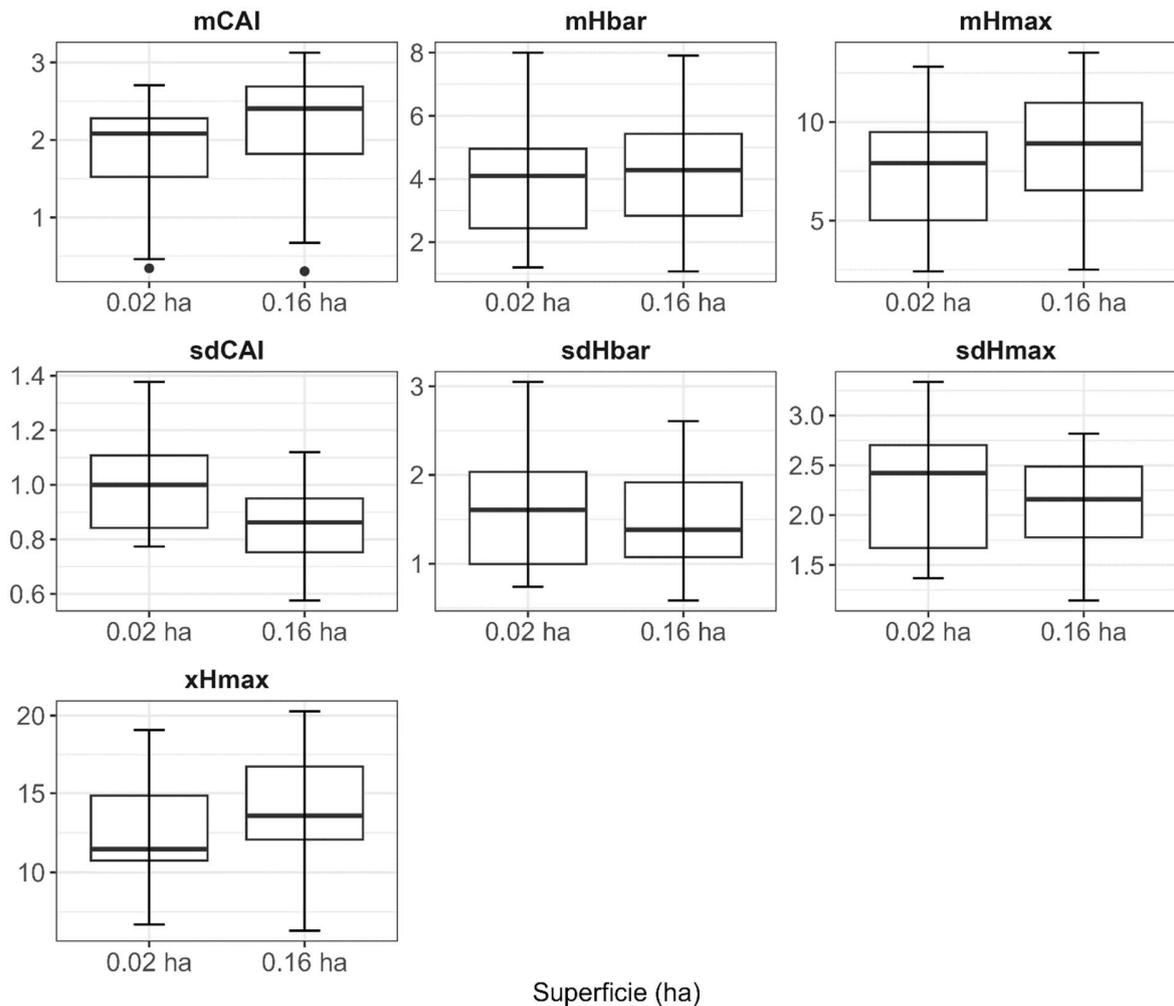


Figura 3.3. Comparación de métricas de LiDAR aéreo obtenidas en transectos de 1 m de ancho por 200 m de longitud aproximadamente (0.02 ha) y en una superficie igual a las parcelas del conglomerado (0.16 ha) en Kaxil Kiuc, estado de Yucatán, México

3.1.2.2. Estimación de la biomasa aérea mediante métricas de LiDAR aéreo

Los modelos para predecir la biomasa aérea a nivel de conglomerado usando datos de LiDAR aéreo (año 2013), mostraron diferencias al realizar diferentes ajustes en el intercepto. El coeficiente de determinación R^2 fue de 0.94 para el modelo donde el intercepto se definió como

CAPÍTULO III

0, mientras que con el intercepto estimado, se obtuvo un valor de 0.91. En la evaluación de los errores de la estimación mediante el porcentaje del RMSE, obtenida a partir de la media de los valores observados, se obtuvieron valores similares, con una diferencia del 7 %, el menor error fue de 20.76 % y corresponde al modelo con el intercepto estimado (Tabla 3.2).

Este resultado muestra que las métricas de LiDAR pueden explicar un porcentaje alto de la variación de la biomasa aérea. Las métricas que fueron seleccionadas en el modelo con intercepto 0, están relacionadas directamente con la altura del dosel, específicamente con la altura media (mHbar).

Por otra parte, en el modelo con el intercepto estimado, la métrica fue mHmax la que aportó en mayor cantidad para la explicación de la varianza. Esta métrica está relacionada directamente con las alturas máximas detectadas por el sensor. Estos resultados indican que la estructura de la vegetación obtenida mediante LiDAR puede ser un excelente estimador de la biomasa aérea contenida en la vegetación arbórea.

Tabla 3.2. Resumen del modelo lineal para la estimación de la biomasa aérea a nivel de conglomerado en 2013 usando datos de LiDAR aéreo en Kaxil Kiuic, estado de Yucatán, México.

Variable	Tipo de modelo	Variable explicativa	Coefficiente	Error estándar	R ²	RMS E	%RMS E
AGB 2013	Intercepto 0	Intercepto	-	-	0.94	30.40	27.66
		mHbar	28.47	1.99			
	Intercepto estimado	Intercepto	-78.25	19.63	0.91	22.83	20.76
		mHmax	22.31	2.16			

3.1.3. Validación de los modelos para estimar la biomasa aérea mediante datos de LiDAR aéreo

En la evaluación del modelo con el método de validación cruzada, se obtuvo una mayor precisión con el intercepto estimado, con un valor de R² de 0.88 y un porcentaje del RMSE al 24.63 %. Sin embargo, no presentó grandes diferencias con el segundo modelo de intercepto igual a cero,

donde se obtuvo una R^2 igual (0.88) y el %RMSE de 29.87 %, la diferencia fue de solamente 5 %. Sin embargo, se puede observar que con el modelo de intercepto estimado, se estimaron valores menores a 0 ton/ha. El intercepto estimado del modelo obtuvo un coeficiente negativo (-78.25), lo que explica la presencia de valores negativos en valores de biomasa cercanos a 0 ton/ha. Por otro lado, en el modelo con intercepto igual a cero, si bien no hay valores negativos, se observó una ligera sobreestimación en valores de biomasa aérea cercanos a 0 y una mayor subestimación en valores más grandes de biomasa que en el otro modelo (Figura 3.4).

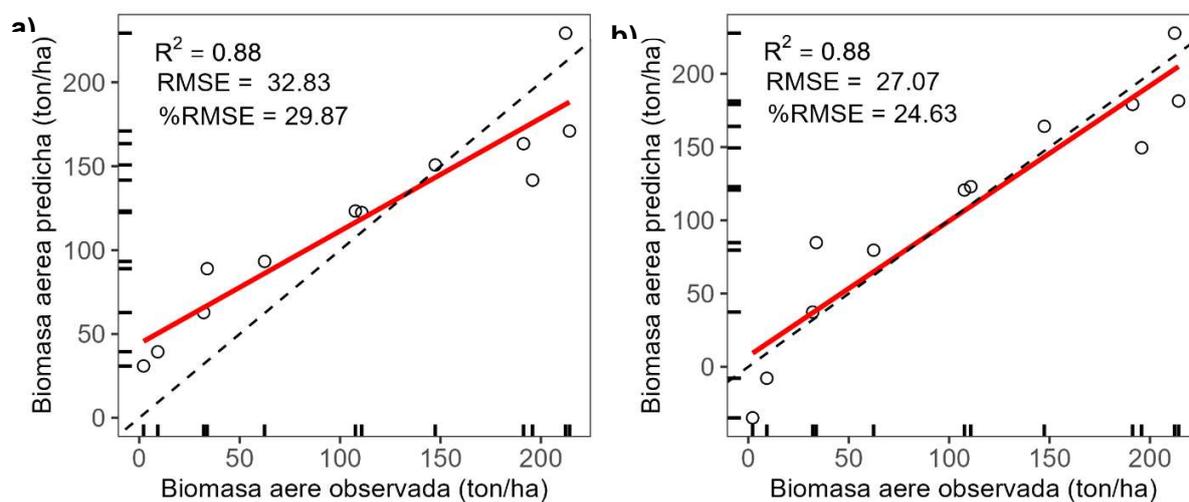


Figura 3.4. Resultados de la validación cruzada para evaluar la precisión de la estimación de la biomasa aérea a nivel de conglomerado usando datos de LiDAR aéreo. a) Modelo con intercepto igual a 0. b) Modelo con intercepto estimado. Los puntos representan la biomasa estimada en función de la biomasa observada, la línea roja representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una relación 1 a 1 en Kaxil Kiuic, estado de Yucatán, México

3.1.4. Estimación biomasa aérea usando métricas de LiDAR terrestre

Los modelos para estimar la biomasa aérea a nivel de conglomerado, usando métricas de datos de LiDAR terrestre en 2021, mostraron mayores diferencias en el ajuste que en los modelos correspondientes al 2013. En el modelo con intercepto igual a 0 y el modelo con intercepto estimado los valores de R^2 fueron de 0.96 y 0.89 respectivamente. Ambos modelos explican un alto porcentaje de la variabilidad de la biomasa aérea, usando métricas relacionadas con la variación de la densidad del dosel (sdCAI) y la variación de la altura media (sdHbar). El segundo

CAPÍTULO III

modelo integró métricas relacionadas directamente con la altura medida de la vegetación (mHbar) y con la densidad de cobertura del dosel (mCAI). El valor del intercepto fue extraordinariamente bajo con un coeficiente negativo de -577.20 y error estándar de 256.14. Sin embargo, el error del modelo, evaluado con el porcentaje del RSME fue de 21.76 %. Mientras que el modelo con intercepto igual a 0 obtuvo un valor de 19.13 % (Tabla 3.3).

Tabla 3.3. Resumen del modelo obtenido para la estimación de la biomasa aérea a nivel de conglomerado usando datos LiDAR terrestre en el año 2021 en Kaxil Kiuic, estado de Yucatán, México.

Variable	Tipo de modelo	Variable explicativa	Coeficiente	Error estándar	R ²	RMSE	%RMSE
AGB 2021		Intercepto	-	-			
	Intercepto 0	sdCAI	-61.45	17.94	0.96	28.77	21.76
		sdHbar	181.52	20.79			
		Intercepto	-577.20	256.14			
	Intercepto estimado	mHbar	61.95	7.31	0.89	25.30	19.13
		mCAI	55.47	35.48			

3.1.5. Validación de los modelos para estimar la biomasa aérea mediante datos de LiDAR terrestre

Al realizar la evaluación de los modelos con el método de la validación cruzada, se obtuvo que la precisión del modelo con intercepto igual a cero e intercepto estimado en el modelo, fue similar en el coeficiente de determinación y el porcentaje del RMSE. Este resultado nos sugiere que usando cualquiera de los dos métodos esperamos una precisión similar en la estimación de la biomasa aérea a nivel de conglomerado. La diferencia más notable en estas estimaciones es que en el método con intercepto igual a cero, se suprime la estimación de valores por debajo de 0 ton/ha, contrariamente a lo que podemos observar en el segundo método (Figura 3.5).

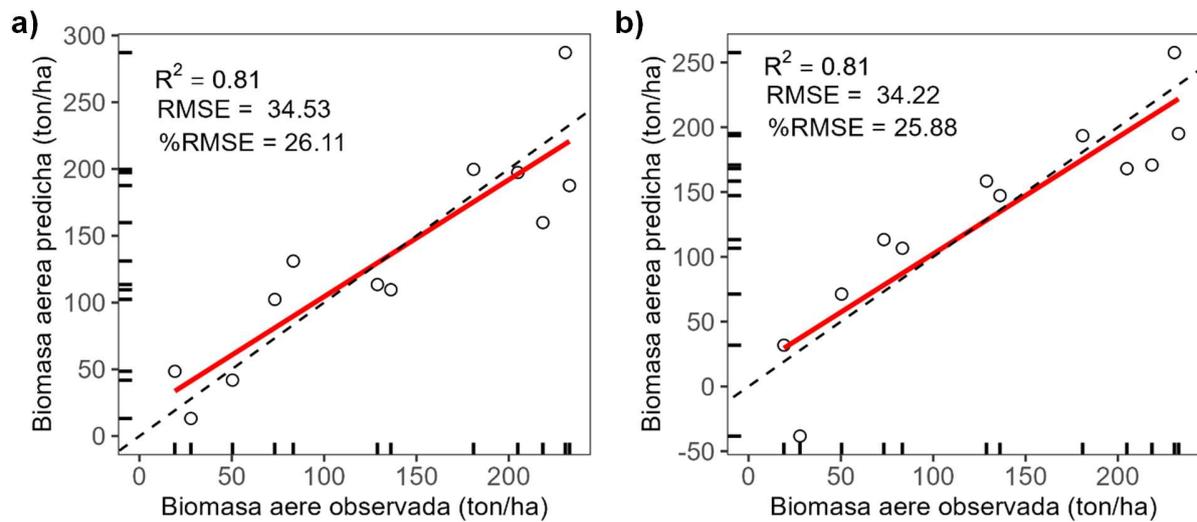


Figura 3.5. Resultados de la validación cruzada para evaluar la precisión de la estimación de la biomasa aérea a nivel de conglomerado usando datos de LiDAR terrestre. a) Modelo con intercepto igual a 0. b) Modelo con intercepto estimado. Los puntos representan la biomasa estimada en función de la biomasa observada, la línea roja representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una relación 1 a 1 en Kaxil Kiucic, estado de Yucatán, México.

3.1.6. Estimación del incremento de la biomasa aérea usando métricas de datos LiDAR (2013 – 2021)

3.1.7. Método indirecto para la estimación del incremento de la biomasa aérea

Las estimaciones indirectas de los incrementos de la biomasa a nivel de conglomerado por ha y año (ton/ha/año) se obtuvieron con los métodos de modelos de intercepto igual a cero e intercepto estimado. Tanto para el año 2013 y 2021 se usaron las métricas con los coeficientes obtenidos anteriormente de forma separada.

La ecuación que corresponde al método con intercepto igual a cero es:

$$\Delta AGB = AGB_{2021} - AGB_{2013}$$

$$\Delta AGB = (0 + \beta sdCAI_{2021} + \beta sdCAI_{2021}) - (0 + \beta mHbar_{2013})$$

$$\Delta AGB = (0 - 61.45sdCAI_{2021} + 181.52sdHbar_{2021}) - (0 + 28.47 mHbar_{2013})$$

CAPÍTULO III

dónde: ΔAGB es el incremento de la biomasa aérea por año; β es el coeficiente estimado de las variables explicativas en cada año.

La estimación del incremento de la biomasa aérea utilizando la diferencia de la biomasa estimada para el año 2013 (AGB_{2013}) y 2021 (AGB_{2021}) tiene una R^2 igual a 0.02 con un porcentaje de error al 110.43 %, estos resultados indican que las estimaciones por este método no generan valores cercanos a los observados (Figura 3.6).

Por otro lado, en el segundo método donde se estima un intercepto para el modelo, la ecuación que corresponde a la estimación del incremento de la biomasa aérea en toneladas por hectárea por año es:

$$\Delta AGB = AGB_{2021} - AGB_{2013}$$

$$\Delta AGB = (\beta_1 + \beta_2 mHbar_{2021} + \beta_3 smCAI_{2021}) - (\beta_1 + \beta_2 mHmax_{2013})$$

$$\Delta AGB = (-577.20 + 61.95 mHbar_{2021} + 55.47 smCAI_{2021}) - (-78.25 + 22.31 mHbar_{2013})$$

dónde: ΔAGB es el incremento de la biomasa aérea por año; β_i son los coeficientes estimados de los parámetros de los modelos.

Los resultados obtenidos con este método presentaron un valor de la R^2 de 0.1, y un porcentaje del error de 61.67 %, si bien el error disminuye y aumenta ligeramente la precisión comparada con el método de intercepto igualado a 0, no se presenta un ajuste entre los valores predichos y observados con estos métodos (Figura 3.6).

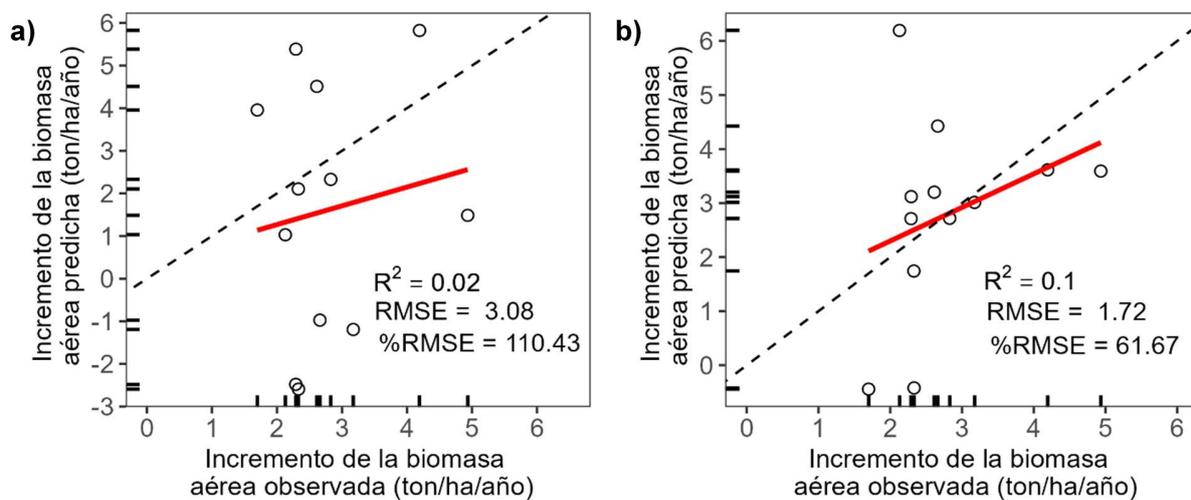


Figura 3.6. Resultados de la estimación de la biomasa aérea a nivel de conglomerado, usando estimaciones de cada año por separado (2013 y 2021) en Kaxil Kiuc, estado de Yucatán, México. a) Validación de los modelos con intercepto igual a 0. b) Validación de los modelos con intercepto estimado. Los puntos representan la biomasa estimada en función de la biomasa observada, la línea roja representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una regresión 1 a 1.

3.1.8. Métodos directos para la estimación del incremento de la biomasa aérea

Al usar las métricas LiDAR del año 2013 y 2021 como un solo conjunto de variables explicativas, se obtuvieron resultados similares en el porcentaje del error (%RMSE) en los modelos con intercepto igual a cero e intercepto estimado. Los errores fueron de 29.39 % y 28.67 % respectivamente, mientras que los valores del coeficiente de determinación R^2 si presentan una mayor diferencia con el valor más bajo de 0.18 con intercepto estimado y 0.92 con el intercepto igual a cero (Tabla 3.4).

La métrica seleccionada por los modelos fue sdCAI en ambos diseños de los modelos, esta métrica está relacionada con la variación de la densidad del dosel. Las métricas del año 2013, que corresponden a LiDAR aéreo no fueron seleccionadas como variables explicativas en ninguno de los modelos.

En el segundo conjunto de variables, donde las variables independientes son las diferencias de cada una de las métricas (2021 – 2013) en el periodo de tiempo evaluado, la precisión del modelo fue mayor con una R^2 igual a 0.97 y un porcentaje de RMSE de 18.55 % en el método del

CAPÍTULO III

intercepto igual a cero. Mientras que, en el modelo con intercepto estimado la presión de a R^2 fue igual a 0.65 y el error similar de 18.44 %.

Las variables seleccionadas para el primer tipo de modelo fueron el incsdCAI y el incxHmax; el primero es la diferencia obtenida de sdCAI (desviación estándar de CAI), la cual está relacionada con la variación en la densidad de cobertura del dosel; el segundo mide el incremento de la métrica de xHmax, la cual representa la altura máxima del dosel. Las variables que fueron significativas en los modelos con el intercepto estimado para estimar el incremento de la biomasa, al igual que en el método del intercepto igual a cero, fueron el incsdCAI y el incxHmax (Tabla 3.4).

Tabla 3.4. Resumen de los modelos obtenidos para la estimación del incremento de la biomasa aérea a nivel de conglomerado usando métricas LiDAR en Kaxil Kiuic, estado de Yucatán, México.

Variable	Tipo de variables predictoras	Tipo de modelo	Variable explicativa	Coeficiente	Error estándar	R^2	RMSE	% RMSE	
Incremento AGB por año	Métricas 2013 y 2021	Intercepto 0	Intercepto	-	-	0.92	0.82	29.39	
			sdCAI 2021	1.89	0.17				
	Diferencia de métricas por año	Intercepto estimado	Intercepto	Intercepto	0.92	1.30	0.18	0.80	28.67
				sdCAI 2021	1.28	0.87			
		Intercepto estimado	Intercepto	Intercepto	-	-	0.97	0.51	18.55
				incsdCAI	31.59	1.88			
Intercepto estimado	Intercepto	incxHmax	incxHmax	-4.79	0.66	0.65	0.51	18.44	
			incsdCAI	29.34	0.65				
Intercepto estimado	Intercepto	incxHmax	incxHmax	-4.41	1.35	0.65	0.51	18.44	
			incsdCAI	29.34	0.65				

3.1.9. Validación de los modelos para estimar el incremento de la biomasa aérea mediante método directos

La precisión de los modelos donde se utilizan los dos conjuntos de métricas por separado (2013 y 2021), no superaron el 7 % en la R^2 , tanto en el modelo con intercepto igual a cero y como en el modelo con intercepto estimado. El resultado de la validación en estos modelos presenta

errores menores a 35 % con respecto a la media de los valores observados, sin embargo, se encontró que para valores altos de las tasas de incremento hay una sobreestimación en estos modelos (Figura 3.7).

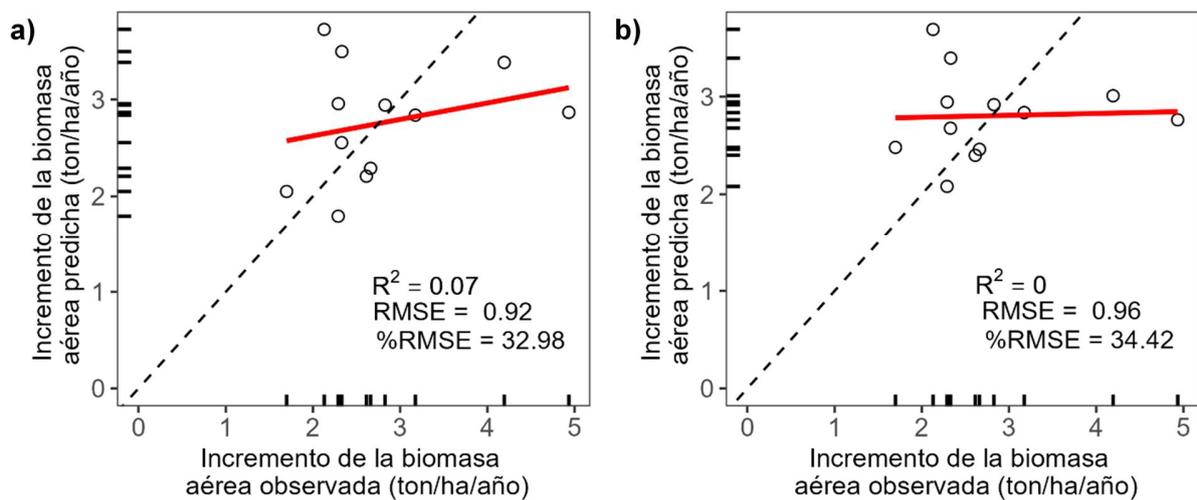


Figura 3.7. Resultados de la validación cruzada para evaluar la precisión de la estimación del incremento de la biomasa aérea a nivel de conglomerado usando métricas de datos LiDAR aéreo y terrestre (2013 y 2021) en Kaxil Kiuic, estado de Yucatán, México. a) Modelo con intercepto a 0. b) Modelo con intercepto estimado. Los puntos representan la biomasa aérea estimada en función de la biomasa aérea observada, la línea azul representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una regresión 1 a 1.

La precisión del modelo usando como variables predictoras las diferencias de las métricas LiDAR del año 2021 y 2013 por año, obtuvo un porcentaje del error de 22.59 % y un valor de R^2 de 0.51 para el modelo con intercepto igual a cero, mientras que en el modelo con intercepto estimado se obtuvo un porcentaje de error del 27.25 % y R^2 igual a 0.33 (Figura 3.8).

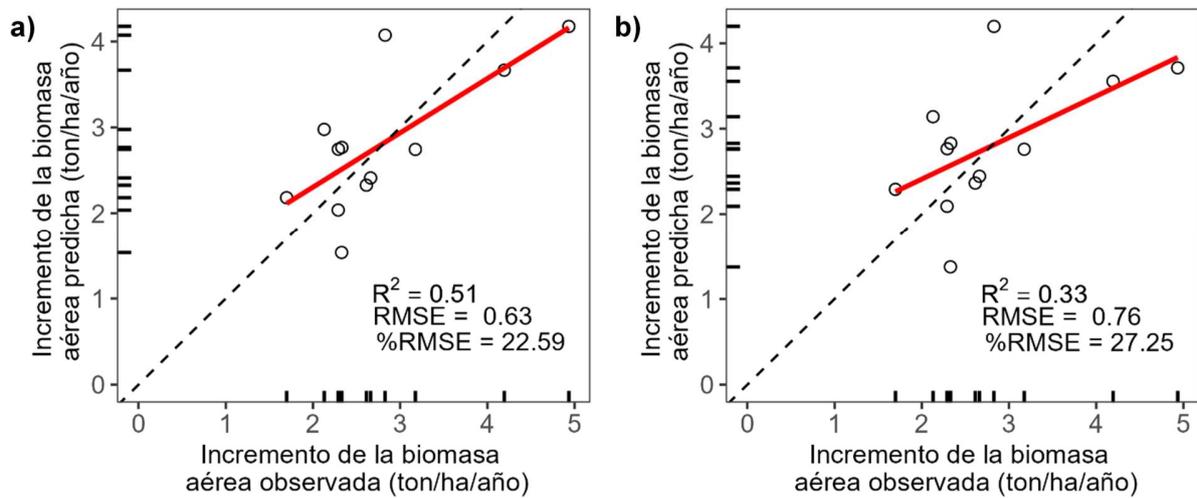


Figura 3.8. Resultados de la validación cruzada para evaluar la precisión de la estimación del incremento de la biomasa aérea a nivel de conglomerado usando diferencias de métricas de datos LiDAR aéreo y terrestre (2013 y 2021) en Kaxil Kiuc, estado de Yucatán, México. a) Modelo con intercepto igual a 0. b) Modelo con intercepto estimado. Los puntos representan la biomasa aérea estimada en función de la biomasa aérea observada, la línea azul representa la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una regresión 1 a 1.

En este estudio el mejor modelo para estimar el incremento de la biomasa fueron los métodos directos de estimación que se ajustan con el intercepto igual a cero, usando el conjunto de todas las métricas de los dos tiempos o la diferencia calculada de las métricas entre los dos años. En cuanto a los conjuntos de métricas predictores, para la estimación del incremento de la biomasa aérea, las diferencias de las métricas se destacaron como los mejores predictores.

CAPITULO IV

4.1. DISCUSIÓN

4.1.1. Biomasa aérea y su incremento del año 2013 a 2021.

En este estudio se encontró una biomasa aérea promedio del bosque tropical seco en Kaxil Kiuic de 109 ton/ha para el año 2013 y 132 ton/ha para el año 2021. Es importante destacar que estos valores son similares a los reportados en otros estudios en la misma región, donde se han reportado valores de biomasa aérea de 100 ton/ha en el mismo tipo de vegetación (Hernández-Stefanoni et al., 2020). Por otro lado, hay que señalar que los resultados son específicos para esta región y podría variar en otros bosques tropicales debido a las condiciones ambientales y el grado de conservación de los bosques.

En los dos años de estudio, se estimó una mayor acumulación de biomasa aérea en edades avanzadas de los bosques. En particular, para edades superiores a 60 años se encontraron valores que superaban las 140 ton/ha en contraste con edades más jóvenes (inferiores a 30 años), las cuales presentaron valores por debajo de esos niveles de biomasa aérea (Figura 3.1). Estos resultados concuerdan con otro estudio que indica que la edad de los bosques es una variable que tiene una gran asociación con la biomasa aérea (Hernández-Stefanoni et al., 2011).

Los resultados también muestran un aumento de la biomasa aérea entre 2013 y 2021 con una tasa de incremento anual de 2.79 ton/ha/año (Tabla 3.1). Este valor se encuentra dentro de los rangos de tasas de incremento reportadas en otros estudios de bosques tropicales, que van desde 1.1 hasta 4.7 ton/ha/año dependiendo de la edad de sucesión (Aryal et al., 2014). Se ha observado que los mayores incrementos en bosques se presentan en edades jóvenes, con valores de 2.9 a 3.0 ton/ha/año (Aryal et al., 2014), mientras que para bosques de edades mayores a 15 años, reportan tasas de incremento de 1.9 ton/ha/año (Calvo-Rodriguez et al., 2021). Los resultados encontrados no mostraron una tendencia clara en el incremento de la biomasa con respecto a la edad sucesional. Si bien no se encontró esta asociación con los incrementos absolutos de la biomasa aérea, el incremento dado como un porcentaje con relación a la biomasa aérea en el tiempo 1 se asoció significativa y negativamente con la edad del bosque. La disminución del aumento de la biomasa en relación con la edad puede estar explicada en gran parte por la disminución gradual del crecimiento relativo de los árboles, además, es importante

considerar que los cambios de biomasa pueden variar según las condiciones ambientales de los bosques (Aryal et al., 2014; Chazdon et al., 2006).

Si bien los cambios de biomasa aérea son en gran parte explicada por la edad (Dupuy et al., 2012), los cambios también pueden explicarse por procesos como la mortalidad y el reclutamiento de individuos (Calvo-Rodriguez et al., 2021; Chazdon et al., 2006). El reclutamiento es crucial en bosques jóvenes para las tasas de incremento de biomasa aérea, mientras que en bosques maduros, el crecimiento de árboles es más relevante (Aryal et al., 2014). Por otro lado, la disminución en la biomasa se atribuye a la pérdida de árboles o ramas, originando huecos en el dosel, especialmente en los bosques de edad avanzada (Feeley et al., 2007). Los resultados muestran mayor incremento relativo de la biomasa en edades más jóvenes, lo cual puede estar asociado a factores como el rápido reclutamiento de las especies en los bosques más jóvenes que de mayor edad (Aryal et al., 2014). Estos procesos demográficos son cruciales en la dinámica de bosques tropicales y pueden afectar las estimaciones de incremento de biomasa en estudios longitudinales, es decir, con mediciones en diferentes tiempos.

4.1.2. Modelos para la estimación de la biomasa aérea con datos LiDAR

En cuanto al uso de datos LiDAR para estimar la biomasa aérea y su incremento, se sabe que los sensores LiDAR proveen datos que representan con gran precisión los detalles de la estructura de los bosques tropicales y tienen un alto potencial de mejorar la precisión de las estimaciones de variables dasométricas (Ortiz-Reyes et al., 2015), de la biomasa aérea (Asner et al., 2012; Hernández-Stefanoni et al., 2014, 2020), así como de las tasas de incremento de la biomasa aérea (McRoberts et al., 2015). Sin embargo, es importante destacar que las características de los datos LiDAR, como la densidad de puntos o la superficie muestreada para realizar las estimaciones, pueden ser factores que afecten la precisión de las estimaciones de los atributos del bosque. Se ha demostrado una mayor precisión al aumentar la superficie de la muestra de 400 m² a 1000 m² (Hernández-Stefanoni et al., 2014) o bien de 314 a 1964 m² (Frazer et al., 2011).

En este estudio se evaluó el efecto de considerar una superficie de 0.02 ha o de 0.16 ha dentro de los conglomerados, sobre la estimación de la biomasa con datos LiDAR aéreo. Esto con el objeto de homologar los datos obtenidos en el año 2021 con un sensor de LiDAR terrestre

(transectos dentro del conglomerado) con los datos obtenidos en 2013 con un sensor de LiDAR aéreo. El tipo de sensor LiDAR y las diferencias en la toma de datos implican una limitación para realizar una comparación directa de los valores estimados por estos sensores. No se encontraron diferencias significativas en las métricas de LiDAR aéreo empleadas en ambas superficies de datos.

Por otro lado, las métricas de los dos sensores utilizados en este estudio, (LiDAR terrestre o LiDAR aéreo) pueden ser comparables. La Rue et al., (2002) reportaron una alta asociación entre algunas métricas empleadas para cuantificar la estructura de la vegetación con diferentes plataformas LiDAR en una gran variedad de bosques. Entre estas métricas se encuentran medidas relacionadas a alturas, coberturas, aberturas del dosel e índices de heterogeneidad del dosel (LaRue et al., 2020).

En este estudio se usaron métricas LiDAR que representan medidas de alturas y densidad del dosel y pueden estar relacionadas con la ausencia de biomasa cuando estas variables son iguales a cero. Por lo tanto, resulta justificable el uso de modelos con intercepto igual a cero, en lugar de intercepto estimado por el modelo. Los resultados mostraron mejores ajustes con el intercepto igual a 0 en todas las estimaciones, con mejoras desde el 3 % con el LiDAR aéreo hasta 74 % en la estimación del incremento de la biomasa aérea usando métricas de 2013 y 2021. La elección de un modelo con un intercepto igual a cero encuentra su justificación en ciertos escenarios específicos. Estudios han subrayado la utilidad en contextos donde la relación de la variable se asemeja a un punto de partida nulo (Schlund et al., 2020). El segundo enfoque empleó un modelo con un intercepto estimado por el propio modelo, lo que proporciona una mayor flexibilidad en la adaptación a las peculiaridades de los datos y permite capturar posibles desviaciones de la línea de base. Esta aproximación se considera valiosa en contextos donde las condiciones son menos predecibles y se espera que la relación entre las variables sea más variable.

Los resultados de estas comparaciones en el ajuste del intercepto de los modelos también revelaron la presencia de valores negativos en los interceptos estimados. Específicamente, se observaron valores negativos en las estimaciones de la biomasa aérea en 2013 y la biomasa aérea en 2021. En el caso de este último, el valor del intercepto estimado se situó en -577 como punto de partida del modelo. Por ello, en las estimaciones de biomasa con valores bajos de las métricas seleccionadas se obtuvieron subestimaciones e incluso valores negativos en la estimación de la biomasa aérea. Por otro lado, en el modelo con intercepto igual a 0 se observan

mayores sobreestimaciones de los valores cercanos a 0, esta relación concuerda con algunos autores quienes mencionan que el modelo puede ser menos preciso si los datos tienen una gran variabilidad en los datos cercanos a cero (Schlund et al., 2020).

En la validación de los modelos entre ambos enfoques en el intercepto fueron muy similares en los valores de R^2 , con una única notable diferencia de un valor bajo de 0.18 en la estimación del incremento de la biomasa aérea usando diferencias de métricas como variables explicativas. No obstante, los valores de RMSE generalmente resultaron más bajos en los modelos con intercepto estimado, con la excepción de la evaluación del modelo del incremento de la biomasa utilizando diferencias de métricas, donde el menor error se encontró en el modelo con intercepto igual a 0. Esto indicó que, en este caso particular, el modelo con intercepto fijo de 0 superó a los modelos con intercepto estimado en términos de precisión, presentando un rendimiento más óptimo en la estimación del incremento de la biomasa con hasta el 4%. Estos resultados de las validaciones dependen del número de observaciones (Picard & Cook, 1984), utilizar un método diferente en lugar de la validación cruzada, podría variar los resultados obtenidos en este trabajo, sin embargo, el número reducido de observaciones limita el uso de otros métodos, como por ejemplo la partición de datos para un conjunto de validación independiente.

Los resultados de las estimaciones de la biomasa aérea, usando datos de LiDAR, concuerdan con otros estudios realizados en la misma región del área de estudio. En este trabajo se obtuvieron valores de R^2 entre 0.94 y 0.91 en el 2013 con LiDAR aéreo y entre 0.96 a 0.89 en el año 2021 con LiDAR terrestre, los cuales son similares a los valores de R^2 reportados por estudios previos usando métricas de datos LiDAR aéreo: 0.88 (Reyes-Palomeque et al., 2019) y 0.89 (Hernández-Stefanoni et al., 2014). De igual manera, los errores de la validación en este estudio, entre 27 a 33 ton/ha en 2013 y aproximadamente 34 ton/ha en 2021, se encuentran dentro del rango de errores encontrados anteriormente, entre 14.47 ton/ha y 37.4 ton/ha de biomasa aérea (Hernández-Stefanoni et al., 2014; Reyes-Palomeque et al., 2019).

En cuanto a las métricas que fueron significativas en los modelos, se encontró que tanto las métricas relacionadas a alturas como mHbar, mHmax o sdHbar, son buenos estimadores de la biomasa aérea. Estos resultados apoyan las afirmaciones de diferentes autores sobre las asociaciones de LiDAR con la estructura de la vegetación arbórea (Almeida et al., 2019; Hernández-Stefanoni et al., 2020; Ortiz-Reyes et al., 2015; Urbazaev et al., 2018). En el caso de las medidas relacionadas con la cobertura del dosel (mCAI y sdCAI), se encontraron asociaciones significativas únicamente en las estimaciones del año 2021. El CAI es un índice

obtenido a partir de la suma de las superficies del dosel a lo largo de la toda la altura del dosel (Parker et al., 2004) por lo que los resultados en este trabajo pueden estar influenciados en cierto grado, por la resolución del sensor. La mayor densidad de puntos LiDAR (por vóxel) en el 2021, que, en el 2013 pudo ser un factor para que esta métrica tuviera un mayor aporte que otras métricas en el 2021.

A través de los resultados obtenidos, se respalda la afirmación de que la capacidad del sensor terrestre coincide con las observaciones previas realizadas por otros investigadores en cuanto a su capacidad para recopilar información del dosel con gran precisión y una alta densidad de puntos (Parker et al., 2004; Stark et al., 2012).

4.1.3. Modelos para estimar el incremento de la biomasa aérea con datos LiDAR

La estimación de las tasas de incremento de la biomasa con el método indirecto no muestra un buen ajuste entre los valores predichos y los valores observados, estos errores pueden estar fuertemente influenciados por los errores generados por cada estimación individual por año (2013 y 2021). En otros estudios similares, donde consideran un método indirecto para la estimación del incremento de la biomasa usando modelos generados para un único tiempo, han encontrado ajustes de hasta 0.67 en la R^2 (McRoberts et al., 2015) en un bosque de Noruega, en comparación con nuestros resultados que fue menores a 0.1. Las diferencias observadas en los resultados de este estudio pueden atribuirse a diversos factores, que abarcan desde la variabilidad en la complejidad de la estructura del dosel y la composición de especies hasta las complejas dinámicas de incremento de biomasa dentro de los bosques tropicales (Chazdon et al., 2006). Esta variabilidad y complejidad son elementos inherentes a los ecosistemas forestales y pueden influir significativamente en la precisión de nuestras estimaciones. Además, los procesos de crecimiento y mortalidad de árboles, la sucesión vegetal y las respuestas a factores ambientales como el clima y la disponibilidad de nutrientes pueden variar considerablemente de un bosque a otro y de un año a otro. Estas variaciones temporales y espaciales contribuyen a la incertidumbre en nuestras estimaciones.

Por otro lado, comparados con el método indirecto, los métodos directos planteados en este estudio mejoraron la precisión de las estimaciones de los incrementos de la biomasa aérea. En el primer conjunto de variables explicativas, que incluyen las métricas de los años 2013 y 2021, se obtuvo una R^2 de 0.18 y 0.92 para el modelo con intercepto estimado e intercepto igual a cero

respectivamente. En un estudio similar, mediante este método para estimar el incremento de la biomasa y usando datos de imágenes ópticas se obtuvieron valores de R^2 similares para ambos métodos desde 0.56 a 0.61 (Puliti et al., 2021). Estas evidencias muestran la factibilidad que pueden representar este método en la estimación de los incrementos de la biomasa aérea. Sin embargo, los errores encontrados en los modelos fueron relativamente bajos (entre 28 y 29 % de RMSE) en el proceso de la validación cruzada no se encontraron ajustes significativos entre los valores predichos y observados (Figura 3.7). Este resultado pudo deberse a diferentes factores que influyen en la capacidad de detectar los cambios en la estructura de la vegetación. Uno de estos puede estar relacionado al método de la validación y el número de observaciones usadas para ajustar los modelos, ya que la validación cruzada es un proceso de permutación de una sola observación a la vez, al permutar observaciones modifica la variabilidad de los datos para entrenar los modelos, este efecto puede ser más importante cuando el número de la muestra es reducido.

Dentro de los diversos factores a considerar, también es relevante analizar las asociaciones generadas en los modelos con respecto a las métricas. A pesar de que en nuestro estudio utilizamos datos de los años 2013 y 2021, es importante destacar que en el proceso de ajuste del modelo se incorporó únicamente una métrica del año 2021, específicamente, sdCAI, como una variable significativa (Tabla 3.4). Esta elección podría estar relacionada con el hecho de que sdCAI refleja la variación en la densidad de puntos de LIDAR, y esta variación podría estar asociada con un aumento en la variabilidad del dosel, particularmente en respuesta a un incremento positivo de la biomasa. Aunque existen pruebas que respaldan la utilidad de las estimaciones basadas en datos unitemporales para evaluar cambios en la biomasa aérea, la literatura también ha evidenciado que las estimaciones mejoran significativamente cuando se emplean datos de dos o más momentos temporales para predecir el incremento de la biomasa. Por lo tanto, subrayamos la importancia de evaluar el método de integración de datos bitemporales siempre que sea factible, ya que esta aproximación puede proporcionar una comprensión más completa y precisa de los cambios en la biomasa y la dinámica del dosel forestal (Puliti et al., 2021).

Por último, en cuanto a los modelos para la estimar el incremento de la biomasa aérea de 2013 a 2021 mediante un conjunto de datos integrados por las diferencias de las métricas, se encontraron mejores ajustes de los modelos y errores más reducidos de las estimaciones en comparación con los demás métodos planteados. Por otro lado, es importante considerar que se analizan diversas plataformas para la recopilación de datos, cada una con sus ventajas y

desventajas. El LIDAR terrestre, por ejemplo, destaca por su capacidad para minimizar la oclusión desde dentro del dosel forestal, lo que facilita la evaluación de la estructura interna del dosel. En cambio, el LIDAR aéreo tiende a ser más efectivo en la evaluación del dosel externo (LaRue et al., 2020). Sin embargo, las métricas que se obtuvieron para ambas plataformas corresponden a las mismas formulaciones estadísticas, esto permite la integración de nuevas variables a los modelos de la estimación de la biomasa aérea basadas en las diferencias de las métricas obtenidas como se ha hecho en otros estudios usando datos de percepción remota (McRoberts et al., 2015; Puliti et al., 2021; Schlund et al., 2020; Stark et al., 2012).

La elección de utilizar la diferencia entre las métricas en lugar de emplear las métricas por sí solas como variables independientes se basa en la capacidad de este enfoque para proporcionar una evaluación más robusta y precisa del incremento de la biomasa en los bosques. En primer lugar, al considerar las diferencias entre las métricas, podemos eliminar factores de ruido o variabilidad que pueden estar presentes en cada métrica de manera independiente. Esto ayuda a reducir el impacto de las posibles fuentes de error en las mediciones individuales. En segundo lugar, al calcular la diferencia entre las métricas, estamos capturando información adicional sobre la dinámica del dosel forestal que podría pasarse por alto si se utilizaran las métricas de manera aislada. Esta información adicional puede incluir cambios sutiles pero significativos en la estructura o la biomasa que pueden ser difíciles de detectar cuando se observan las métricas de forma individual.

Los resultados encontrados se aproximan a los resultados reportados por otros autores (McRoberts et al., 2015) con la misma metodología, donde muestran ajustes significativos en la estimación de la biomasa aérea. Las métricas que se involucraron mediante este método abarcan tanto medidas de alturas como de coberturas del dosel, específicamente la variación de la altura máxima y la variación de la desviación estándar del CAI. Esto indica la importancia de la variación de la densidad del dosel detectada por LiDAR en la detección de la variación de la biomasa aérea. De igual forma, los cambios en la estructura vertical, medida con la altura máxima del dosel, complementa la estimación de las variaciones de biomasa aérea. Los resultados aportan positivamente a los estudios que han resaltado la importancia de detectar la variación de la estructura del dosel para realizar estimaciones de la biomasa y sus tasas de incremento en los bosques tropicales y que esta variación puede ser medida con gran precisión mediante datos LiDAR con plataformas terrestres (Stark et al., 2012).

En el complejo escenario de los bosques tropicales, el dosel forestal cambia constantemente, impulsado por una serie de factores dinámicos. Estos elementos abarcan desde procesos naturales como el crecimiento vegetativo, la pérdida de individuos, tallos o ramas y la incorporación de nuevas especies, hasta las modificaciones estructurales causadas por factores antropogénicos. En este trabajo se exploraron las características del dosel y su papel en la dinámica de la biomasa aérea en un bosque tropical seco. Entender cómo el dosel responde a estas fluctuaciones y cómo estas respuestas influyen en el almacenamiento y liberación de carbono es esencial para indagar en los mecanismos que regulan estos ecosistemas. Principalmente, se ha reforzado que la detección de las características estructurales del dosel mediante percepción remota y sensores LiDAR es una herramienta útil para cuantificar la estructura de la vegetación en los bosques, esto sucede gracias a que emplea una nube tridimensional de puntos que permiten cuantificar diferentes características del dosel (Ortiz-Reyes et al., 2015; Parker et al., 2004).

Es importante destacar que los resultados pueden tener variaciones por diferentes factores, como el estado actual de los bosques, el historial y la intensidad de las perturbaciones, la dinámica de las variaciones estructurales y de composición en las diferentes etapas sucesionales. Adicionalmente, pueden sumarse variaciones por los métodos empleados y la robustez del estudio en la calidad y cantidad de los datos. Con el número de muestras usadas en nuestro estudio, nosotros obtuvimos sólidos resultados estadísticos con los procedimientos empleados.

En el ámbito de las estimaciones de la biomasa aérea, se ha notado una diversidad de enfoques a lo largo de los años, todos centrados en un único punto en el tiempo. Sin embargo, es importante señalar que el nivel de investigación y exploración de las tasas de incremento ha sido significativamente menor, especialmente en el contexto de los bosques tropicales secos (Aryal et al., 2014). Esto podría atribuirse a la complejidad de los bosques tropicales (Chazdon, 2008), que presentan un desafío considerable para estudiar la dinámica de la acumulación de carbono debido a la multitud de factores que influyen en este proceso. El trabajo actual establece un estándar en la investigación sobre las relaciones estructurales de los bosques, gracias a sus métodos y resultados. Este enfoque ofrece una base sólida para comprender procesos cruciales como la dinámica del carbono. Dado que el carbono desempeña un papel esencial en la mitigación del cambio climático, el conocimiento ganado a través de este tipo de investigaciones puede resultar invaluable para trazar estrategias efectivas en la lucha contra este fenómeno global.

CAPITULO V

5.1. CONCLUSIONES

Este trabajo presenta uno de los primeros acercamientos a la estimación de las tasas de incremento de la biomasa en un bosque tropical seco a través de la percepción remota, específicamente en uno de tipo subcaducifolio. Los resultados encontrados muestran la capacidad de la percepción remota, específicamente de sensores activos LiDAR, de brindar una estimación precisa de la biomasa aérea y sus tasas de incremento mediante el ajuste de modelos estadísticos.

La percepción remota es una herramienta que promete enriquecer los estudios de los bosques tanto a niveles locales, regionales e incluso globales. En este estudio, se identificaron variables significativas para la estimación de la biomasa aérea y sus tasas de incremento. Estas variables capturan con precisión la estructura del dosel a través de una nube de puntos, incluyendo la altura (xH_{max} , mH_{bar}) y la densidad del dosel (CAI). Se observó que las variaciones en estas métricas se correlacionaron con las variaciones en la biomasa aérea estimada a partir de los datos de campo. Esto respalda la importancia de estas métricas como indicadores fiables de la biomasa aérea y su evolución. En general, los resultados de los modelos obtenidos indican que la estimación de la densidad del dosel en columnas verticales está estrechamente relacionada con la acumulación de la materia orgánica de los árboles.

Los modelos presentados en este estudio tuvieron los resultados esperados, con porcentajes altos de precisión para estimar la biomasa aérea y la tasa de incremento de la biomasa. En particular, sobre la hipótesis planteada acerca de la precisión de las estimaciones de la biomasa aérea usando LiDAR aéreo, se esperaba que las métricas usadas se asociaran con la biomasa aérea almacenada. Las métricas de altura (mH_{max} y mH_{bar}) demostraron la capacidad de ajustar un modelo con R^2 mayor a 0.90.

Por otro lado, se esperaba que el LiDAR terrestre también se asociara con la biomasa aérea de forma similar al LiDAR aéreo, los resultados indican que, pese a las diferencias en ambas plataformas, LiDAR es buen predictor de la biomasa aérea gracias a que captura la estructura de la vegetación en forma tridimensional. Sin embargo, una diferencia que se pudo observar en estos resultados es el tipo de métricas que son seleccionadas en cada plataforma, para LiDAR aéreo las métricas se relacionaron a las alturas del dosel (mH_{bar} y mH_{max}), mientras que para

CAPÍTULO V

LiDAR terrestre las métricas seleccionadas también se asociaron con la densidad del dosel y su variación (sdCAI y mCAI), esto puede ser producto de la capacidad diferencial de cada sensor de capturar la cobertura del dosel. Comparado con la plataforma aérea, en la terrestre hay una mayor densidad de puntos capturados en todo el dosel, especialmente en las partes más profundas donde se encuentra la mayor cantidad de biomasa aérea almacenada.

En cuanto a la hipótesis planteada sobre las estimaciones de las tasas de incremento de la biomasa aérea, se esperaba que las métricas por sí solas o bien de manera conjunta explicaran gran parte de la variación de los valores obtenidos mediante mediciones en campo. Los resultados mostraron una mejor precisión cuando se usaron las métricas de forma conjunta, específicamente como una tasa de incremento de las métricas. Esto apoya a la hipótesis planteada de que la variación estructural detectada por los sensores se asocia con la variación en los almacenes de carbono en el bosque tropical seco comprendido en este estudio.

Para concluir, este trabajo se centra en la habilidad de llevar a cabo estimaciones precisas de biomasa aérea utilizando técnicas avanzadas de percepción remota. Además, destaca la importancia de estas estimaciones al proporcionar información valiosa sobre la estructura y composición de la vegetación. Este enfoque permite una comprensión más profunda de cómo las variaciones en la biomasa aérea pueden estar relacionadas con las características del dosel, como la altura y la densidad, lo que a su vez contribuye a la investigación y la gestión de ecosistemas de manera más efectiva. Estos hallazgos subrayan la utilidad continua de la percepción remota en la monitorización y comprensión de los ecosistemas terrestres.

5.2. PERSPECTIVAS

Este estudio se ha centrado en el análisis de estimaciones de biomasa aérea mediante el uso de sensores activos LiDAR, logrando calibrar modelos a partir de datos de campo recolectados durante el mismo período. A pesar de los avances logrados en la creación de modelos para estimar la biomasa aérea en un solo año y evaluar el incremento entre dos períodos, es importante señalar que existen oportunidades para ampliar y enriquecer este enfoque en investigaciones futuras.

Uno de los caminos a explorar es la inclusión de un mayor volumen de datos, lo que permitiría una representación más sólida de las diversas etapas de sucesión presentes en estos bosques. Esto proporcionaría una visión más completa de cómo la biomasa aérea evoluciona a lo largo del tiempo y cómo se relaciona con la estructura del dosel.

Además, se podría considerar la recopilación de datos con la misma metodología en momentos diferentes, lo que brindaría una valiosa perspectiva temporal. Estos datos secuenciales tendrían el potencial de representar de manera más precisa las variaciones en la estructura del dosel y la biomasa aérea dentro de los bosques a lo largo de diferentes años, lo que enriquecería aún más nuestra comprensión de estos ecosistemas.

Además, es relevante explorar la integración de una gama más amplia de herramientas de percepción remota para enriquecer la captura de características vegetales. Por ejemplo, la incorporación de imágenes ópticas o datos de radar podría proporcionar una visión más completa y detallada de la vegetación. Estas herramientas complementarias tienen el potencial de mejorar significativamente nuestra comprensión de los bosques y su evolución.

Adicionalmente, esta integración de diversas fuentes de datos puede abrir la puerta a la creación de mapas más detallados a nivel local o regional, aprovechando la información obtenida a través de LiDAR y complementándola con datos de otras fuentes. Esto permitiría una evaluación más precisa de la biomasa aérea y la estructura del dosel en diferentes escalas geográficas, lo que sería de gran utilidad para la gestión y conservación de los recursos forestales.

Por otra parte, al evaluar atributos de la estructura forestal y su variabilidad, resulta esencial considerar aspectos adicionales como las fluctuaciones en la precipitación, los cambios en la temperatura, la exposición a perturbaciones y otros factores que interactúan de manera directa o indirecta con la configuración del dosel en los bosques. Estas relaciones complejas deben ser

CAPÍTULO V

sometidas a evaluaciones exhaustivas en múltiples entornos forestales, ya que su impacto puede variar y manifestarse de diversas formas en comparación con los resultados obtenidos en este estudio.

BIBLIOGRAFÍA

- Almeida, D. R. A. de, Stark, S. C., Shao, G., Schietti, J., Nelson, B. W., Silva, C. A., Gorgens, E. B., Valbuena, R., Papa, D. de A., & Brancalion, P. H. S. (2019). Optimizing the Remote Detection of Tropical Rainforest Structure with Airborne Lidar: Leaf Area Profile Sensitivity to Pulse Density and Spatial Sampling. *Remote Sensing*, *11*(1), 92. <https://doi.org/10.3390/rs11010092>
- Andres-Mauricio, J., Valdez-Lazalde, J. R., George-Chacón, S. P., & Hernández-Stefanoni, J. L. (2021). Mapping structural attributes of tropical dry forests by combining Synthetic Aperture Radar and high-resolution satellite imagery data. *Applied Vegetation Science*, *24*(2). <https://doi.org/10.1111/avsc.12580>
- Aryal, D. R., De Jong, B. H. J., Ochoa-Gaona, S., Esparza-Olguin, L., & Mendoza-Vega, J. (2014). Carbon stocks and changes in tropical secondary forests of southern Mexico. *Agriculture, Ecosystems & Environment*, *195*, 220–230. <https://doi.org/10.1016/j.agee.2014.06.005>
- Asner, G. P., Mascaro, J., Muller-Landau, H. C., Vieilledent, G., Vaudry, R., Rasamoelina, M., Hall, J. S., & van Breugel, M. (2012). A universal airborne LiDAR approach for tropical forest carbon mapping. *Oecologia*, *168*(4), 1147–1160. <https://doi.org/10.1007/s00442-011-2165-z>
- Balvanera, P. (2012). Los servicios ecosistémicos que ofrecen los bosques tropicales. *Ecosistemas*, *21*(1–2), 136–147. <https://doi.org/10.7818/re.2014.21-1-2.00>
- Begon, M., Townsend, C. R., & Harper, J. L. (2006). *Ecology From Individuals to Ecosystems* (4th ed.).
- Bonan, G. B. (2008). Forests and climate change: Forcings, feedbacks, and the climate benefits of forests. *Science*, *320*(5882), 1444–1449. <https://doi.org/10.1126/science.1155121>
- Calvo-Rodriguez, S., Sánchez-Azofeifa, G. A., Durán, S. M., Espírito-Santo, M. M. Do, & Nunes, Y. R. F. (2021). Dynamics of Carbon Accumulation in Tropical Dry Forests under Climate Change Extremes. *Forests* *2021*, *Vol. 12*, *Page 106*, *12*(1), 106. <https://doi.org/10.3390/F12010106>

BIBLIOGRAFÍA

- Campbell, G. S., & Norman, J. M. (1989). The description and measurement of plant canopy structure. En *Plant Canopies* (pp. 1–20). Cambridge University Press. <https://doi.org/10.1017/CBO9780511752308.002>
- Cartus, O., Kellndorfer, J., Walker, W., Franco, C., Bishop, J., Santos, L., & Fuentes, J. M. M. (2014). A national, detailed map of forest aboveground carbon stocks in Mexico. *Remote Sensing*, 6(6), 5559–5588. <https://doi.org/10.3390/rs6065559>
- Ceballos, G., & Garcia, A. (1995). Conserving Neotropical Biodiversity: The Role of Dry Forests in Western Mexico. *Conservation Biology*, 9(6), 1349–1356. <https://doi.org/10.1046/j.1523-1739.1995.09061349.x>
- Chave, J., Andalo, C., Brown, S., Cairns, M. A., Chambers, J. Q., Eamus, D., Fölster, H., Fromard, F., Higuchi, N., Kira, T., Lescure, J. P., Nelson, B. W., Ogawa, H., Puig, H., Riéra, B., & Yamakura, T. (2005). Tree allometry and improved estimation of carbon stocks and balance in tropical forests. *Oecologia*, 145(1), 87–99. <https://doi.org/10.1007/s00442-005-0100-x>
- Chave, J., Condit, R., Lao, S., Caspersen, J. P., Foster, R. B., & Hubbell, S. P. (2003). Spatial and temporal variation of biomass in a tropical forest: Results from a large census plot in Panama. *Journal of Ecology*, 91(2), 240–252. <https://doi.org/10.1046/j.1365-2745.2003.00757.x>
- Chazdon, R. L. (2008). *Chance and Determinism in Tropical Forest Succession*. <https://api.semanticscholar.org/CorpusID:56076966>
- Chazdon, R. L., Letcher, S. G., Van Breugel, M., Martínez-Ramos, M., Bongers, F., & Finegan, B. (2006). Rates of change in tree communities of secondary Neotropical forests following major disturbances. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 362(1478), 273–289. <https://doi.org/10.1098/RSTB.2006.1990>
- CONAFOR, & SEMARNAT. (2012). *Inventario Nacional Forestal y de Suelos, México 2004-2009*.
- Dubayah, R. O., & Drake, J. B. (2000). Lidar Remote Sensing for Forestry. *Journal of Forestry*, 98(6), 44–46. <https://doi.org/10.1093/jof/98.6.44>
- Duncanson, L., Armston, J., Disney, M., Avitabile, V., Barbier, N., Calders, K., Carter, S., Chave, J., Herold, M., MacBean, N., McRoberts, R., Minor, D., Paul, K., Réjou-Méchain, M.,

- Roxburgh, S., Williams, M., Albinet, C., Baker, T., Bartholomeus, H., ... Margolis, H. (2021). *Aboveground Woody Biomass Product Validation: Good Practices Protocol*. <http://repository.si.edu/xmlui/handle/10088/110741>
- Dupuy, J. M., Hernández-Stefanoni, J. L., Hernández-Juárez, R. A., Tetetla-Rangel, E., López-Martínez, J. O., Leyequién-Abarca, E., Tun-Dzul, F. J., & May-Pat, F. (2012). Patterns and Correlates of Tropical Dry Forest Structure and Composition in a Highly Replicated Chronosequence in Yucatan, Mexico. *Biotropica*, *44*(2), 151–162. <https://doi.org/10.1111/j.1744-7429.2011.00783.x>
- Duran, R., & Méndez, M. (Eds.). (2010). *Biodiversidad y Desarrollo Humano en Yucatán*. CICY, PPD-FMAM, CONABIO, SEDUMA. 496 pp.
- EPA. (2023). *Inventory of U.S. Greenhouse Gas Emissions and Sinks: 1990-2021*. U.S. Environmental Protection Agency, EPA 430-R-23-002.
- Espinosa, C. I. (2006). Bosques tropicales secos de la región Pacífico Ecuatorial: diversidad, estructura, funcionamiento e implicaciones para la conservación. *Geology in China*, *33*(3), 626–631.
- Feeley, K. J., Davies, S. J., Ashton, P. S., Bunyavejchewin, S., Nur Supardi, M. N., Kassim, A. R., Tan, S., & Chave, J. (2007). The role of gap phase processes in the biomass dynamics of tropical forests. *Proceedings of the Royal Society B: Biological Sciences*, *274*(1627), 2857. <https://doi.org/10.1098/RSPB.2007.0954>
- Flores, J. S., & Espejel, M. I. (1994). Tipos de vegetación de la Península de Yucatán. En *Etnoflora Yucatanense*. Universidad Autónoma de Yucatán. 135 pp.
- Flores-Guido, J., Durán, R., & Ortiz, J. (2010). Comunidades terrestres. Comunidades vegetales terrestres. En R. Durán & M. E. Méndez (Eds.), *Biodiversidad y Desarrollo Humano en Yucatán* (pp. 125–129).
- Frangi, J. L., & Lugo, A. E. (1985). Ecosystem Dynamics of a Subtropical Floodplain Forest Published by: Ecological Society of America ECOSYSTEM DYNAMICS OF A SUBTROPICAL. *Ecological Monograph*, *55*(3), 351–369.

BIBLIOGRAFÍA

- Frazer, G. W., Magnussen, S., Wulder, M. A., & Niemann, K. O. (2011). Simulated impact of sample plot size and co-registration error on the accuracy and uncertainty of LiDAR-derived estimates of forest stand biomass. *Remote Sensing of Environment*, 115(2), 636–649. <https://doi.org/10.1016/j.rse.2010.10.008>
- Friedlingstein, P., O'Sullivan, M., Jones, M. W., Andrew, R. M., Gregor, L., Hauck, J., Le Quéré, C., Lujikx, I. T., Olsen, A., Peters, G. P., Peters, W., Pongratz, J., Schwingshackl, C., Sitch, S., Canadell, J. G., Ciais, P., Jackson, R. B., Alin, S. R., Alkama, R., ... Zheng, B. (2022). Global Carbon Budget 2022. *Earth System Science Data*, 14(11), 4811–4900. <https://doi.org/10.5194/essd-14-4811-2022>
- Frolking, S., Palace, M. W., Clark, D. B., Chambers, J. Q., Shugart, H. H., & Hurtt, G. C. (2009). Forest disturbance and recovery: A general review in the context of spaceborne remote sensing of impacts on aboveground biomass and canopy structure. *Journal of Geophysical Research: Biogeosciences*, 114(3). <https://doi.org/10.1029/2008JG000911>
- García, E. (1973). *Modificaciones al sistema de clasificación climática de Köppen*. México.
- George-Chacón, S. P., Dupuy, J. M., Peduzzi, A., & Hernandez-Stefanoni, J. L. (2019). Combining high resolution satellite imagery and lidar data to model woody species diversity of tropical dry forests. *Ecological Indicators*, 101(December 2018), 975–984. <https://doi.org/10.1016/j.ecolind.2019.02.015>
- Gómez-Pompa, A. (1965). La vegetación de México. *Boletín de la Sociedad Botánica de México*, 29, 76–120.
- Griscom, H. P., & Ashton, M. S. (2011). Restoration of dry tropical forests in Central America: A review of pattern and process. *Forest Ecology and Management*, 261(10), 1564–1579. <https://doi.org/10.1016/j.foreco.2010.08.027>
- Hernández-Stefanoni, J. L., Castillo-Santiago, M. Á., Andres-Mauricio, J., Portillo-Quintero, C. A., Tun-Dzul, F., & Dupuy, J. M. (2021). Carbon stocks, species diversity and their spatial relationships in the yucatán peninsula, Mexico. *Remote Sensing*, 13(16), 1–18. <https://doi.org/10.3390/rs13163179>
- Hernández-Stefanoni, J. L., Castillo-Santiago, M. Á., Mas, J. F., Wheeler, C. E., Andres-Mauricio, J., Tun-Dzul, F., George-Chacón, S. P., Reyes-Palomeque, G., Castellanos-Basto, B., Vaca,

- R., & Dupuy, J. M. (2020). Improving aboveground biomass maps of tropical dry forests by integrating LiDAR, ALOS PALSAR, climate and field data. *Carbon Balance and Management*, 15(1), 15. <https://doi.org/10.1186/s13021-020-00151-6>
- Hernández-Stefanoni, J. L., & Dupuy, J. M. (2007). Mapping species density of trees, shrubs and vines in a tropical forest, using field measurements, satellite multispectral imagery and spatial interpolation. *Biodiversity and Conservation*. <https://doi.org/10.1007/s10531-007-9182-6>
- Hernández-Stefanoni, J. L., Dupuy, J. M., Johnson, K. D., Birdsey, R., Tun-Dzul, F., Peduzzi, A., Caamal-Sosa, J. P., Sánchez-Santos, G., & López-Merlín, D. (2014). Improving species diversity and biomass estimates of tropical dry forests using airborne LiDAR. *Remote Sensing*, 6(6), 4741–4763. <https://doi.org/10.3390/rs6064741>
- Hernández-Stefanoni, J. L., Dupuy, J. M., Tun-Dzul, F., & May-Pat, F. (2011). Influence of landscape structure and stand age on species density and biomass of a tropical dry forest across spatial scales. *Landscape Ecology*, 26(3), 355–370. <https://doi.org/10.1007/s10980-010-9561-3>
- Hilker, T., Coops, N. C., Newnham, G. J., van Leeuwen, M., Wulder, M. A., Stewart, J., Culvenor, D. S., & Stewart JimStewart, J. (2012). Comparison of Terrestrial and Airborne LiDAR in Describing Stand Structure of a Thinned Lodgepole Pine Forest. *Journal of Forestry*. <https://doi.org/10.5849/jof.11-003>
- Holmes, R. T., & Likens, G. E. (2016). Hubbard Brook: The story of a forest ecosystem. En *Hubbard Brook: The Story of a Forest Ecosystem*. Yale University Press. <https://yalebooks.yale.edu/9780300203646/hubbard-brook>
- Houghton, R. A., Byers, B., & Nassikas, A. A. (2015). A role for tropical forests in stabilizing atmospheric CO₂. *Nature Climate Change*, 5(12), 1022–1023. <https://doi.org/10.1038/nclimate2869>
- Hudak, A. T., Evans, J. S., & Stuart Smith, A. M. (2009). LiDAR Utility for Natural Resource Managers. *Remote Sensing*, 1(4), 934–951. <https://doi.org/10.3390/rs1040934>
- IPCC. (2018a). Resumen para responsables de políticas. En *Calentamiento global de 1,5 °C*. Unidad de Apoyo Técnico del Grupo de Trabajo I.

BIBLIOGRAFÍA

- IPCC. (2018b). Annex I: Glossary. En *Global Warming of 1.5°C* (pp. 541–562). Cambridge University Press. <https://doi.org/10.1017/9781009157940.008>
- IPCC. (2023a). *Climate Change 2023: Synthesis Report. A Report of the Intergovernmental Panel on Climate Change. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change.*
- IPCC. (2023b). Summary for Policymakers. En *Climate Change 2023: Synthesis Report. A Report of the Intergovernmental Panel on Climate Change. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* (p. 36). IPCC, Geneva, Switzerland.
- Keith, H., Mackey, B. G., & Lindenmayer, D. B. (2009). Re-evaluation of forest biomass carbon stocks and lessons from the world's most carbon-dense forests. *Proceedings of the National Academy of Sciences of the United States of America*, 106(28), 11635–11640. <https://doi.org/10.1073/pnas.0901970106>
- Lara Ponce, E., Caso-Barrera, L., Aliphath, M., Ramírez, B., Gil, A., García, G., Aliphath, M., Gil, A., & García Olivares, J. (2012). Etnomapa: Uso de los recursos naturales por los mayas itzaes de San José y San Andrés del Petén, Guatemala. *Universidad y ciencia*, 28(2), 97–117. <https://doi.org/10.19136/era.a28n2.19>
- LaRue, E. A., Wagner, F. W., Fei, S., Atkins, J. W., Fahey, R. T., Gough, C. M., & Hardiman, B. S. (2020). Compatibility of aerial and terrestrial LiDAR for quantifying forest structural diversity. *Remote Sensing*, 12(9), 1–14. <https://doi.org/10.3390/RS12091407>
- Lebrija-Trejos, E., Bongers, F., Pérez-García, E. A., & Meave, J. A. (2008). Successional change and resilience of a very dry tropical deciduous forest following shifting agriculture. *Biotropica*, 40(4), 422–431. <https://doi.org/10.1111/j.1744-7429.2008.00398.x>
- Locatelli, B., Kanninen, M., Brockhaus, M., Colfer, C. J. P., Murdiyarsa, D., & Santoso, H. (2009). Ante un futuro incierto: Cómo se pueden adaptar los bosques y las comunidades al cambio climático. En *Ante un futuro incierto: Cómo se pueden adaptar los bosques y las comunidades al cambio climático* (Número January). Center for International Forestry Research (CIFOR). <https://doi.org/10.17528/cifor/002842>

- Maass, M., & Burgos, A. (2011). Seasonally Dry Tropical Forests. En R. Dirzo, H. S. Young, H. A. Mooney, & G. Ceballos (Eds.), *Seasonally Dry Tropical Forests* (Número August 2016). Island Press/Center for Resource Economics. <https://doi.org/10.5822/978-1-61091-021-7>
- McRoberts, R. E., Næsset, E., Gobakken, T., & Bollandsås, O. M. (2015). Indirect and direct estimation of forest biomass change using forest inventory and airborne laser scanning data. *Remote Sensing of Environment*, 164, 36–42. <https://doi.org/10.1016/j.rse.2015.02.018>
- Miles, L., Newton, A. C., DeFries, R. S., Ravilious, C., May, I., Blyth, S., Kapos, V., & Gordon, J. E. (2006). A global overview of the conservation status of tropical dry forests. *Journal of Biogeography*, 33(3), 491–505. <https://doi.org/10.1111/j.1365-2699.2005.01424.x>
- Miranda, F., & Hernández-X., E. (1963). Los tipos de vegetación de México y su clasificación. *Botanical Sciences*, 28, 29. <https://doi.org/10.17129/botsci.1084>
- Miranda, F., & Hernández-X., E. (2016). Los tipos de vegetación de México y su clasificación. *Botanical Sciences*, 28, 29. <https://doi.org/10.17129/botsci.1084>
- Molles, M. C., & Laursen, A. (2020). *Ecology : concepts and applications* (McGraw-Hill Ryerson., Ed.; 5th ed.).
- Montgomery, D. C., Vining, G. G., & Peck, E. A. (2006). *Introducción Al Análisis de Regresión Lineal* (3ra ed.).
- Mooney, H. A., Bullock, S. H., & Medina, E. (1995). Introduction. En *Seasonally Dry Tropical Forests* (Número May, pp. 1–8). Cambridge University Press. <https://doi.org/10.1017/CBO9780511753398.001>
- Murphy, P. G., & Lugo, A. E. (1986). Ecology of Tropical Dry Forest. En *Annual Review of Ecology and Systematics* (Vol. 17).
- Murphy, P. G., & Lugo, A. E. (1995). Dry forests of Central America and the Caribbean. En *Seasonally Dry Tropical Forests* (pp. 9–34). Cambridge University Press. <https://doi.org/10.1017/CBO9780511753398.002>
- Noguchi, M., Hoshizaki, K., Matsushita, M., Sugiura, D., Yagihashi, T., Saitoh, T., Itabashi, T., Kazuhide, O., Shibata, M., Hoshino, D., Masaki, T., Osumi, K., Takahashi, K., & Suzuki, W. (2022). Aboveground biomass increments over 26 years (1993–2019) in an old-growth cool-

BIBLIOGRAFÍA

- temperate forest in northern Japan. *Journal of Plant Research*, 135(1), 69–79. <https://doi.org/10.1007/S10265-021-01358-5/TABLES/4>
- Ortiz-Reyes, A. D., René Valdez-Lazalde, J., De Los Santos-Posadas, H. M., Ángeles-Pérez, G., Paz-Pellat, F., & Martínez-Trinidad, T. (2015). Inventario y cartografía de variables del bosque con datos derivados de LiDAR: comparación de métodos. *Madera y Bosques*, Vol. 21(Númer: 3), 111–128.
- Parker, G. G., Harding, D. J., & Berger, M. L. (2004). A portable LIDAR system for rapid determination of forest canopy structure. *Journal of Applied Ecology*, 41(4), 755–767. <https://doi.org/10.1111/j.0021-8901.2004.00925.x>
- Parker, G. G., & Russ, M. E. (2004). The canopy surface and stand development: assessing forest canopy structure and complexity with near-surface altimetry. *Forest Ecology and Management*, 189(1–3), 307–315. <https://doi.org/10.1016/j.foreco.2003.09.001>
- Pérez Pelea, L. (2018). ¿Cómo proceder ante el incumplimiento de las premisas de los métodos paramétricos? o ¿cómo trabajar con variables biológicas no normales? *Revista del Jardín Botánico Nacional*, 39, 1–12. <https://www.jstor.org/stable/26600674>
- Pettorelli, N., Nagendra, H., Rocchini, D., Rowcliffe, M., Williams, R., Ahumada, J., De Angelo, C., Atzberger, C., Boyd, D., Buchanan, G., Chauvenet, A., Disney, M., Duncan, C., Fatoyinbo, T., Fernandez, N., Haklay, M., He, K., Horning, N., Kelly, N., ... Wegmann, M. (2017). Remote Sensing in Ecology and Conservation: three years on. *Remote Sensing in Ecology and Conservation*, 3(2), 53–56. <https://doi.org/10.1002/rse2.53>
- Picard, R. R., & Cook, R. D. (1984). Cross-Validation of Regression Models. *Journal of the American Statistical Association*, 79(387), 575–583. <https://doi.org/10.1080/01621459.1984.10478083>
- Pimentel, D., Wilson, C., McCullum, C., Huang, R., Dwen, P., Flack, J., Tran, Q., Saltman, T., & Cliff, B. (1997). Economic and environmental benefits of biodiversity. *BioScience*, 47(11), 747–757. <https://doi.org/10.2307/1313097>
- Poorter, L., Bongers, F., Aide, T. M., Almeyda Zambrano, A. M., Balvanera, P., Becknell, J. M., Boukili, V., Brancalion, P. H. S., Broadbent, E. N., Chazdon, R. L., Craven, D., de Almeida-Cortez, J. S., Cabral, G. A. L., de Jong, B. H. J., Denslow, J. S., Dent, D. H., DeWalt, S. J.,

-
- Dupuy, J. M., Durán, S. M., ... Rozendaal, D. M. A. (2016). Biomass resilience of Neotropical secondary forests. *Nature*, 530(7589), 211–214. <https://doi.org/10.1038/nature16512>
- Poorter, L., Craven, D., Jakovac, C. C., van der Sande, M. T., Amisshah, L., Bongers, F., Chazdon, R. L., Farrior, C. E., Kambach, S., Meave, J. A., Muñoz, R., Norden, N., Rüger, N., van Breugel, M., Zambrano, A. M. A., Amani, B., Andrade, J. L., Brancalion, P. H. S., Broadbent, E. N., ... Hérault, B. (2021). Multidimensional tropical forest recovery. *Science*, 374(6573), 1370–1376.
https://doi.org/10.1126/SCIENCE.ABH3629/SUPPL_FILE/SCIENCE.ABH3629_SM.PDF
- Poorter, L., van der Sande, M. T., Thompson, J., Arets, E. J. M. M., Alarcón, A., Álvarez-Sánchez, J., Ascarrunz, N., Balvanera, P., Barajas-Guzmán, G., Boit, A., Bongers, F., Carvalho, F. A., Casanoves, F., Cornejo-Tenorio, G., Costa, F. R. C., de Castilho, C. v., Duivenvoorden, J. F., Dutrieux, L. P., Enquist, B. J., ... Peña-Claros, M. (2015). Diversity enhances carbon storage in tropical forests. *Global Ecology and Biogeography*, 24(11), 1314–1328. <https://doi.org/10.1111/geb.12364>
- Portillo-Quintero, C. A., & Sánchez-Azofeifa, G. A. (2010). Extent and conservation of tropical dry forests in the Americas. *Biological Conservation*, 143(1), 144–155. <https://doi.org/10.1016/j.biocon.2009.09.020>
- Puliti, S., Breidenbach, J., Schumacher, J., Hauglin, M., Klingenberg, T. F., & Astrup, R. (2021). Above-ground biomass change estimation using national forest inventory data with Sentinel-2 and Landsat. *Remote Sensing of Environment*, 265, 112644. <https://doi.org/10.1016/j.rse.2021.112644>
- Quesada, M., Sanchez-Azofeifa, G. A., Alvarez-Añorve, M., Stoner, K. E., Avila-Cabadilla, L., Calvo-Alvarado, J., Castillo, A., Espírito-Santo, M. M., Fagundes, M., Fernandes, G. W., Gamon, J., Lopezaraiza-Mikel, M., Lawrence, D., Morellato, L. P. C., Powers, J. S., Neves, F. de S., Rosas-Guerrero, V., Sayago, R., & Sanchez-Montoya, G. (2009). Succession and management of tropical dry forests in the Americas: Review and new perspectives. *Forest Ecology and Management*, 258(6), 1014–1024. <https://doi.org/10.1016/j.foreco.2009.06.023>
- R Core Team. (2019). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.r-project.org>.
-

BIBLIOGRAFÍA

- Ramírez, G., Dupuy Rada, J. M., Ramírez y Avilés, L., & Solorio Sánchez, F. J. (2017). Evaluación de ecuaciones alométricas de biomasa epigea en una selva mediana subcaducifolia de Yucatán. *Madera y Bosques*, 23(2), 163–179. <https://doi.org/10.21829/myb.2017.2321452>
- Reichle, D. E. (2020). The physical and chemical bases of energy. En *The Global Carbon Cycle and Climate Change* (pp. 5–14). Elsevier. <https://doi.org/10.1016/B978-0-12-820244-9.00002-0>
- Reyes-Palomeque, G., Dupuy, J. M., D. Johnson, K., Castillo-Santiago, M. A., & Hernández-Stefanoni, J. L. (2019). Combining LiDAR data and airborne imagery of very high resolution to improve aboveground biomass estimates in tropical dry forests. *Forestry: An International Journal of Forest Research*.
- Rodríguez-Veiga, P., Quegan, S., Carreiras, J., Persson, H. J., Fransson, J. E. S., Hoschilo, A., Ziólkowski, D., Stereńczak, K., Lohberger, S., Stängel, M., Berninger, A., Siegert, F., Avitabile, V., Herold, M., Mermoz, S., Bouvet, A., Le Toan, T., Carvalhais, N., Santoro, M., ... Balzter, H. (2019). Forest biomass retrieval approaches from earth observation in different biomes. *International Journal of Applied Earth Observation and Geoinformation*, 77(December 2018), 53–68. <https://doi.org/10.1016/j.jag.2018.12.008>
- Rzedowski, J. (2006). *Vegetación de México*. 1ra. Edición digital. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad, México. 504 pp.
- Schlund, M., Erasmi, S., & Scipal, K. (2020). Comparison of Aboveground Biomass Estimation From InSAR and LiDAR Canopy Height Models in Tropical Forests. *IEEE Geoscience and Remote Sensing Letters*, 17(3), 367–371. <https://doi.org/10.1109/LGRS.2019.2925901>
- Siyum, Z. G. (2020). Tropical dry forest dynamics in the context of climate change: syntheses of drivers, gaps, and management perspectives. *Ecological Processes*, 9(1), 1–16. <https://doi.org/10.1186/S13717-020-00229-6/FIGURES/4>
- Stark, S. C., Leitold, V., Wu, J. L., Hunter, M. O., de Castilho, C. V., Costa, F. R. C., McMahon, S. M., Parker, G. G., Shimabukuro, M. T., Lefsky, M. A., Keller, M., Alves, L. F., Schiatti, J., Shimabukuro, Y. E., Brandão, D. O., Woodcock, T. K., Higuchi, N., de Camargo, P. B., de Oliveira, R. C., & Saleska, S. R. (2012). Amazon forest carbon dynamics predicted by profiles of canopy leaf area and light environment. *Ecology Letters*, 15(12), 1406–1414. <https://doi.org/10.1111/J.1461-0248.2012.01864.X>

- Toledo, V. M., Barrera-Bassols, N., García-Frapolli, E., & Alarcón-Chaires, P. (2008). Uso múltiple y biodiversidad entre los mayas Yucatecos (México). *Interciencia*, 33(5), 345–352.
- Toth, C., & Józków, G. (2015). Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 22–36. <https://doi.org/10.1016/j.isprsjprs.2015.10.004>
- Trejo, I., & Dirzo, R. (2000). Deforestation of seasonally dry tropical forest: A national and local analysis in Mexico. *Biological Conservation*, 94(2), 133–142. [https://doi.org/10.1016/S0006-3207\(99\)00188-3](https://doi.org/10.1016/S0006-3207(99)00188-3)
- Turner, W., Spector, S., Gardiner, N., Fladeland, M., Sterling, E., & Steininger, M. (2003). Remote sensing for biodiversity science and conservation. *Trends in Ecology and Evolution*, 18(6), 306–314. [https://doi.org/10.1016/S0169-5347\(03\)00070-3](https://doi.org/10.1016/S0169-5347(03)00070-3)
- Urbazaev, M., Thiel, C., Cremer, F., Dubayah, R., Migliavacca, M., Reichstein, M., & Schmillius, C. (2018). Estimation of forest aboveground biomass and uncertainties by integration of field measurements, airborne LiDAR, and SAR and optical satellite data in Mexico. *Carbon Balance and Management*, 13(1). <https://doi.org/10.1186/s13021-018-0093-5>
- Vellend, M., Dornelas, M., Baeten, L., Beauséjour, R., Brown, C. D., de Frenne, P., Elmendorf, S. C., Gotelli, N. J., Moyes, F., Myers-Smith, I. H., Magurran, A. E., McGill, B. J., Shimadzu, H., & Sievers, C. (2017). Estimates of local biodiversity change over time stand up to scrutiny. *Ecology*, 98(2), 583–590. <https://doi.org/10.1002/ECY.1660>
- Wang, R., & Gamon, J. A. (2019). Remote sensing of terrestrial plant biodiversity. *Remote Sensing of Environment*, 231(December 2018), 111218. <https://doi.org/10.1016/j.rse.2019.111218>

ANEXOS

Tabla 1a. Lista de valores de la densidad de la madera por especies

Especies	Densidad (g/cm ³)	Autor
<i>Vachellia angustissima</i>	0.85	Chave <i>et al.</i> , 2003
<i>Vachellia cochliacantha</i>	0.94	Barajas Morales, 1987
<i>Vachellia gaumeri</i>	0.9	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Vachellia glomerosa</i>	0.47	Erdoisa Sordo and Castillo Morales, 1992
<i>Vachellia hindsii</i>	0.78	Barajas Morales, 1987
<i>Vachellia pennatula</i>	1.06	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Adelia oaxacana</i>	0.87	Barajas Morales, 1987
<i>Albizia tomentosa</i>	0.45	Hidayat and Simpson [5]
<i>Alseis yucatanensis</i>	0.6	Chave <i>et al.</i> , 2003
<i>Alvaradoa amorphoides</i>	0.54	Reyes-Garcia <i>et al.</i> , 2012
<i>Amphilophium paniculatum var. molle</i>	0.58	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Amphilophium paniculatum var. Paniculatum</i>	0.58	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Apoplanesia paniculata</i>	0.7	Reyes-Garcia <i>et al.</i> , 2012
<i>Astronium graveolens</i>	0.87	Silva Guzman <i>et al.</i> , 1997
<i>Bauhinia divaricata</i>	0.75	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Bauhinia unguolata</i>	0.94	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Bourreria pulchra</i>	0.78	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Brosimum alicastrum</i>	0.75	Silva Guzman <i>et al.</i> , 1997
<i>Bucida buceras</i>	0.93	FAO [8]
<i>Bunchosia swartziana</i>	0.58	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Bursera instabilis</i>	0.24	Barajas Morales, 1987
<i>Bursera simaruba</i>	0.36	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Byrsonima crassifolia</i>	0.63	Tamarit Urias, 1995
<i>Byrsonima spp.</i>	0.64	FAO [8]
<i>Cenostigma gaumeri</i>	0.9	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Caesalpinia platyloba</i>	0.94	Tamarit Urias, 1995
<i>Poinciana pulcherrima</i>	0.84	Barajas Morales, 1987
<i>Caesalpinia spp.</i>	1.05	FAO [8]

<i>Calyptanthes pallens</i>	0.86	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Capparis verrucosa</i>	0.86	Barajas Morales, 1987
<i>Casearia corymbosa</i>	0.67	Barajas Morales, 1987
<i>Casearia emarginata</i>	0.62	Reyes <i>et al.</i> , 1992
<i>Cecropia obtusifolia</i>	0.31	Erdoisa Sordo and Castillo Morales, 1992
<i>Cecropia peltata</i>	0.3	FAO [8]
<i>Cedrela odorata</i>	0.45	FAO [8]
<i>Ceiba aesculifolia</i>	0.48	Barajas Morales, 1987
<i>Ceiba pentandra</i>	0.27	Silva Guzman <i>et al.</i> , 1997
<i>Ceiba schotti</i>	0.48	Reyes-Garcia <i>et al.</i> , 2012
<i>Cesalpineia gaumeri</i>	0.74	Reyes-Garcia <i>et al.</i> , 2012
<i>Chloroleucon mangense</i>	0.59	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Chlorophora tinctoria</i>	0.96	Barajas Morales, 1987
<i>Cnidocolus aconitifolius</i>	0.29	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Coccoloba acapulcensis</i>	0.65	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Coccoloba barbadensis</i>	0.71	Barajas Morales, 1987
<i>Coccoloba diversifolia</i>	0.8	Chave <i>et al.</i> , 2003
<i>Coccoloba spicata</i>	0.86	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Cochlospermum vitifolium</i>	0.23	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Cojoba arborea</i>	0.8	Silva Guzman <i>et al.</i> , 1997
<i>Colubrina elliptica</i>	0.8	Chave <i>et al.</i> , 2003
<i>Cordia alliodora</i>	0.53	Silva Guzman <i>et al.</i> , 1997
<i>Cordia dodecandra</i>	0.96	Silva Guzman <i>et al.</i> , 1997
<i>Cordia gerascanthus</i>	0.75	Chave <i>et al.</i> , 2003
<i>Croton glabellus</i>	1	Tamarit Urias, 1995
<i>Croton nitens</i>	0.53	Barajas Morales, 1987
<i>Croton reflexifolius</i>	1.09	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Cydista diversifolia</i>	0.51	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Cydista potosina</i>	0.51	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Dalbergia glabra</i>	0.47	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Dendropanax arboreus</i>	0.53	Silva Guzman <i>et al.</i> , 1997
<i>Diospyros anisandra</i>	0.94	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Diospyros cuneata</i>	0.82	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Diospyros tetrasperma</i>	0.82	Sanaphre Villanueva <i>et al.</i> , 2016

ANEXOS

<i>Diospyros yucatanensis ssp spectabilis</i>	0.78	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Diospyros yucatanensis ssp yucatanensis</i>	0.9	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Drypetes lateriflora</i>	0.72	Fuentes Salinas <i>et al.</i> , 2008
<i>Ebenopsis ebano</i>	1.06	Zizumbo Cortes, 1998
<i>Enterolobium cyclocarpum</i>	0.45	Silva Guzman <i>et al.</i> , 1997
<i>Erythrina sp.</i>	0.23	FAO [8]
<i>Erythroxylum rotundifolium</i>	0.9	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Eugenia axillaris</i>	0.77	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Eugenia buxifolia</i>	0.91	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Exostema caribaeum</i>	0.88	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Ficus cotinifolia</i>	0.4	Barajas Morales, 1987
<i>Ficus sp.</i>	0.32	FAO [8]
<i>Gliricidia sepium</i>	0.64	Barajas Morales, 1987
<i>Guazuma ulmifolia</i>	0.5	FAO [8]
<i>Guettarda elliptica</i>	0.83	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Guettarda gaumeri</i>	0.74	Yam Uicab, O., 2012
<i>Gymnanthes lucida</i>	1.1	Chave <i>et al.</i> , 2003
<i>Gymnopodium floribundum</i>	0.79	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Gyrocarpus americanus</i>	0.32	Hidayat and Simpson [5]
<i>Haematoxylon brasiletto</i>	1.1	Jimenez <i>et al.</i> , 2008
<i>Havardia albicans</i>	0.74	Yam Uicab, O., 2012
<i>Heliocarpus donnell-smithii</i>	0.16	Chave <i>et al.</i> , 2003
<i>Heteropterys brachiata</i>	0.542	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Hippocratea excelsa</i>	0.74	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Inga vera</i>	0.59	FAO [8]
<i>Ipomoea wolcottiana</i>	0.57	Barajas Morales, 1987
<i>Jacaratia mexicana</i>	0.16	Barajas Morales, 1987
<i>Jacquinia macrocarpa</i>	0.61	Reyes-Garcia <i>et al.</i> , 2012
<i>Jatropha gaumeri</i>	0.43	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Karwinskia humboldtiana</i>	0.86	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Krugiodendron ferreum</i>	0.91	Correa Mendez, 2006
<i>Lachmellea speciosa</i>	0.73	FAO [8]
<i>Laetia thamnia</i>	0.66	Chave <i>et al.</i> , 2003
<i>Leucaena lanceolata</i>	0.94	Barajas Morales, 1987

<i>Leucaena leucocephala</i>	0.76	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Lonchocarpus castilloi</i>	0.83	Silva Guzman <i>et al.</i> , 1997
<i>Lonchocarpus hondurensis</i>	0.83	Chave <i>et al.</i> , 2003
<i>Lonchocarpus parviflorus</i>	0.89	Barajas Morales, 1987
<i>Lonchocarpus rugosus</i>	0.95	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Lonchocarpus sp.</i>	0.69	Reyes <i>et al.</i> , 1992
<i>Lonchocarpus xuul</i>	0.82	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Luehea candida</i>	0.91	Barajas Morales, 1987
<i>Luehea speciosa</i>	0.72	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Lysiloma divaricatum</i>	0.73	Correa Mendez, 2006
<i>Lysiloma latisiliquum</i>	0.55	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Machaonia lindeniana</i>	0.99	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Maclura tinctoria</i>	0.71	Echenique-Manrique [15]
<i>Malpighia glabra</i>	0.91	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Manilkara zapota</i>	0.88	Hidayat and Simpson [5]
<i>Mansoa verrucifera</i>	0.5	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Melicoccus oliviformis</i>	0.71	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Metopium brownei</i>	0.8	Tamarit Urias, 1995
<i>Mimosa bahamensis</i>	0.91	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Nectandra coriacea</i>	0.51	FAO [8]
<i>Nectandra salicifolia</i>	0.46	Barajas Morales, 1987
<i>Neea psychotrioides</i>	0.71	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Neomillspaughia emarginata</i>	0.8	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Pachira aquatica</i>	0.5	Torelli, 1982
<i>Parathesis cubana</i>	0.62	Chave <i>et al.</i> , 2003
<i>Phyllostylon brasiliense</i>	0.72	Reyes-Garcia <i>et al.</i> , 2012
<i>Pimenta dioica</i>	0.96	Barajas Morales, 1987
<i>Piscidia piscipula</i>	0.78	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Pisonia aculeata</i>	0.43	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Pithecellobium dulce</i>	0.72	Reyes-Garcia <i>et al.</i> , 2012
<i>Platymiscium spp.</i>	0.71	FAO [8]
<i>Platymiscium yucatanum</i>	0.9	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Pouteria aff. campechiana</i>	0.75	Sotomayor Castellanos <i>et al.</i> , 2008
<i>Pouteria sapota</i>	0.81	Barajas Morales, 1987

ANEXOS

<i>Protium copal</i>	0.59	Sotomayor Castellanos <i>et al.</i> , 2008
<i>Pseudobombax ellipticum</i>	0.44	Torelli, 1982
<i>Psidium sartorianum</i>	0.85	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Pterocarpus rohrii</i>	0.41	FAO [8]
<i>Randia longiloba</i>	0.74	Yam Uicab, O., 2012
<i>Randia obcordata</i>	0.7	Reyes <i>et al.</i> , 1992
<i>Samyda yucatanensis</i>	0.72	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Sapindus saponaria</i>	0.66	Correa Mendez, 2006
<i>Sapium lateriflorum</i>	0.5	Tamarit Urias, 1995
<i>Sapium laurocerasus</i>	0.38	FAO [8]
<i>Semialarium mexicanum</i>	0.74	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Senna atomaria</i>	0.7	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Senna racemosa</i>	0.68	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Sideroxylon sp.</i>	0.62	Reyes-Garcia <i>et al.</i> , 2012
<i>Sideroxylon obtusifolium</i>	1.07	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Simarouba amara</i>	0.43	Silva Guzman <i>et al.</i> , 1997
<i>Simarouba glauca</i>	0.46	Torelli, 1982
<i>Spondias mombin</i>	0.4	Silva Guzman <i>et al.</i> , 1997
<i>Spondias purpurea</i>	0.31	Barajas Morales, 1987
<i>Spondias radlkoferi</i>	0.56	Barajas Morales, 1987
<i>Swartzia cubensis</i>	1.12	Silva Guzman <i>et al.</i> , 1997
<i>Swartzia guatemalensis</i>	0.89	Barajas Morales, 1987
<i>Swietenia macrophylla</i>	0.42	Torelli, 1982
<i>Tabebuia chrysantha</i>	0.75	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Tabebuia guayacan</i>	0.82	FAO [8]
<i>Tabebuia rosea</i>	0.6	Silva Guzman <i>et al.</i> , 1997
<i>Tabernaemontana alba</i>	0.45	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Talisia floressi</i>	0.84	Reyes <i>et al.</i> , 1992
<i>Talisia olivaeformis</i>	0.71	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Thouinia paucidentata</i>	0.94	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Trema micrantha</i>	0.35	Chave <i>et al.</i> , 2003
<i>Trichilia glabra</i>	0.74	Yam Uicab, O., 2012
<i>Trichilia hirta</i>	0.55	Chave <i>et al.</i> , 2003
<i>Trichilia martiana</i>	0.47	Barajas Morales, 1987

<i>Trichilia moschata</i>	0.88	Barajas Morales, 1987
<i>Trichilia pallida</i>	0.69	Barajas Morales, 1987
<i>Trichilia propingua</i>	0.58	FAO [8]
<i>Trophis racemosa</i>	0.78	Barajas Morales, 1987
<i>Vitex gaumeri</i>	0.65	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Ximenia americana</i>	0.66	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Zanthoxylum caribaeum</i>	0.97	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Zanthoxylum fagara</i>	0.65	Fuentes Salinas <i>et al.</i> , 2008
<i>Zapoteca formosa</i>	0.67	Sanaphre Villanueva <i>et al.</i> , 2016
<i>Zuelania guidonia</i>	0.61	Torelli, 1982

Procesamiento de datos LiDAR aéreo 2013 y obtención de métricas por conglomerado

En este apartado se presentan los scripts usados en este trabajo, los procedimientos generales se describen en el apartado de la materiales y métodos. Los scripts fueron generados en este trabajo con la ayuda de la documentación base de las librerías de R y con la recopilación de códigos en foros digitales de ayuda en el lenguaje de programación R.

```
#### definir el espacio de trabajo ####
setwd("C:/files/shp")
folder <- getwd()

#### leer shapefile ####
library(sf)
shape <- st_read("Parcelas.shp")

proj <- st_crs(shape)

#### leer archivos lidar #####
library(lidR)
dir.LAS <- "C:/files/Lidar/normalizadas"

#### archivos las por subparcela ####
cat <- readLAScatalog(dir.LAS)
projection(cat) <- proj

#### archivos las por subparcela ####
subset <- clip_roi(cat, shape)
listplots <- shape$Plot;listplots

#### crear directorio a guardar LAS ####
dir.clip.LAS <- "Parcelas"
{path = file.path(dir.LAS,dir.clip.LAS)
  ifelse(dir.exists(path),
         dir.clip.LAS <- path,
         dir.create(path))
  dir.clip.LAS <- path
}

# guardar LAS por subparcela
subplots <- data.frame(listplots)
subplots$ID <- as.numeric(rownames(subplots))

for (i in 1:length(listplots)) {
  if (subset[[i]]@header$`Number of point records` != 0 ) {
```

```

writeLAS(subset[[i]],
         paste(dir.clip.LAS, "/",
              subplots$ID[i],
              ".las", sep = ""),
         index = TRUE)
}
}

# Unir archivos LAS de subparcelas por conglomerado
listplots.a <- sort(unique(listplots))

dfSortPlot <- data.frame(ID = 1:length(listplots.a), plot = listplots.a)
dfSortPlot
plots <- list()

for (i in 1:length(listplots.a)) {
  plots[[i]] <- do.call(rbind, subset[subplots[
    which(subplots$listplots == dfSortPlot[i,]$plot),2]]
  )
}

#### Función para obtener métricas usando librería LidR ####
lidRmetrics <- function(LASfile, r, z0){
  if (length(LASfile@data$Z) == 0) {
    metrics <- data.frame(
      mCAI = NA,
      sdCAI = NA,
      xHmax = NA,
      mHmax = NA,
      sdHmax = NA,
      mHbar = NA
    )
  } else {
    r <- r
    canop <- grid_canopy(LASfile, res = r, algorithm = p2r())
    Zval <- na.omit(canop@data@values)
    sdt <- grid_metrics(LASfile, ~sd(Z), res = r )
    Hbar <- grid_metrics(LASfile, ~mean(Z), res = r)
    SAD <- grid_metrics(LASfile, ~sum(LAD(Z, dz = 1, k = 0.5, z0 = 1.5)$lad),
                       res = r)

    metrics <- data.frame(
      mCAI = mean(SAD@data@values, na.rm = TRUE),
      sdCAI = sd(SAD@data@values, na.rm = TRUE),
      xHmax = max(Zval, na.rm = TRUE),
      mHmax = mean(Zval, na.rm = TRUE),
      sdHmax = sd(Zval, na.rm = TRUE),
      mHbar = mean(Hbar@data@values, na.rm = TRUE),

```

```
        sdHbar = sd(Hbar@data@values, na.rm = TRUE)
      )
    }
  }

#### métricas a dataframe ####

Metrics.liDR <- data.frame()
# correr la función
for (i in 1:length(plots)) {
  Metrics.liDR <- rbind(Metrics.liDR,
                       lidRmetrics(plots[[i]], r = 1, z0 = 1.5))
}

# Agregar el número de conglomerado
Metrics.liDR <- cbind(dfSortPlot, Metrics.liDR)
write.csv(Metrics.liDR, "C:/files/met2013parcelas.csv",
          row.names = FALSE)

#####
```

Ajuste y validación de los modelos

```
#### Definir directorio de trabajo ####
setwd("C:/files")
getwd()

# cargar librerías
library(tidyverse)
library(carData)
library(car)
library(corrplot)
library(ggplot2)
library(MASS)
library(Metrics)

# cargar archivos de métricas por año
a13 <- read.csv("met2013Parcelas.csv")
a21 <- read.csv("met2021.csv")

# Realizar pruebas de normalidad
shapiro.test(a21$AGB)
shapiro.test(a13$AGB)

####          2013   con intercepto igual a cero          #
```

```
###

#Definir intercepto
intercept_only13 <- lm(AGB ~ 0, data=a13)

#Definir modelo con todos los predictores
all13 <- lm(AGB ~ mCAI + sdCAI + xHmax + mHmax + sdHmax + mHbar + sdHbar ,
           data=a13)
#ejecutar el modelo mediante pasos
forward13 <- step(intercept_only13, direction='forward',
                 scope=formula(all13), trace=0)

#resultados
forward13$anova
#coeficientes
forward13$coefficients

summary(forward13)

# prueba de multicolinealidad
vif(forward13)

forward13 <- lm(AGB ~ 0 + mHbar , data=a13)
summary(forward13)

forward13$fitted.values
rmse(a13$AGB, forward13$fitted.values)
(rmse(a13$AGB, forward13$fitted.values)/mean(a13$AGB))*100

#####                2013    con intercepto                #

#Definir intercepto del modelo
intercept_only13 <- lm(AGB ~ 1, data=a13)

#Definir modelo con todos los predictores
all13 <- lm(AGB ~ mCAI + sdCAI + xHmax + mHmax + sdHmax + mHbar + sdHbar ,
           data = a13)

#ejecutar el modelo mediante pasos
forward13 <- step(intercept_only13, direction='forward',
                 scope = formula(all13), trace=0)

#resultados
forward13$anova
#coeficientes
```

```
forward13$coefficients

formula(forward13)
summary(forward13)
vif(forward13)

forward13 <- lm(AGB ~ mHmax , data=a13)
summary(forward13)

rmse(a13$AGB, forward13$fitted.values)
(rmse(a13$AGB, forward13$fitted.values)/mean(a13$AGB))*100

####          2021 con intercepto igual a cero          #####

model21 <- lm(AGB ~ 0 + mCAI + sdCAI + xHmax + mHmax +
              sdHmax+ mHbar + sdHbar,
              data= a21 )
summary(model21)

cor21<- cor(a21[,c("AGB","mCAI", "sdCAI" , "xHmax","mHmax" ,
                  "sdHmax" , "mHbar","sdHbar")]);cor21
corrplot(cor21,
          type="upper",
          #order="hclust",
          tl.col="black",
          tl.srt=0,
          tl.cex = 0.7,
          cl.cex = 0.8,
          number.digits = 2,
          addCoefasPercent = TRUE,
          tl.offset = 1,
          addCoef.col = "white",
          number.cex = 0.7,
          number.font = 1)

#ols_step_best_subset(model21)

#Definir intercepto del modelo
intercept_only21 <- lm(AGB ~ 0, data=a21)
#Definir modelo con todos los predictores
all21 <- lm(AGB ~ mCAI + sdCAI + xHmax + mHmax + sdHmax + mHbar + sdHbar,
            data = a21)
#ejecutar el modelo mediante pasos
forward21 <- step(intercept_only21, direction = 'forward',
                 scope=formula(all21), trace = 0)
#resultados
```

```
forward21$anova
#coeficientes
forward21$coefficients

summary(forward21)
vif(forward21)

forward21 <- lm(AGB ~ 0 + sdCAI + sdHbar,
               data=a21)
summary(forward21)
vif(forward21)
formula(forward21)

rmse(a21$AGB, forward21$fitted.values)
(rmse(a21$AGB, forward21$fitted.values)/mean(a21$AGB))*100

####                2021 con intercepto                ####

#Definir intercepto del modelo
intercept_only21 <- lm(AGB ~ 1, data=a21)
#Definir modelo con todos los predictores
all21 <- lm(AGB ~ mCAI + sdCAI + xHmax + mHmax +
           sdHmax+ mHbar + sdHbar,
           data=a21)
#ejecutar el modelo mediante pasos
forward21 <- step(intercept_only21, direction='forward',
                 scope=formula(all21), trace=0)
#resultados
forward21$anova
#coeficientes
forward21$coefficients

summary(forward21)
vif(forward21)

forward21 <- lm(AGB ~ mHbar + mCAI, data = a21)
summary(forward21)
vif(forward21)

formula(forward21)

rmse(a21$AGB, forward21$fitted.values)
(rmse(a21$AGB, forward21$fitted.values)/mean(a21$AGB))*100
```

ANEXOS

```
##### incremento de la biomasa aérea
#####

incremento <- (a21$AGB - a13$AGB) / (2021-2013)
incremento

hist(incremento)
shapiro.test(incremento)

##### modelos de incremento metodo indirecto #####
##### indirecto con intercepto 0 #####

forward13 <- lm(AGB ~ 0 + mHbar , data=a13)
summary(forward13)

forward21 <- lm(AGB ~ 0 + sdCAI + sdHbar, data=a21)
summary(forward21)

incAGBd <- (forward21$fitted.values - forward13$fitted.values) / (2021-2013)
incAGBd

rmse(incremento, incAGBd)
rmse(incremento, incAGBd)/mean(incremento)*100

rmse <- round(rmse(incremento, incAGBd),2);rmse
percrmse <-round((rmse/mean(incremento))*100,2);percrmse

r2<-round(summary(lm(incremento ~ incAGBd))$r.squared,2);r2

##### indirecto con intercepto #####

forward13 <- lm(AGB ~ mHmax , data=a13)
summary(forward13)

forward21 <- lm(AGB ~ mHbar + mCAI, data=a21)
summary(forward21)

incAGBd <- (forward21$fitted.values - forward13$fitted.values)/8
incAGBd

rmse(incremento, incAGBd)
rmse(incremento, incAGBd)/mean(incremento)*100

rmse <- round(rmse(incremento, incAGBd),2);rmse
percrmse <-round((rmse/mean(incremento))*100,2);percrmse
```

```

r2 <- round(summary(lm(incremento ~ incAGBd))$r.squared,2);r2

####                                modelos de incremento metodo directo                                ####
#####                               metodo directo con intercepto 0                               ##

cor(data.frame(incremento, a13$mCAI, a13$sdCAI, a13$xHmax, a13$mHmax,
               a13$sdHmax, a13$mHbar, a13$sdHbar,
               a21$mCAI, a21$sdCAI, a21$xHmax, a21$mHmax, a21$sdHmax,
               a21$mHbar, a21$sdHbar)) -> corinc
corrplot(corinc,
          type="lower",
          #order="hclust",
          tl.col="black",
          tl.srt=0,
          tl.cex = 0.7,
          cl.cex = 0.8,
          number.digits = 2,
          addCoefasPercent = TRUE,
          tl.offset = 1,
          addCoef.col = "white",
          number.cex = 0.7,
          number.font = 1)

intercept_onlyinc <- lm(incremento ~ 0)

#Definir modelo con todos los predictores
allinc <- lm(incremento ~ a13$mCAI + a13$sdCAI + a13$xHmax + a13$mHmax +
            a13$sdHmax + a13$mHbar + a13$sdHbar +
            a21$mCAI + a21$sdCAI + a21$xHmax + a21$mHmax + a21$sdHmax +
            a21$mHbar + a21$sdHbar)

#ejecutar el modelo mediante pasos
forwardinc <- step(intercept_onlyinc, direction = 'forward',
                  scope=formula(allinc), trace=0)

#resultados
forwardinc$anova
#coeficientes
forwardinc$coefficients

summary(forwardinc)
formula(forwardinc)

#vif(forwardinc)

forwardinc <- lm(incremento ~ 0 + a21$sdCAI + a21$edad)
summary(forwardinc)

```

```
rmse(incremento, forwardinc$fitted.values)
(rmse(incremento, forwardinc$fitted.values)/mean(incremento))*100

#####                metodo directo con intercepto                #####

intercept_onlyinc <- lm(incremento ~ 1)
#Definir modelo con todos los predictores
allinc <- lm(incremento ~ a13$mCAI + a13$sdCAI + a13$xHmax + a13$mHmax +
a13$sdHmax + a13$mHbar + a13$sdHbar +
a21$mCAI + a21$sdCAI + a21$xHmax + a21$mHmax + a21$sdHmax +
a21$mHbar + a21$sdHbar)
#ejecutar el modelo mediante pasos
forwardinc <- step(intercept_onlyinc, direction='forward',
scope=formula(allinc), trace=0)

#resultados
forwardinc$anova
#coeficientes
forwardinc$coefficients

summary(forwardinc)
formula(forwardinc)

#vif(forwardinc)

forwardinc <- lm(incremento ~ a21$sdCAI)
summary(forwardinc)

rmse(incremento, forwardinc$fitted.values)
(rmse(incremento, forwardinc$fitted.values)/mean(incremento))*100

#####                diferencia metricas                #####

incmCAI = (a21$mCAI - a13$mCAI)/8
incsdCAI = (a21$sdCAI - a13$sdCAI)/8
incxHmax = (a21$xHmax - a13$xHmax)/8
incmHmax = (a21$mHmax - a13$mHmax)/8
incsdHmax = (a21$sdHmax - a13$sdHmax)/8
incmHbar = (a21$mHbar - a13$mHbar)/8
incsdHbar = (a21$sdHbar - a13$sdHbar)/8

coincsdif <- cor(cbind(incremento, incmCAI, incsdCAI, incxHmax, incmHmax,
incsdHmax, incmHbar, incsdHbar))
```

```

corrplot(coincsdif,
         type="upper",
         #order="hclust",
         tl.col="black",
         tl.srt=0,
         tl.cex = 0.7,
         cl.cex = 0.8,
         number.digits = 2,
         addCoefasPercent = TRUE,
         tl.offset = 1,
         addCoef.col = "white",
         number.cex = 0.7,
         number.font = 1)

##### metodo directo con diferencia de metricas e intercepto 0 #####

#Definir intercepto del modelo
intercept_onlyinc <- lm(incremento ~ 0)
#Definir modelo con todos los predictores
allinca <- lm(incremento ~ incmCAI + incsdCAI + incxHmax + incmHmax +
             incsdHmax + incmHbar + incsdHbar)
#ejecutar el modelo mediante pasos
forwardinca <- step(intercept_onlyinc, direction='forward',
                  scope=formula(allinca), trace=0)

#resultados
forwardinca$anova
#coeficientes
forwardinca$coefficients

summary(forwardinca)
vif(forwardinca)

forwardinca <- lm(incremento ~ 0 + incsdCAI + incxHmax)
summary(forwardinca)
#vif(forwardinc)

rmse(incremento, forwardinca$fitted.values)
(rmse(incremento, forwardinca$fitted.values)/mean(incremento))*100

##### metodo directo con diferencia de metricas e intercepto ##
###

# Definir intercepto del modelo
intercept_onlyinca <- lm(incremento ~ 1)
#Definir modelo con todos los predictores
allinca <- lm(incremento ~ incmCAI + incsdCAI + incxHmax + incmHmax +
             incsdHmax + incmHbar + incsdHbar)

```

```
summary(allinca)
vif(allinca)
#ejecutar el modelo mediante pasos
forwardinca <- step(intercept_onlyinca, direction='both',
                    scope=formula(allinca), trace=0)
#resultados
forwardinca$anova
#coeficientes
forwardinca$coefficients

summary(forwardinca)
vif(forwardinca)

forwardinca <- lm(incremento ~ incsdCAI + incxHmax)
summary(forwardinca)
vif(forwardinca)

rmse(incremento, forwardinca$fitted.values)
(rmse(incremento, forwardinca$fitted.values)/mean(incremento))*100

####                                validacion cruzada                                #
###

#####                               Validacion 2013 con intercepto 0                               ##
###

pred <- vector()
for (i in 1:length(a13$plot)) {
  pred[i] <- predict(
    lm(AGB ~ 0 + mHbar, data = a13[-i,]),
    newdata = a13[i,])
}
pred

val13 <- data.frame(obs = a13$AGB, pred)
rmse <- round(rmse(val13$pred, val13$obs),2);rmse
percrmse <-round((rmse/mean(val13$obs))*100,2);percrmse

r2<-round(summary(lm(pred ~ obs, data = val13))$r.squared,2);r2

#####                               Validacion 2013 con intercepto 1                               #####

pred <- vector()
for (i in 1:length(a13$plot)) {
  pred[i] <- predict(
    lm(AGB ~ mHmax, data = a13[-i,]),
    newdata = a13[i,])
```

```

}
pred

val13 <- data.frame(obs = a13$AGB, pred)
rmse <- round(rmse(val13$pred, val13$obs),2);rmse
percrmse <-round((rmse/mean(val13$obs))*100,2);percrmse

r2<-round(summary(lm(pred ~ obs, data = val13))$r.squared,2);r2

#####          Validacion 2021 con intercepto 0          #####

pred <- vector()
for (i in 1:length(a21$plot)) {
  pred[i] <- predict(
    lm(AGB ~ 0 + sdCAI + sdHbar, data = a21[-i,]),
    newdata = a21[i,])
}
pred

val21 <- data.frame(obs = a21$AGB, pred)
rmse <- round(rmse(val21$pred, val21$obs),2);rmse
percrmse <- round((rmse/mean(val21$obs))*100,2);percrmse

r2 <- round(summary(lm(pred ~ obs, data = val21))$r.squared,2);r2

#####          Validacion 2021 con intercepto 1          #####

pred <- vector()
for (i in 1:length(a21$plot)) {
  pred[i] <- predict(
    lm(AGB ~ mHbar + mCAI, data = a21[-i,]),
    newdata = a21[i,])
}
pred

val21 <- data.frame(obs = a21$AGB, pred)
rmse <- round(rmse(val21$pred, val21$obs),2);rmse
percrmse <- round((rmse/mean(val21$obs))*100,2);percrmse

r2 <- round(summary(lm(pred ~ obs, data = val21))$r.squared,2);r2

#####          Validacion incremento directo con intercepto 0          #####

incrementodf <- data.frame(incremento, sdCAI = a21$sdCAI)
incrementodf
pred <- vector()
for (i in 1:length(incremento)) {
  pred[i] <- predict(

```

```
lm(incremento ~ 0 + sdCAI , data = incrementodf[-i,]),
newdata = incrementodf[i,])
}
pred

valinc <- data.frame(obs = incremento, pred)
rmse <- round(rmse(valinc$pred, valinc$obs),2);rmse
percrmse <- round((rmse/mean(valinc$obs))*100,2);percrmse

r2 <- round(summary(lm(pred ~ obs, data = valinc))$r.squared,2);r2

##### Validacion incremento directo con intercepto 1 #####

incrementodf <- data.frame(incremento, sdCAI = a21$sdCAI)
incrementodf
pred <- vector()
for (i in 1:length(incremento)) {
  pred[i] <- predict(
    lm(incremento ~ sdCAI, data = incrementodf[-i,]),
    newdata = incrementodf[i,])
}
pred

valinc <- data.frame(obs = incremento, pred)
rmse <- round(rmse(valinc$pred, valinc$obs),2);rmse
percrmse <- round((rmse/mean(valinc$obs))*100,2);percrmse

r2 <- round(summary(lm(pred ~ obs, data = valinc))$r.squared, 2);r2

##### Validacion incremento diferencia de metricas e intercepto 0 #####

incrementodf <- data.frame(incremento, incsdCAI, incxHmax )
incrementodf
pred <- vector()
for (i in 1:length(incremento)) {
  pred[i] <- predict(
    lm(incremento ~ 0 + incsdCAI + incxHmax, data = incrementodf[-i,]),
    newdata = incrementodf[i,])
}
pred

valinc <- data.frame(obs = incremento, pred)
rmse <- round(rmse(valinc$pred, valinc$obs),2);rmse
percrmse <- round((rmse/mean(valinc$obs))*100,2);percrmse

r2 <- round(summary(lm(pred ~ obs, data = valinc))$r.squared, 2);r2

##### Validacion incremento diferencia de metricas e intercepto 1 #####
```

```
incrementodf <- data.frame(incremento, incsdCAI, incxHmax )
incrementodf
pred <- vector()
for (i in 1:length(incremento)) {
  pred[i] <- predict(
    lm(incremento ~ incsdCAI + incxHmax, data = incrementodf[-i,]),
    newdata = incrementodf[i,])
}
pred

valinc <- data.frame(obs = incremento, pred)
rmse <- round(rmse(valinc$pred, valinc$obs),2);rmse
percrmse <- round((rmse/mean(valinc$obs))*100,2);percrmse

r2 <- round(summary(lm(pred ~ obs, data = valinc))$r.squared, 2);r2
```