



Ciencia y Tecnología

Secretaría de Ciencia, Humanidades, Tecnología e Innovación



Centro de Investigación Científica de Yucatán, A.C.

Posgrado en Ciencias Biológicas

**CUANTIFICACIÓN Y MAPEO DE LA BIOMASA
AÉREA Y DEL CARBONO REMOVIDO EN MÉRIDA Y
SU ZONA CONURBADA**

Tesis que presenta

KARINA ELIZABETH GONZÁLEZ MUÑOZ

En opción al título de

MAESTRO EN CIENCIAS

(Ciencias Biológicas: **Opción Recursos Naturales**)

Mérida, Yucatán, México

2025

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 Karina Elizabeth González Muñoz titulado **Cuantificación y mapeo de la biomasa aérea y del carbono removido en Mérida y su zona conurbada**, 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 y la codirección del Dr. José Luis Andrade Torres, dentro de la opción de Recursos Naturales, perteneciente al Programa de Posgrado en Ciencias Biológicas de este Centro.

Atentamente



Dr. José Luis Hernández Stefanoni
Director de Docencia

Mérida, Yucatán, México, a 19 de mayo de 2025

DECLARACIÓN DE PROPIEDAD

Declaro que la información contenida en la sección de Materiales y Métodos, los 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 de 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 en el mismo tenor, reconozco que si derivaren de este trabajo productos intelectuales o desarrollos tecnológicos, en lo especial, estos se registrarán en todo caso por lo dispuesto por la Ley Federal del Derecho de Autor y la Ley de la Propiedad Industrial, en el tenor de lo expuesto en la presente Declaración.

Firma:  _____

Karina Elizabeth González Muñoz

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** y co director **Dr. José Luis Andrade Torres**

AGRADECIMIENTOS

Al consejo Nacional de Humanidades, Ciencia y tecnología por la beca otorgada con el número 842854.

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

Tengo un profundo agradecimiento al Dr. José Luis Hernández Stefanoni por su confianza, paciencia y apoyo durante mi estancia en el CICY, tanto en lo académico como en lo personal. También por su amistad, y la de su familia: Dani, Cami y Emi.

Al Dr. José Luis Andrade, por su disposición, revisiones y consejos que ayudaron mucho al desarrollo de esta tesis, incluso cuando lo interrumpía sin avisar.

Y también a la Dra. Diana Cisneros y a la Dra. Helena Huechacona por tomarse el tiempo de revisar este trabajo y aportar ideas para mejorarlo. Al Dr. Luis Alexander Peña, por sus observaciones y comentarios que sumaron bastante.

Laborar con el grupo de Percepción Remota fue una gran experiencia: Mauricio, Luis Hernández, Víctor Peña, Gabriela Palomeque, Marypaz y el técnico Fernando Tun. Gracias por su amistad, por resolver dudas y por su ayuda en campo y gabinete. Esta tesis la entendieron primero ustedes que yo, jaja.

Obtuve mucho apoyo del grupo de Ecofisiología Vegetal, especialmente de Gabriela Cerón, Julio Salas y Aarón Casanova. Gracias por escuchar tantas veces mis presentaciones y por los comentarios que fortalecieron este estudio.

Reconozco también al grupo de Sistemática y Florística. En especial a la Dra. Claudia Ramírez, por acompañarme a los parques a identificar especies, y al Dr. Luis Tapia, por ayudarme con las más difíciles. Su memoria botánica es impresionante.

Salidas a campo con el Dr. Pedro Ruiz han sido fundamentales. Desde los manglares hasta los parques urbanos, siempre ha estado ahí para levantar datos conmigo.

Wendy A. por sus acompañamiento a campo y Luis Lemus, quien realizó su servicio social apoyándome en la digitalización y muestreo de parques; también Mauricio Moo y Alondra Aparicio, quienes durante su estancia profesional colaboraron en la recolección y procesamiento de datos.

Inmensas gracias a Manu, Ivette, Lili, Julia, Mariana, Sarahi, Olivia, Denisse y Nahleli, las chicas más lindas, con quienes, desde que nos conocimos, nunca me han faltado las risas ni su compañía.

Finalmente, a Moni, Melissa, Olivia, Carmen, Eduardo, Alfredo, Bacab y Marco, que de una u otra forma siempre han estado para apoyarme.

Todos ustedes han formado parte de este proceso. Gracias, por tanto. Nos vemos en la siguiente era.

DEDICATORIAS

A mis padres, Evangelina y Vicente, y a la mejor hermana, Jessi, quienes, sin importar la distancia ni la hora, siempre estuvieron disponibles para escucharme. Les agradezco profundamente su tiempo, confianza, apoyo y aliento.

A Mauricio, mi compañero de baile, videojuegos, cine, aventuras y de vida.

A Brandy, Taylor, Melisa y Rosalba, por permanecer a mi lado.

A Eliel, el nuevo integrante de la familia que está por llegar.

A toda mi familia: mis abuelitas, tíos y primos, quienes en todo momento me han brindado su respaldo y cariño.

Sin ustedes, nada de esto habría sido posible.

ÍNDICE

LISTADO DE TABLAS.....	III
LISTADO DE FIGURAS	IV
LISTADO DE ABREVIATURAS.....	V
RESUMEN.....	VII
INTRODUCCIÓN.....	1
1. CAPITULO I.....	4
1.1. ANTECEDENTES.....	4
1.1.1. LA MITIGACIÓN DEL CAMBIO CLIMÁTICO.....	4
1.1.2. ARBOLADO URBANO Y LOS SERVICIOS ECOSISTÉMICOS	6
1.1.3. BIOMASA AÉREA Y SU ESTIMACIÓN	7
1.1.4. PERCEPCIÓN REMOTA.....	10
1.1.5. IMÁGENES PLANET.....	14
1.1.6. ÍNDICES DE VEGETACIÓN	16
1.1.7. MEDIDAS DE TEXTURAS.....	18
1.2. PLANTEAMIENTO DEL PROBLEMA	22
1.3. PREGUNTAS DE INVESTIGACIÓN	23
1.4. HIPÓTESIS.....	24
1.5. OBJETIVOS	25
1.5.1. OBJETIVO GENERAL	25
1.5.2. OBJETIVO ESPECÍFICOS.....	25
2. CAPITULO II.....	26
2.1. MATERIALES Y MÉTODOS.....	26
2.1.1. ÁREA DE ESTUDIO.....	26
2.1.2. DISEÑO DE MUESTREO	27

2.1.3.	CÁLCULO DE LA BIOMASA	29
2.1.4.	ANÁLISIS DE LAS IMÁGENES DE ALTA RESOLUCIÓN ESPACIAL	30
2.1.5.	CAMBIOS DE COBERTURA Y ESTIMACIÓN DE LA BIOMASA REMOVIDA Y EL CARBONO LIBERADO 33	
3.	CAPITULO III	35
3.1.	RESULTADOS	35
3.1.1.	BIOMASA ÁREA DE LOS DATOS DE CAMPO	35
3.1.2.	BIOMASA ÁREA DE LA IMAGEN DE ALTA RESOLUCIÓN PLANETSCOPE	37
3.1.3.	BIOMASA AÉREA EN EL ÁREA DE ESTUDIO	39
3.1.4.	BIOMASA AÉREA EN PARQUES.....	40
3.1.5.	BIOMASA AÉREA EN EL 2021 Y 2023.....	40
3.1.6.	CAMBIO DE COBERTURA ARBÓREA Y CARBONO REMOVIDO	42
4.	CAPITULO IV	44
4.1.	DISCUSIÓN	44
4.1.1.	ESTIMACIÓN DE LA BIOMASA AÉREA EN PARQUES DENTRO DEL ANILLO PERIFÉRICO DE MÉRIDA, YUCATÁN.....	44
4.1.2.	VARIABLES MÁS IMPORTANTES PARA LA ESTIMACIÓN DE LA BIOMASA AÉREA.....	47
4.1.3.	MAPA DE LA BIOMASA AÉREA EN LA ZONA CONURBADA AL ANILLO PERIFÉRICO DE LA CIUDAD MÉRIDA, YUCATÁN.....	50
5.	CAPITULO V.....	53
5.1.	CONCLUSIÓN.....	53
5.2.	PERSPECTIVAS	53
	BIBLIOGRAFÍA.....	55
	ANEXOS	74

LISTADO DE TABLAS

Tabla 1.1 Característica de las bandas que contienen las imágenes de alta resolución de PlanetScope	15
Tabla 1.2 Descripción de las medidas de textura mediante las matrices de coocurrencia (GLCM) (Haralick et al., 1973; Reyes-Palomeque et al., 2019).....	20
Tabla 3.1 Estimación de la biomasa aérea basada en datos de campo en cada parque muestreado.....	36
Tabla 3.2 Variables explicativas a partir de la imagen PlanetScope para la estimación de la Biomasa aérea en arbolado urbano	37
Tabla 5.1 Coordenadas de las parcelas medidas para la medición de las variables estructurales en campo.....	74

LISTADO DE FIGURAS

Figura 1.1 Regiones del Espectro electromagnético (Bautista-Zúñiga et al., 2004).....	11
Figura 1.2 Reflectancia foliar (Murillo-Sandoval & Carbonell-González, 2012).....	13
Figura 2.1 Localización del área de estudio y las parcelas de muestreo en la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán.....	26
Figura 2.2 Diseño de las parcelas para el cálculo de la biomasa aérea	29
Figura 3.1 Densidad de cobertura arbórea en parques de la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán, ciudad de Mérida, Yucatán.	35
Figura 3.2 Evaluación de la validación cruzada para evaluar la precisión de la estimación de la biomasa aérea. Los puntos representan la biomasa estimada en función de la biomasa observada, la línea verde es la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una relación 1 a 1.....	38
Figura 3.3 Mapa de la biomasa aérea (Mg/ha) en el 2023 en la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán.	39
Figura 3.4 Histograma de la distribución de la biomasa aérea (AGB) en parques urbanos de la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán.	40
Figura 3.5 Mapa de la biomasa aérea en el año 2021 y 2023 en la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán.	41
Figura 3.6 Mapa de los cambios en la cobertura arbórea en la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán que hubo entre los años 2021 y 2023.	42

LISTADO DE ABREVIATURAS

%RMSE (por sus siglas en inglés, Porcentaje del Error Cuadrático Medio)

AGB (por sus siglas en inglés, Biomasa aérea)

b6 (Banda roja)

b6_idm (Homogeneidad de la banda roja)

b8_asm (El segundo momento angular de la banda infrarroja)

b8_var (Varianza de la banda infrarroja)

CO2 (Dióxido de carbono)

DAP (diámetro a la altura del pecho)

GEI (Gases de efecto invernadero)

GLCM (Matriz de co-ocurrencia de niveles de grises)

GPS (por sus siglas en inglés, Sistema de Posicionamiento Global)

ha (Hectáreas)

IV (Índice de vegetación)

LÍDAR (por sus siglas en inglés, Light Detection and Ranging)

Mg (Megagramos)

NDRE (Índice de Vegetación de Diferencia Normalizada de Borde Rojo)

NDVI (Índice de Vegetación de Diferencia Normalizada)

NDVI_diss (Disimilaridad en el NDVI)

NIR (por sus siglas en inglés, Infrarrojo cercano)

nm (nanómetros)

Ppm (Partes por millón)

R² (Coeficiente de determinación)

REDD+ (Reducción de Emisiones por Deforestación y Degradación Forestal, y Conservación, Gestión Forestal Sostenible y Aumento de las Reservas de Carbono)

RMSE (por sus siglas en inglés, Error Cuadrático Medio)

VIF (Valor de inflación de la varianza)

RESUMEN

El arbolado urbano proporciona múltiples bienes y servicios ecosistémicos, entre ellos el almacenamiento de carbono. Este estudio se centró en la cuantificación y mapeo de la biomasa aérea y del carbono removido en Mérida y su zona conurbada, utilizando imágenes del satélite PlanetScope. A través de un modelo de estimación, se calculó la biomasa dentro del anillo periférico de Mérida y en la zona conurbada, identificando una variabilidad significativa en su distribución: valores de 70 ± 54 Mg/ha en áreas de bosque remanente y en zonas urbanizadas rondan en 43 ± 40 Mg/ha. Los resultados mostraron una disminución en la biomasa aérea en parques urbanos y en la biomasa aérea asociados con el cambio de uso de suelo fuera del anillo periférico. Entre 2021 y 2023, se estimó una variación de 38 Mg/ha en la biomasa aérea, en promedio, esta variabilidad equivale a una posible liberación de 19 Mg/ha de carbono, los valores elevados de la desviación estándar se deben a la heterogeneidad de las áreas verdes de la ciudad y la vegetación remanente. Este fenómeno resalta el impacto del cambio de uso de suelo en el almacenamiento de carbono, contribuyendo a la reducción de áreas de vegetación natural y al incremento de emisiones de gases de efecto invernadero. La combinación de datos espectrales y texturales mejoró la precisión en la estimación de biomasa aérea, mientras que el mapa generado permitió identificar áreas prioritarias para la conservación y reforestación.

INTRODUCCIÓN

A menudo se dice que lo mejor de la vida no se planea, simplemente sucede. Sin embargo, cuando se trata del desarrollo de una comunidad, no llevar a cabo una planificación conlleva repercusiones ambientales significativas (Useni Sikuzani et al., 2019). En las ciudades, las áreas verdes representan entornos naturales convertidos en espacios de uso público o privado (Vargas-Hernández, Pallagst, & Hammer, 2018), destacando por su vegetación y su propósito principal: proporcionar oportunidades de recreación, como el entretenimiento, el ocio y la relajación. No obstante, es esencial considerar también el valor de estos espacios en términos de los beneficios que proporcionan a la sociedad (Vargas-Hernández et al., 2023).

Los árboles desempeñan un papel clave en la mitigación del cambio climático al absorber dióxido de carbono (CO₂) a través de la fotosíntesis, cuya concentración ha aumentado por actividades humanas como la quema de combustibles fósiles y la deforestación. Además, los árboles contribuyen a la regulación térmica en las ciudades mediante la transpiración, lo que ayuda a reducir las islas de calor (Zhao et al., 2023). Éstos también favorecen la retención de aguas pluviales y disminuyen la demanda energética en espacios urbanos al proporcionar sombra (Steenberg et al., 2019).

Para evaluar su impacto en la captura de carbono, es fundamental cuantificar su biomasa, ya que esta representa la cantidad de carbono almacenado. La biomasa depende de factores como la especie, el tamaño y la densidad de la madera (Morales-Gallegos et al., 2023) y se puede medir de manera directa, a través del pesaje del material vegetal, o de forma indirecta, mediante ecuaciones alométricas, que permiten estimaciones sin intervenir físicamente los árboles (Chave et al., 2014). Sin embargo, la cuantificación se vuelve más compleja cuando se trabaja a nivel de comunidades forestales debido a la diversidad de especies y estructuras en los ecosistemas (Réjou-Méchain et al., 2019).

En las últimas décadas, la percepción remota ha facilitado la estimación de biomasa en grandes extensiones (Manzo-Delgado & Meave, 2003; Toth & Józskó, 2016). A través de sensores ópticos y de radar, es posible derivar índices de vegetación, como el Índice de Vegetación de Diferencia Normalizada (NDVI) y el Índice de Vegetación de Diferencia

Normalizada de Borde Rojo (NDRE), así como parámetros de polarización que reflejan la densidad y salud de la vegetación (Hernández-Stefanoni et al., 2020). Por otro lado, los sensores LiDAR (Light Detection and Ranging) permiten obtener información tridimensional de la estructura del dosel, lo que mejora la modelación de la biomasa aérea (Fritz et al., 2013).

Las imágenes utilizadas en estos análisis presentan diferentes resoluciones: espacial, temporal, radiométrica y espectral (Toth & Józków, 2016) La elección de la resolución influye en los resultados obtenidos. Algunas resoluciones permiten análisis detallados, generalmente en estudios a nivel local (McKinney et al., 2022; Wavrek et al., 2023), mientras que otras son más adecuadas para estimaciones generales en estudios regionales o globales (Hernández-Stefanoni et al., 2021; George-Chacón et al., 2022). Por lo tanto, según el tipo de estudio, es importante seleccionar la resolución más adecuada y, posteriormente, identificar los sensores que poseen esas características. Esto contribuye a minimizar las limitaciones al uso de la percepción remota, como las condiciones atmosféricas, la variabilidad espacial y temporal, y las diferencias entre las fechas de adquisición de datos de campo e imágenes satelitales (Baccini et al., 2007; Réjou-Méchain et al., 2019).

Dado que las ciudades no abarcan vastas extensiones y sus áreas verdes están en constante evolución, es crucial trabajar con imágenes de muy altas resoluciones debido a que se pueden capturar detalles finos de la estructura de las áreas verdes, como la distribución de árboles y la heterogeneidad en la composición (Réjou-Méchain et al., 2019).

En este contexto, los drones son una excelente opción, ya que estos dispositivos pueden llevar sensores de muy alta resolución, capaces de obtener píxeles de menos de 1 metro lo que los convierte en una herramienta ideal para estudiar y gestionar de manera actualizada las áreas verdes urbanas (Torresan et al., 2017; McKinney et al., 2022). Sin embargo, la cobertura de las imágenes del dron y su adquisición pueden no ser siempre accesibles, limitando su uso en ciertas situaciones por ejemplo en estudios de gran tamaño.

Por la importancia del estudio de la biomasa aérea de los árboles ante el cambio climático, este estudio tiene como objetivo crear un mapa de la biomasa aérea en la ciudad de Mérida, Yucatán y la zona conurbada al anillo periférico, para evaluar las cobertura del arbolado en

un período de dos años y estimar el carbono que ha sido removido debido a los cambios en estas coberturas.

1. CAPITULO I

1.1. ANTECEDENTES

1.1.1. La mitigación del cambio climático

Se estima que más de la mitad de la población mundial reside en áreas urbanas (UNDESA, 2019), y esta tendencia sigue en aumento. Las ciudades están en constante cambio, con la construcción de nuevos complejos residenciales, centros comerciales y la expansión de redes viales para mejorar la movilidad. Sin embargo, este desarrollo conlleva una creciente degradación de los bosques y una mayor emisión de Gases de Efecto Invernadero (GEI) (Murray-Tortarolo et al., 2016; Zhang et al., 2024).

Los GEI provocan alteraciones en la atmósfera al contribuir al calentamiento global. Este proceso ocurre debido a que los gases absorben la radiación infrarroja y emiten calor en todas direcciones (Eichhorst & Bongardt, 2017). Cuantos más de estos gases se liberan, más difícil resulta que el calor escape al espacio, contribuyendo al efecto invernadero. El aumento de estos gases comenzó a partir de 1760 con el inicio de la Revolución Industrial (Arévalo Moscoso, 2019), y han sido tan abundantes que los ecosistemas naturales no pueden eliminarlos por completo.

Entre estos gases se encuentran el vapor de agua, el dióxido de carbono (CO₂), el metano (CH₄), el óxido nitroso (N₂O), el ozono (O₃) y cualquier fluorocarbono (CEPAL, 2008). Sin embargo, uno de los gases con mayor acumulación en la atmósfera es el CO₂ (IPCC, 2023). El CO₂ presente en la atmósfera proviene de la quema de combustibles fósiles y procesos industriales (CO₂-FFI), uso de suelo, cambio de uso de suelo y actividades silvícolas y gases fluorados (IPCC, 2023). Estos factores han incrementado con el tiempo observándose un aumento de 1850 al 2019 (IPCC, 2023). Por ejemplo, en 2024, la concentración de CO₂ en la atmósfera alcanzó las 422 ppm según el Global Carbon Budget 2024 (Friedlingstein et al., 2024). Por otra parte, en México, durante el año 2019, se registraron emisiones de 736.63 millones de megagramos (Mg) de CO₂, mientras que solo se absorbieron 201.94 millones de Mg, lo que resultó en emisiones netas de 534.69 millones de Mg de CO₂ (INECC, 2021).

Para mitigar estas emisiones, existen diversas opciones, desde el desarrollo de tecnologías sostenibles, como la generación de energía eólica o solar, que se estima aumentarán en un 165% en México para 2031 (Cabrera Reyes et al., 2024), hasta el uso de transporte eléctrico. Por ejemplo, la implementación de 6,417 vehículos eléctricos en la Ciudad de México entre 2016 y 2025 podría evitar la emisión de 87,339 Mg de CO₂/km (Castillo Rodríguez, 2024). También es clave la adopción de políticas específicas (Arévalo-Moscoso, 2018). Un ejemplo destacado es el Acuerdo de París, que entró en vigor en 2020 con el objetivo de reducir las emisiones de GEI en un 30% por unidad de PIB para 2030 (UNFCCC, 2015). Este acuerdo involucra a 190 países, incluidos China y Estados Unidos, que representan el 39% de las emisiones de GEI a nivel mundial (Olivier & Peters, 2018).

Una de las estrategias del Acuerdo de París para la reducción del CO₂ es el uso de créditos de carbono (IPCC, 2023), de este modo, gobiernos y empresas adquieren estos bonos para compensar su huella de carbono, ya que cada bono representa la mitigación de un Mg de CO₂ (SEMARNAT-INECC-GGGI, 2024). En México, los precios de los bonos de carbono oscilan entre 3.8 y 25 USD (SEMARNAT-INECC-GGGI, 2024). De esta manera los árboles ayudan en la mitigación del carbono, ya que mediante la fotosíntesis logran almacenar el carbono del CO₂ en su estructura como biomasa (Rodríguez-Larramendi, 2016; Molina-Alomar, 2021) y de esta manera a nivel mundial los bosques almacenan aproximadamente 295,000 millones de Mg de carbono (FAO, 2020), de las cuales un 25% se encuentra almacenado en los bosques tropicales (Poorter et al., 2015). En este ecosistema, el almacenamiento de carbono se debe más a la estructura de sus estratos forestales que a la diversidad de especies (Ali & Yan, 2017; Wen et al., 2022; Khan et al., 2024).

En América Latina los bosques tropicales, representan el 58.1% de su territorio (FRA, 2015), lo que la posiciona como el segundo mayor proveedor de créditos voluntarios a nivel mundial (Blanton et al., 2024). Los mercados de carbono en la región están dominados por proyectos REDD+ (Reducción de Emisiones por Deforestación y Degradación Forestal, y Conservación, Gestión Forestal Sostenible y Aumento de las Reservas de Carbono), seguidos por iniciativas de energía renovable, restauración de bosques nativos, eficiencia energética y cambio de combustibles (Blanton et al., 2024). Sin embargo, proyectos como “Alianza México REDD+” se centran mayormente en áreas extensas de bosque, como los ejidos (Alianza México REDD+, s/f), dejando a un lado el arbolado urbano.

1.1.2. Arbolado urbano y los servicios ecosistémicos

Todo árbol ubicado dentro de un asentamiento humano se considera parte del arbolado urbano (Vargas-Hernández, Pallagst, & Zdunek-Wielgołaska, 2018). Aunque no forma un conjunto homogéneo, este arbolado se clasifica en función de su tamaño, ubicación y propósito, encontrándose en parques, jardines, zoológicos, campos deportivos, camellones, patios, cementerios, muros verdes, plazas cívicas, áreas de recuperación, y otras áreas urbanas que cumplen múltiples funciones (Byrne & Sipe, 2010; Vargas-Hernández, Pallagst, & Zdunek-Wielgołaska, 2018). Por lo que la OMS recomienda una disponibilidad mínima de 9 m² de área verde por habitante (Sorensen et al., 1998) y de 15 m² por la ONU para maximizar los beneficios ecológicos y sociales de estos espacios (Alanís Rodríguez et al., 2023). Esto se debe a que cuanto mayor sea la extensión de las áreas verdes, mayor será el valor de sus servicios ecosistémicos y los beneficios ecológicos asociados (Cerón-Palma et al., 2013; Yang et al., 2023). Sin embargo, en ciudades muy densas, la distribución de parques y áreas verdes puede ser desigual o insuficiente, por ejemplo, en Mérida, Yucatán, un estudio de 2015 reveló la falta de suficientes parques para la población y el deterioro de las instalaciones, especialmente en el noroeste y la zona sur de la ciudad (Pérez-Medina & López-Falfán, 2015). Estas desigualdades pueden repercutir en los servicios que los árboles urbanos proporcionan.

Los servicios ecosistémicos se dividen en cuatro categorías: los servicios culturales representan beneficios intangibles obtenidos de la interacción con los ecosistemas, como la recreación al aire libre, la estética, el conocimiento tradicional y un sentido de conexión con la naturaleza. Los servicios de aprovisionamiento incluyen productos obtenidos directamente de los ecosistemas, como alimentos y recursos naturales. Los servicios de regulación se derivan indirectamente de los procesos de los ecosistemas e incluyen aspectos como la regulación climática, el almacenamiento de carbono, la purificación del aire y la gestión de inundaciones y finalmente, los servicios de soporte sostienen el funcionamiento de los otros tres servicios (EM, 2003; Renner, 2019; Orellana-Asenjo, 2022). Con el tiempo, el valor de estos servicios supera el costo inicial de la plantación y el mantenimiento del arbolado urbano (McPherson et al., 2015).

A pesar de estos beneficios, el arbolado urbano enfrenta retos. Las malas decisiones sobre las especies a plantar y el mantenimiento inadecuado pueden generar problemas como

daños a la infraestructura urbana debido al crecimiento de raíces o riesgos por la caída de ramas (Drew-Smythe et al., 2023), lo que afecta la cantidad y calidad de las áreas verdes, reduciendo así la efectividad de los servicios ecosistémicos. Para maximizar sus beneficios, las políticas públicas deben fomentar la creación de nuevas áreas verdes y el adecuado mantenimiento de las existentes (López-López et al., 2018).

Además, el arbolado urbano contribuye a contrarrestar los efectos negativos de las actividades humanas, como la reducción del consumo energético (Cerón-Palma et al., 2013), la disminución de la contaminación del aire y del agua (Chen, 2017), la mitigación de la formación de islas de calor (Carrillo-Niquete et al., 2022), la retención de agua (Ramírez-Medina, 2022) y destacado significativamente en la reducción de las concentraciones de CO₂ contribuyendo directamente a mitigar el calentamiento global (McPherson, 1998; McHale et al., 2007; Ramírez-Medina, 2022; Liu et al., 2023; Guo et al., 2024; Jenerette & Herrmann, 2024; Kurtz et al., 2024). Por ejemplo, en la ciudad de Chicago, el arbolado urbano almacena cerca de 2.5 millones de Mg de CO₂ anualmente (Nowak et al., 2014), mientras que el Jardín Botánico de Río de Janeiro, Brasil, puede llegar a almacenar aproximadamente 14,000 Mg de CO₂ (Kurtz et al., 2024).

Este proceso de captura de CO₂ se relaciona con variables, como la composición y la estructura de los árboles, que influyen en su capacidad para almacenar el carbono (Yachi & Loreau, 1999), debido a que árboles más grandes están almacenando más carbono (Stephenson et al., 2014). Sin embargo, el factor clave sigue siendo la cantidad de árboles (Dash et al., 2022), para aumentar esa cantidad, es necesario implementar prácticas de conservación tanto en áreas urbanas como en bosques naturales (Ren et al., 2019; Dash et al., 2022). En este sentido, las áreas verdes, como parques y jardines botánicos, tienden a ser grandes reservorios de CO₂ en las ciudades (Kurtz et al., 2024), albergando una amplia variedad de plantas, principalmente árboles, lo que optimiza su capacidad de almacenamiento de carbono (Dash et al., 2022). Por ello, comprender el papel del arbolado urbano en la captura de CO₂ es esencial para la mitigación del cambio climático.

1.1.3. Biomasa aérea y su estimación

La biomasa incluye toda la materia orgánica viva sobre y bajo el suelo, como los árboles, arbustos, enredaderas, etc., así como la materia muerta, como la hojarasca y la madera,

excluyendo el contenido de agua con la finalidad de reflejar su peso seco (Brown, 1997). Para estimar la biomasa total de un bosque, se mide principalmente la biomasa aérea de los árboles, que comprende las hojas, ramas, tronco y corteza (Zheng et al., 2007; McHale et al., 2009; Fischer et al., 2019), ya que estos componentes representan la mayor parte de la biomasa viva. Esta cantidad se expresa en toneladas secas por unidad de área, comúnmente en megagramos por hectárea (Mg/ha) (Brown, 1997), y se conoce como densidad de biomasa. Así, para calcular la biomasa total de un área, basta con multiplicar esta densidad por el área de estudio.

La estimación de la biomasa aérea puede abordarse de manera directa o indirecta. El método directo, aunque preciso, implica dificultades, ya que requiere derribar el árbol, secarlo y pesar cada una de sus partes, como señalan estudios anteriores (Diaz-Franco et al., 2007). Ante la impracticabilidad del método directo, se recurre a la estimación indirecta. Este método implica el uso de modelos matemáticos (ecuaciones alométricas) basados en diversos parámetros obtenidos de los árboles, pero sin recurrir a la destrucción del árbol (Avendaño-Hernández et al., 2009). Las ecuaciones alométricas se asocian a parámetros estructurales de la vegetación que son factibles de medir, como el diámetro a la altura del pecho (generalmente medido a 1.3 m sobre el suelo), la altura del árbol (la altura total y la altura en donde comienza la copa), el tamaño de la copa o con la densidad de la madera (Wilkes et al., 2018). La densidad de la madera es especialmente importante para estimar la biomasa aérea, sobre todo en bosques tropicales donde la diversidad de especies es alta (Chave et al., 2014). Sin embargo, debido a esta diversidad y las variaciones locales, es difícil obtener la densidad de la madera para cada especie en el área de estudio. En estos casos, se pueden utilizar aproximaciones como los promedios de densidad por género o familia, o, en su defecto, el promedio de la densidad de la madera en la parcela. En los bosques del sudeste asiático, el promedio de densidad de madera de los géneros explicó el 56% de la variación en las especies individuales y hasta el 72,5% al excluir valores atípicos (Slik, 2006).

El cálculo de la biomasa aérea utilizando ecuaciones alométricas se hace a nivel de árbol. Para estimar la biomasa aérea de un área se incluyen todos los árboles en esa área y se suma su biomasa (Jo & McPherson, 2001; Rodríguez-Larramendi, 2016; Guo et al., 2024). Una de las formas en la que se recomienda realizar el inventario en las ciudades es con el

uso de parcelas circulares de 400 m² las cuales presentan un error estándar relativo del 12% (Nowak et al., 2008). Se recomienda ampliar el tamaño de la muestra para obtener una mayor variabilidad de la biomasa aérea y poder tener estimaciones con mayor precisión (Hernández-Stefanoni et al., 2018).

Es importante considerar el error asociado al uso de ecuaciones alométricas desarrolladas para bosques naturales, cuando se aplican a áreas urbanas (McHale et al., 2009). Las condiciones cambian significativamente entre un bosque natural y un entorno urbano. Por ejemplo, en las áreas urbanas hay una menor densidad de árboles, lo que reduce la competencia por luz, agua y nutrientes, influyendo en el crecimiento y la densidad de la madera (Rhoades & Stipes, 1999; McHale et al., 2009). Además, las condiciones ambientales, como la humedad del suelo, la temperatura del aire, la temperatura de las hojas, la humedad relativa y el déficit de presión de vapor, pueden variar en entornos urbanos, afectando negativamente el crecimiento de los árboles. Esto se traduce en un crecimiento más lento, sistemas de raíces menos densos e incluso la caída prematura de las hojas (McHale et al., 2009).

Para reducir este error, se recomienda utilizar ecuaciones alométricas locales que incluyan el mismo tipo de vegetación (Ramírez Ramírez et al., 2017; Ramírez-Medina, 2022). Esto es esencial porque la información obtenida puede variar significativamente según la ubicación del estudio. Actualmente, existe una mayor cantidad de información sobre el arbolado urbano en diferentes partes del mundo. El 47% de los estudios se han realizado en zonas templadas, mientras que los biomas tropicales y áridos solo representan el 23% de las estimaciones alométricas disponibles (Jenerette & Herrmann, 2024). La mayoría de estos estudios utilizan el programa i-Tree Eco para estimar el almacenamiento de carbono (Martin et al., 2011; Wu et al., 2019; Ramírez-Medina, 2022). Este programa es un software gratuito desarrollado por investigadores del Servicio Forestal de los Estados Unidos de América (USFS), que proporciona una serie de herramientas para el análisis y evaluación de los beneficios del arbolado urbano. Actualmente, i-Tree Eco ha sido adaptado con datos de contaminación y meteorología en cinco países, incluido México, para mejorar la precisión de sus estimaciones en el cálculo del carbono almacenado por árbol (i-Tree, 2018).

Otro método útil para la estimación de la biomasa aérea y que es factible en términos de tiempo y dinero, es la percepción remota. En los últimos años, los avances en la

teledetección y en los Sistemas de Información Geográfica, han facilitado la medición de la cobertura de los bosques y en este caso sería del arbolado urbano (Pettorelli et al., 2017). Sin embargo, para estimar la biomasa aérea en el arbolado urbano, las observaciones discontinuas y de corto plazo no son suficientes, es necesario contar con datos continuos y a largo plazo que reflejen adecuadamente las variaciones temporales y espaciales (Wang et al., 2021) y con la perfección remota se podría realizar.

1.1.4. Percepción remota

La percepción remota se refiere a la capacidad de obtener información sobre un objeto o fenómeno sin necesidad de estar físicamente presente en el lugar (Hernández-Stefanoni et al., 2021). Esta técnica se lleva a cabo a través de sensores ubicados en diversas plataformas, como aeronaves, satelitales o vehículos no tripulados, utilizando energía electromagnética (Ciesla, 2000; Murillo-Sandoval & Carbonell-González, 2012; Pettorelli et al., 2017). La energía electromagnética que proviene del sol y puede ser transferida de un punto a otro de tres maneras, a través de la conducción, conexión o radiación (Bautista-Zúñiga et al., 2004). La radiación tiene un interés particular en la percepción remota, este tipo de energía se transfiere en diferentes longitudes de onda, medidas en micrómetros (μm) y su frecuencia en hercios (Hz) que es el número de ondas por unidad de tiempo (Bautista-Zúñiga et al., 2004), formando lo que se conoce como el espectro electromagnético (Verhoeven, 2017). El espectro electromagnético se divide en diferentes regiones con longitudes de onda que varían significativamente, desde las extremadamente cortas, como los rayos X, hasta las bastante largas, como las ondas de radio (Ciesla, 2000; Gilabert Navarro et al., 1997) (**Figura 1.1**).

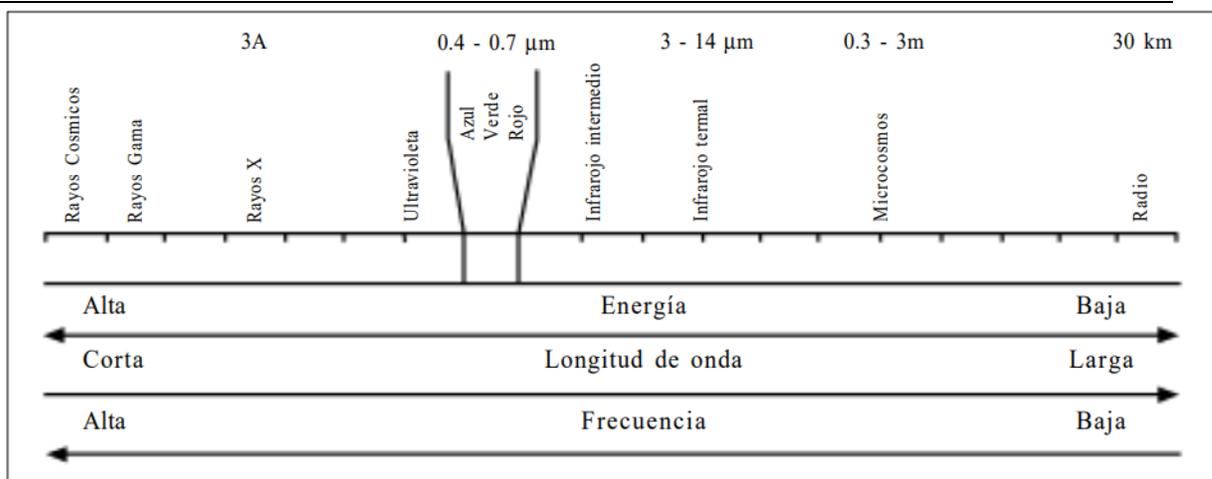


Figura 1.1 Regiones del Espectro electromagnético (Bautista-Zúñiga et al., 2004)

Este tipo de energía llega a los objetos y puede ser reflejada, absorbida o transmitida. La cantidad de energía reflejada, absorbida o transmitida varía según el tipo de superficie terrestre, lo que permite identificar distintos rasgos de la superficie a través de sus propiedades espectrales (Bautista-Zúñiga et al., 2004). La información es recopilada por los sensores, pero las diferencias espectrales que estos captan dependen de cuatro factores: la resolución espacial, la resolución temporal, la resolución radiométrica y la resolución espectral (Toth & Józków, 2016).

La resolución espectral es la cantidad de bandas espectrales o regiones del espectro que un sensor puede capturar. Cuantas más bandas espectrales pueda registrar, más información se puede obtener sobre la composición de los objetos y fenómenos en la escena. Los sensores multispectrales son capaces de registrar varias longitudes de onda.

La resolución radiométrica se relaciona con la capacidad de un sensor para medir la radiación reflejada o emitida por los objetos en la escena. Una mayor resolución radiométrica permite detectar variaciones más sutiles en la intensidad de la energía electromagnética.

La resolución temporal está relacionada con la frecuencia con la que un sensor pasa sobre la misma área. Esto se traduce en la rapidez con la que se pueden detectar cambios en la superficie a lo largo del tiempo

La resolución espacial hace referencia al tamaño de píxel o la capacidad de un sensor para distinguir los detalles en la superficie de la Tierra. Una mayor resolución espacial significa que puede detectar objetos más pequeños.

De esta manera, la percepción remota ha sido una herramienta valiosa en el mapeo de atributos y cobertura de la superficie terrestre y se ha utilizado en diversos campos, incluyendo estudios ecológicos, monitoreo de recursos forestales, planificación urbana y evaluación de los servicios ecosistémicos (Myers et al., 1966; Ciesla, 2000; Turner et al., 2003; Giri, 2016; Fischer et al., 2019).

En la vegetación, el comportamiento espectral depende de las propiedades de las hojas, como la pigmentación, el grosor, la composición y la cantidad de agua libre dentro del tejido foliar, así como de la estructura del dosel. Estas características varían entre especies, y también cambian si las plantas están afectadas por enfermedades o plagas, y a lo largo del tiempo (Murillo-Sandoval & Carbonell-González, 2012). Por lo tanto, el comportamiento espectral de la vegetación varía con cada tipo de longitud de onda (**Figura 1.2**).

En la banda azul y roja, la radiación es absorbida por los pigmentos de la hoja, mientras que en la banda verde existe un poco más de reflectancia que las otras bandas del espectro visible, lo que explica por qué vemos la vegetación de este color. Sin embargo, la reflectancia es significativamente mayor en el infrarrojo cercano debido al aire presente en el parénquima esponjoso de las hojas (Knipling, 1970). Por lo tanto, la vegetación saludable refleja una gran proporción de la energía electromagnética en esta región del espectro (Ollinger, 2011).

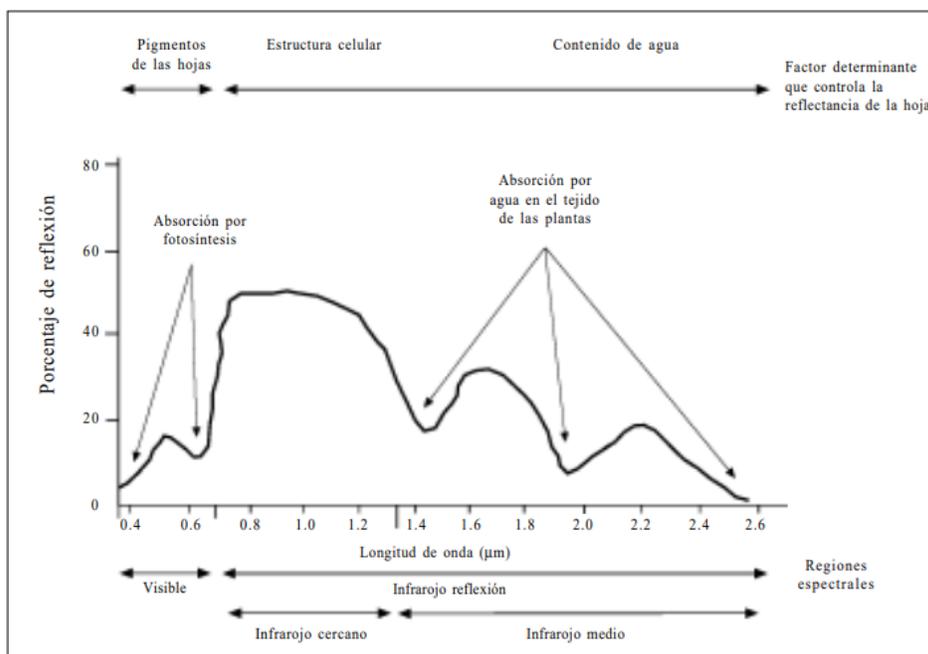


Figura 1.2 Reflectancia foliar (Murillo-Sandoval & Carbonell-González, 2012)

Los sensores utilizados en percepción remota pueden variar en su tecnología y fuente de energía (Reddy, 2018). Algunos sensores, como los sensores ópticos, utilizan cámaras y lentes para registrar la radiación electromagnética en el espectro visible e infrarrojo, proporcionando imágenes de alta resolución espacial (Joshi et al., 2016). Ejemplos de sensores ópticos incluyen Landsat, SPOT, MODIS y los satélites Sentinel.

Por otro lado, los sensores de radar generan su propia energía mediante pulsos de microondas. Ejemplos de estos sensores incluyen RADARSAT, ALOS y los satélites Sentinel-1 (Marchionni & Cavayas, 2014; Joshi et al., 2016; NASA: Earthdata, 2023). Además, existen sensores de nube de puntos que utilizan tecnología LiDAR (Light Detection and Ranging) para obtener información tridimensional de la superficie terrestre, emitiendo pulsos de luz láser y midiendo el tiempo que tardan en reflejarse y regresar al sensor (Béland & Kobayashi, 2021). En el caso de los sensores LiDAR que generan una nube de puntos, a pesar de proporcionar información detallada y tridimensional, presentan limitaciones, como una cobertura espacial limitada y requerimientos de recursos significativos que pueden hacer que no sean la opción más adecuada para el estudio que se va a llevar a cabo (Béland & Kobayashi, 2021).

Es importante tener en cuenta que cada tipo de sensor tiene sus propias ventajas y limitaciones. Los satélites, por ejemplo, pueden estar ubicados hasta a 35,000 km de la Tierra, lo que les permite abarcar una extensa zona (Bautista-Zúñiga et al., 2004). Sin embargo, debido a esta gran distancia, presentan una baja resolución espacial. Entre los satélites más conocidos con estas características se encuentran Landsat a 700 km dando como resultado una resolución espacial de 30 m y Sentinel-2 a 780 km brinda una resolución espacial de 10 m (Francini et al., 2020).

La resolución espacial es uno de los principales requerimientos para el monitoreo, ya que brinda un mejor detalle de la superficie terrestre (Atkinson & Aplin, 2004). Estudiar el arbolado urbano a partir de imágenes con resolución baja o media puede ocasionar errores, ya que el arbolado urbano no es completamente visible en estas imágenes, lo que podría resultar en representaciones incompletas de lo que realmente está en el terreno (Twumasi et al., 2022). Esto puede afectar las estimaciones de biomasa, la captura de carbono y otros análisis de cobertura terrestre. Sin embargo, la teledetección ha desempeñado un papel importante al crear mejores herramientas de monitoreo de la condición del ecosistema del bosque urbano.

1.1.5. Imágenes Planet

Las imágenes PlanetScope son imágenes satelitales multispectrales de alta resolución. Estos son obtenidos con una constelación de más 130 satélites en órbita, lanzados por Planet desde el año 2017. La constelación PlanetScope obtiene imágenes con una resolución de 3.7 metros por píxel alrededor de toda la Tierra. Este tipo de resolución se clasifica como alta resolución (> 1 a ≥ 5 m) (Dowman et al., 2013). Las imágenes PlanetScope son derivados de tres tipos de instrumentos que Planet ha incorporado en diferentes años en los satélites, se identifican como PS2, PS2.SD y PSB.SD, con el primero se capturaron imágenes en los canales de rojo, verde, azul e infrarrojo cercano (NIR) en el año 2014 hasta el año 2022, con el segundo se capturaron imágenes desde el año 2019 al 2022 en los mismo canales que el primero, sin embargo realizaron mejoras en los filtros de los canales, mientras que el tercero (PSB.SD) presenta los mismos filtros de la segunda, pero se incorporan canales de nuevo borde rojo, verde I, azul costero y canal amarillo, estas imágenes están disponibles a partir del 2020 (**Tabla 1.1**) Estos satélites recopilan datos de 200 millones de km²/día, operan a 400 km de altura, tienen una resolución espacial de 3 m

remuestreada y una resolución temporal de un día (Planet, 2024). Estas características hacen que las imágenes sean útiles para monitorear perturbaciones forestales (Francini et al., 2020).

Tabla 1.1 Característica de las bandas que contienen las imágenes de alta resolución de PlanetScope

Banda	Nombre	Longitud de onda (nm)
1	Azul costero	443
2	Azul	490
3	Verde I	531
4	Verde	565
5	Amarillo	610
6	Rojo	665
7	Borde Rojo	705
8	Infrarrojo	865

Estas imágenes se han utilizado para estimar la biomasa aérea en los bosques tropicales montañosos de Usambara Occidental, Tanzania. En este estudio, se comparó la eficacia de sensores ópticos y de radar de apertura sintética (PlanetScope, Sentinel-2, Landsat 8 OLI, ALOS-2/PALSAR-2 y Sentinel-1). Los resultados indicaron que las imágenes del sensor óptico de PlanetScope fueron las más precisas para la estimación de la biomasa aérea, con un coeficiente de determinación (R^2) de 0.16 y un error cuadrático medio (RMSE) de 69.19%. Las variables predictoras utilizadas en la estimación incluyeron texturas de índices de vegetación, las cuales ayudaron a mitigar problemas de saturación (Madundo et al., 2023).

Para el arbolado urbano, las imágenes de PlanetScope han demostrado un gran potencial debido a las características que presentan sus resoluciones. Por ejemplo, en Buffelsdraai,

Sudáfrica, se logró estimar con precisión las existencias de carbono reforestado, alcanzando un coeficiente de determinación (R^2) de 0.78 y 0.81, y un error cuadrático medio (RMSE) de 27.33 y 29.75 Mg Ha⁻¹. En este estudio, las variables predictoras fueron índices de vegetación que utilizaron la banda del borde rojo (Matiza et al., 2024). Otro estudio en el que se estimó la biomasa aérea en arbolado urbano fue en Jebres, Surakarta, donde se obtuvo un coeficiente de determinación (R^2) de 0.44 utilizando únicamente el índice de vegetación normalizada (NDVI) como variable predictora (Permatasari et al., 2023).

Las características de resolución de las imágenes de PlanetScope, junto con la aplicación de técnicas como los índices de vegetación y las medidas de textura, han demostrado buenos resultados en la estimación de la biomasa aérea.

1.1.6. Índices de vegetación

El uso de una sola banda espectral para estudiar la vegetación crea dificultades en la interpretación, debido a que el comportamiento de las bandas espectrales está en función de su reflectancia y saturación (Paz-Pellat et al., 2014). La banda del rojo tiene una baja reflectancia debido a la absorción de la clorofila y se satura rápidamente, mientras que la banda del infrarrojo cercano posee una alta reflectancia determinada por la estructura del mesófilo esponjoso foliar, lo que le permite mantener un rango más amplio de valores sin saturarse (Paz-Pellat et al., 2014). Dado que las banda Roja e Infrarroja tienen comportamientos opuestos en términos de saturación y reflectancia, su combinación permite diferenciar la vegetación, por esta razón, una alternativa efectiva es emplear índices de vegetación (IV) (Meneses et al., 2015; Casiano dominguez & Paz Pellat, 2018). La ventaja que tienen los IV es que muestran una mayor correlación con parámetros ecológicos y agronómicos, por ejemplo, la biomasa o el índice de área foliar (Paz-Pellat et al., 2014). Estos índices permiten distinguir entre áreas con alta actividad fotosintética de vegetación, zonas con poca actividad fotosintética y áreas sin vegetación, a través de operaciones algebraicas sencillas y resultados fáciles de interpretar (Wavrek et al., 2023). Estos índices utilizan firmas espectrales de la vegetación para evaluar la productividad y salud de los bosques. Las firmas espectrales son el reflejo de la energía que emiten en este caso las plantas y pueden variar en función de factores como el color, tamaño y estrés (Assmann et al., 2019).

En la región visible del espectro electromagnético, los pigmentos de las hojas absorben la mayor parte de la energía y reflejan muy poco en el infrarrojo cercano. Esto crea un contraste espectral entre las bandas roja e infrarrojo cercano, lo que permite distinguir la vegetación de otras coberturas (Huete, 2012). A pesar de las correlaciones entre diferentes índices de vegetación, su uso conjunto puede mejorar la caracterización de las propiedades de la vegetación (Huete, 2012).

Entre los diferentes índices de vegetación, el más utilizado es el Índice de vegetación de Diferencia Normalizada (NDVI) (Huete, 2012; McKinney et al., 2022), es eficaz para detectar la verdor del dosel vegetal (McKinney et al., 2022). El NDVI presenta valores que van de -1 a +1, donde valores menores a 0.1 indican cuerpos de agua y tierra desnuda, mientras que valores altos reflejan áreas con alta actividad fotosintética, como selvas, bosques y plantaciones agrícolas (Huete, 2012). En cuanto al almacenamiento de carbono, el NDVI es uno de los índices más recomendados para estimarlo debido a su capacidad de detectar la vegetación (Guo et al., 2024). Su ecuación es la siguiente:

$$(\text{Infrarrojo cercano} - \text{rojo}) / (\text{Infrarrojo cercano} + \text{rojo}) \text{ (McKinney et al., 2022)}$$

Sin embargo, los índices basados en el verdor, como el NDVI, pueden presentar problemas de saturación, especialmente en áreas con vegetación densa, debido a la fuerte absorción de la banda roja en la parte superior del dosel de las plantas (McKinney et al., 2022), donde valores similares pueden corresponder a diferentes niveles de biomasa (Kumar & Mutanga, 2017). Además, esta saturación también ocurre en sitios donde se registra un crecimiento rápido tras un desmonte (Grogan et al., 2016; George-Chacón et al., 2022).

Una alternativa es calcular un índice similar utilizando la banda del borde rojo, conocida como NDRE, que está diseñada para aprovechar datos de reflectancia de alta resolución espectral (Gates et al., 1965). Su principal ventaja sobre el NDVI es que es menos susceptible a la saturación durante las mediciones. Este índice tiene aplicaciones destacadas en el monitoreo forestal, la detección de incendios y el estrés de la vegetación (Evangelides & Nobajas, 2020) y al igual que el NDVI, el NDRE está normalizado en un rango de valores entre -1 y 1 (Barnes et al., 2000). Su ecuación es la siguiente:

$$(\text{Infrarrojo cercano} - \text{red edge}) / (\text{Infrarrojo cercano} + \text{red edge}).$$

En cuanto a las imágenes de PlanetScope, se ha observado que los siguientes índices son buenos estimadores para la biomasa y el almacenamiento de carbono: el Índice de Vegetación Normalizada Verde (GNDVI), el Índice de Vegetación de Diferencia Normalizada de Borde Rojo (NDRE), el Índice de Relación Simple de Borde Rojo (SRRED) (Matiza et al., 2024). Además, se ha encontrado que el índice de clorofila de borde rojo también es efectivo, con una R^2 de 0.89 en la estimación del carbono almacenado (Andreatta et al., 2022). Este rendimiento se debe a que los índices de vegetación basados en la región espectral del borde rojo tienen un mejor desempeño en las imágenes de PlanetScope (Andreatta et al., 2022).

1.1.7. Medidas de texturas

La textura es una medida de la variabilidad de los valores en el píxel y en los píxeles vecinos dentro de una ventana de análisis (Warner, 2011). Se utilizan matrices de coocurrencia espacial para establecer las relaciones entre los píxeles vecinos en diferentes direcciones (Pinto Leal, 2006). El cálculo de la textura se realiza moviendo la ventana de análisis por toda la imagen y asignando un valor único al píxel central en cada movimiento (Pinto Leal, 2006). Se utilizan medidas de primer y segundo orden para cuantificar la textura (**Tabla 1.2**). Las medidas de primer orden se basan en valores estadísticos generados a partir de los valores originales de los píxeles, mientras que las medidas de segundo orden consideran la dependencia e interacción entre los píxeles dentro de la ventana (Haralick et al., 1973; Presutti, 2004).

Las medidas de textura son útiles para estudiar la estructura y características de la vegetación. Se ha demostrado que la heterogeneidad espectral, medida a través de la textura, está relacionada con la heterogeneidad ambiental y la diversidad funcional de la vegetación (Schweiger et al., 2018). También se ha encontrado correlación entre las texturas de las imágenes y atributos de la vegetación como el índice de área foliar, la altura de la vegetación y la biomasa aérea (Hernández-Stefanoni et al., 2014; Ploton et al., 2017). Debido a que analizan la estructura horizontal de la vegetación mediante variaciones en los niveles de gris de la imagen, siendo útiles para derivar variables que no alcancen la saturación y permitan diferenciar entre aperturas de dosel, brechas de dosel o el esparcimiento entre árboles (Andrés-Mauricio et al., 2021). Esta técnica de procesamiento de imágenes es un mejor estimador de la biomasa área que los índices de vegetación,

siendo de mucha utilidad en el mapeo de la biomasa área en bosques tropicales donde la vegetación es más densa (Cutler et al., 2012). Por ejemplo, en un estudio realizado en pastizales, sabanas y bosques, los valores de píxeles y las medidas de textura explicaron hasta un 79% de la variación en la diversidad de la altura del follaje y la estructura horizontal (Wood et al., 2012). Por lo tanto, en la estimación de la biomasa y el almacenamiento de carbono en los bosques tropicales, basada en datos satelitales de alta resolución, la aplicación de modelos que implementen medidas de textura además de la información espectral puede mejorar los resultados (Eckert, 2012).

Tabla 1.2 Descripción de las medidas de textura mediante las matrices de coocurrencia (GLCM) (Haralick et al., 1973; Reyes-Palomeque et al., 2019).

Medidas de textura	Ecuación	Descripción
Homogeneidad	$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1} + (i - j)^2$	Mide la similitud de los valores de intensidad entre píxeles adyacentes. Cuando el contraste entre los píxeles es bajo (son similares), la homogeneidad es alta.
Contraste	$\sum_{i,j=0}^{N-1} P_{i,j}(i - j)^2$	Es la cantidad de variaciones locales en los niveles de gris de la imagen. Cuanto mayor es la variación en los niveles de gris, mayor es el contraste. Si el contraste es 0, los niveles de gris son constantes en toda la imagen.
Disimilaridad	$\sum_{i,j=0}^{N-1} P_{i,j} i - j $	Mide cuán diferentes son los valores de intensidad entre píxeles adyacentes. A mayor diferencia entre los píxeles, mayor es la disimilaridad. Los valores más bajos (cerca de 0) representan colores oscuros, y los valores más altos (cerca de 255) corresponden a colores blancos
Media	$\sum_{i,j=0}^{N-1} iP_{i,j}$	Valor promedio de los píxeles en una matriz. Sus valores varían según la cantidad de tonos de gris en la imagen. Valores altos están relacionados con áreas homogéneas, mientras que valores bajos indican mayor variabilidad
Segundo momento angular	$\sum_{i,j=0}^{N-1} P_{i,j}^2$	También conocido como uniformidad, indica el grado de uniformidad en los niveles de gris de una imagen. Cuanto mayor sea este valor (acercándose a 1), más uniforme es la imagen; si el valor es

1, la imagen es completamente uniforme.

Entropía	$\sum_{i,j}^{N-1} -P_{i,j} \ln(P_{i,j})$	<p>Es una medida de la complejidad de la imagen. Una alta entropía indica una distribución variada y menos uniforme de los niveles de gris, reflejando patrones complejos y texturas detalladas.</p>
Correlación	$\sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right]$	<p>Es la dependencia lineal de los niveles de gris en la imagen. Si la correlación es 0, no existe correlación lineal entre los niveles de gris.</p>
Varianza	$\frac{1}{k} \sum_{i=1}^K (x_i - \mu)^2$	<p>Calcula qué tan dispersos están los valores de los píxeles con respecto a la media de la imagen. Si la varianza es baja, significa que los tonos de gris son más homogéneos y la variación en los valores de los píxeles es menor.</p> <hr/>

1.2. PLANTEAMIENTO DEL PROBLEMA

Actualmente en México, el arbolado urbano no se considera en los estudios de mitigación de CO₂, lo que le resta importancia a un ecosistema crucial en esta situación. Con el rápido crecimiento de las poblaciones, es esencial resaltar su relevancia no solo para aumentar la cobertura, sino también para implementar prácticas de monitoreo y conservación efectiva del arbolado urbano. La Ciudad de Mérida, Yucatán, ha experimentado un rápido incremento demográfico del 19.8% de acuerdo con los datos del censo de Instituto Nacional de Estadística y Geografía (INEGI) (INEGI, 2011, 2021), lo que conlleva no solo un aumento en las emisiones de CO₂, sino también una reducción de los recursos naturales, como los árboles (Carrillo-Niquete et al., 2022), afectando significativamente los beneficios que estos proporcionan (Lomas-Cerón & Ordóñez-Rodríguez, 2016).

No obstante, la ciudad de Mérida ha implementado diversas prácticas para el conocimiento y cuidado de sus áreas verdes. Esto incluye la realización de un inventario del arbolado urbano, donde se encontró un almacenamiento de carbono de 182,100 Mg/ha, (Ayuntamiento de Mérida, 2018b). La información se obtuvo midiendo la mayoría de los árboles de la ciudad mediante 592 parcelas. Además, se realizó un estudio diagnóstico en 541 parques, obteniendo una estimación de 7,179 Mg de carbono almacenado, utilizando el software i-Tree (Ayuntamiento de Mérida, 2018a).

La elaboración de estos informes fue un proceso costoso y laborioso, ya que implicó la medición de casi todos los árboles de la ciudad. Repetir este procedimiento cada cinco años no parece viable, especialmente en una ciudad en constante cambio, además de contar con tecnología que puede optimizar este trabajo mediante el uso de la percepción remota. Integrar estas tecnologías avanzadas ofrece una solución más eficiente y rentable para el monitoreo continuo del arbolado urbano, garantizando una gestión sostenible y precisa de estos importantes recursos naturales. Este estudio propone la elaboración de un mapa para estimar la biomasa aérea del arbolado urbano en la zona conurbada al anillo periférico de la ciudad de Mérida, utilizando imágenes de PlanetScope y analizando los cambios en la cobertura del suelo entre los años 2021 y 2023 para estimar el carbono removido en este periodo.

1.3. PREGUNTAS DE INVESTIGACIÓN

¿Cuál es la contribución de los parques urbanos a la biomasa aérea total en Mérida?

¿Cuál de las siguientes métricas medidas de textura, índices de vegetación (NDVI y NDRE) o bandas espectrales tiene un mayor peso para estimar la biomasa aérea en el arbolado urbano?

¿Cuál es la extensión de la pérdida de cobertura vegetal en la ciudad de Mérida entre los años 2021 y 2023, y cómo impacta esto en la biomasa aérea y el almacenamiento de carbono?

1.4. HIPÓTESIS

Hipótesis 1.

En el año 2023, los parques urbanos de la ciudad de Mérida presentan una biomasa aérea arbórea significativa, comparable o cercana a la estimada en los bosques tropicales colindantes no intervenidos, debido a su mantenimiento regular y selección de especies arbóreas.

Hipótesis 2.

Las variables derivadas de imágenes satelitales PlanetScope como NDRE, medidas de textura y bandas espectrales (roja, infrarroja y borde rojo), presentan mayor capacidad explicativa (valores de R^2 más altos y RMSE más bajos) en la estimación de biomasa aérea arbórea en Mérida, en comparación con los valores de las bandas y NDVI.

Hipótesis 3.

Los cambios en el paisaje urbano modifican la capacidad de los ecosistemas para capturar y almacenar carbono, un proceso clave en la mitigación del cambio climático. La transformación del paisaje urbano de Mérida entre 2021 y 2023 afecta significativamente la biomasa aérea y el almacenamiento de carbono en el área de estudio.

1.5. OBJETIVOS

1.5.1. Objetivo general

Generar un mapa de la biomasa aérea en la ciudad de Mérida y en la zona conurbada al anillo periférico de Mérida, Yucatán, así como estimar los cambios en las cobertura del suelo en un período de dos años y el carbono removido debido a los cambios en la cobertura del suelo.

1.5.2. Objetivo específicos

Estimar la biomasa aérea en parques urbanos de la ciudad de Mérida utilizando datos de campo obtenidos en muestreos aleatorios en parques urbanos de la ciudad de Mérida.

Identificar las variables de las imágenes satelitales que contribuyan a la estimación de la biomasa aérea en el área de estudio, analizando la relación de las bandas espectrales, el NDVI, el NDRE y las medidas de textura con los valores de biomasa obtenidos a partir de las parcelas de muestreo.

Estimar la pérdida de cobertura vegetal en el área de estudio entre los años 2021 y 2023 mediante imágenes satelitales, y calcular la cantidad de biomasa aérea y carbono que se perdió como resultado de la deforestación durante ese periodo.

2. CAPITULO II

2.1. MATERIALES Y MÉTODOS

2.1.1. Área de estudio

La ciudad de Mérida se encuentra en el noroeste de la península de Yucatán, en las coordenadas $20^{\circ}58'N$ $89^{\circ}37'W$. Con una extensión de 651.72 km^2 (**Figura 2.1**), alberga una población de 995,129 habitantes de los 2,454,550 que hay en todo Yucatán (INEGI, 2021). El clima predominante es de tipo Awo, caracterizado como cálido subhúmedo con precipitaciones en la temporada de verano. La temperatura media anual se mantiene entorno a los $26.2^{\circ}C$, con una precipitación promedio anual de 1023.8 mm y la época de lluvias abarca desde junio hasta septiembre (INEGI, 2022).

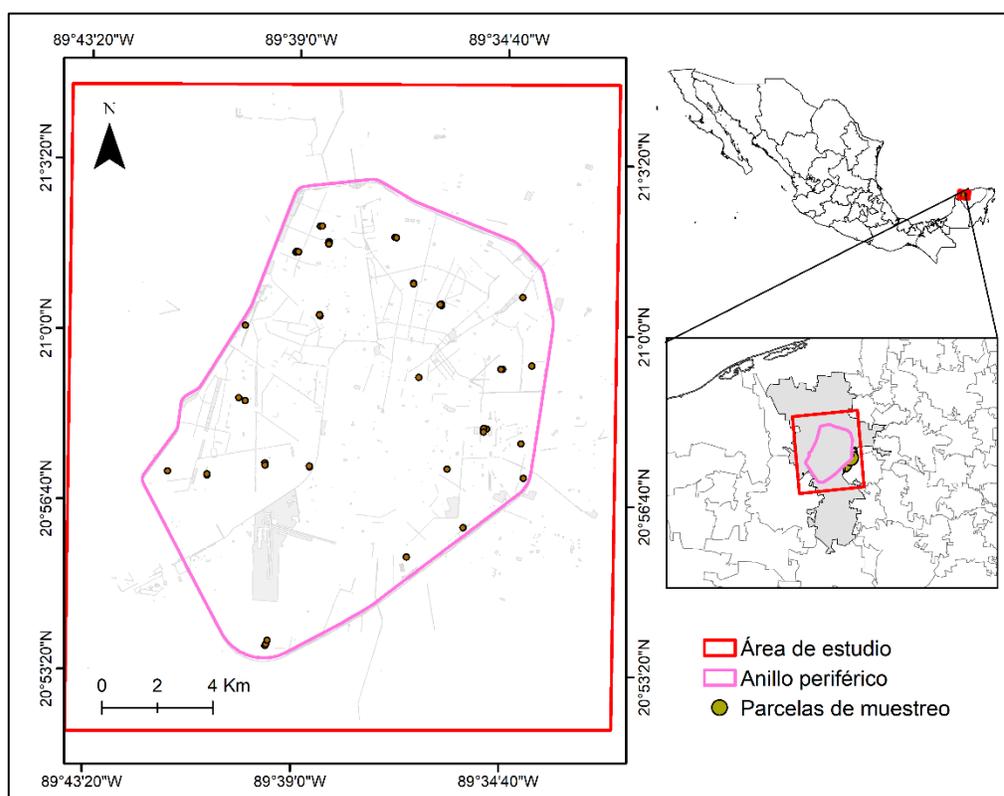


Figura 2.1 Localización del área de estudio y las parcelas de muestreo en la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán.

2.1.2. Diseño de muestreo

Selección de parques

Para estimar la biomasa aérea en la zona de estudio, fue necesario contar con datos de biomasa obtenidos en campo, los cuales permitieron calibrar y validar la estimación a partir de sensores remotos. Con este fin, se establecieron 42 parcelas de muestreo dentro de parques urbanos, ya que estos espacios concentran la mayor diversidad de especies arbóreas de la ciudad y facilitan la medición de la estructura de los árboles. La zona de estudio se delimitó considerando la región conurbada de Mérida, Yucatán, dentro de un radio promedio de 5 ± 2.33 km a partir del anillo periférico.

Se digitalizaron 526 parques ubicados dentro del área delimitada por el anillo periférico de la ciudad de Mérida, incluyendo el Jardín Botánico Regional del CICY "Roger Orellana", utilizando el programa *Google Earth Pro*, basándose en la información disponible del *Geoportal* de la ciudad de Mérida y en estudios previos, como el diagnóstico de parques realizado por la ciudad (Ayuntamiento de Mérida, 2018a). Posteriormente, se realizó una clasificación supervisada utilizando el algoritmo de Random Forest en *Google Earth Engine* (Gorelick et al., 2017) en una imagen de PlanetScope del mes de septiembre, que tiene una resolución espacial de 3 metros y una resolución radiométrica de 16 bits. Las bandas utilizadas fueron la azul (B2), verde (B4), roja (B6), borde rojo (B7) e infrarroja (B8); para establecer puntos de control, se empleó una composición de falso color con el objetivo de distinguir únicamente la vegetación de otros elementos de la ciudad, creando tres tipos de clases: vegetación, cuerpos de agua y zona urbana. De la totalidad de los puntos establecidos, se utilizó el 70% para la clasificación y el 30% restante para la validación de esta. La validación se evaluó mediante el valor del índice de kappa.

Se calculó el área de cada uno de los parques utilizando herramientas del software ArcMap 10.3, con lo cual se obtuvo la superficie ocupada por la vegetación en relación con otros tipos de cobertura. Finalmente, con la herramienta "*Field Calculator*", herramienta que permite realizar cálculos y manipulaciones de datos directamente en la tabla de atributos de una capa, se determinó la densidad de la vegetación para cada uno de los parques, donde se creó un nuevo campo en la tabla de atributos para almacenar los valores de

densidad de la vegetación y en la ventana de la "*Field Calculator*", se introdujo la siguiente ecuación:

Ecuación 1

$$\text{Densidad de la vegetación: } \frac{\text{Área de vegetación}}{\text{Área total}} * 100$$

Se realizaron clasificaciones de densidades en tres niveles a través del método de rupturas naturales (Jenks); es un método de agrupamiento de datos que busca reducir la varianza dentro de las clases y maximizar la varianza entre las clases (Mărgărint et al., 2013; Liu et al., 2019)

Densidad de vegetación Baja: del 0 al 26%

Densidad de vegetación Media: del 26.1% al 51%

Densidad de vegetación Alta: del 51.1% al 100%

Estas clasificaciones proporcionan una visión clara de la variabilidad de la cobertura vegetal en los parques de Mérida, facilitando así la selección de los parques para las parcelas de muestreo. A partir de esta clasificación, se seleccionaron 22 parques para el muestreo de datos de campo en parcelas de 500 m². La selección se realizó asegurando la inclusión de parques con las tres densidades de cobertura vegetal (alta, media y baja), procurando además una distribución equitativa en diferentes zonas de la ciudad y considerando la accesibilidad a los parques. Como resultado, se incluyeron 12 parques con densidad alta, 7 con densidad media y 3 con densidad baja.

Muestreo de datos de campo

El diseño de muestreo se realizó mediante la selección aleatoria de 42 parcelas de 500 m² dentro de los parques seleccionados. Cada parcela tenía un radio de 12.62 m (**Figura 2.2**). Para la recopilación de datos, se consideraron todos los individuos arbóreos con un diámetro a la altura del pecho (DAP, a 1.30 m sobre el nivel del suelo) mayores o iguales a 5 cm. Para cada árbol se midieron la altura total y el área de la copa, además de su identificación taxonómica. Estas variables permitieron estimar la biomasa aérea.

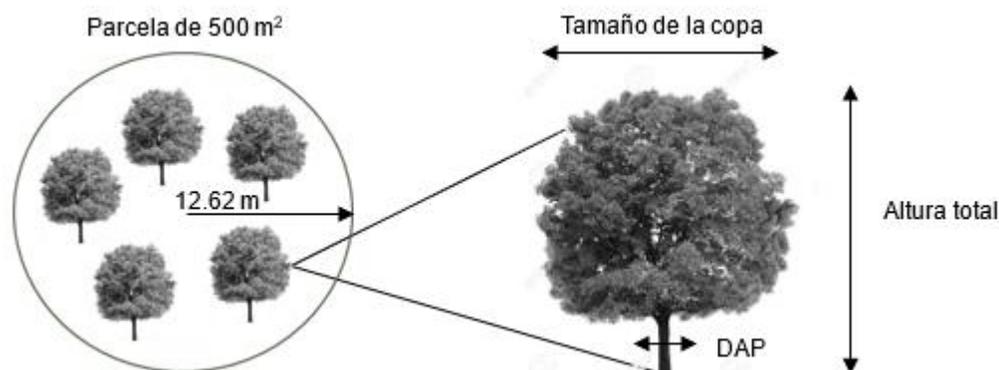


Figura 2.2 Diseño de las parcelas para el cálculo de la biomasa aérea

En total, se establecieron 42 parcelas distribuidas según la densidad de vegetación: una parcela en cada parque de densidad baja, dos parcelas en los de densidad media y tres parcelas en los de densidad alta. Todas las parcelas fueron georreferenciadas con un GPS diferencial, asegurando una precisión de milímetros en sus coordenadas centrales. Como resultado, se registraron 1,270 árboles.

2.1.3. Cálculo de la biomasa

El tamaño de parcela de 500 m² se seleccionó debido a su uso estandarizado en el cálculo de la biomasa aérea en bosques (Machado-Carcasés & León-Sánchez, 2005). Para llevar a cabo el cálculo de la biomasa aérea en el campo, se empleó el programa I-Tree Eco V6 (i-Tree, 2018), específico para México. Este programa incluyó ecuaciones alométricas diseñadas específicamente para árboles en entornos urbanos, lo cual redujo el riesgo de subestimar o sobrestimar la biomasa aérea en comparación con ecuaciones generales o aquellas desarrolladas para árboles en bosques naturales. Sin embargo, el programa proporcionó únicamente los valores de carbono almacenado, y no directamente los de biomasa. Para estimar la biomasa aérea, se dividieron los valores de carbono por un factor promedio de 0.48, que representa el contenido medio de carbono en la biomasa seca. Este valor se basa en los factores de conversión publicados por CONAFOR (2015), en su lista de ecuaciones para el cálculo de carbono en distintos tipos de vegetación en México. Aunque este factor no está específicamente determinado para el arbolado urbano, se utilizó como una aproximación general, debido a la ausencia de un valor específico para el arbolado urbano.

Para los árboles cuya especie pudo identificarse, la biomasa fue calculada directamente con i-Tree Eco, utilizando las ecuaciones y valores de densidad de la madera disponibles en su base de datos. En cambio, para aquellos que no pudieron ser identificados, se emplearon ecuaciones alométricas diseñadas para árboles tropicales en ambientes naturales y locales (**Ecuación 2**) (Chave et al., 2005). En estos casos, debido a la falta de información específica sobre la densidad de la madera, se utilizó un valor promedio de 0.64 correspondiente a especies tropicales de la región (Hernández-Stefanoni et al., 2020). Este enfoque permitió obtener estimaciones más precisas de la biomasa aérea, incluso para especies menos comunes en entornos urbanos.

Ecuación 2

$$AGB = DENSI * EXP(-0.667 + 1.784 * LN(DAP) + 0.207 * (LN(DAP))^2 - 0.0281 * (LN(DAP))^3)$$

Donde;

AGB = Biomasa aérea arbórea estimada para un árbol (kg)

DENSI = Densidad básica de la madera (g/cm³)

DAP = Diámetro a la altura del pecho (cm)

ln(DAP) = Logaritmo natural del DAP

EXP = Función exponencial

Una vez obtenida la biomasa, esta se expresó en kg m⁻² con relación al área de la parcela; y se convirtió a Mg/ha. Para realizar esta transformación, se multiplicó por 0.020, dado el tamaño de la parcela de 500 m² (Reyes-Palomeque et al., 2019).

De los 1270 árboles medidos 1193 fueron identificados y se calculó su almacenamiento de carbono utilizando el programa I-Tree, mientras que para los 77 restantes se empleó la ecuación general.

2.1.4. Análisis de las imágenes de alta resolución espacial

Las imágenes multiespectrales de alta resolución espacial (3 metros por píxel) se obtuvieron de la plataforma de Planet (Planet, 2024), descargando un conjunto de 4 escenas que, combinadas, cubren el área de estudio en Mérida, Yucatán, para cada uno de los años de interés (septiembre de 2021 y septiembre de 2023). Estas escenas incluyen

8 bandas espectrales: azul costero, azul, verde 1, verde, amarillo, rojo, borde rojo e infrarroja. Sin embargo, para este estudio solo se consideraron las bandas azul, verde, roja, borde rojo e infrarroja. Las imágenes abarcan los periodos de septiembre de 2021 y 2023, seleccionados porque corresponden a la temporada de lluvias, cuando la vegetación presenta una mayor cantidad foliar.

Análisis de los datos de la imagen de PlanetScope

Con las imágenes multispectrales de PlanetScope se obtuvieron índices de vegetación como el NDVI y el NDRE. Además, para obtener medidas de homogeneidad y heterogeneidad como variables auxiliares de las imágenes, se calcularon las medidas de texturas de las bandas espectrales (rojo, verde, azul, borde rojo e infrarrojo) y de los índices de vegetación mediante el uso de la plataforma Google Earth Engine (Gorelick et al., 2017).

Ecuación 3

$$\text{NDVI} = ((\text{IRC} - \text{R}) / (\text{IRC} + \text{R}))$$

Donde;

IRC =Banda infrarrojo cercano (B8)

R= Banda roja (B6)

Ecuación 4

$$\text{NDRE} = ((\text{BR} - \text{R}) / (\text{BR} + \text{R}))$$

Donde;

BR =Banda borde rojo (B7)

R= Banda roja (B6)

Para obtener las medidas de textura se utilizó el algoritmo denominado *gIcmTexture*. Con este proceso, se lograron obtener ocho tipos de texturas de primer y segundo orden: segundo momento angular, contraste, correlación, entropía, disimilaridad, media, varianza y homogeneidad.

Por último, se realizó la extracción de los valores de las imágenes correspondientes a las parcelas de campo en la plataforma de Google Earth Engine.

Construcción del modelo predictivo

Una vez realizados estos procesos, se procedió a llevar a cabo el modelo de regresión para la estimación de la biomasa aérea utilizando los datos de las imágenes a través de la interfaz de RStudio del lenguaje de programación R (R Core Team, 2021). Se realizaron pruebas de normalidad de la biomasa aérea, utilizando la prueba de Shapiro-Wilk para la hipótesis de normalidad.

Los datos de biomasa no mostraron una distribución normal inicialmente, por lo que se decidió aplicar una transformación logarítmica. Luego de esta transformación, los datos demostraron una distribución normal ($p < 0.05$). Posteriormente, con las variables calculadas a partir de las imágenes multiespectrales, se obtuvo el modelo utilizando la función "*regsubsets*". Esta función seleccionó el mejor subconjunto de variables identificando el modelo óptimo que contenía un número determinado de predictores.

Una vez que se obtuvo el modelo, para descartar la multicolinealidad se utilizó el análisis del Factor de Inflación de la Varianza (VIF). El VIF puede tener valores de uno al infinito, pero valores superiores a 7 indicaron que una o más variables podían estar sobreestimadas debido al efecto de la multicolinealidad (Montgomery et al., 2006). Tras este análisis, se depuraron las variables con VIF elevado y en el modelo final se conservaron únicamente cinco: la disimilaridad en el NDVI, la homogeneidad en la banda roja, el segundo momento angular de la banda infrarroja y la varianza de la banda infrarroja.

Para evaluar la precisión del modelo, se procedió a realizar el método de validación cruzada. La validación cruzada fue una técnica esencial que permitió evaluar la capacidad del modelo para generalizar datos no utilizados previamente. Este método consistió en remover una a una las observaciones para después estimar su valor con el modelo ajustado sin esa observación. Esto permitió obtener una matriz de datos observados y predichos para todas las observaciones en el conjunto de datos. Posteriormente, se obtuvieron estimadores como el Coeficiente de determinación (R^2), Raíz del error medio cuadrático (RMSE) y el porcentaje de RMSE (%RMSE) relativo a la media de los valores observados. Un valor bajo de RMSE indicó una estimación precisa por parte del modelo, mientras que una R^2 alta sugiere una relación lineal fuerte entre los valores observados y los predichos.

Mapa de la biomasa aérea en dos periodos de tiempo 2021 y 2023

La estimación del mapa de la biomasa aérea se llevó a cabo en Google Earth Engine donde se utilizaron los coeficientes correspondientes de las variables explicativas al modelo seleccionado.

Ecuación 5

$$AGB = \beta_1 + \beta_2 X_1 + \beta_3 X_2 + \beta_4 X_3 \dots + \beta_n X_n$$

Dónde;

β_n = Coeficientes estimados del modelo

X_n = es la métrica n (n = 1, 2, 3, ... n métrica)

Este modelo fue aplicado para ambas imágenes (2021 y 2023). Posteriormente, en la interfaz de RStudio del lenguaje de programación R, se estimó la densidad de cobertura vegetal en cada año a partir de la construcción y aplicación de una matriz de reclasificación. Dicha matriz permitió estandarizar los valores de clasificación en ambas capas, agrupando las coberturas en dos clases principales: "bosque" y "no bosque", para facilitar la comparación temporal.

Una vez que se aplicó el modelo en cada una de las imágenes lo que siguió después fue la realización del mapa en el programa de QGIS versión 3.22.14.

2.1.5. Cambios de cobertura y estimación de la biomasa removida y el carbono liberado

Se asociaron los valores de "no bosque" a todas aquellas coberturas previamente clasificadas como pasto, nubes, cuerpos de agua y zona urbana, mientras que la clase "vegetación" se mantuvo como "bosque". Esta reclasificación permitió simplificar las categorías para facilitar el análisis de cambios en la cobertura vegetal entre 2021 y 2023.

Para identificar los cambios en la cobertura, se definió una función de clasificación que asigna categorías de cambio: "bosque que se mantiene" (bosque en ambos años), "pérdida de bosque" (bosque en 2021, no bosque en 2023) y "ganancia de bosque" (no bosque en

2021, bosque en 2023). Luego, esta función se aplicó a las capas de reclasificación mediante el método local apply (*lapp*) en el software R. Esta herramienta nos permite aplicar nuestra función de clasificación a cada píxel de las imágenes, lo cual es esencial cuando se trabaja con imágenes de alta resolución espacial. El método *lapp* de la librería *terra* en R fue elegido debido a su eficiencia y capacidad para realizar cálculos personalizados en grandes conjuntos de datos raster. La función *lapp* analizó cada píxel de las imágenes de 2021 y 2023 para determinar en qué categoría de cambio encajaron. Posteriormente usando la máscara de cambio de bosque, se calculó la biomasa aérea total.

Finalmente, para mejorar la estimación del cambio en la cobertura arbórea entre 2021 y 2023, se consideraron solo las áreas mayores a 1 ha. Esta decisión se basó en que las áreas más grandes ofrecen una muestra más representativa y precisa de los cambios significativos en la biomasa, reduciendo el ruido proveniente de áreas pequeñas. Además, este enfoque es comúnmente utilizado en estudios de teledetección, ya que mejora la fiabilidad de los resultados (Camacho Sanabria et al., 2017). El cálculo de la biomasa en estas áreas se realizó utilizando el software ArcMap 10.3, y con la herramienta "Región Group" se agruparon los píxeles del raster para generar áreas homogéneas. Posteriormente, se eliminaron las áreas menores utilizando la herramienta "Set Null". Este proceso facilitó un análisis comparativo entre las coberturas de 2021 y 2023, permitiendo cuantificar los cambios en la biomasa y la captura de carbono.

3. CAPITULO III

3.1. RESULTADOS

3.1.1. Biomasa área de los datos de campo

La clasificación de densidad de cobertura vegetal, obtenida a partir de las imágenes satelitales mediante el modelo de biomasa, fue evaluada mediante el índice kappa, el cual resultó en un valor de 0.80, lo que indica un buen nivel de concordancia con los datos de campo recolectados en las parcelas. Este resultado valida la precisión de la clasificación al reflejar un alto grado de coincidencia entre la información satelital y las observaciones reales. Como se muestra en la **Figura 3.1**, la mayoría de los parques ubicados en la zona sur pertenecen a la categoría de baja densidad arbórea, mientras que en la zona norte predominan los parques clasificados como de densidad media.

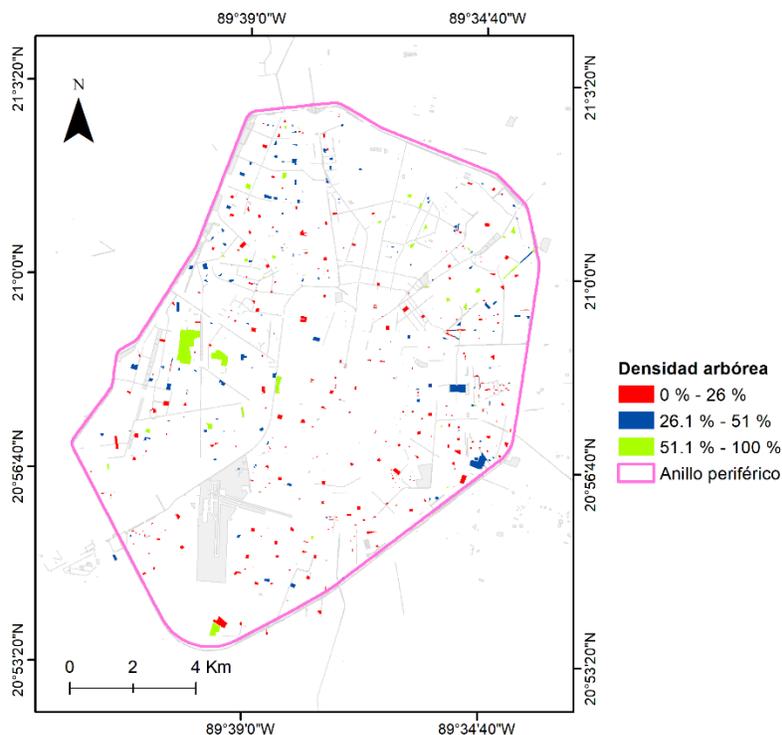


Figura 3.1 Densidad de cobertura arbórea en parques de la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán, ciudad de Mérida, Yucatán.

Los árboles analizados presentaron un DAP promedio de 12.77 cm y una altura promedio de 6.82 m. En cuanto a la abundancia total de individuos registrados, las tres especies más comunes fueron: *Gymnopodium floribundum* Rolfe (ts'iits'ilche') con 218 individuos, *Piscidia piscipula* (L.) Sarg. (Jabín) con 119 individuos y *Bursera simaruba* (L.) Sarg. (Chaká) con 83 individuos.

La biomasa aérea promedio calculada en las 42 parcelas fue de 95.24 Mg/ha, con un error estándar de 10.82 Mg/ha. Los parques con alta densidad de vegetación, que presentaron el mayor contenido de biomasa aérea, fueron el Jardín Botánico Regional del CICY "Roger Orellana" y el Parque Ecológico Metropolitano del Sur (**Tabla 3.1**), con un promedio de 216.25 Mg/ha de biomasa aérea, lo que representa cerca del 36.17 % del total estimado en los 22 parques muestreados. En contraste, los parques con densidad de vegetación media y baja presentaron valores promedio de biomasa aérea de 54.38 Mg/ha y 44.46 Mg/ha, respectivamente.

Tabla 3.1 Estimación de la biomasa aérea basada en datos de campo en cada parque muestreado

Área verde	Densidad	Parcelas	AGB promedio (Mg/ha)
Jardín Botánico Regional del CICY "Roger Orellana"	Alta	3	265.57
Ecológico Metropolitano del Sur	Alta	3	166.73
Rosario Chuburná	Alta	2	110.78
Eco-Arqueológico del Poniente	Alta	3	101.19
La Rampa Francisco de Montejo	Alta	2	101.1
Las Arboledas Francisco de Montejo II	Alta	3	93.42
Villa Magna	Alta	3	92.52
Florida Norte	Alta	1	80.57
Arqueo-Ecológico de Xoclán	Alta	2	71.45
La Juventud, San Antonio Cinta	Alta	3	51.97
Emiliano Zapata Norte	Alta	2	45.9
Japonés	Alta	2	31.93
Las Llantas	Media	1	81.64
Pedro Infante Hundido	Media	1	70.22

San Pablo Oriente	Media	1	66.28
El Porvenir	Media	1	53.43
Montes de Amés	Media	2	43.08
Vicente Guerrero	Media	2	34.22
Polígono 108 CTM	Media	1	31.83
Amalia Solórzano	Baja	1	65.07
San Nicolás del Sur	Baja	1	63.02
Jesús Carranza	Baja	1	5.29
Promedio			95.21
Desviación estándar			71.82
Error estándar			10.82

3.1.2. Biomasa área de la imagen de alta resolución PlanetScope

El modelo resultante se obtuvo a partir de cinco variables (**Tabla 3.2**) con las cuales se obtuvieron los valores de β estandarizados.

Tabla 3.2 Variables explicativas a partir de la imagen PlanetScope para la estimación de la Biomasa aérea en arbolado urbano

Variable	Estimación	Error Estándar	p-valor
Intercepto	-30.12	14.6	0.04636
Banda Roja	-0.00205	0.00027	5.46E-09
NDVI-Disimilaridad	0.00947	0.00184	9.56E-06
Banda Roja-Homogeneidad	21.99	3.78	1.23E-06
Banda Infrarroja - Segundo momento angular	4559	1967	0.02625
Banda Infrarroja-Varianza	4.37E-06	1.54E-06	0.00755

El modelo para estimar la biomasa aérea mostró que cuando disminuyen los valores de la banda roja (b6), la biomasa aumenta. En cambio, todas las variables texturales presentaron una relación positiva con la biomasa: la disimilaridad en el NDVI (NDVI_diss), la homogeneidad en la banda roja (b6_idm), el segundo momento angular de la banda infrarroja (b8_asm), y la varianza de la banda infrarroja (b8_var). De estas, el segundo momento angular de la banda infrarroja (b8_asm) mostró una relación particularmente fuerte (**Tabla 3.2**), mientras que la varianza de la banda infrarroja (b8_var) tuvo una relación menor. Estas relaciones positivas indican que mayores niveles de estas medidas texturales están asociados con un incremento en la biomasa aérea.

La fórmula quedó de la siguiente manera:

$$\text{AGB} = \exp(-30.12 + (-0.00205 * \mathbf{b6}) + (0.00947 * \mathbf{NDVI_diss}) + (21.99 * \mathbf{b6_idm}) + (4559 * \mathbf{b8_asm}) + (0.00000437 * \mathbf{b8_var})) * 0.37294$$

La validación cruzada del modelo de regresión lineal tuvo un coeficiente de determinación R^2 de 0.80 y porcentaje del RMSE al 37.89%. Se presentó una leve sobreestimación en los valores bajos de la biomasa sin embargo como se van incrementando estos valores esta sobreestimación va disminuyendo (**Figura 3.2**).

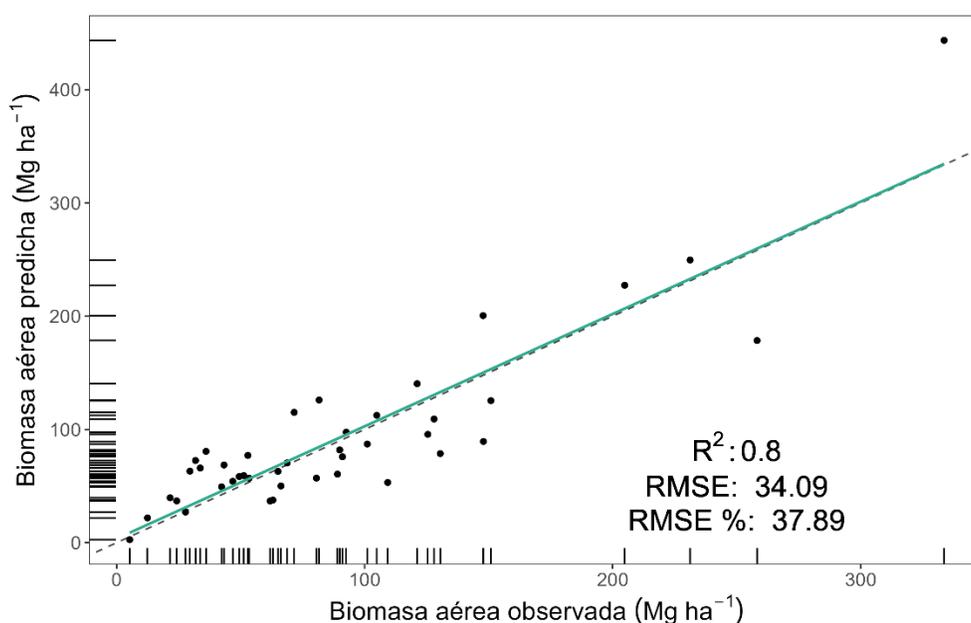


Figura 3.2 Evaluación de la validación cruzada para evaluar la precisión de la estimación de la

biomasa aérea. Los puntos representan la biomasa estimada en función de la biomasa observada, la línea verde es la línea de tendencia entre estos valores, mientras que la línea punteada es la referencia de una relación 1 a 1.

3.1.3. Biomasa aérea en el área de estudio

Al aplicar el modelo, se identificó una densidad de biomasa media de 63 ± 52 Mg/ha. En el mapa generado (**Figura 3.3**), se observan valores más altos de biomasa aérea afuera del anillo periférico, donde se registraron cantidades superiores a 70 ± 54 Mg/ha, principalmente en áreas con vegetación densa como remanentes de bosque tropical. En contraste, dentro del anillo periférico donde se presentan valores considerablemente menores, con áreas predominantes por debajo de las 43 ± 40 Mg/ha, debido a la alta urbanización en estas áreas es más común encontrarlas en parques, camellones, glorietas y patios.

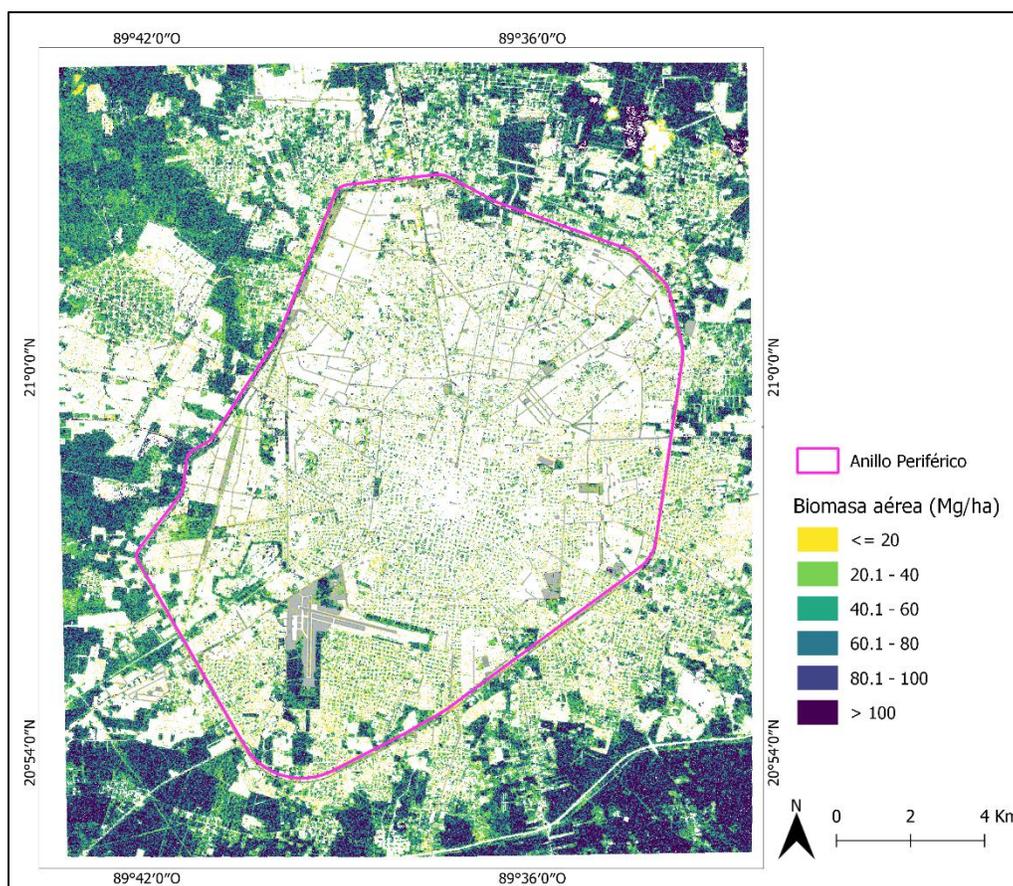


Figura 3.3 Mapa de la biomasa aérea (Mg/ha) en el 2023 en la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán.

3.1.4. Biomasa aérea en parques

En este estudio, se analizaron 526 parques ubicados dentro del anillo periférico de Mérida, con una superficie total de 368.74 hectáreas. De estos, solo 498 parques presentaron cobertura arbórea, sumando 173.98 hectáreas con vegetación arbórea, representando el 47%. En estos últimos, se calculó una biomasa aérea total de 8,884 Mg, con un promedio de 35 ± 23 Mg/ha. Esto equivale a un almacenamiento estimado de carbono de 4,264 Mg. La mayoría de los parques presentan valores de biomasa en el rango de 20 a 50 Mg/ha, mientras que los valores superiores a 100 Mg/ha únicamente son representados por el 1.7% de los parques estudiados (Figura 3.4).

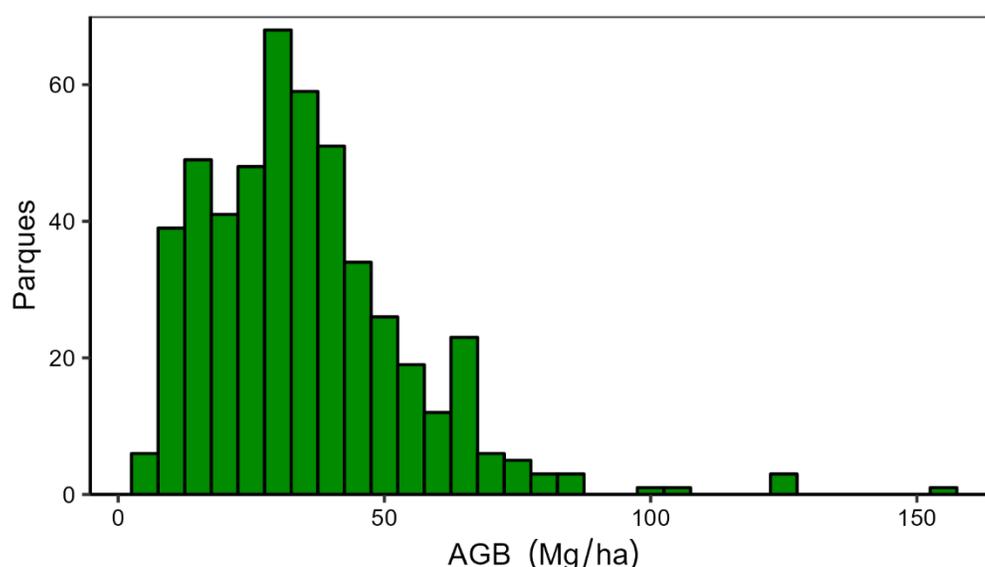


Figura 3.4 Histograma de la distribución de la biomasa aérea (AGB) en parques urbanos de la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán.

3.1.5. Biomasa aérea en el 2021 y 2023

Al aplicar el modelo de biomasa aérea a la imagen correspondiente al año 2021, se obtuvo una densidad promedio de 103 ± 83 Mg/ha, mientras que en 2023 la densidad promedio disminuyó a 65 ± 52 Mg/ha. Los valores de biomasa aérea en 2023 oscilaron entre 1.24 y 287 Mg/ha, mostrando una reducción considerable respecto al año 2021, en el que predominaban áreas con valores superiores a 100 Mg/ha. Al comparar los mapas generados para ambos años, se identificaron cambios notables en la distribución espacial

de la biomasa, especialmente en zonas ubicadas fuera del anillo periférico de la ciudad (**Figura 3.5**). Además, se observó la pérdida de cobertura vegetal en áreas que en 2021 presentaban densidades menores a 20 Mg/ha, lo que sugiere remoción o degradación en estos sitios.

En contraste, dentro del anillo periférico, la biomasa aérea se incrementó en varias zonas para el año 2023, siendo más evidente la presencia de valores en el rango de 20 a 40 Mg/ha, lo que indica un aumento en la biomasa en la zona urbana.

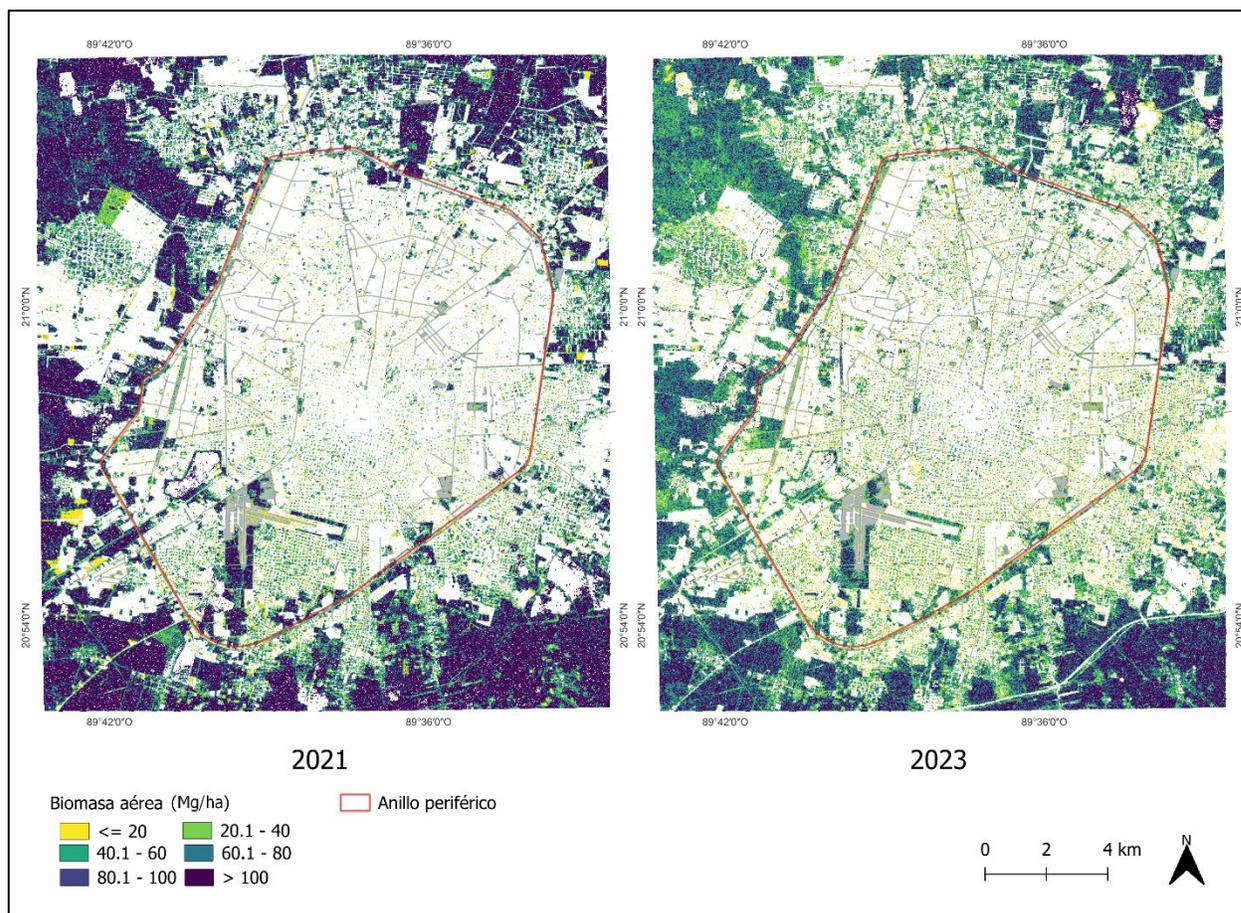


Figura 3.5 Mapa de la biomasa aérea en el año 2021 y 2023 en la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán.

3.1.6. Cambio de cobertura arbórea y carbono removido

Se observó una notable disminución en la cobertura arbórea, que afectó a 1,214 ha, lo que resultó en la pérdida de 97,407 Mg de biomasa aérea, equivalente a la liberación de 46,755 Mg de carbono, resultando un promedio de 82 ± 76 Mg/ha. Esta remoción de vegetación fue más pronunciada fuera del anillo periférico, aunque también hubo disminuciones en la parte sur dentro del mismo (**Figura 3.6**).

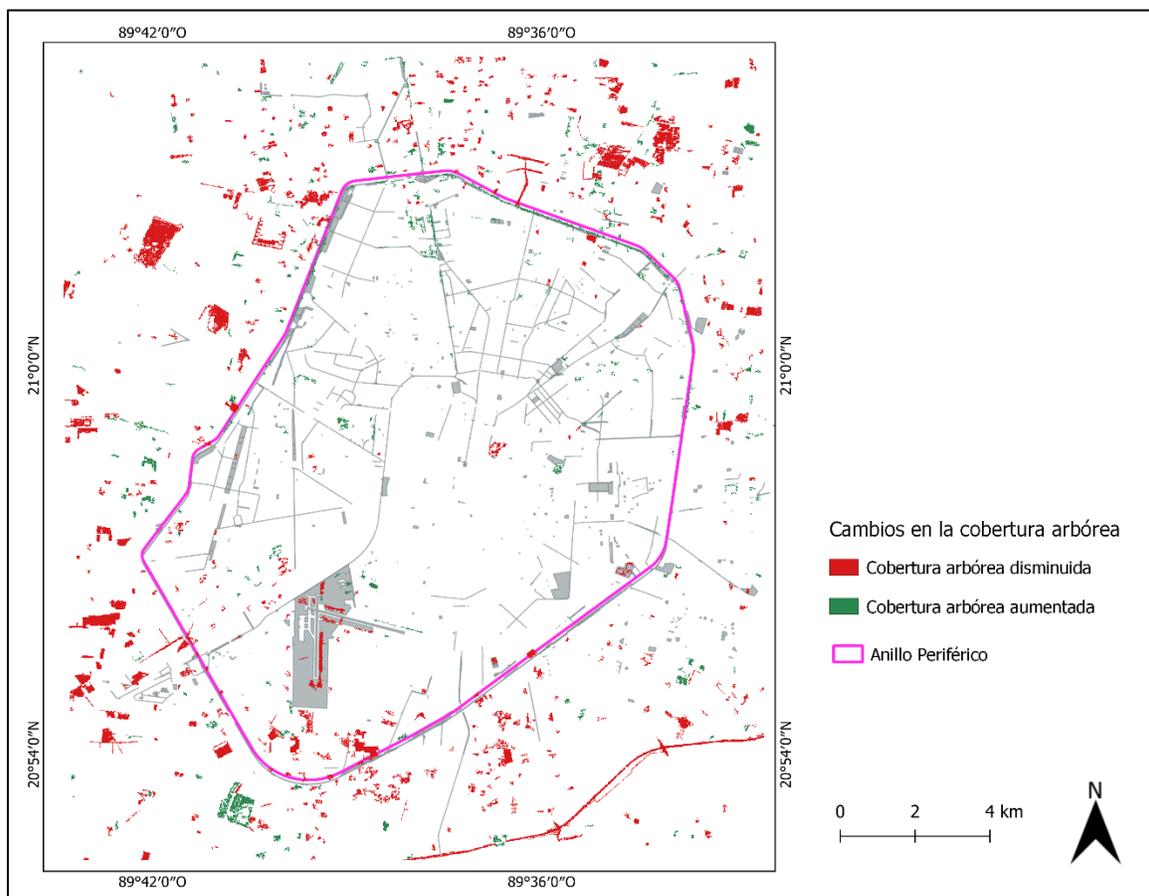


Figura 3.6 Mapa de los cambios en la cobertura arbórea en la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán que hubo entre los años 2021 y 2023.

Por otro lado, se detectó un aumento en la cobertura arbórea en 360 ha con un promedio de 59 ± 57 Mg/ha, lo que se tradujo en un incremento de 20,937 Mg de biomasa aérea y el almacenamiento de 10,050 Mg de carbono. Este aumento fue particularmente evidente fuera del anillo periférico, especialmente en el sector sur del área de estudio. En resumen,

el cambio neto en la cobertura arbórea entre 2021 y 2023 fue de 854 ha, con una pérdida neta de 76,470 Mg de biomasa aérea en el area de estudio, lo que implicó la liberación neta de 36,706 Mg de carbono del año 2021 al 2023.

4. CAPITULO IV

4.1. DISCUSIÓN

4.1.1. Estimación de la biomasa aérea en parques dentro del anillo periférico de Mérida, Yucatán

La biomasa aérea total estimada para el 2023 en este estudio es 5,473 Mg menos en comparación con lo reportado en 2018 (Ayuntamiento de Mérida, 2018b) de una biomasa aérea de 14,358 Mg en 484 parques, lo que correspondía a 7,179 Mg de carbono. Este decremento puede atribuirse a los cambios de los componentes urbanos. En ambos estudios se utilizó el programa I-Tree Eco, una herramienta que emplea ecuaciones alométricas adaptadas para arbolado urbano (i-Tree, 2018), lo que permite comparación entre los resultados. I-Tree Eco ha sido utilizado en diversos estudios para la obtención de datos del arbolado urbano (Alonzo et al., 2016; Ramírez-Medina, 2022).

No obstante, existen diferencias importantes en las metodologías empleadas. El Ayuntamiento realizó un censo completo, evaluando todos los árboles en 470 parques y empleando parcelas en los 14 parques más grandes. Esta metodología permitió obtener una estimación precisa, aunque requirió un mayor esfuerzo en tiempo y recursos humanos. En contraste, este estudio utilizó 42 parcelas distribuidas en 22 parques, optando por un enfoque de muestreo que, aunque menos exhaustivo, es una técnica comúnmente utilizada para obtener resultados representativos con menor costo y tiempo (Hernández-Stefanoni et al., 2018; Ramírez-Medina, 2022; Andrés-Mauricio, 2023).

Las diferencias en el diseño metodológico influyen directamente en los valores estimados de biomasa. Factores como el tamaño, número y ubicación de las parcelas afectan la representación de especies y estructuras arbóreas. Los censos totales tienden a captar toda la variabilidad del sistema, mientras que el muestreo puede subestimar o sobrestimar ciertos tipos de vegetación si no está adecuadamente estratificado. Asimismo, la inclusión o exclusión de árboles jóvenes, muertos en pie, o errores en la medición de diámetros y alturas pueden generar diferencias acumulativas. Incluso variaciones mínimas en la parametrización de las ecuaciones alométricas pueden amplificarse al extrapolarse a toda

el área de estudio. Por ello, es posible que diferentes estudios, aún realizados en los mismos parques y utilizando el mismo software, produzcan estimaciones diferentes.

A pesar de estas limitaciones, el uso de parcelas ofrece ventajas significativas, como la posibilidad de representar áreas específicas sin necesidad de censar la totalidad del parque. Esto permite obtener estimaciones robustas de biomasa y otros parámetros estructurales del arbolado. Además, el establecimiento de parcelas permanentes facilita el monitoreo a largo plazo, permitiendo estudiar dinámicas de crecimiento, almacenamiento de carbono y cambios en la estructura vegetal a lo largo del tiempo (Phillips, 2023). Para futuros estudios, se marcaron las coordenadas centrales de cada parcela, lo que simplifica su localización y seguimiento (**Tabla 5.1**).

Un ejemplo de estas diferencias se observa en el Parque Metropolitano del Sur, el Parque Arqueoecológico del Poniente, el Parque Xoclán y el Jardín Botánico Regional del CICY. En estos parques, que tienen un alto almacenamiento de biomasa, es crucial contar con un monitoreo continuo que permita observar las dinámicas del ecosistema a lo largo del tiempo. La sostenibilidad no solo se refiere a la permanencia de las parcelas en el tiempo, sino también al manejo adecuado del parque para asegurar que su capacidad de generar y almacenar biomasa no se vea comprometida por actividades humanas o cambios ambientales. El monitoreo regular de la biomasa permite detectar tendencias en la salud del ecosistema y actuar en consecuencia para mitigar cualquier impacto negativo, como la pérdida de vegetación o la degradación de su biodiversidad (Leyva-Ovalle et al., 2017).

En el caso del Parque Metropolitano del Sur, diferentes estudios han reportado variaciones en la biomasa aérea: 292 Mg/ha en 2016 (Ayuntamiento de Mérida, 2018a), 106 Mg/ha en 2020 (Ramírez-Medina, 2022) y en este estudio se estimó una biomasa aérea de 80 Mg/ha en 2024. Estas diferencias pueden estar relacionadas con metodologías de medición distintas, como el tamaño y la ubicación de las parcelas, pero también reflejan la necesidad de realizar un seguimiento más consistente para evaluar si los cambios en la biomasa corresponden a variaciones naturales del ecosistema o a factores externos que puedan estar alterando su capacidad de regeneración. Por lo tanto, para garantizar la sostenibilidad de estos espacios verdes, es necesario establecer un sistema de monitoreo permanente y consistente que facilite la toma de decisiones en cuanto a su manejo y conservación,

promoviendo prácticas que no comprometan su capacidad de generar beneficios ecológicos, como el almacenamiento de carbono, en el futuro

La desviación estándar de todos los parques (23 Mg/ha) explica la alta proporción de parques con densidad baja y media. La clasificación empleada contrasta con la realizada por el Ayuntamiento, que identificó 192 parques pequeños y 392 medianos. Mientras el Ayuntamiento clasificó los parques según su tamaño (pequeños: < 0.4 ha; grandes: >1.2 ha; medianos: >0.4 ha y <1.2 ha) y su número de árboles, este estudio utilizó percepción remota y el método de rupturas naturales (Jenks) basado en la densidad de cobertura. Este enfoque permitió agilizar la clasificación y tomar decisiones estratégicas para seleccionar parques representativos de cada categoría. Además, se creó un mapa temático que identifica áreas prioritarias para mejorar el arbolado urbano en la ciudad.

Los resultados obtenidos respaldan parcialmente la Hipótesis 1, al mostrar que los parques urbanos de la ciudad de Mérida desempeñan un papel relevante en el almacenamiento de biomasa aérea arbórea dentro del entorno urbano. En el año 2023, se estimó un total de 8,884 Mg de biomasa aérea distribuida en los parques evaluados, lo cual equivale aproximadamente al 50 % de la densidad de biomasa registrada en los bosques tropicales remanentes localizados fuera del anillo periférico. Esta proporción sugiere que, si bien los parques urbanos no alcanzan los valores máximos de biomasa observados en ecosistemas no intervenidos, mantienen niveles significativos que reflejan su capacidad para conservar carbono en un entorno altamente urbanizado.

Cabe destacar que esta capacidad de acumulación de biomasa en parques urbanos puede atribuirse a factores como el mantenimiento constante, la selección planificada de especies arbóreas con buen desarrollo fustal, y su disposición en espacios verdes diseñados para favorecer el crecimiento arbóreo. Sin embargo, debido a la limitada extensión total de estas áreas en comparación con los parches de vegetación natural remanente, no se puede concluir que concentren la mayor proporción de biomasa aérea del sistema urbano en su conjunto.

A pesar de ello, los parques urbanos constituyen núcleos de vegetación estratégicos para la mitigación del cambio climático, la provisión de servicios ecosistémicos y la regulación del microclima (Mexia et al., 2018). Su aporte relativo a la conservación del carbono resulta

particularmente relevante ante el avance del cambio de uso de suelo y la fragmentación de hábitats naturales en el área conurbada de Mérida.

4.1.2. Variables más importantes para la estimación de la biomasa aérea

En este estudio, se seleccionaron imágenes ópticas del satélite PlanetScope debido a su resolución espacial de 3 m, lo cual facilita la identificación precisa de los árboles en ambientes urbanos, una ventaja clave frente a las imágenes de Sentinel-2, que ofrecen 10 m de resolución espacial. Aunque Sentinel-2 cuenta con una mayor resolución espectral al disponer de 13 bandas (Wang & Gong, 2024), para este estudio, solo se emplearon las bandas RGB, el borde rojo e infrarroja cercana, haciendo de PlanetScope la opción más adecuada. PlanetScope, con su alta resolución espacial y las bandas necesarias, se adapta mejor a las necesidades del análisis detallado del arbolado urbano. Estudios previos han validado el uso de imágenes de PlanetScope en el análisis de vegetación urbana (Madundo et al., 2023; Permatasari et al., 2023; Matiza et al., 2024), demostrando su eficacia y precisión en este tipo de contextos.

El modelo desarrollado con las imágenes de PlanetScope es similar con los reportados en el estudio de Buffelsdraai, Sudáfrica, donde se alcanzaron valores de R^2 de 0.78 y 0.81, junto con RMSE de 27.33 y 29.75 t ha⁻¹ para los conjuntos de calibración y validación (Matiza et al., 2024), lo que confirma la utilidad de las imágenes de PlanetScope para la estimación de reservas de carbono en zonas urbanas, además, un estudio en Jebres, Surakarta, demostró que PlanetScope puede mapear con alta precisión los espacios verdes urbanos con una estimación del 91.3% y un error estándar 0.256367).

En particular, los índices espectrales utilizados en este estudio podrían no haber capturado de manera óptima las diferencias sutiles en la cobertura vegetal de las áreas urbanas, lo que puede explicar el mayor error en áreas de baja biomasa. Además, las características específicas del área de estudio, como la heterogeneidad de los parques urbanos en Mérida, podrían haber contribuido a la sobreestimación en áreas con baja cobertura vegetal.

Una limitación destacada en este estudio fue la sobreestimación en áreas con baja biomasa, lo que sugiere que el modelo podría beneficiarse de ajustes adicionales en áreas con escasa cobertura vegetal. Esta sobreestimación es especialmente relevante en el contexto urbano, donde la distribución de la vegetación no es homogénea. A medida que

aumenta la biomasa, la sobreestimación disminuye, lo que indica que el modelo tiene una mejor precisión en áreas con mayor densidad de vegetación. En particular, la variabilidad en la densidad de la vegetación y la estructura del arbolado urbano de Mérida podría haber afectado los resultados, lo que hace necesario un refinamiento del modelo para mejorar la precisión en áreas de baja biomasa.

Las variables explicativas más significativas incluyeron una combinación de datos espectrales y de texturas, lo que permitió capturar tanto información directa de las bandas como los patrones espaciales de la vegetación. Entre las variables texturales empleadas destacaron la disimilaridad, homogeneidad, segundo momento angular y varianza, lo que coincide con estudios previos que resaltan la utilidad de las texturas para representar la heterogeneidad estructural de la vegetación (Hernández-Stefanoni et al., 2014; Ploton et al., 2017; Schweiger et al., 2018). Se observó que una mayor disimilaridad en el NDVI está asociada con un incremento en la biomasa, indicando que áreas con un patrón de NDVI más variable tienden a tener una estructura vegetal más compleja pero rica en biomasa. La homogeneidad en la banda roja también mostró una relación positiva significativa con la biomasa, indicando que zonas con tonos de gris más homogéneos en esta banda suelen tener una mayor biomasa. Asimismo, el segundo momento angular de la banda infrarroja presentó una relación positiva fuerte, sugiriendo que una textura más uniforme en esta banda se relaciona con un mayor contenido de biomasa. Por último, la varianza de la banda infrarroja mostró que áreas con menor variabilidad en la reflectancia tienden a tener una menor biomasa aérea, reflejando una vegetación más homogénea, es decir, con una estructura más uniforme. Estos resultados también son consistentes con investigaciones realizadas en Mérida, donde las texturas fueron variables clave en la estimación de biomasa aérea urbana (Ramírez-Medina, 2022).

En cuanto a las bandas espectrales, la banda roja mostró una relación negativa significativa con la biomasa aérea ($p < 0.001$), lo cual es coherente con estudios que asocian esta banda con la absorción de clorofila (Porcar-Castell et al., 2014; Muhe & Argaw, 2022). Sin embargo, el coeficiente negativo indica que en áreas de alta cobertura vegetal puede ocurrir saturación. Para mitigar el problema de saturación en áreas de alta cobertura vegetal, las texturas desempeñaron un papel crucial en el modelo. Mientras que los índices espectrales tradicionales como el NDVI se basan en la relación entre las bandas del espectro

electromagnético, las texturas permiten capturar variaciones espaciales más finas dentro de una misma área, reflejando mejor las diferencias en la estructura y densidad de la vegetación. Las texturas proporcionan información adicional sobre la distribución espacial de la vegetación, como la variabilidad en la forma y tamaño de los elementos vegetales, que no se captura completamente con los índices espectrales. Esta capacidad de las texturas para diferenciar áreas de alta biomasa sin que se produzca saturación las hace especialmente útiles en paisajes urbanos donde la cobertura vegetal varía considerablemente. Así, al incluir las texturas, el modelo puede evitar la saturación en áreas densamente vegetadas y proporcionar una estimación más precisa de la biomasa aérea.

Aunque el NDVI es reconocido como un índice eficiente para mapear biomasa en bosques naturales (Guo et al., 2024), no mostró un impacto significativo en este estudio. Esto podría deberse a los problemas de saturación que presenta en la estimación de biomasa durante los periodos posteriores a la temporada de lluvias (Kumar & Mutanga, 2017), cuando la densidad de vegetación y la productividad primaria están en su punto máximo. Por esta razón, se esperaba una mayor contribución del NDRE, conocido por su capacidad para evitar la saturación en áreas densas (Evangelides & Nobajas, 2020). Sin embargo, en este estudio tampoco se identificó como una variable explicativa importante, posiblemente debido a la heterogeneidad de la cobertura vegetal en las ciudades. En contraste, las texturas demostraron ser más relevantes, ya que analizan las variaciones en los valores de los píxeles dentro de un área específica. Esto permite identificar patrones espaciales detallados en la superficie terrestre, algo que los índices espectrales simples, como el NDVI y el NDRE, no pueden lograr debido a que se basan únicamente en relaciones espectrales y no consideran la estructura espacial (Galeote-Leyva et al., 2022).

La integración de variables espectrales y texturales no solo mejoró la precisión del modelo, sino que también destaca la necesidad de incorporar medidas que capturen tanto las propiedades espectrales como la variabilidad de la vegetación en ambientes urbanos. Este enfoque, junto con la exploración de imágenes de mayor resolución, puede abrir nuevas oportunidades para mejorar la estimación de biomasa aérea en entornos urbanos.

Los resultados respaldan la hipótesis 2. Se comprobó que los valores de reflectancia, como el NDVI, presentaron saturación en áreas con vegetación densa, limitando su utilidad para estimar biomasa aérea en entornos urbanos. Aunque el NDRE no fue tan relevante como

se esperaba, las medidas de textura ofrecieron una solución eficaz al capturar mejor la variabilidad estructural de la vegetación. Por tanto, se confirma que las texturas proporcionan estimaciones más precisas en comparación con los índices espectrales en áreas urbanas heterogéneas.

4.1.3. Mapa de la biomasa aérea en la zona conurbada al anillo periférico de la ciudad Mérida, Yucatán.

Este estudio es el primero en realizar un mapa de la distribución de la biomasa aérea en la zona conurbada al anillo periférico de Mérida. Los resultados obtenidos mediante la aplicación del modelo para estimar la densidad de biomasa en el área de estudio presentan una variabilidad en su distribución. Esto muestra diversos factores como el uso del suelo, la urbanización y la presencia de vegetación remanente son clave en la distribución de la biomasa (Singh et al., 2017). El resultado obtenido de la biomasa aérea del exterior e interior del periférico, con una diferencia de 27 Mg/ha mayor en el exterior, muestra el impacto de la urbanización en la distribución de la biomasa. Este contraste resalta la importancia de preservar los remanentes de vegetación natural, ya que son esenciales para el almacenamiento de carbono en la región (Mannan et al., 2019), de esta manera la urbanización, al modificar el uso del suelo y la cobertura vegetal, altera los patrones de almacenamiento de carbono y puede aumentar la emisión de GEI debido a la remoción de la vegetación.

La disminución de la biomasa observada entre 2021 y 2023 en Mérida, especialmente en áreas fuera del anillo periférico, evidencia una pérdida significativa de vegetación en un periodo de solo dos años, con una pérdida neta de 854 ha. Estas pérdidas pueden estar relacionadas con el cambio de uso de suelo, asociado al crecimiento urbano. Estudios previos han demostrado que los periodos de mayor expansión urbana coinciden con una mayor deforestación, como ocurrió entre 2007 y 2012, lo cual también contribuyó a la formación de islas de calor en zonas donde la vegetación fue sustituida por infraestructura urbana (Carrillo-Niquete et al., 2022). Este patrón sugiere que la pérdida de biomasa no solo afecta la captura de carbono, sino también el microclima urbano.

En términos climáticos, durante 2021, la temperatura promedio fue de 28.4°C y la precipitación alcanzó los 181.4 mm, mientras que para 2023 la temperatura aumentó a

29.4°C y la precipitación disminuyó a 150.6 mm (Conagua, 2024). Estas variaciones climáticas pueden haber afectado directamente la salud de la vegetación, al incrementar el estrés hídrico y reducir la disponibilidad de agua, elementos esenciales para el crecimiento y mantenimiento de biomasa. Estudios previos han demostrado que las condiciones de estrés hídrico, como el aumento en el déficit de presión de vapor, afectan la capacidad de especies que se encuentran en mayor cantidad en los parques como *Bursera simaruba* y *Piscidia piscipula* para brindar regulación térmica en entornos urbanos (Carrillo-Niquete, 2022). Si bien estas especies tienen mecanismos de adaptación al estrés hídrico, el incremento de eventos extremos puede superar su capacidad de respuesta. Para mitigar estos impactos y equilibrar el crecimiento urbano con la conservación de los servicios ambientales que proporciona la vegetación, sería fundamental implementar estrategias de planificación que incluyan requisitos mínimos de áreas verdes. Por ejemplo, garantizar 15 m² de vegetación por habitante, como recomienda la Organización Mundial de la Salud (Alanís Rodríguez et al., 2023), permitiría mantener una capacidad de captura de carbono adecuada y mejorar la calidad de vida en zonas urbanas.

Sin embargo, también se identificaron zonas donde la cobertura arbórea aumentó, lo que indica que, a pesar de los procesos de urbanización, persisten dinámicas locales de revegetación o conservación. Este incremento puede estar relacionado con políticas municipales de arborización, esfuerzos ciudadanos o procesos naturales de regeneración. Aunque estos cambios representan una señal positiva, su efecto es relativamente limitado si se compara con la pérdida general de vegetación observada en el mismo periodo. Además, se ha señalado que, en contextos urbanos, el crecimiento de biomasa suele concentrarse en espacios controlados como parques, lo que restringe su potencial para generar conectividad ecológica o capturar carbono a gran escala (Wang et al., 2021). Entonces, aunque el aumento de la biomasa en algunas áreas es relevante, es necesario considerar las condiciones en las que ocurre y su efectividad real frente al ritmo de pérdida de cobertura vegetal.

Por lo tanto, los resultados del estudio confirman la hipótesis 3, al evidenciar que los cambios en el paisaje urbano de Mérida entre 2021 y 2023 afectaron significativamente la biomasa aérea y, con ello, la capacidad de los ecosistemas para capturar y almacenar carbono. La pérdida neta de cobertura vegetal, vinculada al crecimiento urbano y al cambio

de uso de suelo, refleja una disminución en la funcionalidad ecológica del entorno urbano. Aunque se registraron aumentos localizados de cobertura arbórea, estos fueron insuficientes frente a la pérdida generalizada, lo que limita su impacto en términos de conectividad ecológica y mitigación del cambio climático. Así, se confirma que la transformación del paisaje urbano compromete los servicios ecosistémicos esenciales, especialmente la regulación del carbono, reforzando la necesidad de incorporar estrategias de planificación urbana que prioricen la conservación y restauración de la vegetación.

5. CAPITULO V

5.1. CONCLUSIÓN

Este estudio demuestra la importancia de los espacios verdes urbanos y naturales, aun cuando se identificó una reducción respecto a estimaciones previas. Esta disminución podría estar vinculada a transformaciones urbanas recientes y a diferencias en las metodologías empleadas. A pesar de ello, los parques urbanos mantienen niveles relevantes de biomasa en comparación con los ecosistemas naturales no intervenidos. Las variaciones observadas entre distintos estudios evidencian la necesidad de fortalecer los sistemas de monitoreo y estandarizar los métodos de evaluación, a fin de comprender con mayor precisión la dinámica del arbolado urbano

La integración de variables espectrales y texturales mejoró la precisión en la estimación de biomasa, lo que subraya el potencial de las herramientas de percepción remota en el monitoreo de vegetación urbana. Además, la creación de un mapa de biomasa aérea permite identificar áreas prioritarias para estrategias de conservación y reforestación, enfatizando la necesidad de preservar remanentes de vegetación natural. Este aspecto es crucial, ya que el almacenamiento de carbono que brindan estos ecosistemas naturales es fundamental para mitigar los efectos del cambio climático y reducir la concentración de gases de efecto invernadero (GEI) en la atmósfera.

5.2. PERSPECTIVAS

Este estudio resalta la importancia de la vegetación urbana en la captura de carbono en la ciudad de Mérida, Yucatán, utilizando imágenes del satélite PlanetScope. Sin embargo, es importante señalar áreas de mejora que podrían enriquecer este enfoque en futuras investigaciones.

Se recomienda establecer parcelas permanentes en los parques para un monitoreo continuo. Esto permitiría una estimación más precisa de cómo la biomasa aérea cambia a lo largo de los años, proporcionando información sobre el estado de la estructura del dosel y facilitando la identificación de parques que necesiten intervención. Además, sería crucial

fomentar políticas urbanas que prioricen la protección y el incremento de áreas verdes, asegurando un equilibrio entre el desarrollo urbano y la sostenibilidad ambiental.

Ampliar el alcance de este tipo de estudios a otras ciudades con climas similares podría proporcionar una visión más amplia de los efectos de la urbanización en la biomasa aérea y el almacenamiento de carbono. Comparar diferentes tipos de entornos urbanos permitiría identificar patrones comunes o estrategias que hayan tenido éxito en otras regiones, lo que podría ser útil para adaptarlos a la ciudad de Mérida.

Para mejorar la estimación de la biomasa aérea en áreas urbanas, se podría avanzar en el desarrollo de modelos predictivos utilizando técnicas de aprendizaje automático que integren no solo índices de vegetación y medidas texturales, sino también variables climáticas y del uso de suelo. Estos modelos podrían ofrecer una predicción más precisa de la biomasa aérea en el futuro, ajustándose dinámicamente a los cambios en la vegetación y el clima urbano.

Asimismo, sería valioso aplicar esta metodología a todo el municipio de Mérida. Esto podría realizarse utilizando imágenes de PlanetScope, o integrando otros sensores de percepción remota, lo que permitiría un análisis más completo de la biomasa aérea y su relación con el entorno urbano.

BIBLIOGRAFÍA

- Alanís Rodríguez, E., Mora-Olivo, Dr. A., Jiménez Pérez, J., y Cuéllar Rodríguez, G. (2023). Uso de árboles nativos en áreas verdes urbanas: tendencias en el noreste de México. *Revista Mexicana de Ciencias Forestales*, 14(76), 4–21.
- Ali, A., y Yan, E.-R. (2017). The forest strata-dependent relationship between biodiversity and aboveground biomass within a subtropical forest. *Forest Ecology and Management*, 401, 125–134.
- Alianza México REDD+. (s/f). *Un impulso al desarrollo rural sustentable*. Sistema Nacional REDD+.
- Alonzo, M., McFadden, J. P., Nowak, D. J., y Roberts, D. A. (2016). Mapping urban forest structure and function using hyperspectral imagery and lidar data. *Urban Forestry & Urban Greening*, 17, 135–147.
- Andreatta, D., Gianelle, D., Scotton, M., y Dalponte, M. (2022). Estimating grassland vegetation cover with remote sensing: A comparison between Landsat-8, Sentinel-2 and PlanetScope imagery. *Ecological Indicators*, 141, 109102.
- Andrés-Mauricio, J. (2023). *Estimación de la biomasa aérea y su incremento en bosques tropicales secos usando datos de campo y de LiDAR aéreo y terrestre*. Centro de investigación científica de Yucatán.
- Andrés-Mauricio, J., Valdez-Lazalde, J. R., George-Chacón, S. P., y 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).
- Arévalo Moscoso, R. O. (2019). La Industria y sus efectos en el cambio climático Global. *RECIAMUC*, 2, 595–611.

- Arévalo-Moscoso, R. O. (2018). La Industria y sus efectos en el cambio climático Global. *Revista Científica de Investigación actualización del mundo de las Ciencias*, 2, 595–611.
- Assmann, J. J., Kerby, J. T., Cunliffe, A. M., y Myers-Smith, I. H. (2019). Vegetation monitoring using multispectral sensors — best practices and lessons learned from high latitudes. *Journal of Unmanned Vehicle Systems*, 7(1), 54–75.
- Atkinson, P. M., y Aplin, P. (2004). Spatial variation in land cover and choice of spatial resolution for remote sensing. *International Journal of Remote Sensing*, 25(18), 3687–3702.
- Avendaño-Hernández, D. M., Acosta-Mireles, M., Carrillo-Anzures, F., y Etcheveres-Barra, J. D. (2009). Estimación de biomasa y carbono en un bosque de *Abies religiosa*. *Fitotecnia Mexicana*, 32(3), 233–238.
- Ayuntamiento de Mérida. (2018a). *Estudio diagnóstico del arbolado urbano en parques públicos de Mérida*.
- Ayuntamiento de Mérida. (2018b). *Inventario del arbolado urbano de la Ciudad de Mérida*.
- Baccini, A., Friedl, M. A., Woodcock, C. E., y Zhu, Z. (2007). Scaling Field Data to Calibrate and Validate Moderate Spatial Resolution Remote Sensing Models. *Photogrammetric Engineering & Remote Sensing*, 73(8), 945–954.
- Barnes, E., Clarke, T. R., Richards, S. E., Colaizzi, P., Haberland, J., Kostrzewski, M., Waller, P., Choi, C., Riley, E., y Thompson, T. L. (2000). *Coincident detection of crop water stress, nitrogen status, and canopy density using ground based multispectral data*.
- Bautista-Zúñiga, F., Delfín-González, H., Palacio-Prieto, J. L., y Delgado-Carranza, M. del. C. (2004). Sensores remotos y manejo de información geográfica. En *Técnicas de muestreo para manejadores de recursos naturales* (Vol. 1, pp. 453–495).
- Béland, M., y Kobayashi, H. (2021). Mapping forest leaf area density from multiview terrestrial lidar. *Methods in Ecology and Evolution*, 12(4), 619–633.

- Blanton, A., Mohan, M., Galgamuwa, G. A. P., Watt, M. S., Montenegro, J. F., Mills, F., Carlsen, S. C. H., Velasquez-Camacho, L., Bomfim, B., Pons, J., Broadbent, E. N., Kaur, A., Direk, S., de-Miguel, S., Ortega, M., Abdullah, M., Rondon, M., Wan Mohd Jaafar, W. S., Silva, C. A., ... Ewane, E. B. (2024). The status of forest carbon markets in Latin America. *Journal of Environmental Management*, 352, 119921.
- Brown, S. (1997). Purpose and scope of primer on estimating biomass. En *Estimating biomass and biomass change of tropical forests*. FAO Forestry Paper.
- Byrne, J., y Sipe, N. (2010). *Green and open space planning for urban consolidation - A review of the literature and best practice*. UrbanResearch Program. Griffith University.
- Cabrera Reyes, B., Amaro Reyes, J., y Contreras Turrubiarres, M. M. M. (2024). Por un futuro brillante: Energías Renovables y Sostenibilidad en México. *Tendencias en energías renovables y sustentabilidad*, 3(1), 55–59.
- Camacho Sanabria, R., Camacho Sanabria, J. M., Balderas Plata, M. Á., y Sánchez López, M. (2017). Cambios de cobertura y uso de suelo: estudio de caso en Progreso Hidalgo, Estado de México. *Madera y Bosques*, 23(3), 39–60.
- Carrillo-Niquete, G. A. (2022). *Los servicios ambientales del arbolado urbano de Mérida y las posibles consecuencias de la urbanización acelerada*. Centro de Investigación Científica de Yucatán, A.C.
- Carrillo-Niquete, G. A., Andrade, J. L., Valdez-Lazalde, J. R., Reyes-García, C., y Hernández-Stefanoni, J. L. (2022). Characterizing spatial and temporal deforestation and its effects on surface urban heat islands in a tropical city using Landsat time series. *Landscape and Urban Planning*, 217, 104280.
- Casiano dominguez, M., y Paz Pellat, F. (2018). Índice espectral de vegetación para la caracterización simultánea de la floración y crecimiento vegetal. *REVISTA TERRA LATINOAMERICANA*, 36(2), 169.
- Castillo Rodriguez, J. (2024). La producción y uso de autos eléctricos en la Ciudad de México, para la disminución de la contaminación. *Revista Universitaria Digital de Ciencias Sociales (RUDICS)*, 15(28), 1–16.

-
- CEPAL. (2008). *Energía y cambio climático: oportunidades para una política energética integrada en América Latina y el Caribe*.
- Cerón-Palma, I., Sanyé-Mengual, E., Oliver-Solà, J., Montero, J.-I., Ponce-Caballero, C., y Rieradevall, J. (2013). Towards a green sustainable strategy for social neighbourhoods in Latin America: Case from social housing in Merida, Yucatan, Mexico. *Habitat International*, 38, 47–56.
- 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., y Yamakura, T. (2005). Tree allometry and improved estimation of carbon stocks and balance in tropical forests. *Oecologia*, 145(1), 87–99.
- Chave, J., Réjou-Méchain, M., Búrquez, A., Chidumayo, E., Colgan, M. S., Delitti, W. B. C., Duque, A., Eid, T., Fearnside, P. M., Goodman, R. C., Henry, M., Martínez-Yrizar, A., Mugasha, W. A., Muller-Landau, H. C., Mencuccini, M., Nelson, B. W., Ngomanda, A., Nogueira, E. M., Ortiz-Malavassi, E., ... Vieilledent, G. (2014). Improved allometric models to estimate the aboveground biomass of tropical trees. *Global Change Biology*, 20(10), 3177–3190.
- Chen, W. Y. (2017). *Urban Nature and Urban Ecosystem Services* (Springer, pp. 181–199).
- Ciesla, W. M. (2000). *Remote sensing in forest health protection*.
- CONAFOR. (2015). *Estimación de las reservas de carbono en la biomasa forestal en México*.
- Cutler, M. E. J., Boyd, D. S., Foody, G. M., y Vetrivel, A. (2012). Estimating tropical forest biomass with a combination of SAR image texture and Landsat TM data: An assessment of predictions between regions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 70, 66–77.

- Dash, S. A., Pradhan, A., y Behera, N. (2022). Estimation of above-ground biomass and carbon stock of tree species in public parks of Bhubaneswar, Odisha. *Arboricultural Journal*, 44(2), 72–83.
- Diaz-Franco, R., Acosta-Mireles, F., Carrillo-Anzures, E., Buendía-Rodríguez, E., Flores-Ayala, E., y Etchevers-Barra, J. D. (2007). Determinación de ecuaciones alométricas para estimar biomasa y carbono en *Pinus patula* Schl. et. Cham. *Madera y Bosques*, 13, 25–34.
- Dowman, I., Jacobsen, K., Konecny, G., y Sandau, R. (2013). High resolution optical satellite imagery. *hittles Publishing*, 230.
- Drew-Smythe, J. J., Davila, Y. C., McLean, C. M., Hingee, M. C., Murray, M. L., Webb, J. K., Krix, D. W., y Murray, B. R. (2023). Community perceptions of ecosystem services and disservices linked to urban tree plantings. *Urban Forestry & Urban Greening*, 82, 127870.
- Eckert, S. (2012). Improved Forest Biomass and Carbon Estimations Using Texture Measures from WorldView-2 Satellite Data. *Remote Sensing*, 4(4), 810–829.
- Eichhorst, U., y Bongardt, D. (2017). *MobiliseYourCity - Monitoring & reporting approach for GHG emissions*.
- EM. (2003). *Evaluación de Ecosistemas del Milenio*.
- Evangelides, C., y Nobajas, A. (2020). Red-Edge Normalised Difference Vegetation Index (NDVI705) from Sentinel-2 imagery to assess post-fire regeneration. *Remote Sensing Applications: Society and Environment*, 17, 100283.
- FAO. (2020). *Global forest resources assessment 2020: Main report*. Food and Agriculture Organization of the United Nations.
- Fischer, R., Knapp, N., Bohn, F., Shugart, H. H., y Huth, A. (2019). The relevance of forest structure for biomass and productivity in temperate forests: New perspectives for remote sensing. *Surveys in Geophysics*, 40(4), 709–734.

FRA. (2015). *Evaluación de los Recursos Forestales Mundiales*.

Francini, S., McRoberts, R. E., Giannetti, F., Mencucci, M., Marchetti, M., Scarascia Mugnozza, G., y Chirici, G. (2020). Near-real time forest change detection using PlanetScope imagery. *European Journal of Remote Sensing*, 53(1), 233–244.

Friedlingstein, P., O’Sullivan, M., Jones, M. W., Andrew, R. M., Hauck, J., Landschützer, P., Le Quéré, C., Li, H., 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., ... Zeng, J. (2024). *Global Carbon Budget 2024*.

Fritz, A., Kattenborn, T., y Koch, B. (2013). UAV-BASED PHOTOGRAMMETRIC POINT CLOUDS – TREE STEM MAPPING IN OPEN STANDS IN COMPARISON TO TERRESTRIAL LASER SCANNER POINT CLOUDS. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1/W2, 141–146.

Galeote-Leyva, B., Valdez-Lazalde, J. R., Ángeles-Pérez, G., De los Santos-Posadas, H. M., y Romero Padilla, J. M. (2022). Inventario forestal asistido por LIDAR: efecto de la densidad de retornos y el diseño de muestreo sobre la precisión. *Madera y Bosques*, 28(2).

Gates, D. M., Keegan, H. J., Schleiter, J. C., y Weidner, V. R. (1965). Spectral Properties of Plants. *Applied Optics*, 4(1), 11.

George-Chacón, S. P., Mas, J. F., Dupuy, J. M., Castillo-Santiago, M. A., y Hernández-Stefanoni, J. L. (2022). Mapping the spatial distribution of stand age and aboveground biomass from Landsat time series analyses of forest cover loss in tropical dry forests. *Remote Sensing in Ecology and Conservation*, 8(3), 347–361.

Giri, C. (2016). Observation and Monitoring of Mangrove Forests Using Remote Sensing: Opportunities and Challenges. *Remote Sensing*, 8(9), 783.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., y Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27.

- Grogan, K., Pflugmacher, D., Hostert, P., Verbesselt, J., y Fensholt, R. (2016). Mapping Clearances in Tropical Dry Forests Using Breakpoints, Trend, and Seasonal Components from MODIS Time Series: Does Forest Type Matter? *Remote Sensing*, 8(8), 657.
- Guo, Y., Ren, Z., Wang, C., Zhang, P., Ma, Z., Hong, S., Hong, W., y He, X. (2024). Spatiotemporal patterns of urban forest carbon sequestration capacity: Implications for urban CO₂ emission mitigation during China's rapid urbanization. *Science of The Total Environment*, 912, 168781.
- Hernández-Stefanoni, J. L., Castillo-Santiago, M. A., Andrés-Mauricio, J., Mas, J. F., Tun-Dzul, F., y Dupuy-Rada, J. M. (2021). *Mapeo de la biomasa aérea de los bosques mediante datos de sensores remotos y R – Libros ECOSUR*. El Colegio de la Frontera Sur: Centro de Investigación Científica de Yucatán .
- 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., y 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.
- Hernández-Stefanoni, J. L., Dupuy, J. M., Johnson, K. D., Birdsey, R., Tun-Dzul, F., Peduzzi, A., Caamal-Sosa, J. P., Sánchez-Santos, G., y López-Merlín, D. (2014). Improving Species Diversity and Biomass Estimates of Tropical Dry Forests Using Airborne LiDAR. *Remote Sensing* , 6(6), 4741–4763.
- Hernández-Stefanoni, J. L., Reyes-Palomeque, G., Castillo-Santiago, M. Á., George-Chacón, S. P., Huechacona-Ruiz, A. H., Tun-Dzul, F., Rondon-Rivera, D., y Dupuy, J. M. (2018). Effects of Sample Plot Size and GPS Location Errors on Aboveground Biomass Estimates from LiDAR in Tropical Dry Forests. *Remote Sensing*, 10(10), 1586.
- Huete, A. R. (2012). Vegetation Indices, Remote Sensing and Forest Monitoring. *Geography Compass*, 6(9), 513–532.

-
- INECC. (2021). *Inventario Nacional de Emisiones de Gases y Compuestos de Efecto Invernadero 1990 - 2019*.
- INEGI. (2011). *Censo de Población y Vivienda 2010*.
- INEGI. (2021). *Censo de Población y Vivienda 2020*.
- INEGI. (2022). *Aspectos geograficos* .
- IPCC. (2023). *Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]* .
- i-Tree. (2018). *Adaptación del programa i-Tree Eco a México* .
- Jenerette, G. D., y Herrmann, D. L. (2024). A global synthesis of reported urban tree carbon production rates and approaches. *Frontiers in Ecology and Evolution*, 11.
- Jo, H.-K., y McPherson, E. G. (2001). Indirect carbon reduction by residential vegetation and planting strategies in Chicago, USA. *Journal of Environmental Management*, 61(2), 165–177.
- Joshi, N., Baumann, M., Ehammer, A., Fensholt, R., Grogan, K., Hostert, P., Jepsen, M. R., Kuemmerle, T., Meyfroidt, P., Mitchard, E. T. A., Reiche, J., Ryan, C. M., y Waske, B. (2016). A Review of the Application of Optical and Radar Remote Sensing Data Fusion to Land Use Mapping and Monitoring. *Remote Sensing 2016, Vol. 8, Page 70*, 8(1), 70.
- Khan, Md. N. I., Azad, Md. S., Hasan, T., Prova, A. F., Islam, Md. S., Islam, Md. R., y Mollick, A. S. (2024). Structural diversity and carbon stocks in a tropical semi-evergreen forest in Bangladesh. *Trees, Forests and People*, 16, 100534.
- Knipling, E. B. (1970). Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment*, 1(3), 155–159.
- Kumar, L., y Mutanga, O. (2017). Remote Sensing of Above-Ground Biomass. *Remote Sensing*, 9(9), 935.

- Kurtz, B. C., de Almeida, T. M. H., Coelho, M. A. N., Deccache, L. S. J., Tortorelli, R. M., Gonzaga, D. R., Madureira, L. K., Guedes-Oliveira, R., Barros, C. F., y de Siqueira, M. F. (2024). Quantifying the Carbon Stocks in Urban Trees: The Rio de Janeiro Botanical Garden as an Important Tropical Carbon Sink. *Journal of Zoological and Botanical Gardens*, 5(4), 579–589.
- Leyva-Ovalle, Á., Valdez-Lazalde, J. R., De los Santos-Posadas, H. M., Martínez-Trinidad, T., Herrera-Corredor, J. A., Lugo-Espinosa, O., y García-Nava, J. R. (2017). Monitoreo de la degradación forestal en México con base en el inventario nacional forestal y de suelos (Infys). *Madera y Bosques*, 23(2), 69–83.
- Liu, Li, T., Zhao, W., Wang, S., y Fu, B. (2019). Landscape functional zoning at a county level based on ecosystem services bundle: Methods comparison and management indication. *Journal of Environmental Management*, 249, 109315.
- Liu, S., Brandt, M., Nord-Larsen, T., Chave, J., Reiner, F., Lang, N., Tong, X., Ciais, P., Igel, C., Pascual, A., Guerra-Hernandez, J., Li, S., Mugabowindekwe, M., Saatchi, S., Yue, Y., Chen, Z., y Fensholt, R. (2023). The overlooked contribution of trees outside forests to tree cover and woody biomass across Europe. *Science Advances*, 9(37).
- Lomas-Cerón, F., y Ordóñez-Rodríguez, R. (2016). *Prácticas para el mejoramiento del paisaje urbano de la Ciudad de Mérida*.
- López-López, S. F., Martínez-Trinidad, T., Benavides-Meza, H. M., García-Nieto, M., y Ángeles-Pérez, G. (2018). Reservorios de biomasa y carbono en el arbolado de la primera sección del Bosque de Chapultepec, Ciudad de México. *Madera y Bosques*, 24(3).
- Machado-Carcasés, G., y León-Sánchez, M. A. (2005). Selección del tamaño de parcela de muestreo para el inventario de los bosques pluvisilvas en Guantánamo. *Ciencia en su PC*, 3.
- Madundo, S. D., Mauya, E. W., y Kilawe, C. J. (2023). Comparison of multi-source remote sensing data for estimating and mapping above-ground biomass in the West Usambara tropical montane forests. *Scientific African*, 21, e01763.

- Mannan, A., Liu, J., Zhongke, F., Khan, T. U., Saeed, S., Mukete, B., ChaoYong, S., Yongxiang, F., Ahmad, A., Amir, M., Ahmad, S., y Shah, S. (2019). Application of land-use/land cover changes in monitoring and projecting forest biomass carbon loss in Pakistan. *Global Ecology and Conservation*, 17, e00535.
- Manzo-Delgado, L., y Meave, J. A. (2003). La vegetación vista desde el espacio: la fenología foliar a través de la percepción remota. *Ciencia*, 18–28.
- Marchionni, D. S., y Cavayas, F. (2014). La teledetección por radar como fuente de información litológica y estructural: Análisis espacial de imágenes SAR de RADARSAT-1. *Geoacta*, 39(1), 62–89.
- Mărgărint, M. C., Grozavu, A., y Patriche, C. V. (2013). Assessing the spatial variability of coefficients of landslide predictors in different regions of Romania using logistic regression. *Natural Hazards and Earth System Sciences*, 13(12), 3339–3355.
- Martin, N. A., Chappelka, A. H., Keever, G. J., y Loewenstein, E. F. (2011). *A 100% tree inventory using i-Tree Eco protocol: A case study at Auburn University, Alabama*. Auburn University.
- Matiza, C., Mutanga, O., Odindi, J., y Mngadi, M. (2024). The utility of Planetscope spectral data in quantifying above-ground carbon stock in an urban reforested landscape. *Ecological Informatics*, 80, 102472.
- McHale, M. R., Burke, I. C., Lefsky, M. A., Peper, P. J., y McPherson, E. G. (2009). Urban forest biomass estimates: is it important to use allometric relationships developed specifically for urban trees? *Urban Ecosystems*, 12(1), 95–113.
- McHale, M. R., Gregory McPherson, E., y Burke, I. C. (2007). The potential of urban tree plantings to be cost effective in carbon credit markets. *Urban Forestry & Urban Greening*, 6(1), 49–60.
- McKinney, M., Wavrek, M., Carr, E., y Jean-Philippe, S. (2022). Drone Remote Sensing in Urban Forest Management: A Case Study. *SSRN Electronic Journal*.
- McPherson, Doorn, N., y Goede, J. (2015). *The State of California's Street Trees*.

- McPherson, E. G. (1998). Atmospheric carbon dioxide reduction by Sacramento's urban forest. *Journal of Arboriculture*, 24(4), 215–223.
- Meneses, V. A. B., Téllez, J. M., y Velasquez, D. F. A. (2015). USO DE DRONES PARA EL ANALISIS DE IMÁGENES MULTIESPECTRALES EN AGRICULTURA DE PRECISIÓN. *@limentech, Ciencia y Tecnología Alimentaria*, 13(1).
- Mexia, T., Vieira, J., Príncipe, A., Anjos, A., Silva, P., Lopes, N., Freitas, C., Santos-Reis, M., Correia, O., Branquinho, C., y Pinho, P. (2018). Ecosystem services: Urban parks under a magnifying glass. *Environmental Research*, 160, 469–478.
- Molina-Alomar, J. (2021). Acuerdo para la creación de los mercados de carbono y la aceleración de las finanzas climáticas: la COP 26 también dejó algunas buenas noticias. *País circular*.
- Montgomery, D. C., Vining, G. G., y Peck, E. A. (2006). *Introducción Al Análisis de Regresión Lineal* (3ra ed.).
- Morales-Gallegos, L. M., Martínez-Trinidad, T., Hernández-De la Rosa, P., Gómez-Guerrero, A., Alvarado-Rosales, D., y Saavedra-Romero, L. de L. (2023). Diversidad, estructura y salud del arbolado en áreas verdes de la ciudad de Texcoco, México. *Bosque (Valdivia)*, 44(2), 401–414.
- Muhe, S., y Argaw, M. (2022). Estimation of above-ground biomass in tropical afro-montane forest using Sentinel-2 derived indices. *Environmental Systems Research*, 11(1), 5.
- Murillo-Sandoval, P. J., y Carbonell-González, J. A. (2012). *Principios y aplicaciones de la percepción remota en el cultivo de caña de azúcar en Colombia* (Cenicaña, Vol. 1).
- Murray-Tortarolo, G., Friedlingstein, P., Sitch, S., Jaramillo, V. J., Murguía-Flores, F., Anav, A., Liu, Y., Arneeth, A., Arvanitis, A., Harper, A., Jain, A., Kato, E., Koven, C., Poulter, B., Stocker, B. D., Wiltshire, A., Zaehle, S., y Zeng, N. (2016). The carbon cycle in Mexico: past, present and future of C stocks and fluxes. *Biogeosciences*, 13(1), 223–238.

-
- Myers, V. I., Carter, D. L., y Rippert, W. J. (1966). Remote Sensing for Estimating Soil Salinity. *Journal of the Irrigation and Drainage Division*, 92(4), 59–70.
- NASA: Earthdata. (2023, abril 25). *What is Synthetic Aperture Radar?* .
- Nowak, D. J., Hoehn, R. E., Bodine, A. R., Crane, D. E., Dwyer, J. F., Bonnewell, V., y Watson, G. (2014). *Urban trees and forests of the Chicago Region*.
- Nowak, Walton, J., Stevens, J., Crane, D., y Hoehn, R. (2008). Effect of Plot and Sample Size on Timing and Precision of Urban Forest Assessments. *Arboriculture & Urban Forestry*, 34(6), 386–390.
- Olivier, J. G. J., y Peters, J. A. H. W. (2018). *Trends in global CO2 and total greenhouse gas emissions: 2020 Report*. PBL Netherlands Environmental Assessment Agency.
- Ollinger, S. V. (2011). Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytologist*, 189(2), 375–394.
- Orellana-Asenjo, G. J. (2022). *Los servicios ecosistemicos del arbolado urbano: caso de estudio Barcelona* . Universitat Politecnica de Catalunya.
- Paz-Pellat, F., Romero-Sánchez, M., Palacios-Vélez, E., Bolaños-González, M., Valdez, L. J. R., y Aldrete, A. (2014). ALCANCES Y LIMITACIONES DE LOS ÍNDICES ESPECTRALES DE LA VEGETACIÓN: MARCO TEÓRICO. *Terra Latinoamericana*, 32(3).
- Pérez-Medina, S., y López-Falfán, I. (2015). Áreas verdes y arbolado en Mérida, Yucatán. Hacia una sostenibilidad urbana. *Economía, Sociedad y Territorio*, 47, 1–33.
- Permatasari, V. Y., Suharyadi, R., y Hidayati, I. N. (2023). Utilization of Planetscope Imagery for Carbon Stock Estimation of Standing Green Open Space in Jebres Sub-District, Surakarta. *E3S Web of Conferences*, 468, 03009.
- 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.
- Phillips, O. L. (2023). Sensing Forests Directly: The Power of Permanent Plots. *Plants*, 12(21), 3710.
- Planet. (2024, junio 8). *Planet*. Planet Imagery Products.
- Ploton, P., Barbier, N., Coutron, P., Antin, C. M., Ayyappan, N., Balachandran, N., Barathan, N., Bastin, J. F., Chuyong, G., Dauby, G., Droissart, V., Gastellu-Etchegorry, J. P., Kamdem, N. G., Kenfack, D., Libalah, M., Mofack, G., Momo, S. T., Pargal, S., Petronelli, P., ... Pélissier, R. (2017). Toward a general tropical forest biomass prediction model from very high resolution optical satellite images. *Remote Sensing of Environment*, 200, 140–153.
- 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.
- Porcar-Castell, A., Tyystjärvi, E., Atherton, J., van der Tol, C., Flexas, J., Pfündel, E. E., Moreno, J., Frankenberg, C., y Berry, J. A. (2014). Linking chlorophyll a fluorescence to photosynthesis for remote sensing applications: mechanisms and challenges. *Journal of Experimental Botany*, 65(15), 4065–4095.
- R Core Team. (2021). *R: A Language and Environment for Statistical Computing*. Vienna, Austria: R Foundation for Statistical Computing, Vienna, Austria.
- Ramírez Ramírez, G., Dupuy Rada, J. M., Ramírez y Avilés, L., y 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.

-
- Ramírez-Medina, M. (2022). *Estimación de la biomasa aérea e intercepción de lluvia mediante imágenes de muy alta resolución espacial en bosques urbanos de Mérida*. Centro de investigación Científica de Yucatán, CICY .
- Reddy, G. P. O. (2018). *Satellite Remote Sensing Sensors: Principles and Applications* (pp. 21–43).
- Réjou-Méchain, M., Barbier, N., Coutron, P., Ploton, P., Vincent, G., Herold, M., Mermoz, S., Saatchi, S., Chave, J., de Boissieu, F., Féret, J.-B., Takoudjou, S. M., y Pélissier, R. (2019). Upscaling Forest Biomass from Field to Satellite Measurements: Sources of Errors and Ways to Reduce Them. *Surveys in Geophysics*, 40(4), 881–911.
- Ren, Z., Zheng, H., He, X., Zhang, D., Shen, G., y Zhai, C. (2019). Changes in spatio-temporal patterns of urban forest and its above-ground carbon storage: Implication for urban CO₂ emissions mitigation under China's rapid urban expansion and greening. *Environment International*, 129, 438–450.
- Renner, I. (2019). *Integración de los servicios ecosistémicos en la planificación y gestión urbana Un enfoque sistemático en pasos para profesionales*.
- Reyes-Palomeque, G., Dupuy, J. M., Johnson, K. D., Castillo-Santiago, M. A., y 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*, 92(5), 599–615.
- Rhoades, R., y Stipes, R. J. (1999). Growth of trees on the Virginia Tech campus in response to various factors. . *Journal of Arboriculture*, 25, 211–217.
- Rodriguez-Larramendi, L. A. (2016). Estimación de biomasa y carbono almacenado en bosques comunitarios de la región Frailesca de Chiapas, México. *Revista mexicana de ciencias forestales*, 7(37), 77–94.
- Sayer, E. J., Leitman, S. F., Wright, S. J., Rodtassana, C., Vincent, A. G., Bréchet, L. M., Castro, B., Lopez, O., Wallwork, A., y Tanner, E. V. J. (2024). Tropical forest above-ground productivity is maintained by nutrients cycled in litter. *Journal of Ecology*, 112(4), 690–700.

- Schweiger, A. K., Cavender-Bares, J., Townsend, P. A., Hobbie, S. E., Madritch, M. D., Wang, R., Tilman, D., y Gamon, J. A. (2018). Plant spectral diversity integrates functional and phylogenetic components of biodiversity and predicts ecosystem function. *Nature Ecology & Evolution* 2018 2:6, 2(6), 976–982.
- SEMARNAT-INECC-GGGI. (2024). *Mercado Voluntario de Carbono en México: Caracterización y resultados de su estudio en territorio*.
- Singh, K. K., Bianchetti, R. A., Chen, G., y Meentemeyer, R. K. (2017). Assessing effect of dominant land-cover types and pattern on urban forest biomass estimated using LiDAR metrics. *Urban Ecosystems*, 20(2), 265–275.
- Slik, J. W. F. (2006). Estimating species-specific wood density from the genus average in Indonesian trees. *Journal of Tropical Ecology*, 22(4), 481–482.
- Sorensen, M., Barzetti, V., Keipi, K., y Williams, J. (1998). *Manejo de las áreas verdes urbanas*.
- Steenberg, J. W. N., Duinker, P. N., y Nitoslawski, S. A. (2019). Ecosystem-based management revisited: Updating the concepts for urban forests. *Landscape and Urban Planning*, 186, 24–35.
- Stephenson, N. L., Das, A. J., Condit, R., Russo, S. E., Baker, P. J., Beckman, N. G., Coomes, D. A., Lines, E. R., Morris, W. K., Rüger, N., Álvarez, E., Blundo, C., Bunyavejchewin, S., Chuyong, G., Davies, S. J., Duque, Á., Ewango, C. N., Flores, O., Franklin, J. F., ... Zavala, M. A. (2014). Rate of tree carbon accumulation increases continuously with tree size. *Nature*, 507(7490), 90–93.
- Torresan, C., Berton, A., Carotenuto, F., Di Gennaro, S. F., Gioli, B., Matese, A., Miglietta, F., Vagnoli, C., Zaldei, A., y Wallace, L. (2017). Forestry applications of UAVs in Europe: a review. *International Journal of Remote Sensing*, 38(8–10), 2427–2447.
- Toth, C., y Józków, G. (2016). Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 22–36.

- Turner, W., Spector, S., Gardiner, N., Fladeland, M., Sterling, E., y Steininger, M. (2003). Remote sensing for biodiversity science and conservation. *Trends in Ecology & Evolution*, 18(6), 306–314.
- Twumasi, Y. A., Asare-Ansah, A. B., Merem, E. C., Loh, P. M., Namwamba, J. B., Ning, Z. H., Yeboah, H. B., Anokye, M., Armah, R. N. D., Apraku, C. Y., Atayi, J., Frimpong, D. B., Okwemba, R., Oppong, J., Kangwana, L. A., Mjema, J., Njeri, L. W., McClendon-Peralta, J., y Jeruto, V. (2022). Fusion of Landsat 8 OLI and PlanetScope Images for Urban Forest Management in Baton Rouge, Louisiana. *Journal of Geographic Information System*, 14(05), 444–461.
- UNDESA. (2019). *Publications: 2018 revision of world urbanization prospects*.
- UNFCCC. (2015). *Paris Agreement*.
- Useni Sikuzani, Y., Malaisse, F., Cabala Kaleba, S., Kalumba Mwanke, A., Yamba, A. M., Nkuku Khonde, C., Bogaert, J., y Munyemba Kankumbi, F. (2019). Tree diversity and structure on green space of urban and peri-urban zones: The case of Lubumbashi City in the Democratic Republic of Congo. *Urban Forestry & Urban Greening*, 41, 67–74.
- Vargas-Hernández, J. G., Pallagst, K., y Hammer, P. (2018). Urban Green Spaces as a Component of an Ecosystem Functions, Services, Users, Community Involvement, initiatives and Actions. *Int J Environ Sci Nat Res.*, 8.
- Vargas-Hernández, J. G., Pallagst, K., y Zdunek-Wielgołaska, J. (2018). Urban Green Spaces as a Component of an Ecosystem. En *Handbook of Engaged Sustainability* (pp. 885–916). Springer International Publishing.
- Vargas-Hernández, J. G., Pallagst, K., y Zdunek-Wielgołaska, J. (2023). Urban Green Spaces as a Component of an Ecosystem. En *Sustainable Development and Environmental Stewardship* (pp. 165–198). Springer International Publishing.
- Verhoeven, G. (2017). The reflection of two fields – Electromagnetic radiation and its role in (aerial) imaging. *AARGnews*, 1(55), 13–18.

- Wang, y Gong, F.-Y. (2024). Quantifying City- and Street-Scale Urban Tree Phenology from Landsat-8, Sentinel-2, and PlanetScope Images: A Case Study in Downtown Beijing. *Remote Sensing*, 16(13), 2351.
- Wang, Y., Chang, Q., y Li, X. (2021). Promoting sustainable carbon sequestration of plants in urban greenspace by planting design: A case study in parks of Beijing. *Urban Forestry & Urban Greening*, 64, 127291.
- Warner, T. (2011). Kernel-Based Texture in Remote Sensing Image Classification. *Geography Compass*, 5(10), 781–798.
- Wavrek, M. T., Carr, E., Jean-Philippe, S., y McKinney, M. L. (2023). Drone remote sensing in urban forest management: A case study. *Urban Forestry & Urban Greening*, 86, 127978.
- Wen, Z., Jiang, Z., Zheng, H., y Ouyang, Z. (2022). Tropical forest strata shifts in plant structural diversity-aboveground carbon relationships along altitudinal gradients. *Science of The Total Environment*, 838, 155907.
- Wilkes, P., Disney, M., Vicari, M. B., Calders, K., y Burt, A. (2018). Estimating urban above ground biomass with multi-scale LiDAR. *Carbon Balance and Management*, 13(1), 10.
- Wood, E. M., Pidgeon, A. M., Radeloff, V. C., y Keuler, N. S. (2012). Image texture as a remotely sensed measure of vegetation structure. *Remote Sensing of Environment*, 121, 516–526.
- Wu, J., Wang, Y., Qiu, S., y Peng, J. (2019). Using the modified i-Tree Eco model to quantify air pollution removal by urban vegetation. *Science of The Total Environment*, 688, 673–683.
- Yachi, S., y Loreau, M. (1999). Biodiversity and ecosystem productivity in a fluctuating environment: The insurance hypothesis. *Proceedings of the National Academy of Sciences*, 96(4), 1463–1468.
- Yang, Y., Ma, J., Liu, H., Song, L., Cao, W., y Ren, Y. (2023). Spatial Heterogeneity analysis of urban forest ecosystem services in Zhengzhou City. *PLOS ONE*, 18(6), e0286800.

Zhang, Z., Ni, W., Quegan, S., Chen, J., Gong, P., Rodriguez, L. C. E., Guo, H., Shi, J., Liu, L., Li, Z., He, Y., Liu, Q., Shimabukuro, Y., y Sun, G. (2024). Deforestation in Latin America in the 2000s predominantly occurred outside of typical mature forests. *The Innovation*, 5(3), 100610.

Zhao, Zhou, L., Chen, C., Xuejian, L., Du, H., Yu, J., Lv, L., Huang, L., y Song, M. (2023). Urban Forest Above-Ground Biomass Estimation Based on UAV 3D Real Scene. *Drones*, 7(7), 455.

Zheng, G., Chen, J. M., Tian, Q. J., Ju, W. M., y Xia, X. Q. (2007). Combining remote sensing imagery and forest age inventory for biomass mapping. *Journal of Environmental Management*, 85(3), 616–623.

ANEXOS

Tabla 5.1 Coordenadas de las parcelas medidas para la medición de las variables estructurales en campo

Parque	Parcela	X	Y	AGB por parcela	AGB promedio
Jardín Botánico Regional del CICY "Roger Orellana"	1	225688.9512	2327682.969	333.63	
	2	225665.5787	2327637.246	258.22	265.57
	3	225680.6544	2327593.225	204.85	
	4	224494.8569	2327299.813	147.89	
Las Arboledas Francisco de Montejo II	5	224532.5894	2327337.777	89.06	93.42
	6	224592.44	2327312.314	43.31	
La Rampa Francisco de Montejo	7	225378.3435	2328238.338	51.29	101.1
	8	225447.9479	2328250.742	150.92	
Montes de Amés	9	228067.7646	2327840.385	61.89	43.08
	10	228123.7616	2327818.228	24.26	
Rosario Chuburná	11	225367.6297	2324999.999	130.50	110.78
	12	225347.4412	2325039.925	91.06	
El Porvenir	13	222671.0297	2324666.783	53.43	53.43
Emiliano Zapata Norte	14	228740.5555	2326182.098	49.46	45.9
	15	228743.4836	2326146.857	42.33	
	16	229753.7725	2325369.946	33.74	
La Juventud, San Antonio Cinta	17	229747.3431	2325426.894	92.59	51.97
	18	229700.0586	2325402.986	29.58	
Jesús Carranza	19	228931.5347	2322773.07	5.29	5.29

	20	231959.9326	2323067.519	46.85	
Vicente Guerrero					34.22
	21	231889.076	2323066.984	21.58	
Poligono 108 CTM	22	233008.8308	2323182.523	31.83	31.83
Florida Norte	23	232686.227	2325663.188	80.57	80.57
Las llantas	24	219855.8591	2319402.902	81.64	81.64
	25	221283.0818	2319251.577	104.88	
Villa Magna	26	221283.0818	2319251.577	71.60	92.52
	27	221277.9924	2319292.201	101.08	
	28	223372.2349	2319692.294	27.80	
Japonés					31.93
	29	223380.0606	2319608.337	36.05	
	30	224982.8786	2319536.602	127.99	
Pedro Infante Hundido					70.22
	31	224976.0969	2319569.2	12.45	
Arqueo-Ecológico de Xoclán	32	222661.4767	2321943.65	89.96	
	33	222431.9035	2322041.224	52.93	71.45
Amalia Solórzano	34	232617.7246	2320376.277	65.07	65.07
	35	231367.218	2320913.665	109.32	
Eco-Arqueológico del Poniente	36	231277.7927	2320929.324	125.48	101.19
	37	231267.5492	2320803.926	68.77	
San Pablo Oriente	38	232707.6078	2319127.121	159.45	66.28
San Nicolás del Sur	39	228477.9956	2316284.434	251.28	63.02
	40	223368.4876	2313086.877	66.28	
Ecológico Metropolitano del Sur	41	223403.1889	2313144.743	63.02	166.73
	42	223448.1798	2313281.682	147.77	
