



UNIVERSIDAD MICHOACANA DE SAN NICOLÁS DE HIDALGO
INSTITUTO DE INVESTIGACIONES SOBRE LOS RECURSOS NATURALES



Estimación de la altura del dosel en bosques de mangle mediante el uso de sensores remotos

Tesis presentada por

Biól. José de la Paz Soto

**como requisito para obtener el título profesional de
Maestro en Ciencias en Ecología Integrativa**

Director de tesis:

Dr. Rafael Hernández Guzmán

Morelia, Michoacán, julio de 2021

Resumen

Los bosques de manglar proveen importantes servicios ecológicos fundamentales para las comunidades costeras, cobrando mayor importancia por su contribución para enfrentar el cambio climático, por su alta captación de carbono. Por lo tanto, la comprensión del cambio climático global implica parámetros forestales como la altura del dosel y la biomasa aérea. Lo anterior, puede lograrse con la ayuda de la percepción remota; drones, imágenes multiespectrales y datos obtenidos mediante radares. Este trabajo tiene el objetivo de generar modelos de la altura del dosel de manglar mediante el uso de sensores remotos en la Reserva de la Biósfera Marismas Nacionales Nayarit, además de tener una caracterización reciente de la cobertura de manglar de la zona. Se realizó una caracterización de la cobertura de manglar utilizando imágenes satelitales Sentinel-2 para 2019; evaluando la exactitud con datos obtenidos en campo mediante una unidad GPS. Se realizaron levantamientos de fotografía aérea con ayuda de un dron comercial. Además de realizar levantamientos fotogramétricos para construir modelos digitales de superficie (MDS). De manera paralela, se generarán MDS a partir de imágenes SAR (Radar de Apertura Sintética). Finalmente, los modelos generados con sensores pasivos y validados en campo serán relacionados con los generados con otros sensores y se buscará espacializar la altura del dosel en toda el área de estudio mediante el uso de índices multiespectrales así como la implementación de modelos estadísticos para determinar el mejor modelo de altura para toda la reserva. Los mapas temáticos fueron validados en campo alcanzando una exactitud global de 88%, encontrando 57,071 ha de manglar en buen estado para 2019. Al comparar el análisis estadístico de la altura observada y la altura modelada se obtuvo un valor de $R^2 = 0.9$, cuando se utilizaron índices multiespectrales, la altura media del dosel se estimó en 6.36 m ($\pm 1,15$ m). Sin embargo, cuando se utilizaron imágenes SAR, la altura media del dosel se estimó en 3.66 m ($\pm 1,56$ m). Nuestros resultados pueden ayudar a informar la toma de decisiones sobre la creación y coordinación de esfuerzos en programas para la restauración y protección de los ecosistemas de manglares.

Keywords: Modelo digital de superficie; Sentinel-2; Marismas Nacionales; Fotogrametría; Percepción remota, altura del dosel.

Abstract

Mangrove forests provide important fundamental ecological services for coastal communities, which have become more important for their contribution to face climate change, due to their high carbon sequestration. Therefore, understanding global climate change involves forest parameters such as canopy height and aboveground biomass. This can be achieved with the help of remote sensing; drones, multispectral images and data obtained by radars. This work has the objective of generating models of the height of the mangrove canopy height through the use of remote sensors in the Marismas Nacionales Biosphere Reserve in Nayarit State, in addition to having a recent characterization of the mangrove cover of the area. A characterization of the mangrove cover was carried out using Sentinel-2 satellite images for 2019; evaluating the accuracy with data obtained in the field using a GPS unit. Aerial photography surveys were carried out with the help of a commercial drone. In addition to carrying out photogrammetric surveys to build digital surface models (DSM). In parallel, DSM will be generated from SAR (Synthetic Aperture Radar) images. Finally, the models generated with passive sensors and validated in the field will be related to those generated with other sensors and it will be sought to spatialize the height of the canopy in the entire study area through the use of multispectral indices as well as the implementation of statistical models to determine the best height model for the entire reserve. The thematic maps were validated in the field, reaching a global accuracy of 88%, finding 57,071 ha of mangroves in “good condition” for 2019. When comparing the observed heights in the field and the modeled heights with the drone, a value of $R^2 = 0.9$ was obtained. When multispectral indices were used, a mean canopy height was estimated at 6.36 m (± 1.15 m). However, when SAR images were used, the mean canopy height was estimated at 3.66 m (± 1.56 m). Our results can help to inform decision-making on the creation and coordination of efforts in programs for the restoration and protection of mangrove ecosystems.

Keywords: Digital surface model; Sentinel-2; Marismas Nacionales; Photogrammetry; Remote sensing, Canopy height.

AGRADECIMIENTOS

De manera muy especial quiero dedicar este trabajo a mi madre y mis hermanos, quienes fueron el pilar fundamental en todo lo que íntegramente soy tanto como en lo profesional como en lo personal, a ellos gracias porque gracias a ellos soy lo que soy.

A mis amigos por acompañarme a cada paso del camino, por hacer de esta travesía los mejores años de mi vida, por dejarme impactar en sus vidas tanto como impactaron ellos en la mía.

A mi asesor el Dr. Rafael Hernández Guzmán por su paciencia, confianza, y sobre todo el apoyo al realizar este trabajo, por transmitirme su noción y la pasión por el trabajo que realizamos.

A mis sinodales el Dr. Arturo Ruiz Luna, el Dr. Héctor Nava Bravo, el Dr. José Arnulfo Blanco García y el Dr. Leonel López Toledo, por el apoyo y conocimiento aportado, así como sus atinadas correcciones y sugerencias para de esa manera pulir este trabajo.

A mi madre por darme los medios físicos y morales para terminar este proceso y cumplir mis objetivos.

La familia que yo elegí, mi familia de vida, las grandes personas que han pasado por mi vida y la han marcado para ser la persona que soy.

Al Instituto de Investigaciones sobre los Recursos Naturales por brindarme buenos docentes, compañeros y amigos y sobre todo formarme académicamente.

Al Consejo Nacional de Ciencia y Tecnología por brindarme los medios económicos para continuar con esta travesía académica.

Capítulo 1	10
Introducción General	10
Objetivos	13
Hipótesis	14
Zona de estudio	14
<i>Hidrología</i>	14
<i>Clima</i>	16
<i>Geomorfología</i>	16
<i>Vegetación</i>	16
<i>Fauna</i>	16
Referencias	17
Capítulo 2	23
Estimación de la distribución espacio-temporal del bosque de mangle de la Reserva de la Biosfera Marismas Nacionales, Nayarit mediante imágenes Landsat	23
Introducción	23
Zona de estudio	24
Metodología	27
<i>Análisis de imágenes multiespectrales</i>	27
<i>Validación de la exactitud</i>	28
<i>Análisis de detección de cambio</i>	28
<i>Determinación de la tasa de pérdida</i>	28
Resultados	29
<i>Extensión de manglar</i>	29
<i>Análisis de detección de cambio</i>	32
Discusión	36
Conclusiones	39
Referencias	40
Anexo 2.1. Área estimada de la cobertura de manglar reportada para la zona de estudio por diversos autores.	47
Capítulo 3	50
Estimación de la altura del dosel en bosques de mangle utilizando sensores remotos	50
Introducción	50
Zona de estudio	54
Metodología	56
<i>Integración general de fases metodológicas</i>	56
<i>Análisis de imágenes Sentinel-2</i>	56
<i>Validación de la exactitud</i>	57
<i>Muestreo de manglar</i>	57
<i>Fotografía aérea y proceso fotogramétrico</i>	58
<i>Evaluación el potencial de los datos SAR para estimar la altura del dosel</i>	59
<i>Incorporación de índices multiespectrales para las estimaciones de la altura del dosel</i> ...	59

Resultados	61
<i>Levantamientos fotogramétricos</i>	63
<i>Análisis estadístico</i>	64
<i>Modelo de Radar de Apertura Sintética (SAR) ALOS-PALSAR</i>	64
<i>Evaluación de los índices espectrales</i>	66
Discusiones.....	71
Conclusiones	74
Referencias	75
Anexo 3.1. Levantamientos fotogramétricos.....	84
Anexo. 3.2 Análisis de regresión lineal y línea de tendencia de la altura modelada contra los valores de los índices restantes calculados en el estudio.....	98
Anexo. 3.3 Coeficiente de determinación (R^2) de índices individuales y combinaciones de dos o más índices.	99
Anexo 3.4. Coeficiente de determinación (R^2) de la altura modelada frente a los índices NDVI, GRVI y NDWI _{MC} en tres fechas diferentes.....	100

Índice de figuras

Figura 1.1 Ubicación geográfica de la Reserva de la Biosfera Marismas Nacionales, Nayarit.....	12
Figura 2.1 Ubicación geográfica de la Reserva de la Biosfera Marismas Nacionales, Nayarit.....	24
Figura 2.2 Caracterización de Manglar en buen estado de conservación (verde) y muerto (rojo) en una crono-secuencia de imágenes Landsat a 30 m de resolución espacial.....	29
Figura 2.3 Detección de cambio mediante un traslape de caracterizaciones de 1990 y 2019, con zona que se mantuvo sin cambios (verde), zonas con pérdida de cobertura de manglar (rojo), zona de recuperación de cobertura de manglar (naranja).....	31
Figura 3.1 Ubicación geográfica de la Reserva de la Biosfera Marismas Nacionales, Nayarit.....	53
Figura 3.2 Caracterización de Manglar en buen estado de conservación (verde) y muerto (rojo) para imágenes Sentinel-2 (10 m de resolución) a) temporada seca; b) temporada de lluvia.....	60
Figura 3.3 Análisis de regresión lineal de la altura real contra la altura modelada mediante el MDE. $y =$ Ecuación de la recta con base en la altura modelada.....	61
Figura 3.4 a) Modelo digital de superficie utilizando imágenes de radar (ALOS-PALSAR); b) Proyección del Sistema de Monitoreo de carbono (SMC) de la NASA (Simard et al., 2019) c) Curvas de densidad normal estimadas para cada una de las proyecciones.....	62
Figura 3.5. Análisis de regresión lineal y línea de tendencia de la altura modelada contra los índices estadísticamente mejor relacionados.....	64
Figura 3.6. Proyecciones de altura máxima para la RBMN; a) proyección de alturas con NDVI; b) proyección de alturas con NDVI + NDWI; c) proyección de alturas con GRVI +	

NDVI + NDWI; **d)** curvas de densidad normal estimadas para cada una de las proyecciones.....65

Figura 3.7. Proyecciones de altura máxima para la RBMN; **a)** condiciones promedio de las diferentes proyecciones calculadas; **b)** proyección del Sistema de Monitoreo de carbono (SMC) de la NASA ([Simard et al., 2019](#)); **e)** curvas de densidad normal estimadas para cada una de las proyecciones.....67

Índice de tablas

Tabla 2.1 Evaluación de exactitud para la clasificación de manglares en Marismas Nacionales basada en imágenes Landsat, puntos de control reunidos en 2019 y 2020.....	27
Tabla 2.2 Cobertura (en hectáreas y porcentaje) de las diferentes condiciones de manglar para las fechas analizadas, obtenidas mediante el procesamiento de imágenes de satélite Landsat.....	28
Tabla 2.3. Cobertura en hectáreas de manglar perdidas (o ganadas) durante el periodo correspondiente; Tasa de Cambio Anual para cada periodo analizado.....	32
Tabla 2.4. Matrices de tabulación cruzada (en hectáreas) de los mapas temáticos entre los diferentes periodos. A) 1990 - 2000; B) 2000 - 2009; C) 2009 - 2019; D) 1990 – 2019. MN – Manglar; MND – Manglar muerto; OC – Otra cobertura.....	33
Tabla 3.1. Descripciones paramétricas de las imágenes de radar (ALOSPALSAR) utilizadas durante el estudio.....	57
Tabla 3.2 Evaluación de exactitud para la clasificación de manglares en Marismas Nacionales basada en imágenes Landsat, puntos de control reunidos en 2019 y 2020.....	59
Tabla 3.3. Análisis de regresión lineal entre la altura modelada con fotogrametría aérea y la altura proyectada mediante los mejores ajustes de índices espectrales obtenidos; adicional los valores extraídos del Sistema de Monitoreo de carbono (SMC).....	68

Capítulo 1

Introducción General

Los manglares son ecosistemas forestales de árboles leñosos y arbustivos encontrados principalmente en zonas intermareales de las regiones costeras tropicales y subtropicales del mundo (Giri et al., 2011). Estos son reconocidos por su adaptación a la dinámica de suelos blandos, poco oxígeno y salinidad variable, propios de la dinámica de mareas (Kathiresan y Bingham, 2001; Gaxiola, 2011; Romañach et al., 2018). En el mundo existen entre 70 y 73 especies/subespecies de manglares y a pesar de no ser numerosos taxonómicamente, son uno de los ecosistemas forestales más productivos de la tierra (Polidoro et al., 2010; Moity et al., 2019).

En México, se reconocen al menos cinco especies de manglar: *Rhizophora mangle* L. (mangle rojo), *Avicennia germinans* L. (mangle negro; Nash y Nee, 1984), *Laguncularia racemosa* L. Gaertn. (Mangle blanco), *Conocarpus erectus* L. (mangle botoncillo), y *Rizophora harrissonni* (Rico-Gray, 1981) (Portillo y Ecurra, 2002; Agraz-Hernández et al., 2006). Esta última especie es reportada solo en zonas aisladas de las costas de Chiapas.

Los ecosistemas de manglar brindan hábitat a especies de fauna comercial y silvestre, proveen recursos, protegen de la línea de costa, previenen de inundaciones, aportan nutrientes, filtran contaminantes, secuestran y almacenan carbono y la recarga de agua de los mantos freáticos (Berlanga-Robles et al., 2007; Kelleway et al., 2017; Menéndez et al., 2020). Debido a esto, los manglares y sus múltiples servicios y funciones ecológicas, recreativas y culturales, resultan fundamentales para el bienestar de muchas comunidades costeras (Menéndez et al., 2020). A pesar de que cubren solo el 0.1% de la superficie continental total del mundo (Polidoro et al., 2010) recientemente se ha enfatizado su importancia en los ciclos biogeoquímicos como el del carbonocarbono, aportando al menos el 10% del total de carbono transportado a los océanos (Dittmar et al., 2006; Valderrama-Landeros et al., 2014).

En las últimas décadas, cuando la sociedad ha buscado soluciones para enfrentar la amenaza del cambio climático, los manglares han cobrado mayor importancia, principalmente por su alta captación de carbono, almacenada en el componente aéreo (biomasa de árboles, hojas, propágulos, neumatóforos, raíces adventicias y ramas) y

subterráneo (sedimento y biomasa de las raíces) (Kauffman et al, 2013; Herrera-Romero et al., 2015). Considerando que México tiene entre el 5-6% de los manglares del planeta (Rodríguez-Zuñiga et al., 2013, CONABIO, 2021), juega un papel fundamental en la regulación del ciclo global del carbono, siendo capaces de disminuir las concentraciones de dióxido de carbono (CO₂) apoyando a mitigar los efectos del calentamiento global (Inoue, 2019; Sippo et al., 2020).

De esta manera, la estimación y el seguimiento de las reservas forestales de carbono se han vuelto cada vez más importantes, debido a su relevancia para los programas de adaptación y mitigación del cambio climático (Steininger, 2000; Fatoyimbo et al., 2018). Lo anterior implica necesariamente la cuantificación de parámetros forestales como el volumen, la altura, la biomasa aérea (AGB por sus siglas en inglés) y los stocks de carbono forestal (Steininger, 2000; Fatoyimbo et al., 2018; Kumagai et al., 2020). En este sentido, se ha determinado la importancia de la estructura forestal debido a su efecto en los ciclos de nutrientes, agua y carbono siendo considerada como una variable esencial para el monitoreo de la biodiversidad mundial (Pereira et al., 2013; Bispo et al., 2016; García et al., 2018).

Debido a esto, son necesarias mediciones precisas de altura del dosel, cobertura fraccional, tamaño de la copa y AGB (Smith, 2008), además de métodos de estimación de AGB de bajo costo y mayor cobertura (Pham et al., 2019). Si bien, el uso de los métodos tradicionales para el monitoreo de AGB continúan siendo importantes para su estimación, integrarlos con datos modernos de Percepción Remota (PR) ayudarían a cuantificar, monitorear y modelar la AGB forestal a diversas escalas. Por lo tanto, los métodos que incorporan la PR proporcionan una mejor alternativa para el monitoreo de AGB forestal en términos de accesibilidad y costo.

Tomando en cuenta que: a) los ecosistemas de manglar son considerados unos de los principales reservorios de biomasa aérea (Alongi, 2012); b) en proporción a su extensión, son uno de los ecosistemas boscosos de mayor biomasa, concentración de carbono y productividad (Adame et al., 2013) y; c) son unos de los ecosistemas más amenazados debido a las actividades antropogénicas (Donato et al., 2011; Lithgow et al., 2019); es importante elaborar estrategias de manejo y conservación apropiadas y generar conocimientos útiles que ayuden a los tomadores de decisiones a fomentar políticas de uso y protección de este tipo de ecosistemas en México. De esta manera, podrán verse beneficiados el continuo

funcionamiento ecológico y los servicios ecosistémicos que ofrecen los manglares. Por ello, resulta imprescindible conocer la dinámica y modificaciones a los flujos del carbono en estos ecosistemas forestales, derivadas de los patrones de cambio de uso de suelo y la estructura del bosque (Kumagai et al., 2020). La información sobre la estructura forestal a mayor escala y mejor resolución espacial es de gran importancia para diseñar estrategias de manejo forestal sostenible y mitigar las emisiones de gases de efecto invernadero (García et al., 2018). Lo anterior puede lograrse con ayuda de la PR.

Actualmente, el uso de imágenes satelitales para el monitoreo y detección de cambios en la vegetación se ha documentado a fondo y existe un gran progreso en su análisis (Cisell et al., 2018). Sin embargo, los datos que describen los cambios en el paisaje, suelen ser incompletos e inexactos, esto es atribuido a que muchos estudios omiten la evaluación de la exactitud y de variaciones metodológicas (Berlanga-Robles y Ruiz-Luna, 2007; Kuenzer, 2011). De acuerdo con esto, el cambio de cobertura del suelo requiere un enfoque de tres niveles: 1) mediciones directas de la tasa de los cambios de la cobertura del suelo, así como de la ubicación, el patrón espacial y las características temporales de dichos cambios; 2) estudios de caso de los cambios en la cobertura del suelo; y 3) identificación de los factores a gran escala que impulsan los cambios en la cobertura del suelo (Skole et al., 1994).

En este sentido, la PR, además de ofrecer un medio económico y eficiente, proporciona una visión sinóptica de la superficie terrestre (Pham et al., 2019). Su cobertura temporal ofrece datos históricos, necesarios para la detección de cambios, mientras que su formato digital los hace fácilmente integrables en un Sistema de Información Geográfica (SIG) ampliando su capacidad de análisis. Con base en esto, las herramientas SIG han demostrado ser fundamentales para este tipo de monitoreo, debido a su contribución al estudio y comprensión del entorno global a través del tiempo y a la calibración de modelos que ayudan a construir escenarios ambientales a futuro (Li et al., 2019; Pham et al., 2019).

En la actualidad, existen métodos menos dependientes de datos de campo tales como el uso de fotografías aéreas de alta resolución, imágenes multi e hiperespectrales, así como datos procedentes de una variedad de radares (Ramírez-Mejía et al., 2018, Pham et al., 2019). Estos nos permiten inferir parámetros forestales descriptivos de los árboles como diámetro de la copa, densidad y altura de los árboles, y en algunas ocasiones, la composición de especies (Popescu, 2007). Sin embargo, estos métodos tienen sus limitantes como cobertura

espacial limitada y suelen ser costosos aunado a la importancia de contar con series históricas más amplias (Wulder et al., 2008; Zamora-Martínez, 2017).

Este estudio aborda la utilización de estimaciones de altura de dosel basadas en datos multiespectrales a nivel regional, apoyados con modelos digitales de superficie (MDS) generados mediante un proceso de fotogrametría aérea derivado de imágenes obtenida con un Vehículo Aéreo No tripulado (VANT) (dron, en lo consecutivo) y MDS derivados de datos de Radars de Apertura Sintética (SAR, por sus siglas en inglés).

Específicamente se buscó, 1) realizar una aproximación del cálculo de altura observada mediante MDS creados a partir de fotogrametría apoyada por dron; 2) evaluar el potencial de los datos SAR para estimar la altura del dosel en ecosistemas de manglar; 3) investigar si la incorporación de información multiespectral ayuda a mejorar las estimaciones de la altura del dosel.

Se planteó obtener Modelos Digitales de Elevación haciendo uso de técnicas propias de diferentes sensores remotos y buscar obtener mediciones precisa de altura del dosel en la Reserva de la Biósfera Marismas Nacionales Nayarit. Se espera que los resultados contribuyan a constatar el nivel de presión bajo la cual se encuentran los ecosistemas de manglar en la Reserva de la Biósfera Marismas Nacionales Nayarit, zona definida como área de estudio y contribuyan a fortalecer la implementación de políticas para mantener y mejorar los servicios que estos proveen

Objetivos

Objetivo particular

Generar modelos de altura del dosel del ecosistema de manglar mediante el uso de diferentes sensores remotos.

Objetivos específicos

- 1) Realizar una caracterización reciente de la cobertura de manglar en la Reserva de la Biósfera Marismas Nacionales;
- 2) Realizar un levantamiento de fotografía aérea con la ayuda de un dron, en sitios estratégicos seleccionados y generar modelos de altura del dosel;

- 3) Evaluar el potencial de los datos SAR para estimar la altura del dosel de ecosistemas de manglar;
- 4) Investigar si la incorporación de información multispectral ayuda a mejorar las estimaciones de la altura del dosel.

Hipótesis

La implementación de la Percepción Remota en ecosistemas de manglar resulta particularmente complicada ya que, por definición, los humedales están expuestos a inundación frecuente. Por lo anterior, se presume que la incorporación de información proveniente de múltiples sensores mejorará significativamente los MDS (visto como altura de los árboles), que es un insumo indispensable para estimaciones regionales de AGB.

Zona de estudio

La zona de estudio corresponde a la Reserva de la Biosfera Marismas Nacionales Nayarit (RBMN), un gran complejo estuarino (~134,000 ha)(CONANP, 2013) ubicado en la costa noroeste del Pacífico mexicano en la llanura aluvial del estado de Nayarit entre los 21° 44' y 22° 35' de latitud Norte y 105° 18' y 105° 45' de longitud Oeste ([Figura 1](#)). La RBMN abarca el complejo de humedales más extenso del Pacífico mexicano, que representa el ~8% de la extensión nacional de manglares ([Valderrama-Landeros et al., 2017](#); [CONABIO, 2021](#)).

Hidrología

El sistema lagunar pertenece a la provincia denominada Planicie costera de Nayarit con una superficie de 852 km² y más de 150,000 ha de canales de marea, llanuras de inundaciones, lagunas y manglares, alimentado por varios afluentes entre los que destacan los ríos San Pedro, Acaponeta, Cañas, Rosa Morada, Bejuco y Santiago, los cuales descargan grandes cantidades de agua dulce y sedimentos ricos en nutrientes de las cuencas circundantes y componen una superficie total de las cuencas de 161,515 km², por lo que el establecimiento del manglar ha sido resultado del amplio sistema de deltas entre cuencas ([de la Lanza-Espino et al., 1996](#); [Hernández-Guzmán et al., 2019](#)). Por su parte la apertura del Canal de Cuautla en 1972 fue una de las perturbaciones hidrológicas más significativas debido a que altero de

manera drástica los niveles de salinidad y el régimen de mareas de toda la región (Kovacs et al., 2009; Serrano et al., 2019).

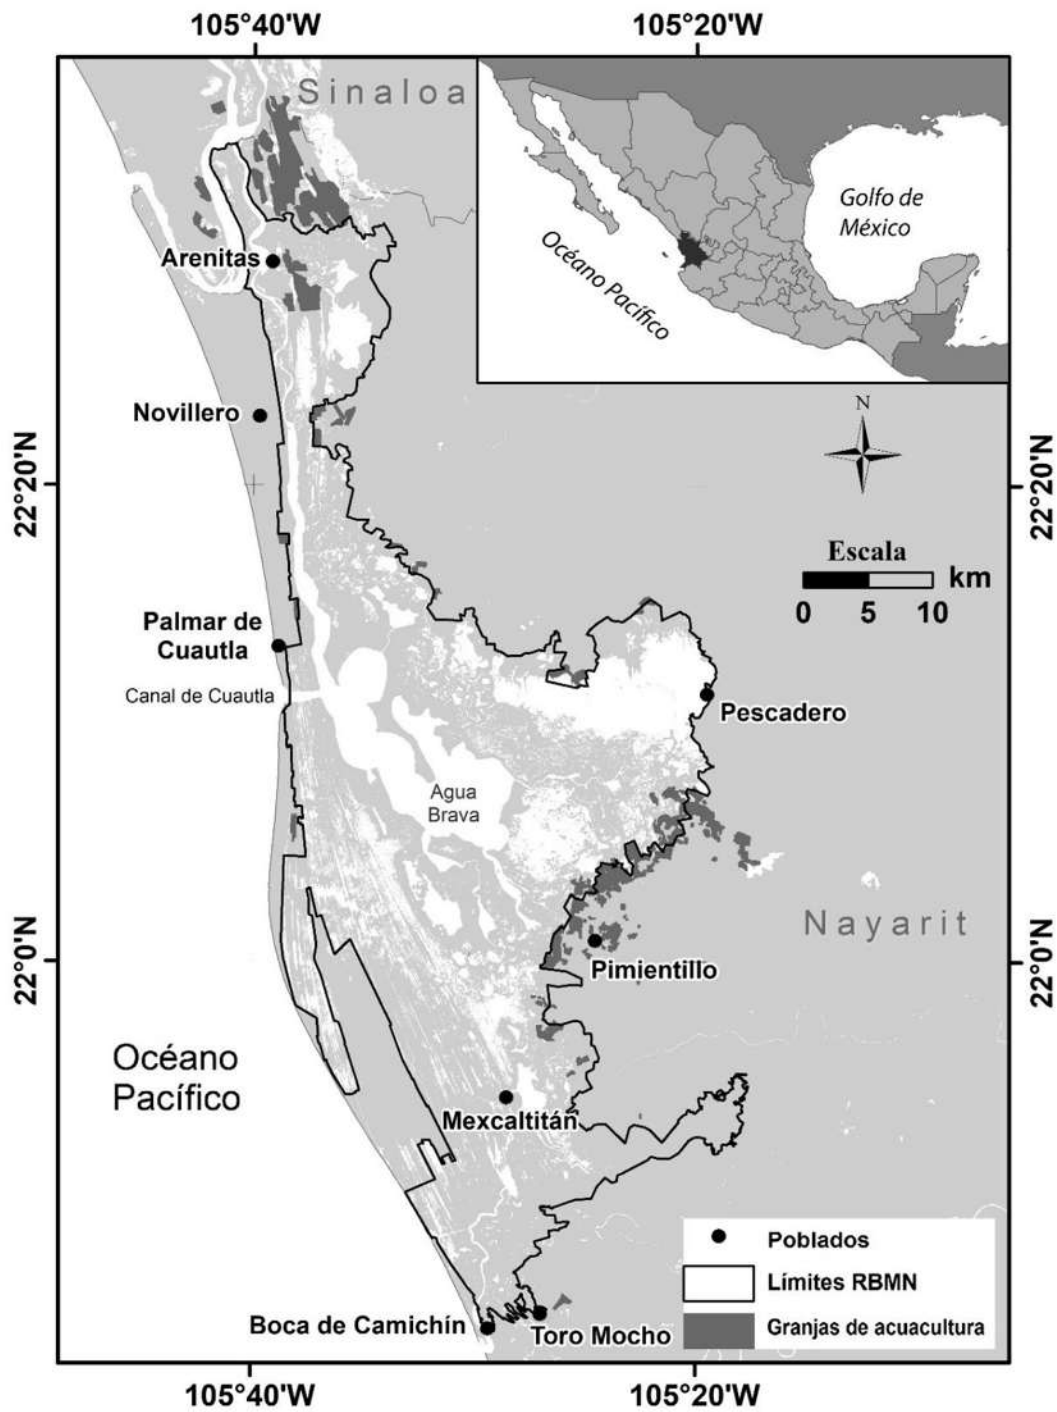


Figura 1.1 Ubicación geográfica de la Reserva de la Biosfera Marismas Nacionales, Nayarit.

Clima

El área se encuentra principalmente caracterizada por un clima cálido sub-húmedo con una temperatura media anual que varía entre los 22 y 26 °C. La época de secas se presenta desde diciembre a junio, con una precipitación entre 928 y 1,457 mm durante el verano. Cerca del 80% de la precipitación anual cae de julio a octubre durante la temporada de lluvias (Zhang et al., 2014; Hernández-Guzmán et al., 2019).

Geomorfología

Mediante criterios de flujo hidrológico y sedimentario se ha determinado que la RBMN está asociada hidrogeomorfológicamente a diez subregiones hidrológicas continentales, catorce cuencas mareales y cuarenta y siete subcuencas mareales (Blanco y Correa, 2012). Conformado principalmente por las lagunas de Mexcaltitán y Agua Brava son las principales lagunas costeras de la región. Estas tienen características geomorfológicas únicas que consisten en aproximadamente 280 cordilleras de arena sub-paralelas formadas por la acumulación sucesiva de cordilleras estrechas de playa durante la transgresión del Holoceno (hace 3,600–4,750 años) (Curry & Moore, 1964). Consta de extensas llanuras costeras salinas, cuyo proceso de salinización tiene su origen en cambios relacionados con transgresiones y regresiones marinas ocurridas en periodos del Pleistoceno y Holoceno, y proveen numerosos servicios ambientales y alta productividad biológica (Curry & Moore, 1964; Herrera-Romero et al., 2019). Se tiene conocimiento que la vegetación y el uso del suelo afecta significativamente la salinidad de los ecosistemas costeros. (Herrera-Romero, 2015).

Vegetación

Los principales tipos de vegetación son: vegetación halófila principalmente manglar, además de otros tipos de vegetación como selva mediana subcaducifolia con palmar; aunque existen también manchones de selva baja caducifolia con elementos de bosque espinoso y vegetación de dunas costeras (Flores-Verdugo & Pulido, 2010).

Fauna

Marismas Nacionales es una importante región de refugio invernal para aves migratorias en la ruta del Pacífico (Canadá y Estados Unidos), así como para especies en peligro de extinción como cocodrilos (*Crocodylus acutus*) y jaguares (*Panthera onca*) (Flores-Verdugo et al., 2014). Debido a su importancia clave para la conservación de las aves acuáticas y playeras, en 1992 la Red Hemisférica de Reservas para Aves Playeras (RHRAP) decretó a la RBMN como sitio de Importancia Internacional por ser utilizada por más de 100,000 individuos al año. En 1995, fue designada como Sitio Ramsar para la conservación de humedales y desde 1998 es considerada un Área de Importancia para la Conservación de las Aves (AICA) (Cervantes-Abrego, 2000; Mendoza et al., 2019).

Referencias

- Adame, M.F., Kauffman, J.B., Medina, I., Gamboa, J.N., Torres, O., Caamal, J.P., Reza, M. & Herrera-Silveira, J.A. 2013. Carbon stocks of tropical coastal wetlands within the karstic landscape of the Mexican Caribbean. *PLoS ONE*, 8: e56569. Doi: 10.1371/journal.pone.0056569
- Agraz-Hernández, C., Noriega-Trejo, R., López-Portillo, J., Flores-Verdugo, F. & Jiménez-Zacarías, J. 2006. *Guía de campo*. Identificación de los manglares en México. CENTRO EPOMEX-UAC.
- Alongi, D.M. 2012. Carbon sequestration in mangrove forests. *Carbon Management*, 3(3), 313–322. Doi: 10.4155/cmt.12.20
- Berlanga-Robles, C.A. & Ruiz-Luna, A. 2007. Análisis de las tendencias de cambio del bosque de mangle del sistema lagunar Teacapán-Agua Brava, México. Una aproximación con el uso de imágenes de satélite Landsat. *Universidad y Ciencia*, 23(1), 29-46.
- Bispo, P.C., dos Santos, J.R., Morisson-Valeriano, M., Lima P.M.G., Balzter, H., Franca, H. & Bispo, P.C. 2016. Predictive Models of Primary Tropical Forest Structure from Geomorphometric Variables Based on SRTM in the Tapajós Region, Brazilian Amazon. *PLoS ONE* 11(4), e0152009. Doi: 10.1371/journal.pone.0152009
- Blanco y Correa, M.J., 2012. Diagnostico Funcional De Marismas Nacionales. Informe final de los convenios de coordinación entre la Universidad Autónoma de Nayarit y la

- Comisión Nacional Forestal con el patrocinio del Gobierno del Reino Unido, Tepic, Nayarit. 190 páginas, 84 mapas + 1 DVD
- Cervantes-Abrego, M. 2000. Marismas Nacionales. En: M. del Coro-Arizmendi & L. Márquez-Valdelamar (Eds.), Áreas de Importancia para la Conservación de las Aves en México. México: CONABIO
- Cissell, J.R., Delgado, A.M., Sweetman, B.M., & Steinberg, M.K. 2018. Monitoring mangrove forest dynamics in Campeche, Mexico, using Landsat satellite data. *Remote Sensing Applications: Society and Environment*, 9, 60-68. Doi: 10.1016/j.rsase.2017.12.001.
- CONABIO [Comisión Nacional para el Conocimiento y Uso de la Biodiversidad]. 2021. Geoportal del Sistema Nacional de Información sobre Biodiversidad. CONABIO. Available at: http://geoportal.conabio.gob.mx/#!l=mx_man20gw:l@m=mixto
- Curry, J. R. & Moore, D. G. 1964. Holocene regressive littoral sand, Costa de Nayarit, Mexico. *Deltaic and Shallow Marine Deposits*, 76–82. Doi: 10.1016/s0070-4571(08)70470-9
- de la Lanza-Espino, G., Sánchez-Santillán, N., Sorani, V. & Bojórquez-Tapia, J.L. 1996. Características geológicas, hidrológicas y del manglar en la planicie costera de Nayarit, México. *Investigaciones Geográficas*, (32), 33-54
- Dittmar, T., Hertkorn, N., Kattner G., & Lara, R.J. 2006. Mangroves, a major source of dissolved organic carbon to the oceans. *Global Biogeochemical Cycles* 20, GB1012 Doi: 10.1029/2005GB002570
- Donato, D.C., Kauffman, J.B., Murdiyarso, D., Kurnianto, S., Stidham, M., & Kanninen, M. 2011. Mangroves among the most carbon-rich forests in the tropics. *Nature Geoscience*, 4(5), 293-297.
- Fatoyinbo, T., Feliciano, E.A., Lagomasino, D., Lee, S.K., & Trettin, C. 2018. Estimating mangrove aboveground biomass from airborne LiDAR data: a case study from the Zambezi River delta. *Environmental Research Letters*, 13(2), 025012. Doi: 10.1088/1748-9326/aa9f03
- Flores-Verdugo, F., & Pulido, S.H. 2010. Vulnerabilidad costera: caso de estudio del sistema de humedales Marismas Nacionales. *Cambio Climático En México*, 205.

- Flores-Verdugo, F., Amezcua, F., Kovacs, J.M., Serrano, D., & Blanco-Correa, M. 2014. Changes in the hydrological regime of coastal lagoons affect mangroves and small scale fisheries: the case of the mangrove-estuarine complex of Marismas Nacionales (Pacific coast of Mexico) in Fisheries management of Mexican and Central American estuaries (pp. 81-91). *Springer*, Dordrecht. Doi: 10.1007/978-94-017-8917-2_6
- García, M., Saatchi, S., Ustin, S. & Baltzer, H. 2018. Modelling forest canopy height by integrating airborne LiDAR samples with satellite Radar and multispectral imagery. *International Journal of Applied Earth Observation and Geoinformation* 66, 159-173
- Gaxiola, J.M.D. 2011. Una revisión sobre los manglares: características, problemáticas y su marco jurídico. Importancia de los manglares, el daño de los efectos antropogénicos y su marco jurídico: caso sistema lagunar de Topolobampo. Ra Ximhai: *Revista Científica de Sociedad, Cultura y Desarrollo Sostenible*, 7(3), 355-369.
- Giri, C., Ochieng, E., Tieszen, L.L., Zhu, Z., Singh, A., Loveland, T., Masek, J. & Duke, N. 2011. Status and distribution of mangrove forests of the world using earth observation satellite data. *Global Ecology and Biogeography*, 20(1), 154-159. Doi: 10.1111/j.1466-8238.2010.00584.x
- Hernández-Guzmán R., Ruiz-Luna A., Cervantes-Escobar A. 2019. Environmental flow assessment for rivers feeding a coastal wetland complex in the Pacific coast of northwest Mexico. *Water and Environment Journal*, 33(4), 536-546. Doi: 10.1111/wej.12423
- Herrera-Romero, J.A. 2015. Salinidad de suelos y vegetación asociada a marismas de Nayarit, México. Tesis de maestría. Universidad Autónoma de Nayarit, México. Disponible en línea en: <http://dspace.uan.mx:8080/jspui/handle/123456789/1616>
- Herrera-Romero, J. A., Bojórquez-Serrano, J. I., Can-Chulim, A., Madueño-Molina, A., & García-Paredes, J. D. 2019. Salinidad y propiedades de suelos de las barras costeras en marismas nacionales de México. *Revista bio ciencias*, 6
- Inoue, T. 2019. Carbon sequestration in mangroves. In blue carbon in shallow coastal ecosystems (pp. 73-99). *Springer*, Singapore. Doi: 10.1007/978-981-13-1295-3_3
- Kauffman, J.B., D.C. Donato & M.F. Adame. 2013. Protocolo para la medición, monitoreo y reporte de la estructura, biomasa y reservas de carbono de los manglares. Documento de Trabajo 117. Cifor. Bogor.

- Kathiresan, K. & Bingham, B.L. 2001. Biology of mangroves and mangrove ecosystems. *Advances in Marine Biology*, 40, 81-251. Doi: 10.1016/S0065-2881(01)40003-4
- Kelleway, J.J., Cavanaugh, K., Rogers, K., Feller, I.C., ENS, E., Doughty, C., & Saintilan, N. 2017. Review of the ecosystem service implications of mangrove encroachment into salt marshes. *Global Change Biology*, 23(10), 3967-3983. Doi: 10.1111/gcb.13727
- Kovacs, J.M., King, J.M.L., Flores-de-Santiago, F., & Flores-Verdugo, F. 2009. Evaluating the condition of a mangrove forest of the Mexican Pacific based on an estimated leaf area index mapping approach. *Environmental, Monitoring and Assessment*, 157, 137–149. Doi: 10.1007/s10661-008-0523-z
- Kuenzer, C., Bluemel, A., Gebhardt, S., Quoc, T.V. & Dech, S. 2011. Remote sensing of mangrove ecosystems: A review. *Remote Sensing*, 3(5), 878-928. Doi: 10.3390/rs3050878
- Kumagai, J. A., Costa, M.T., Ezcurra, E., & Aburto-Oropeza, O. 2020. Prioritizing mangrove conservation across Mexico to facilitate 2020 NDC ambition. *Ambio*, 1-11. Doi: 10.1007/s13280-020-01334-8
- Li, Z., Zan, Q., Yang, Q., Zhu, D., Chen, Y., & Yu, S. 2019. Remote estimation of mangrove aboveground carbon stock at the species level using a low-cost unmanned aerial vehicle system. *Remote Sensing*, 11(9), 1018. Doi: 10.3390/rs11091018
- Lithgow, D., de la Lanza, G. & Silva R. 2019. Ecosystem-Based management strategies to improve aquaculture in developing countries: Case study of Marismas Nacionales. *Ecological Engineering*, 130, 296-305. Doi: 10.1016/j.ecoleng.2017.06.039
- Mendoza, L.F., Carmona, R., de la Cruz Agüero, G., del Monte Luna, P., & de la Cruz Agüero, J. 2019. Abundancia, distribución espacial y temporal de aves playeras (Orden: Charadriiformes) en Marismas Nacionales, México. *Revista de Biología Tropical*, 67(4)
- Menéndez, P., Losada, I.J., Torres-Ortega, S., Narayan, S., & Beck, M.W. 2020. The global flood protection benefits of mangroves. *Scientific Reports*, 10, 4404. Doi: 10.1038/s41598-020-61136-6

- Moity, N., Delgado, B., & Salinas-de-León, P. 2019. Mangroves in the Galapagos Islands: Distribution and dynamics. *PloS one*, 14(1), e0209313. Doi: 10.1371/journal.pone.0209313
- Pham, T.D., Yokoya, N., Bui, D.T., Yoshino, K., & Friess, D.A. 2019. Remote sensing approaches for monitoring mangrove species, structure, and biomass: Opportunities and challenges. *Remote Sensing*, 11(3), 230. Doi: 10.3390/rs11030230
- Pereira, H., Ferrier, S., Walters, M., Geller, G.N., Jongman, R.H.G. et al., 2013. Essential biodiversity variables. *Science* 339, 277-278. Doi: 10.1126/science.1229931
- Polidoro, B.A., Carpenter, K.E., Collins, L., Duke, N. C., Ellison, A. M., Ellison, J.C., Farnsworth, E.J., Fernando, E.S., Kathiresan, K., Koedam, N.E., Livingstone, S.R., Miyagi, T., Moore, G.E., Nam, V.N., Ong, J.E., Primavera, J.H., Salmo III, S.G., Sanciangco, J.C., Sukardjo, S., Wang, Y., & Hong Yong, J.W. 2010. The loss of species: mangrove extinction risk and geographic areas of global concern. *PloS one*, 5(4), e10095. Doi: 10.1371/journal.pone.0010095
- Popescu, S.C. 2007. Estimating biomass of individual pine trees using airborne lidar. *Biomass and Bioenergy*, 31(9), 646-655. Doi: 10.1016/j.biombioe.2007.06.022
- Portillo, J. L., & Ezcurra, E. 2002. Los manglares de México: una revisión. *Madera y Bosques*, 8(Es1), 27-51.
- Ramírez-Mejía, D., Gómez-Tagle, A. & Ghilardi, A. 2018. Using aerial photography to estimate wood suitable for charcoal in managed oak forests. *Environmental Research Letters*, 13(2), 025006. Doi: 10.1088/1748-9326/aa9c63
- Rodríguez-Zúñiga, M.T., Troche-Souza C., Vázquez-Lule, A.D., Márquez-Mendoza, J. D., Vázquez-Balderas, B., Valderrama-Landeros, L., Velázquez-Salazar, S., Cruz-López, M.I., Ressler, R., Uribe-Martínez, A., Cerdeira-Estrada, S., Acosta-Velázquez, J., Díaz-Gallegos, J., Jiménez-Rosenberg, R., Fueyo-Mac Donald, L. y Galindo-Leal, C. 2013. Manglares de México: Extensión, Distribución y Monitoreo. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad, México D. F. 128 pp
- Romañach, S.S., DeAngelis, D.L., Koh, H.L., Li, Y., Teh, S.Y., Barizan, R.S.R., & Zhai, L. 2018. Conservation and restoration of mangroves: Global status, perspectives, and prognosis. *Ocean & Coastal Management*, 154, 72-82. Doi: 10.1016/j.ocecoaman.2018.01.009

- Serrano, D., Flores-Verdugo, F., Ramírez-Félix, E., Kovacs, J. M., & Flores-de-Santiago, F. 2019. Modeling tidal hydrodynamic changes induced by the opening of an artificial inlet within a subtropical mangrove dominated estuary. *Wetlands Ecology, and Management*, 28, 103-118. Doi: 10.1007/s11273-019-09697-w
- Skole, D.L., Chomentowski, W.A., Sallas, W.A., & Nobre, A.D. 1994: Physical and human dimensions of deforestation in Amazonia. *Bioscience* 44, 314-22. Doi: 10.2307/1312381
- Sippo, J.Z., Sanders, C.J., Santos, I. R., Jeffrey, L.C., Call, M., Harada, Y., Maguire, K., Brown, D., Conrad, S. R. & Maher, D.T. 2020. Coastal carbon cycle changes following mangrove loss. *Limnology and Oceanography*. Doi:10.1002/lno.11476
- Smith, M. L., Anderson, J., & Fladeland, M. 2008. Forest canopy structural properties. In *Field Measurements for Forest Carbon Monitoring* (pp. 179-196). *Springer*, Dordrecht. Doi: 10.1007/978-1-4020
- Steininger, M.K. 2000. Satellite estimation of tropical secondary forest above-ground biomass: data from Brazil and Bolivia. *International Journal of Remote Sensing*, 21(6-7), 1139-1157. Doi: 10.1080/014311600210119
- Valderrama, L., Troche, C., Rodríguez, M.T., Marquez, D., Vázquez, B., Velázquez, S., Vázquez, A., Cruz, Ma. I. & Ressler, R. 2014. Evaluation of mangrove cover changes in Mexico during the 1970–2005 period. *Wetlands*, 34(4), 747-758. Doi: 10.1007/s13157-014-
- Wulder, M.A., Bater, C.W., Coops, N.C., Hilker, T., & White, J.C. 2008. The role of LiDAR in sustainable forest management. *The Forestry Chronicle*, 84(6), 807-826. Doi: 10.5558/tfc84807-6
- Zamora-Martínez, M.C. 2017. La tecnología LiDAR, herramienta útil para el estudio de la biodiversidad. *Revista Mexicana de Ciencias Forestales*, 8(39), 4-6.
- Zhang, C., Kovacs, J., Liu, Y., Flores-Verdugo, F., & Flores-de-Santiago, F. 2014. Separating mangrove species and conditions using laboratory hyperspectral data: A case study of a degraded mangrove forest of the Mexican Pacific. *Remote Sensing*, 6(12), 11673-11688. Doi: 10.3390/rs61211673

Capítulo 2

Estimación de la distribución espacio-temporal del bosque de mangle de la Reserva de la Biosfera Marismas Nacionales, Nayarit mediante imágenes Landsat

Introducción

A pesar de los múltiples beneficios ecológicos, económicos y culturales que los bosques de mangle ofrecen, son uno de los ambientes más amenazados a nivel global ([Menéndez et al., 2020](#)). Aunque el estado de los manglares varía según el país y la región, muchos bosques de mangle experimentan amenazas similares a su persistencia desde el desarrollo urbano ([Alatorre et al., 2011](#); [Romañach et al., 2019](#)). La mayor amenaza a estos ecosistemas es el cambio climático, la alteración de flujos hidrológicos y la modificación de las tasas de sedimentación, escurrimiento e inundaciones resultado de las actividades humanas a nivel local y regional ([Lithgow et al., 2019](#)). Además, la sobrepesca, ganadería, plagas de animales y actividades recreativas han reducido considerablemente la extensión de estos bosques ([Romañach et al., 2019](#); [Adame et al., 2020](#); [Chamberlain, 2020](#)).

A nivel global, para la década de los años 80's los manglares ocupaban 18.1×10^6 ha en el mundo ([Spalding et al., 1997](#)); sin embargo, para el año 2010 la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) reportó aproximadamente 15.6×10^6 ha ([FAO, 2010](#)). Un estudio más reciente identificó un decremento en la extensión mundial de manglares a 13.931×10^6 ha en 2014 ([Hamilton y Casey, 2016](#)). Por su parte, en México, existe gran variación en las estimaciones de la extensión de los manglares ([Ruiz-Luna et al., 2008](#)). [Palacio-Prieto et al. \(2000\)](#) reportaron a través del Inventario Nacional Forestal 942,047 ha. [Flores-Mejía \(2010\)](#) reportó que para el año 2000 la cobertura de manglar era de 880,000 ha. [Rodríguez-Zúñiga \(2013\)](#) reportó que en el 2005 México contaba

con 774,090 ha de manglar. Esta cifra varía en 0.5% con relación a la primera de 770,057 ha para ese mismo año reportada por la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO, 2009). Por su parte, Valderrama-Landeros (2017) reportó que el área total de manglares era de 764,774 ha para 2010 y documenta una ligera recuperación de este ecosistema a nivel nacional con 775,555 ha para el 2015. Finalmente, CONABIO (2021) reportó que para el año 2020 México contaba con un total de 905,086 ha, este importante incremento lo atribuyen a la modernidad de los sensores satelitales que adicionó áreas de manglares que anteriormente no se habían considerado. Es notorio que las cifras sobre extensión de manglares son inconstantes debido a las diferencias metodológicas y discrepancias en la estandarización de técnicas de análisis, además, muchas de las estimaciones carecen de un adecuado sustento técnico para su validez (Berlanga-Robles et al. 2007; Ruiz-Luna et al., 2008; CONABIO, 2021).

Dicho lo anterior y a pesar de que los inventarios forestales en campo son críticos para la calibración y validación de estimaciones de estructura forestal basadas en percepción remota (PR), estos suelen ser costosos y consumen tiempo y recursos en demasía (White et al., 2016; Pham, 2019). Por lo tanto y considerando que los manglares cubren grandes áreas a menudo inaccesibles para la investigación de campo, se dificulta capturar la heterogeneidad de la estructura forestal en todo el paisaje. En este sentido, la PR se perfila como una herramienta para obtener datos sinópticos de grandes áreas geográficas de manera uniforme en el tiempo y el espacio (Hernández-Guzmán et al., 2019a). Además de permitir el análisis de una región con la precisión suficiente de una manera eficiente, rápida y de bajo costo (Berlanga-Robles y Ruiz-Luna., 2002; Alonso-Pérez et al., 2003; Pham, 2019).

El presente trabajo es un aporte de continuidad a las investigaciones que se han realizado en la Reserva de la Biosfera Marismas Nacionales, Nayarit (Berlanga-Robles y Ruiz-Luna, 2002; Berlanga-Robles et al., 2019; Valderrama-Landeros et al., 2020). Se utilizaron imágenes adquiridas por sensores remotos, mismas que fueron analizadas dentro de un Sistema de Información Geográfica con el objetivo de realizar un análisis reciente de la extensión de la cobertura de manglar estimando sus tasas anuales de conversión, valores de pérdida, ganancia y cambio neto actualizando la información hasta el 2019.

Zona de estudio

La zona de estudio corresponde a la Reserva de la Biosfera Marismas Nacionales (RBMN), un gran complejo estuarino (~134,000 ha) ubicado en la costa noroeste del Pacífico mexicano en la llanura aluvial del estado de Nayarit entre los 21° 44' y 22° 35' de latitud Norte y 105° 18' y 105° 45' de longitud Oeste ([Figura 2.1](#)). La RBMN abarca el humedal más extenso del Pacífico mexicano, que representa el 8% de la extensión nacional de manglares ([CONANP, 2013](#); [Valderrama-Landeros et al., 2017](#); [CONABIO, 2021](#)). El sistema es alimentado por varios afluentes entre los que destacan los ríos San Pedro y Acajoneta, lo cuales descargan grandes cantidades de agua dulce y sedimentos ricos en nutrientes de las cuencas circundantes ([Hernández-Guzmán et al., 2019b](#)). El área se encuentra principalmente caracterizada por un clima cálido sub-húmedo con una temperatura media anual que varía en los 22 y 26 °C. La época de secas se presenta desde diciembre a junio, con una precipitación entre 928 y 1,457 mm durante el verano. Cerca del 80% de la precipitación anual cae de julio a octubre (temporada de lluvias) ([Zhang et al., 2014](#); [Hernández-Guzmán et al., 2019b](#)).




Figura 2.1 Ubicación geográfica de la Reserva de la Biosfera Marismas Nacionales, Nayarit.

Metodología

El análisis de los cambios en la cobertura de manglar para el periodo 1990-2019 se realizó a partir de mapas temáticos obtenidos mediante la clasificación de imágenes de satélite de mediana resolución (30 m de tamaño del pixel).

Análisis de imágenes multiespectrales

Para cubrir el área de estudio se utilizaron imágenes Landsat de los sensores Thematic Mapper (TM) y Operational Land Imager (OLI) de los path-rows (incluir sistema o sistemas): 31-44 y 31-45, para 1990, 2000, 2009 y 2019. Todas las escenas Landsat se registraron entre abril y mayo durante la temporada seca dada su calidad y disponibilidad libre de nubes. Todas las escenas fueron descargadas de la plataforma Global Visualization Viewer (GloVis) del Servicio Geológico de Estados Unidos (USGS por sus siglas en inglés).

Para el análisis de las imágenes se empleó una técnica de clasificación híbrida que combinó los métodos de clasificación supervisados y no supervisados. Primeramente, el área de estudio fue aislada de todas las escenas mediante un proceso de enmascaramiento producido por la rasterización del archivo vectorial del ANP Marismas Nacionales Nayarit (CONANP, 2012). Para ambos sensores (TM y OLI) se descartaron las bandas adquiridas en la porción del infrarrojo térmico. Para la fecha que incluyó al sensor OLI, adicionalmente se descartaron las bandas B1 ‘costera’ y B9 ‘cirrus’.

Para la clasificación supervisada, se realizó un procedimiento de segmentación de píxeles, el cual agrupa los píxeles adyacentes en segmentos de la imagen según su similitud espectral (Berlanga-Robles y Ruiz-Luna, 2007). La segmentación emplea un enfoque de delineación de cuencas hidrográficas para las imágenes de entrada particionado en función de su variación. La imagen de varianza derivada de este proceso se trata como una imagen de superficie que asigna píxeles a segmentos particulares en función de la similitud de la varianza (Eastman, 2016). Utilizando el vector de segmentación generado en el paso anterior, se seleccionaron campos de entrenamiento y se creó un archivo de firmas espectrales, mismo que fue utilizado dentro de una red neuronal utilizando el algoritmo de Multi-Layer Perceptron (MLP) para producir la clasificación de manglar. Posteriormente, las clases espectrales detectadas como cobertura de manglar, fueron agrupadas en una sola clase para producir imágenes binarias, asignando el valor de 1 a los píxeles identificados como manglar

y de 0 al resto de la imagen. Finalmente, esta imagen booleana fue utilizada como máscara dentro de una clasificación no-supervisada con el algoritmo K-means para separar condiciones de la cobertura de manglar con base en su respuesta espectral detectada en pasos previos (Manglar en buen estado de conservación y manglar muerto) así como para excluir aquellos pixeles que, identificados como manglar en el MLP, realmente no pertenecían a manglar si no a diferentes coberturas como campos agrícolas, áreas de acuicultura y otros tipos de vegetación como el bosque seco caducifolio y el palmar.

Validación de la exactitud

Para la validación del mapa temático más reciente, se colectaron datos en campo con ayuda de un GPS Garmin Montana 680. Durante los años 2019 y 2020, se hicieron recorridos por las rutas con posibilidad de acceso como carreteras y caminos y a bordo de una embarcación menor sobre canales entre el manglar. Con los puntos colectados se construyó una matriz de error, a partir de la cual se estimaron indicadores generales de la exactitud de la clasificación como la exactitud global, las exactitudes de usuario (EU) y de productor (EP) (Congalton y Green, 2019). La clasificación fue aceptada hasta que la exactitud global estuvo por arriba del 80%.

Una vez evaluada la exactitud, se describió la distribución espacial de la cobertura de mangle y se evaluaron las cifras finales sobre la extensión del manglar con notas sobre las tendencias temporales del cambio en la extensión y la condición del manglar.

Análisis de detección de cambio

Aunque existen varios procedimientos para el análisis de cambio, se decidió que la detección de cambio entre escenas se realizaría mediante un análisis postclasificadorio (Pontius et al., 2001; 2004), analizando los cambios para los periodos 1990-2000, 2000-2009, 2009-2019, así como la tabulación cruzada para para todo el periodo (1990-2019) con la finalidad de conocer las zonas en las que se está ganando o perdiendo cobertura de manglar.

Determinación de la tasa de pérdida

La tasa anual de cambio de la cobertura forestal (tac), se calculó mediante la metodología propuesta por la FAO (FAO, 1995; Puyravaud, 2003). La fórmula empleada fue:

$$tac = \left(\frac{A_2}{A_1}\right)^{\frac{1}{(t_2-t_1)}} - 1$$

Donde: tac es porcentaje anual del cambio de la cobertura del bosque; A₁ y A₂ son las superficies en ha para el tiempo T₁ y T₂, respectivamente.

Resultados

Extensión de manglar

El mapa temático más reciente alcanzó una exactitud global de 88% basado en 460 puntos colectados con la ayuda de una unidad GPS (Tabla 2.1). Para ambas coberturas, tanto la exactitud de usuario (EU) como de productor (EP) fue ≥ 80%.

Tabla 2.1. Evaluación de exactitud para la clasificación de manglares en la RNMN basada en imágenes Landsat, puntos de control colectados en 2019 y 2020.

	<i>Coberturas</i>	<i>Datos de Referencia</i>			
		<i>Manglar</i>	<i>No Manglar</i>	<i>Total</i>	<i>EU</i>
Clasificación	<i>Manglar</i>	269	34	303	89%
	<i>No manglar</i>	21	136	157	87%
	<i>Total</i>	290	170	Exactitud Global	
	EP	93%	80%	88%	

La distribución espacial de la cobertura de manglar se puede apreciar en la Figura 2.2, mientras que la extensión de cada una de las diferentes condiciones de esta cobertura se aprecia en la Tabla 2.2 Se pudo diferenciar el manglar en buen estado de conservación de aquel que tiene cierto grado de deterioro para una crono-secuencia de imágenes Landsat para las fechas 1990, 2000, 2009 y 2019 (Figura 2.2). De aproximadamente 58,642 ha encontradas para 1990, sólo 55,107 ha se encontraron en 2019. Una tendencia inversa se observó con el manglar muerto, incrementado de 3,109 ha en 1990 a 5,460 ha en 2019 (Tabla 2.2).

Tabla 2.2 Cobertura (en hectáreas y porcentaje) de las diferentes condiciones de manglar para las fechas analizadas, obtenidas mediante el procesamiento de imágenes de satélite Landsat.

<i>Cobertura</i>	<i>1990</i>		<i>2000</i>		<i>2009</i>		<i>2019</i>	
	ha	%	ha	%	ha	%	ha	%
<i>Conservado</i>	58642	94.97	56426	93.39	54741	88.51	55107	90.9
<i>Muerto</i>	3109	5.03	3996	6.61	7105	11.49	5460	9.1
<i>Total</i>	61751		60422		61846		60567	

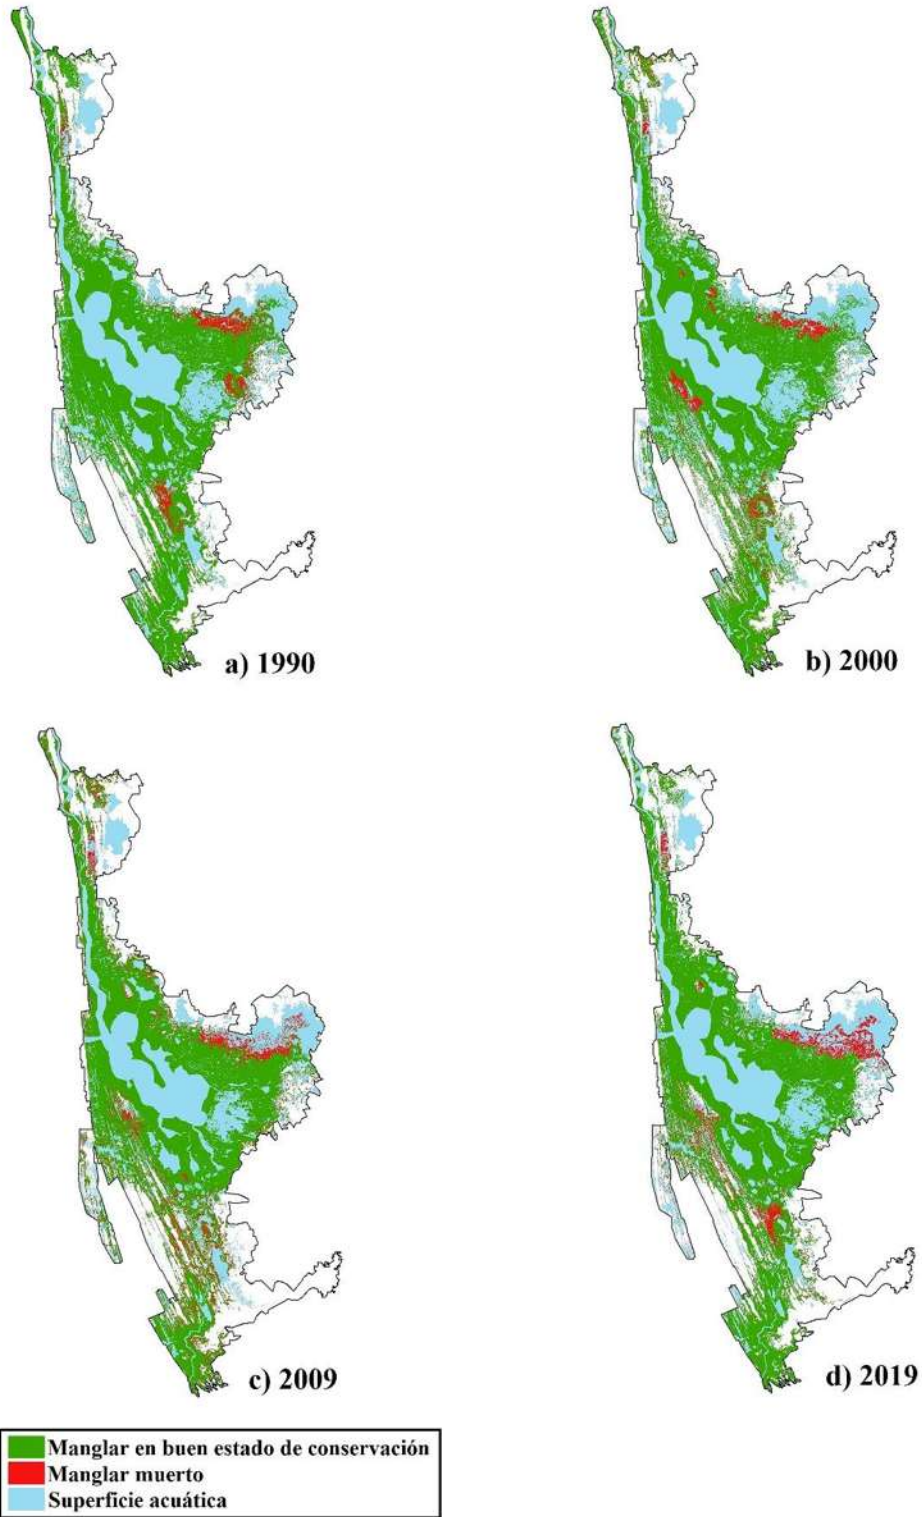


Figura 2.2 Caracterización de manglar en buen estado de conservación (verde) y muerto (rojo) en una crono-secuencia de imágenes Landsat a 30 m de resolución espacial.

El manglar conservado se encontró a las orillas de los esteros y lagunas, generalmente en zonas de accesibilidad limitada y lejana de asentamientos urbanos. El manglar muerto se detectó en mayor proporción en la zona este de la reserva conocida como Pescadero y en la zona más norteña del área de estudio conocida como Arenitas (~ 5,000 ha), así como en zonas aledañas a carreteras y poblados. Hacia la parte sur de Pescadero se encontraron un área extensa de granjas camaronícolas, bordeando lo que aparentemente son zonas de recuperación de manglar (~ 1,000 ha). En la parte sur de la zona de estudio (Camichín y Toro Mocho) no se observó pérdida de manglar.

Análisis de detección de cambio

Durante los recorridos en campo se ubicaron los principales cambios en la zona de Pescadero (Figura 2.3). Aquí, el manglar muerto se redujo a pequeños manchones y árboles aislados. En menor medida se encontraron las zonas al norte de la laguna de Mexcaltitán donde también se registró una porción importante de manglar muerto, además de zonas donde en fechas previas se registró la presencia de manglar, actualmente son zonas desprovistas de vegetación. El análisis mostró una ligera recuperación de manglar mediante la metodología de sobre lapo de imágenes en las zonas al este de la RBMN bordeadas por zonas de intensa actividad acuícola, dedicada al cultivo de camarón.

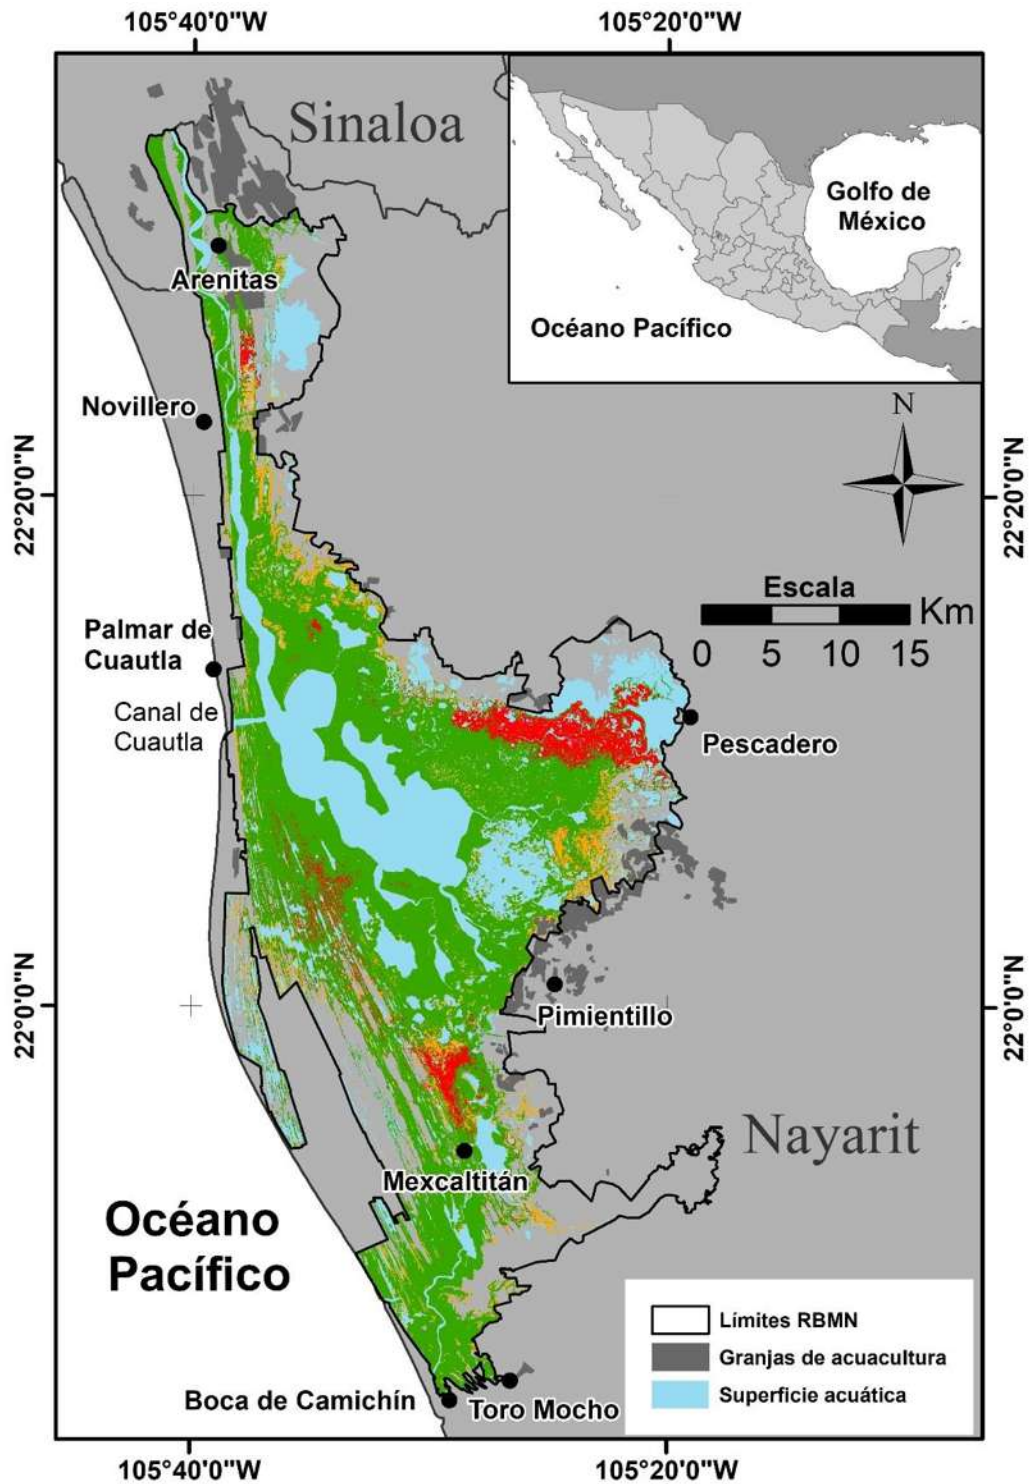


Figura 2.3. Detección de cambio mediante un traslape de caracterizaciones de 1990 y 2019, que mostraron zonas que se mantuvieron sin cambios (verde), zonas con pérdida de cobertura de manglar (rojo), zona de recuperación de cobertura de manglar (naranja).

No fue posible visitar las zonas donde se reportó recuperación de manglar debido a que en su mayoría está delimitada como propiedad privada, dedicada a granjas camaronícolas. Lo anterior se pudo verificar mediante la interpretación visual de imágenes de alta resolución disponibles en Google Earth. El cálculo de la tasa de cambio anual para cada uno de los periodos analizados reveló que las principales pérdidas de cobertura de manglar conservado ocurrieron entre 1990 y 2009. Para el periodo de tiempo comprendido entre 2009 y 2019 se registró una tasa de cambio positiva lo que indica una ligera recuperación de cobertura de manglar (Tabla 2.3). El análisis post-clasificadorio registró la permanencia o cambio entre las diferentes condiciones de manglar (manglar conservado, manglar muerto y otra cobertura) de los periodos analizados. Visiblemente se pudo apreciar una tendencia de pérdida de la cobertura de manglar en buen estado de conservación entre 1990 y 2009. Sin embargo, demostró un leve aumento en esta cobertura para el año 2019 lo que indica una recuperación de la cubierta forestal (Tabla 2.4).

Tabla 2.3. Cobertura en hectáreas de manglar perdidas (o ganadas) y tasa de cambio anual (%) para cada periodo analizado.

Condición	Cambio (ha)				Tasa de cambio anual (%)			
	90-00	00-09	09-19	90-19	90-00	00-09	09-19	90-19
<i>Conservado</i>	-2216	-1685	366	-3535	-0.39	-0.34	0.07	-0.21
<i>Muerto</i>	887	3109	-1645	2351	2.51	6.39	-2.63	1.94

Tabla 2.4. Matrices de tabulación cruzada (en hectáreas) de los mapas temáticos entre los diferentes periodos. A) 1990 - 2000; B) 2000 - 2009; C) 2009 - 2019; D) 1990 – 2019. MN – manglar; MND – manglar muerto; OC – otra cobertura.

A) 1990

	Categoría	MN	MND	OC	Total
2000	MN	49300	1420	5706	56426
	MND	2812	822	362	3996
	OC	6530	867	65322	72720
	Total	58642	3109	71390	

B) 2000

	Categoría	MN	MND	OC	Total
2009	MN	46703	1235	6803	54741
	MND	3703	1184	2218	7105
	OC	6020	1577	63699	71296
	Total	56426	3996	72720	

C) 2009

	Categoría	MN	MND	OC	Total
2019	MN	46794	3737	4577	55107
	MND	2149	1332	1979	5460
	OC	5798	2036	64742	72576
	Total	54741	7105	71297	

D) 1990

	Categoría	MN	MND	OC	Total
2019	MN	48282	1081	5744	55107
	MND	3784	807	869	5460
	OC	6576	1222	64778	72576
	Total	58642	3109	71390	

Discusión

Los inventarios confiables que describen la cantidad y calidad de los recursos naturales son esenciales para ejecutar programas para su conservación y manejo (White et al., 2016). Sin embargo, evaluaciones pasadas realizadas en manglares para México han resultado cuestionables llevando a una gran variación en las estimaciones de la extensión de manglar (Berlanga-Robles y Ruiz-Luna 2007; Ruiz-Luna et al., 2010). Para reducir el error de estimación, estos inventarios deben basarse en técnicas de diseño de muestreo que utilicen métodos estadísticos para obtener evaluaciones con intervalos de confianza confiables (Ruiz-Luna et al., 2010).

A partir de las diferentes estimaciones de la cobertura de manglar en las últimas décadas, se pudo detectar una marcada tendencia hacia la pérdida de cobertura de manglar hasta 2005 (Anexo 2.1), que fue de la mano con la creación de canales, caminos y carreteras que alteraron los flujos hidrológicos naturales, así como el aumento de la acuicultura en la RBMN (Lithgow et al., 2019). Esta tendencia de aumento a un ritmo constante en la acuicultura desde 1997 hasta 2005 ya ha sido reportada por Lithgow et al. (2019). Sin embargo, Valderrama-Landeros et al. (2017) reportó recuperación de esta cobertura forestal a partir de 2010. Esta tendencia también es observada en los resultados obtenidos, donde algunas zonas mostraron recuperación de manglar en coexistencia con las granjas camaronícolas. A pesar de que la tendencia de pérdida nos indica la acelerada perturbación a este ecosistema producto del cambio de uso de suelo y la extracción y remoción de mangle por actividades antrópicas (Lithgow et al., 2019), parece ser que la implementación de programas de protección al ecosistema está mostrando resultados positivos al registrarse una recuperación (~1,090 ha) en la parte más sureña de la zona de estudio (Toromocho y Boca de Camichín).

Un estudio realizado por la CONABIO reportó un área de 77,448 ha para la zona Teacapán-Agua Brava en 2005 (Acosta-Velázquez y Zúñiga, 2007) y un estudio subsecuente de Berlanga Robles y Ruiz-Luna (2007) estimaron aproximadamente 66,500 ha para el 2006. Estas cifras son ligeramente superiores de las encontradas en este estudio ya que para el año 2009, se obtuvo un área de 61,846 ha de cobertura de manglar.

Ruiz-Luna et al. (2010) reportaron una disminución de aproximadamente el 2% del área total durante las últimas décadas para todo el Noroeste de México. Los resultados del

presente trabajo indicaron una disminución del 6% de la cobertura de manglar (de 58,642 a 55,107 ha de 1990 a 2019). Las tasas de cambio anual han disminuido de -0.38% a 0.07%. Esta tasa positiva para el último periodo implica un incremento de esta cobertura, lo que puede estar asociado a los esfuerzos de conservación bajo los programas de Pago por Servicios Ambientales (PSAs), ya que de acuerdo con SEMARNAT (2012), Nayarit cuenta con 66,000 ha de manglares cubiertas bajo en un esquema de PSAs.

Para de realizar una identificación de extensión de manglares, es necesario comparar los resultados de grupos de investigación independientes que trabajan con el mismo conjunto de datos y así tener una reducción de la incertidumbre. Por lo tanto, la comparación de dichos resultados permitirá la reducción de las discrepancias y la producción de cifras confiables (Ruiz-Luna et al., 2008). Los resultados de este trabajo son comparables con los obtenidos por otros autores (Anexo 2.1) y dan continuidad a las estimaciones de manglar en la RBMN.

La causa de este decremento en la cobertura de manglar está dada principalmente por las intensas modificaciones en los patrones hidrológicos, como canalizaciones, la apertura del Canal de Cuautla, cambios en la magnitud de los escurrimientos y áreas de inundación lo que ha cambiado las concentraciones típicas de la salinidad en la zona y esto resulta nocivo para esa vegetación y su zonación original (Ruiz-Luna, et al., 2008; Flores-Verdugo 2010). Kovacs et al. (2001) mencionó que la mortalidad a gran escala y cualquier asociación con posibles causas antrópicas sería extremadamente especulativa. Se sabe que ciertos fenómenos como los huracanes pueden generar cambios a gran escala en los manglares y contribuir a un extenso daño mecánico. Algunos autores mencionaron también que si bien la acuicultura fue un factor determinante para la pérdida de cobertura de manglar (Molina et al., 2018; Lithgow et al., 2019), con la actualización de las normas oficiales de protección ambiental (NOM-022-SEMARNAT-2003; NOM-059-SEMARNAT-2010) y la reducción del establecimiento de granjas de acuicultura directamente sobre cobertura forestal desde 2005, algunos de estos manglares han sido capaces de estabilizar y recuperar su cobertura (Berlanga-Robles et al., 2011; Lithgow et al., 2019).

En el presente trabajo, la zona más afectada es la región conocida como “Pescadero”, al mostrar un severo deterioro tanto en los análisis por imágenes satelitales como en la validación directa en campo. Esta misma tendencia es descrita por Kovacs et al. (2001), quienes calcularon que esto ocurrió en la década de los 70s y 80s. Sin embargo, Ruiz-Luna

et al. (2010) mencionaron que los sistemas de manglares en el noroeste de México no están todos bajo las mismas condiciones de estrés o deforestación. Durante los recorridos en lancha dentro de la laguna de Agua Brava se observó el difícil acceso a dichas zonas, el cual se restringe a pescadores y un número muy limitado de turistas y observadores de aves. Lo anterior, tiene como efecto que estas zonas tengan manglar mejor conservado.

La falta de conocimiento en estas áreas ha llevado a cometer errores afectando al sistema. De acuerdo con Herrera-Romero (2015), el caso más relevante de este ecosistema es el canal de Cuautla que provocó erosión en gran parte del sistema costero debido al impacto que causan las olas provenientes del mar; además, deposita sales directas del mar y provoca la muerte de vegetación por hipersalinidad.

Otros estudios hacen ver la importancia de las metodologías estandarizadas y con procedimientos confiables por lo que es necesario realizar evaluaciones que arrojen información sobre la condición actual y las tendencias de cambio de los bosques de mangle y otros humedales. A pesar de la atención prestada en años recientes a estos ecosistemas, aún se encuentran bajo una fuerte presión (Camacho-Valdez, 2013).

Aunado a lo anteriormente mencionado, los manglares juegan un papel vital en la existencia de la biodiversidad local y global además de proporcionar una gama de diferentes servicios ecosistémicos y económicos a las poblaciones costeras (Pham et al., 2019). En un marco de transferencia de valores para realizar un análisis de costo-beneficio, el valor económico de los manglares mundiales varía aproximadamente de US \$ 475 a \$ 11,675 por ha por año, y reducen anualmente el daño a la propiedad en más de US \$ 65 mil millones de manera global y protegen a más de 15 millones de personas según el enfoque de valoración y las condiciones del mercado (Giri, 2016; Menéndez, 2020). Hermon et al. (2018) y Miyajima et al. (2015) advirtieron que con la disminución de los manglares en la zona costera también reducirá la capacidad de absorción de carbono por estos ecosistemas, el cual se estima entre 25 y 42 mil millones de toneladas de CO₂ (Nellemann et al., 2009; Polidoro et al., 2010). Por lo tanto, la conservación y rehabilitación de los ecosistemas de manglares son necesarios para mantener la absorción y el almacenamiento del carbono. Sin embargo, con la reciente transformación de manglares leñosos en marismas y la probabilidad de que estos cambios tengan grandes impactos en la estructura, función y provisión de servicios de los humedales costeros; existe una gran incertidumbre con respecto a la dirección y magnitud de

estos cambios (Kelleway et al., 2017). Whitt et al. (2020) encontraron que las transiciones del ecotono de manglar a marisma en el hemisferio sur podrían deberse a interacciones complejas entre el calentamiento global y los procesos geomórficos locales. Se ha documentado que al igual que los manglares, las marismas proporcionan numerosos e importantes servicios ecosistémicos, incluida la protección de la costa, el ciclo del carbono y los nutrientes y es un hábitat esencial para muchas especies (Camacho-Valdez et al., 2013; 2014). Si bien el reemplazo de los manglares por marismas desprovistas de vegetación puede influir en la estructura de la comunidad de fauna, no se tiene aún evidencia de que estos impactos aumenten o disminuyan la producción pesquera (Meynecke et al., 2007; Kelleway et al., 2016). Es probable que la pérdida del hábitat de marismas tenga un impacto negativo en ciertas especies amenazadas, especialmente para varias aves migratorias, pero estos impactos serán específicos del sitio (Kelleway et al., 2016; Molina et al., 2018). Kelleway et al. (2017) encontraron evidencias de que la expansión de los manglares puede aumentar el potencial de acumulación de carbono a largo plazo. En general, existe un mayor potencial para el almacenamiento de C en la biomasa aérea de la vegetación de manglares leñosos, en comparación con la marisma herbácea (Murray et al., 2011; Kelleway et al. 2017). Este enfoque más informado permitirá cambiar las prioridades y mejorar las medidas y políticas de conservación de manglares teniendo en cuenta el valor económico y ambiental de las contribuciones de los humedales a la supervivencia humana y al bienestar con la finalidad de sustentar mejores planes de manejo y conservación de estos ambientes (Berlanga-Robles y Ruiz-Luna, 2007; Camacho-Valdez, 2014).

Conclusiones

Se realizó con éxito una caracterización reciente de la cobertura de manglares del área de la RBMN que alcanza una exactitud del 88% para el 2019 pudiendo diferenciar manglar en buen estado del manglar muerto. De manera general, el manglar de la RBMN mostró una tendencia hacia la pérdida en el periodo analizado (1990-2019). Se identificó como el principal factor de pérdida de cobertura de manglar al cambio de los patrones hidrológicos naturales. Las zonas más afectadas por las alteraciones resultaron Pescadero y Arenitas.

En términos generales, el área de manglar continúa disminuyendo. Sin embargo, hay indicios de recuperación en algunas zonas de manglar y esto puede estar relacionado a los diferentes programas de Pagos por Servicios Ambientales (PSAs) que existen en la zona.

Referencias

- Acosta-Velázquez, J., & Zúñiga, M. R. 2007. Los manglares de México: estado actual y establecimiento de un programa de monitoreo a largo plazo: 1ra. Etapa. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad, México D. F.
- Adame, M. F., Reef, R., Santini, N. S., Najera, E., Turschwell, M. P., Hayes, M. A., Masque, P., & Lovelock, C. E. 2020. Mangroves in arid regions: Ecology, threats, and opportunities. *Estuarine, Coastal and Shelf Science*, 106796. Doi: 10.1016/j.ecss.2020.106796
- Alatorre, L. C., Sánchez-Andrés, R., Cirujano, S., Beguería, S., & Sánchez-Carrillo, S. 2011. Identification of mangrove areas by remote sensing: The ROC curve technique applied to the northwestern Mexico coastal zone using Landsat imagery. *Remote Sensing*, 3(8), 1568-1583. Doi: 10.3390/rs3081568
- Alonso-Pérez, F., Ruiz-Luna, A., Turner, J., Berlanga-Robles, C. A., & Mitchelson-Jacob, G. 2003. Land cover changes and impact of shrimp aquaculture on the landscape in the Ceuta coastal lagoon system, Sinaloa, Mexico. *Ocean & Coastal Management*, 46(6-7), 583-600. Doi: 10.1016/S0964-5691(03)00036-X
- Berlanga-Robles, C. A., & Ruiz-Luna, A. 2002. Land use mapping and change detection in the coastal zone of northwest Mexico using remote sensing techniques. *Journal of Coastal Research*, 514-522
- Berlanga-Robles, C. A., & Ruiz-Luna, A. 2007. Análisis de las tendencias de cambio del bosque de mangle del sistema lagunar Teacapán-Agua Brava, México. Una aproximación con el uso de imágenes de satélite Landsat. *Universidad y Ciencia*, 23(1), 29-46.
- Berlanga-Robles, C. A., Ruiz-Luna, A., Bocco, G., & Vekerdy, Z. 2011. Spatial analysis of the impact of shrimp culture on the coastal wetlands on the Northern coast of Sinaloa, Mexico. *Ocean & Coastal Management*, 54(7), 535-543. Doi: 10.1016/j.ocecoaman.2011.04.004

- Camacho-Valdez, V., Ruiz-Luna, A., Ghermandi, A., & Nunes, P. A. 2013. Valuation of ecosystem services provided by coastal wetlands in northwest México. *Ocean & Coastal Management*, 78, 1-11. Doi: 10.1016/j.ocecoaman.2013.02.017
- Camacho-Valdez, V., Ruiz-Luna, A., Ghermandi, A., Berlanga-Robles, C. A., & Nunes, P. A. 2014. Effects of land use changes on the ecosystem service values of coastal wetlands. *Environmental Management*, 54(4), 852-864. Doi: 10.1007/s00267-014-0332-9
- Chamberlain, D., Phinn, S., & Possingham, H. 2020. Remote sensing of mangroves and estuarine communities in central Queensland, Australia. *Remote Sensing*, 12(1), 197. Doi: 10.3390/rs12010197
- CONANP (Comisión Nacional de Áreas Naturales Protegidas). 2012. Catálogo de metadatos geográficos. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. Ciudad de México, México. Disponible en: http://www.conabio.gob.mx/informacion/metadatos/gis/anp_agosto12gw.xml?_httpcache=yes&_xsl=/db/metadatos/xsl/fgdc_html.xsl&_indent=no
- CONANP (Comisión Nacional de Áreas Naturales Protegidas). 2013. Programa de manejo Reserva de la Biosfera Marismas Nacionales Nayarit, CONANP, Ciudad de México, México, p. 199p.
- CONABIO (Comisión Nacional para el Conocimiento y Uso de la Biodiversidad). 2009. Manglares de México: Extensión y distribución. 2ª ed. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. México. 99.
- CONABIO [Comisión Nacional para el Conocimiento y Uso de la Biodiversidad]. 2021. Geoportal del Sistema Nacional de Información sobre Biodiversidad. CONABIO. Available at: http://geoportal.conabio.gob.mx/#!l=mx_man20gw:1@m=mixto
- Congalton, R. G., & Green, K. 2019. Assessing the accuracy of remotely sensed data: principles and practices. CRC press.
- Eastman, J.R. 2016. IDRISI Terrset Manual. Clark Labs-Clark University: Worcester, MA, USA.
- FAO (Food and Agriculture Organization of the United Nations). 1995. Forest resources assessment 1990: Global Synthesis. *FAO forestry Paper*, 124, 1-44.

- FAO (Food and Agriculture Organization of the United Nations). 2010. State of world fisheries and aquaculture. Rome, Italy. FAO Fisheries and Aquaculture Department. 197 p.
- Flores-Mejía, M. F., Vallejo, A. A., Hernández, M. F., & Govea, X. G. 2010. El impacto que produce el sector turismo en los manglares de las costas mexicanas. *Contactos*, 77, 33-38
- Flores-Verdugo, F., & Pulido, S. H. 2010. Vulnerabilidad costera: caso de estudio Del sistema de humedales Marismas Nacionales. *Cambio Climático en México*, 205
- Giri, C. 2016. Observation and monitoring of mangrove forests using remote sensing: opportunities and challenges. *Remote Sensing*, 8, 783. Doi: 10.3390/rs8090783
- Hamilton, S. E., & Casey, D. 2016. Creation of a high spatio-temporal resolution global database of continuous mangrove forest cover for the 21st century (CGMFC-21). *Global Ecology and Biogeography*, 25(6), 729-738. Doi: 10.1111/geb.12449
- Hermon, D., Ganefri, P. A., & Oktorie, O. 2018. The model of mangrove land cover change for the estimation of blue carbon stock change in Belitung Island-Indonesia. *International Journal of Applied Environmental Sciences*, 13(2), 191-202
- Hernández-Guzmán R., Ruiz-Luna A. González C. 2019a. Assessing and modeling the impact of land use and changes in land cover related to carbon storage in a western basin in Mexico. *Remote Sensing Applications: Society and Environment*, 13, 318-327. Doi: 10.1016/j.rsase.2018.12.005
- Hernández-Guzmán R., Ruiz-Luna A., Cervantes-Escobar A. 2019b. Environmental flow assessment for rivers feeding a coastal wetland complex in the Pacific coast of northwest Mexico. *Water and Environment Journal*, 33(4), 536-546. Doi: 10.1111/wej.12423
- Herrera-Romero, J. A. 2015. Salinidad de suelos y vegetación asociada a marismas de Nayarit, México. Tesis de maestría. Universidad Autónoma de Nayarit, México. Disponible en línea en: <http://dspace.uan.mx:8080/jspui/handle/123456789/1616>
- Kelleway, J. J., Saintilan, N., Macreadie, P. I., Skilbeck, C. G., Zawadzki, A., & Ralph, P. J. 2016. Seventy years of continuous encroachment substantially increases ‘blue carbon’ capacity as mangroves replace intertidal saltmarshes. *Global Change Biology*, 22, 1097–1109. Doi: 10.1111/gcb.13158

- Kelleway, J. J., Cavanaugh, K., Rogers, K., Feller, I. C., Ens, E., Doughty, C., & Saintilan, N. 2017. Review of the ecosystem service implications of mangrove encroachment into salt marshes. *Global Change Biology*, 23(10), 3967-3983. Doi: 10.1111/gcb.13727
- Kovacs, J. M., Wang, J., & Blanco-Correa, M. 2001. Mapping disturbances in a mangrove forest using multi-date Landsat TM imagery. *Environmental Management*, 27(5), 763-776. Doi: 10.1007/s002670010186
- Lithgow, D., de la Lanza, G. & Silva, R. 2019. Ecosystem-Based management strategies to improve aquaculture in developing countries: Case study of Marismas Nacionales. *Ecological Engineering*, 130, 296-305. Doi: 10.1016/j.ecoleng.2017.06.039
- Menéndez, P., Losada, I. J., Torres-Ortega, S., Narayan, S., & Beck, M. W. 2020. The global flood protection benefits of mangroves. *Scientific Reports*, 10, 4404. Doi: 10.1038/s41598-020-61136-6
- Meynecke, J.-O., Lee, S. Y., Duke, N. C., & Warnken, J. 2007. Relationships between estuarine habitats and coastal fisheries in Queensland, Australia. *Bulletin of Marine Science*, 80, 773–793
- Miyajima, T., Hori, M., Hamaguchi, M., Shimabukuro, H., Adachi, H., Yamano, H. & Nakaoka, M. 2015. Geographic variability in organic carbon stock and accumulation rate in sediments of east and southeast Asian seagrass meadows. *Global Biogeochemical Cycles*, 29, 397–415. Doi: 10.1002/2014GB004979
- Molina, D., Cavitt, J., Carmona, R., & Cruz-Nieto, M. 2018. Non-breeding distribution, density and population structure of American Avocet (*Recurvirostra americana*, Gmelin 1789) in Marismas Nacionales, Nayarit, Mexico. *HUITZIL: Journal of Mexican Ornithology*, 19(1)
- Murray, B. C., Pendleton, L., Jenkins, W. A., & Sifleet, S. 2011. Green payments for blue carbon: Economic incentives for protecting threatened coastal habitats. Nicholas Institute for Environmental Policy Solutions, Report NI, 11
- Nellemann, C., Corcoran, E., Duarte, C. M., Valdés, L., De Young, C., Fonseca, L., Grimsditch, G. 2009. Blue carbon. A rapid response assessment. *United Nations Environment Programme*, GRID-Arendal, www.grida.no

- NOM-022-SEMARNAT-2003. 2003. Norma Oficial Mexicana. Que establece las especificaciones para la preservación, conservación, aprovechamiento sustentable y restauración de los humedales costeros en zonas de manglar. Diario Oficial de la Federación.
- NOM-059-SEMARNAT-2010. 2010. Norma Oficial Mexicana. Protección ambiental-Especies nativas de México de flora y fauna silvestres-Categorías de riesgo y especificaciones para su inclusión, exclusión o cambio-Lista de especies en riesgo. Diario Oficial de la Federación.
- Pham, T. D., Yokoya, N., Bui, D. T., Yoshino, K., & Friess, D. A. 2019. Remote sensing approaches for monitoring mangrove species, structure, and biomass: Opportunities and challenges. *Remote Sensing*, 11(3), 230. Doi: 10.3390/rs11030230
- Polidoro, B. A., Carpenter, K. E., Collins, L., Duke, N. C., Ellison, A. M., Ellison, J. C., Farnsworth, E.J., Fernando, E.S., Kathiresan, K., Koedam, N.E., Livingstone, S.R., Miyagi, T., Moore, G.E., Nam, V.N., Ong, J.E., Primavera, J.H., Salmo III, S.G., Sanciangco, J.C., Sukardjo, S., Wang, Y., & Hong Yong, J. W. 2010. The loss of species: mangrove extinction risk and geographic areas of global concern. *PloS one*, 5(4), e10095. Doi: 10.1371/journal.pone.0010095
- Pontius Jr, R. G., Cornell, J. D., & Hall, C. A. 2001. Modeling the spatial pattern of land-use change with GEOMOD2: application and validation for Costa Rica. *Agriculture, Ecosystems & Environment*, 85(1-3), 191-203. Doi: 10.1016/S0167-8809(01)00183-9
- Pontius Jr., R. G., Shusas, E., & McEachern M. 2004. Detecting important categorical land changes while accounting for persistence. *Agriculture, Ecosystems and Environment*, 101, 251–268 Doi: 10.1016/j.agee.2003.09.008
- Palacio-Prieto, J. L., Bocco, G., Velázquez, A., Mas, J. F., Takaki-Takaki, F., Victoria, A., & Trejo-Vázquez, I. 2000. La condición actual de los recursos forestales en México: resultados Del Inventario Forestal Nacional 2000. *Investigaciones Geográficas*, (43), 183-203
- Puyravaud, J. P. 2003. Standardizing the calculation of the annual rate of deforestation. *Forest Ecology and Management*, 177(1-3), 593-596. Doi: 10.1016/S0378-1127(02)00335-3

- Rodríguez-Zúñiga, M.T., Troche-Souza C., Vázquez-Lule, A.D., Márquez-Mendoza, J. D., Vázquez-Balderas, B., Valderrama-Landeros, L., Velázquez-Salazar, S., Cruz-López, M.I., Ressler, R., Uribe-Martínez, A., Cerdeira-Estrada, S., Acosta-Velázquez, J., Díaz-Gallegos, J., Jiménez-Rosenberg, R., Fueyo-Mac Donald, L. & Galindo-Leal, C. 2013. Manglares de México: Extensión, Distribución y Monitoreo. *Comisión Nacional para el Conocimiento y Uso de la Biodiversidad*, México D. F. 128 pp.
- Romañach, S. S., DeAngelis, D. L., Koh, H. L., Li, Y., Teh, S. Y., Barizan, R. S. R., & Zhai, L. 2018. Conservation and restoration of mangroves: Global status, perspectives, and prognosis. *Ocean & Coastal Management*, 154, 72-82. Doi: 10.1016/j.ocecoaman.2018.01.009
- Ruiz-Luna A, Acosta-Velázquez J. & Berlanga-Robles CA 2008. On the reliability of the data of the extent of mangroves; a case study in Mexico. *Ocean & Coastal Management*, 51, 34–351. Doi: 10.1016/j.ocecoaman.2007.08.004
- Ruiz-Luna, A., Cervantes-Escobar, A. & Berlanga-Robles, C. 2010. Assessing distribution patterns, extent and current condition of Northwest Mexico mangroves. *Wetlands*, 30, 717–723, 2010. Doi: 10.1007/s13157-010-0082-2
- Spalding, M., Blasco, F., and Field, C. 1997. World mangrove atlas. The International Society for Mangrove Ecosystems, Okinawa, Japan. 178pp
- SEMARNAT-CNF-CGPI (Secretaría de Medio Ambiente y Recursos Naturales, Comisión Nacional Forestal, Coordinación General de Planeación e Información), 2012. Superficie incorporada al programa de pago por servicios ambientales. (Accesado en 10 de septiembre de 2020).
- Valderrama-Landeros, L. H., Rodríguez-Zúñiga, M. T., Troche-Souza, C., Velázquez-Salazar, S., Villeda-Chávez, E., Alcántara-Maya, J. A., Vázquez-Balderas, B., Cruz-López, M.I., & Ressler, R. 2017. Manglares de México: actualización y exploración de los datos del sistema de monitoreo 1970/1980-2015. Ciudad de México, *Comisión Nacional para el Conocimiento y Uso de la Biodiversidad*
- Valderrama-Landeros, L. H., López-Portillo, J., Velázquez-Salazar, S., Alcántara-Maya, J. A., Troche-Souza, C., Rodríguez-Zúñiga, M. T., & Ressler, R. 2020. Regional Distribution and Change Dynamics of Mangroves in México between 1970/80 and 2015. *Wetlands*. Doi: 10.1007/s13157-020-01299-0

- White, J. C., Coops, N. C., Wulder, M. A., Vastaranta, M., Hilker, T., & Tompalski, P. 2016. Remote sensing technologies for enhancing forest inventories: A review. *Canadian Journal of Remote Sensing*, 42(5), 619-641. Doi: 10.1080/07038992.2016.1207484
- Whitt, A. A., Coleman, R., Lovelock, C. E., Gillies, C., Ierodionou, D., Liyanapathirana, M., & Macreadie, P. I. 2020. March of the mangroves: Drivers of encroachment into southern temperate saltmarsh. *Estuarine, Coastal and Shelf Science*, 106776. Doi: 10.1016/j.ecss.2020.106776
- Zhang, C., Kovacs, J., Liu, Y., Flores-Verdugo, F., & Flores-de-Santiago, F. 2014. Separating mangrove species and conditions using laboratory hyperspectral data: A case study of a degraded mangrove forest of the Mexican Pacific. *Remote Sensing*, 6(12), 11673-11688. Doi: 10.3390/rs61211673

Anexo 2.1. Área estimada de la cobertura de manglar reportada para la zona de estudio por diversos autores.

Año de análisis	Región	Área (ha)	Fuente
1970	Sistema Teacapán-Agua Brava	111387	Flores-Verdugo et al. (1990)
1970	Estado de Nayarit	78024	Rodríguez-Zúñiga et al. (2013)
1975	Agua Brava- Marismas Nacionales	83214	Flores-Verdugo et al. (1992)
1975	Marismas Nacionales-Nayarit	47488	Flores-Verdugo et al. (1992)
1980	Sistema Teacapán-Agua Brava-Marismas Nacionales	83000	Flores-Verdugo et al. (1989)
1980	Estado de Nayarit	77924	Rodríguez-Zúñiga et al. (2013)
1990	Sistema Teacapán-Agua Brava-Marismas Nacionales	71090	Acosta-Velázquez (2003)
1992	Estado de Nayarit	80000	Secretaría de Agricultura y Recursos Hidráulicos (SARH) (1992)
2000	Sistema Teacapán-Agua Brava	75042	Berlanga-Robles y Ruiz Luna (2007)
2000	Sistema Teacapán-Agua Brava-Marismas Nacionales	64115	Acosta-Velázquez (2003)
2005	Sistema Teacapán-Agua Brava	77448	Acosta-Velázquez (2007)
2005	Estado de Nayarit	66500	Ruiz-Luna et al. (2010)
2005	Estado de Nayarit	69784	Rodríguez-Zúñiga et al. (2013)
2005	Pacífico occidental (sur de Sinaloa y Nayarit)	82862	Valderrama-Landeros et al. (2020)
2005	Estado de Nayarit	69784	Valderrama-Landeros et al. (2017)
2005	Sistema Teacapán-Agua Brava	77448	Rodríguez-Zúñiga et al. (2012)
2005	Marismas Nacionales-Nayarit	56,525	Ruiz-Luna et al. (2010)
2010	Estado de Nayarit	66920	Rodríguez-Zúñiga (2013)
2010	Marismas Nacionales-Nayarit	55255	Valderrama-Landeros et al. (2017)
2015	Marismas Nacionales-Nayarit	55962	Valderrama-Landeros et al. (2017)
2020	Estado de Nayarit	66,849	CONABIO (2021)

Referencias (Anexo 2.1)

- Acosta-Velázquez, J. 2003 Análisis de la condición del bosque de manglar en el Sistema Lagunar Teacapán-Agua Brava-Marismas Nacionales y sus relaciones a nivel de paisaje. Tesis de Maestría. Centro de Investigación en Alimentación y Desarrollo AC, México.7
- Acosta-Velázquez, J., & Zúñiga, M. R. 2007. Los manglares de México: estado actual y establecimiento de un programa de monitoreo a largo plazo: 1ra. Etapa. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad, México D. F.
- Berlanga-Robles, C. A., & Ruiz-Luna, A. 2007. Análisis de las tendencias de cambio del bosque de mangle del sistema lagunar Teacapán-Agua Brava, México. Una aproximación con el uso de imágenes de satélite Landsat. *Universidad y Ciencia*, 23(1), 29-46.
- CONABIO (Comisión Nacional para el Conocimiento y Uso de la Biodiversidad). 2021. Manglares de México: Extensión y distribución. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. México. 99. Disponible en: <https://www.biodiversidad.gob.mx/monitoreo/smmm/extensionDist>, fecha de consulta 12/02/2021
- Flores-Verdugo, F., González-Farías, F., Ramírez-Flores, O., Amezcua-Linares, F., Yáñez-Arancibia, A., Álvarez-Rubio, M. J. W. D., & Day, J. W. 1990. Mangrove ecology, aquatic primary productivity, and fish community dynamics in the Teacapán-Agua Brava lagoon-estuarine system (Mexican Pacific). *Estuaries*, 13(2), 219-230. Doi: 10.2307/1351591
- Flores-Verdugo, F., González-Farías, F., Zamorano, D.S., Ramírez-García, P., 1992. Mangrove ecosystems of the Pacific coast of Mexico: Distribution, structure, litterfall, and detritus dynamics. In: Seeliger, E. Ed., *Coastal Plant Communities of Latin America*. Academic Press, New York, pp. 269–288. Doi. 10.1016/B978-0-08-092567-7.50023-4
- Rodríguez-Zúñiga M.T., Troche-Souza C., Vázquez-Lule A. D., Márquez-Mendoza J. D., Vázquez-Balderas B., Valderrama-Landeros L., Velázquez-Salazar S., Uribe-Martínez A., Acosta-Velázquez J., Díaz-Gallegos J., Cruz-López M. I. y Ressler R. 2012. Los manglares de México: estado actual y establecimiento de un programa de monitoreo a largo plazo: 2ª y 3era etapas. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. Informe final SNIB-CONABIO proyecto No. GQ004. México.
- Rodríguez-Zúñiga, M.T., Troche-Souza C., Vázquez-Lule, A.D., Márquez-Mendoza, J. D., Vázquez-Balderas, B., Valderrama-Landeros, L., Velázquez-Salazar, S., Cruz-López, M.I., Ressler, R., Uribe-Martínez, A., Cerdeira-Estrada, S., Acosta-Velázquez, J., Díaz-Gallegos, J., Jiménez-Rosenberg, R., Fueyo-Mac Donald, L. y Galindo-Leal, C. 2013. Manglares de México: Extensión, Distribución y Monitoreo. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad, México D. F. 128 pp.
- Ruiz-Luna, A., Cervantes-Escobar, A., & Berlanga-Robles, C. 2010. Assessing distribution patterns, extent and current condition of Northwest Mexico mangroves. *Wetlands*, 30, 717–723, 2010. Doi: 10.1007/s13157-010-0082-2

- SARH (Secretaría de Agricultura y Recursos Hidráulicos). 1992. Inventario Nacional Forestal de Gran Visión, Reporte Principal. Subsecretaría Forestal, Secretaría de Agricultura y Recursos Hidráulicos. D.F., México. 51 p.
- Valderrama-Landeros, L. H., Rodríguez-Zúñiga, M. T., Troche-Souza, C., Velázquez-Salazar, S., Villeda-Chávez, E., Alcántara-Maya, J. A., & Ressler, R. 2017. Manglares de México: actualización y exploración de los datos del sistema de monitoreo 1970/1980-2015. Ciudad de México, Comisión Nacional para el Conocimiento y Uso de la Biodiversidad.
- Valderrama-Landeros, L. H., López-Portillo, J., Velázquez-Salazar, S., Alcántara-Maya, J. A., Troche-Souza, C., Rodríguez-Zúñiga, M. T., & Ressler, R. 2020. Regional Distribution and Change Dynamics of Mangroves in México between 1970/80 and 2015. *Wetlands*. Doi: 10.1007/s13157-020-01299-0

Capítulo 3

Estimación de la altura del dosel en bosques de mangle utilizando sensores remotos

Introducción

Los manglares son ecosistemas forestales que brindan importantes y múltiples servicios ecológicos, económicos y culturales (Kelleway et al., 2017; Menéndez et al., 2020). Todos estos son fundamentales para el bienestar de muchas comunidades costeras. Recientemente se ha enfatizado su importancia por su participación activa en ciclos biogeoquímicos como el de carbono (c) (Romañach, 2018; Moity et al., 2019). A pesar de los múltiples beneficios que ofrecen, los manglares son uno de los ambientes más amenazados a nivel mundial debido a cambios en los patrones hidrológicos naturales y al cambio climático (Alatorre et al., 2011; Romañach et al., 2018; Menéndez et al., 2020). Considerando la importancia de los manglares para la zona costera, su caracterización, conservación y monitoreo se vuelve crucial para medir, monitorear y reportar la estructura, la biomasa y las existencias de carbono en estos ecosistemas (Sinha et al., 2015; Castillo et al., 2017).

Uno de los parámetros estructurales de mayor importancia de los manglares es la altura del dosel ya que es factor esencial para estimar su biomasa y a través de esta la cuantificación del almacenamiento global de C así como para realizar modelos de la dinámica del crecimiento forestal (Feldpausch et al., 2012; Riel et al., 2018). Una estimación inexacta de la altura del dosel puede resultar en una estimación inexacta de biomasa área (AGB por sus siglas en inglés) (Kearsley et al., 2013), esta caracterización estructural de los manglares

permite el análisis de su salud y contribuye a los esfuerzos de monitoreo (de Souza-Pereira et al., 2016).

A pesar de que los métodos tradicionales de recopilación de datos en campo como los inventarios forestales proporcionan mediciones de la estructura forestal con base en un muestreo estadístico del paisaje y son críticos para la calibración y validación de modelos que permiten estimaciones de la estructura del bosque en áreas extensas (Köhl et al., 2006), esta tarea puede ser ineficaz, costosa y llevar mucha inversión de tiempo especialmente en lugares de difícil acceso como los manglares. No obstante, el uso de datos de percepción remota (PR) se ha extendido ampliamente para este propósito (Navarro et al., 2019). En las últimas décadas, se ha intensificado la utilización de la PR, ya que esta ofrece oportunidades para mapear los parámetros estructurales y biofísicos de los manglares (AGB y reservas de C) con menor costo, mayor velocidad y a una escala más amplia que las mediciones de campo (Kumar et al., 2017; Pham et al., 2019).

En los últimos años, han surgido nuevas formas de calcular la altura de los árboles como los datos de Radar de Apertura Sintética (SAR, por sus siglas en inglés), con el principal motivo de realizar estimaciones de biomasa de la vegetación por lo que juega un papel crucial en la comprensión y el seguimiento de la respuesta de los ecosistemas y su contribución al ciclo global del carbono (Kumar et al., 2017). Los datos provenientes de radar como SAR y LiDAR (Light Detection and Ranging) pueden ofrecer otros enfoques para la recuperación de la altura de árboles además de tener la ventaja de penetrar el dosel. Por esta razón, se consideran las herramientas más útiles para determinar estructura vertical o medidas forestales volumétricas y la estimación de AGB (Laurin et al., 2018; Pham et al., 2019).

Estudios recientes destacan el uso de datos del sensor SAR Sentinel-1 e imágenes multiespectrales Sentinel-2 (MSI) en la recuperación y mapeo de la AGB de manglares, especialmente con la incorporación de datos de elevación (Sinha et al., 2015; Castillo et al., 2017; Cunliffe et al., 2020). Los datos SAR han sido el principal insumo para este tipo de trabajos. Por ejemplo, Mougin et al. (1999) investigaron la relación entre el coeficiente de retrodispersión del radar y los parámetros forestales de los manglares en la Guayana Francesa, determinando que el uso de diferentes frecuencias y polarizaciones permite realizar estas estimaciones con precisión. Baltzer et al. (2007) encontraron que las estimaciones de estructura forestal utilizando SAR tenían varias limitaciones como la dependencia de la

densidad del dosel, las condiciones de humedad en la vegetación, además de la interpolación sobre áreas con una contribución insuficiente del suelo a la señal que podría dar lugar a estimaciones inexactas. Simard y Denbina (2017) mencionaron que los datos de SAR tienen un gran potencial para realizar estimaciones de altura precisas a escala de paisaje, y que estas estimaciones se pueden mejorar con la integración de LiDAR incluso en condiciones de de-correlación temporal.

Por lo tanto, se ha sugerido que los datos de sensores remotos activos (SAR y LiDAR) ofrecen enfoques para estimar la altura del dosel de los árboles que pueden superar las desventajas de los datos de percepción remota óptica, como una menor sensibilidad, que depende de las condiciones meteorológicas (Kuenzer et al., 2011; García et al., 2018; Pham et al., 2019). Sin embargo, aunque los datos de radar son útiles para detectar la estructura del bosque, también se ha identificado que la propia estructura del bosque (sistema de raíces y tallos), variables ambientales (régimen de mareas e inundaciones), además de la configuración del sensor (ángulo de incidencia y de-correlación temporal) pueden producir inconsistencias en la interpretación de los datos (Lucas et al., 2007; de Souza-Pereira et al., 2016). Como resultado, se ha propuesto que la combinación de datos provenientes de diferentes sensores remotos tiene una mayor eficacia y precisión que sensores aplicados individualmente (Lisein et al., 2013; Balenović et al., 2015).

Considerando que la vegetación tiene propiedades espectrales específicas, la PR se ha utilizado con éxito para identificar la vegetación de manglar en función de la reflectancia espectral y correlacionarla con propiedades biofísicas de los árboles (Alatorre et al., 2011). Además, es posible caracterizar la estructura del bosque mediante imágenes multiespectrales (SPOT, Landsat TM y ETM+) (Rodríguez-Veiga et al., 2016; García et al., 2018). Si bien las imágenes de resolución media-alta presentan la limitación de la saturación mixta de píxeles, estas se han utilizado de manera eficiente en la clasificación de especies y evaluaciones de la biomasa aérea y la altura del dosel (Fayad et al., 2016; Purnamasayangasukasih et al., 2016; Pham et al., 2019). Sin embargo, el acceso a estos datos sigue siendo caro, cubre áreas pequeñas y la necesidad de equipos específicos de almacenamiento y procesamiento los hace de uso limitado, de ahí la importancia de integrar datos de otros tipos de sensores (Purnamasayangasukasih et al., 2016; Pham et al., 2019).

Aunado a lo anterior, con los recientes avances en la tecnología de vehículos aéreos no tripulados (VANTs, dron en lo consecutivo) y las capacidades de procesamiento de datos, ha sido posible obtener imágenes de alta resolución y generar modelos tridimensionales que pueden utilizarse para monitorear ecosistemas forestales (Lukcas et al., 2016; Kattenborn et al., 2019). Maimaitijiang et al. (2020) encontraron que, debido a su capacidad para proporcionar información detallada de la estructura del dosel en tres dimensiones, los drones son una herramienta prometedora para monitorear la estructura del árbol. En particular, los procesos fotogramétricos que utilizan estos datos han aumentado la eficiencia del trabajo de campo al recopilar información espacial más amplia en menos tiempo que el trabajo de campo tradicional, así como al hacer estimaciones de los atributos estructurales del bosque como la altura del árbol, el diámetro y volumen del tallo (Navarro al., 2019; 2020; Warfield et al., 2019).

Por lo tanto, los drones utilizados para aplicaciones forestales ofrecen reducción de costos, simplificación y automatización de procesos, mayor calidad, menor tiempo de trabajo de campo, acceso a áreas de alto riesgo y reducción del personal necesario (Pajares, 2015; Navarro et al., 2020). Debido a la mayor flexibilidad, este tipo de datos tienen un gran potencial para el monitoreo de manglares (Tuominen et al., 2015). Además, este tipo de estudios abren la posibilidad de mediciones fácilmente repetibles y de bajo costo donde se puede obtener un enfoque rápido y rentable para monitorear los bosques de mangle en áreas grandes (Navarro et al., 2020).

A pesar de los numerosos estudios sobre el tema y que estos ecosistemas representan uno de los principales reservorios de AGB, con mayor biomasa y productividad, son uno de los ecosistemas más amenazados del mundo debido a las actividades antropogénicas (Alongi, 2012; Adame et al., 2013; Menéndez et al., 2020). Por lo tanto, es fundamental la implementación de técnicas de PR para medir, monitorear y reportar la estructura forestal, alturas, biomasa y reservas de carbono de los manglares en una escala espacial consistente que permita establecer la adecuada incorporación de políticas para conservar estos ecosistemas y los servicios que estos proveen (Sinha et al., 2015; Castillo et al., 2017; Rahman y Aslan, 2017).

Este estudio tiene como objetivo crear modelos de altura del dosel de la cobertura de manglar en la Reserva de la Biosfera de Marismas Nacionales (RBMN), utilizando datos

provenientes de múltiples sensores remotos. Se presume que la integración de datos multiespectrales con datos SAR mejorará estas estimaciones.

Zona de estudio

La zona de estudio RBMN, un gran complejo estuarino (~134,000 ha) ubicado en la costa noroeste del Pacífico mexicano en la llanura aluvial del estado de Nayarit entre los 21° 44' y 22° 35' de latitud Norte y 105° 18' y 105° 45' de longitud Oeste (Figura 2.1). La RBMN abarca el humedal más extenso del Pacífico mexicano, que representa el 8% de la extensión nacional de manglares (CONANP, 2013; Valderrama-Landeros et al., 2017; CONABIO, 2021). El sistema es alimentado por varios afluentes entre los que destacan los ríos San Pedro y Acajoneta, lo cuales descargan grandes cantidades de agua dulce y sedimentos ricos en nutrientes de las cuencas circundantes (Hernández-Guzmán et al., 2019b). El área se encuentra principalmente caracterizada por un clima cálido sub-húmedo con una temperatura media anual que varía en los 22 y 26 °C. La época de secas se presenta desde diciembre a junio, con una precipitación entre 928 y 1,457 mm durante el verano. Cerca del 80% de la precipitación anual cae de julio a octubre (temporada de lluvias) (Zhang et al., 2014; Hernández-Guzmán et al., 2019b).

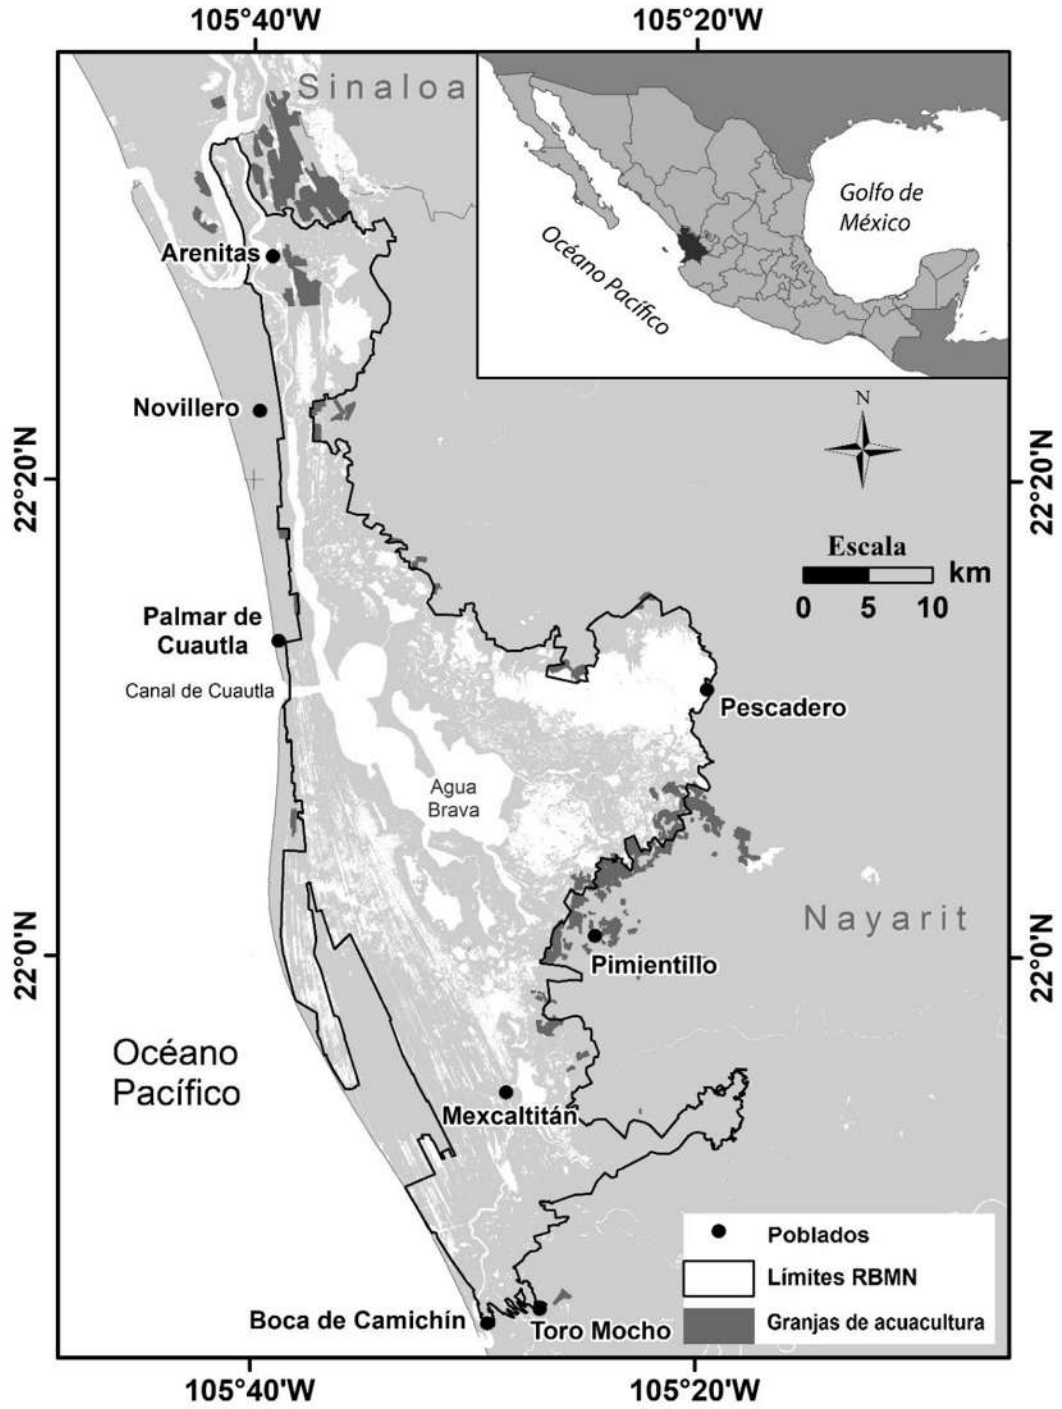


Figura 3.1. Ubicación geográfica de la Reserva de la Biosfera Marismas Nacionales, Nayarit.

Metodología

Integración general de fases metodológicas

En un panorama general de sobre la metodología realizada en este estudio se optó por realizar un resumen de las fases metodológicas que comprenden: 1) Se realizó un análisis de imágenes Sentinel-2 con el fin de identificar la cobertura de manglar y su extensión. 2) Se produjo una recolección de datos de cobertura directa en campo mediante un GPS para realizar una validación de campo. 3) Mediante un muestreo de manglar se registró la altura, especie, y coordenadas de por lo menos 25 individuos identificados en las unidades de muestreo además, se realizaron levantamientos fotogramétricos en dichas unidades. 4) Mediante un proceso fotogramétrico se estimó la altura de los mangles y se buscó relacionarla con la altura observada en campo mediante análisis estadísticos. 5) se realizó una estimación de la altura del dosel mediante imágenes SAR (ALOS-PALSAR) y se integró a la estimación realizada anteriormente en el proceso fotogramétrico. 6) Como último sensor en integrarse se utilizaron índices multiespectrales y su relación con la altura obtenida con fotogrametría aunada a la obtenida mediante la metodología SAR (ALOS-PALSAR) para realizar una proyección de altura en toda la RBMN. 7) Por último, se utilizó un análisis estadístico de regresión lineal para identificar el nivel de relación que tienen los distintos modelos de proyección de altura generados por los diferentes sensores y adicionalmente la proyección de altura del Sistema de Monitoreo de carbono de la NASA.

Análisis de imágenes Sentinel-2

En este estudio, utilizamos imágenes Sentinel-2A (bandas a una resolución espacial de 10 m) tile T13QDE para la temporada seca (11 de abril de 2019) y lluviosa (14 de agosto de 2019). Ambas escenas se descargaron de la plataforma Global Visualization Viewer (GloVis) del Servicio Geológico de los Estados Unidos (USGS). Se utilizó un enfoque de clasificación híbrido para la caracterización de imágenes que combinó técnicas de clasificación supervisadas y no supervisadas. Como primer paso, el área de estudio se aisló de todas las escenas mediante un proceso de enmascaramiento producido por la rasterización del archivo vectorial del área natural protegida RBMN. Posteriormente, como una primera etapa de la clasificación supervisada, se realizó un procedimiento de segmentación de píxeles. Este proceso agrupa los píxeles adyacentes en segmentos de imagen de acuerdo con su similitud espectral (Eastman, 2016). Con este archivo vectorial de segmentación, se seleccionaron los

campos de entrenamiento y se generó un archivo de firma espectral, que se utilizó dentro de una red neuronal utilizando el algoritmo Multi-Layer Perceptron (MLP) para generar la clasificación de la cobertura de manglar. Finalmente, esta imagen booleana se utilizó como máscara dentro de una clasificación no supervisada con el algoritmo K-means para separar las condiciones del manglar (manglar en buen estado y manglar muerto) así como para excluir aquellos píxeles que, identificados como manglar en el MLP, no pertenecía realmente a esta clase.

Validación de la exactitud

Para la validación del mapa temático de la temporada de secas, se utilizaron datos colectados en campo con ayuda de un GPS Garmin Montana 680 durante el 2019 y 2020. Para su colecta, se realizaron recorridos por las rutas con posibilidad de acceso como carreteras y caminos, pero también a bordo de una embarcación menor sobre canales entre el manglar. Con los puntos colectados se construyó una matriz de error, a partir de la cual se estimaron indicadores generales de la exactitud de la clasificación como la exactitud global, las exactitudes de usuario (EU) y de productor (EP) (Congalton y Green, 2019). La clasificación fue aceptada hasta que la exactitud global estuvo por arriba del 80%.

Una vez evaluada la exactitud, se describió la distribución espacial de la cobertura de mangle y se evaluaron las cifras finales sobre su extensión.

Muestreo de manglar

Se aplicó el diseño de muestreo para zonas de manglar propuesto por Rodríguez-Zúñiga et al., (2018). Este diseño se planificó delimitando un área de amortiguamiento alrededor de cuerpos de agua, caminos y asentamientos humanos, y distribuyendo las unidades de muestreo (UM) dentro de ella. Este enfoque asume que las áreas que rodean las zonas accesibles no varían de aquellas que son inaccesibles, por lo que los parámetros estimados son similares en ambas áreas (Stringer et al., 2015; Rodriguez-Zuñiga et al., 2018).

Se establecieron, de manera dirigida 14 unidades de muestreo (UM) de 100 x 100 m en tres unidades de mangle: cinco UM en paralelo a cuerpos de agua, cinco UM paralelas a carreteras-caminos y cuatro UM cercanas a asentamientos humanos (Kauffman et al., 2013; Téllez-García et al., 2012). En cada UM se registró la altura, especie, y coordenadas de por

lo menos 25 individuos identificados. Cuando fue posible, la altura de los árboles se obtuvo con ayuda de un clinómetro Suunto PM-5/360 PC. Cuando no fue posible, se usó un estadal construido con tubos de PVC, se tomó la foto y se registró la coordenada con la ayuda de un GPS Garmin Montana 680 que tiene una precisión de ~1 m. Estas fotos fueron analizadas con el software ImageJ, utilizado para detectar la altura de los ejemplares medidos con estadal (<https://imagej.nih.gov/ij/>).

Fotografía aérea y proceso fotogramétrico

Considerando que no toda el área de estudio corresponde a superficie de manglar y que no podría ser cartografiada en su totalidad con la ayuda de un dron, se establecieron los sitios de muestreo en campo mencionados anteriormente como UM. En estos sitios se realizó una serie de levantamientos fotogramétricos con la ayuda de un dron tipo cuadricóptero DJI Phantom 4 equipado con cámara de 12 Megapíxeles y autonomía de vuelo de 28 minutos.

Para cada sitio se diseñaron y ejecutaron 15 misiones de vuelo con parámetros definidos de altura (100 m), velocidad de vuelo (25 km/h), así como los intervalos entre cada toma de fotografías (2 segundos). El diseño de estas misiones se realizó sobre la plataforma Litchi Mission Hub (<https://flylitchi.com/hub>). El despegue y aterrizaje se realizó de forma manual por razones de seguridad. Las fotografías tuvieron un solapamiento longitudinal de por lo menos el 80% con el objetivo de poder aplicar el principio de la visión estereoscópica a los fotogramas aéreos (Torres-Sánchez et al., 2018).

Después del trabajo de campo y la recolección de datos, todas las fotos (cámaras) se cargaron en el software fotogramétrico Agisoft Metashape Professional v1.5 donde la selección y alineación de las cámaras es fundamental. En un primer paso, el algoritmo buscó puntos comunes en las cámaras y los comparó, además de que encontró la posición de la cámara y redefinió los parámetros de calibración para calcular la información de profundidad combinando cada píxel en una única nube de puntos densa. El siguiente paso consistió en construir una malla poligonal 3D o un modelo digital de elevación (MDE) que representa la superficie del objeto en función de la nube de puntos; esto permitió la generación y visualización del MDE. Con la información anterior, fue posible realizar mediciones de distancia, área y volumen con base al MDE (Klosterman, 2018). Este modelo finalmente se exportó para ser utilizado en otro software SIG.

Todo lo anterior se realizó mediante el software fotogramétrico Agisoft Metashape Professional v1.5 (<https://www.agisoft.com/>).

Evaluación el potencial de los datos SAR para estimar la altura del dosel

En este estudio, utilizamos imágenes ALOS-PALSAR (banda L), las cuales son de acceso libre a través de internet en la plataforma Alaska Satellite Facility (<https://search.asf.alaska.edu/#/>). La banda L puede penetrar la vegetación y recibe una onda reflejada desde el suelo consistente incluso en un área forestal, sin embargo, tiene una cobertura temporal muy limitada que terminó en 2011 (ASF, 2018). Considerando que las imágenes seleccionadas deben ser del mismo número de ruta y deben cubrir la misma área, en este estudio, se utilizaron una serie de imágenes ALOS-PALSAR (Banda L) de alta resolución con corrección del terreno. Las escenas contaban con los siguientes parámetros: Hora de inicio (17/03/07), Ruta (510), Frames (3170 y 3180), Dirección de vuelo (descendente) y polarización (HH + HV) y escenas con Hora de inicio (ene-2011), Ruta (197), Frames (420 y 430), Dirección de vuelo (ascendente) y Polarización (HH).

Las escenas se importaron al software ArcGIS v 10.3.1 y se proyectaron en un sistema de coordenadas geográficas WGS 1984 UTM zona 13. A partir de estas imágenes, se creó un mosaico para cubrir toda el área de estudio y aislarla mediante un proceso de enmascaramiento para trabajar solo con la cobertura de manglar estimada en pasos anteriores. Una vez finalizado este proceso y teniendo en cuenta que el MDE tenía valores negativos, se determinó un punto conocido de "altura 0" mediante validación de campo y se recalcularon los valores de altura.

Incorporación de índices multispectrales para las estimaciones de la altura del dosel

Los índices de vegetación son una de las principales herramientas para monitorear y estimar diferentes atributos físicos de la vegetación ya que se han utilizado con éxito para realizar diferentes mediciones relacionadas con propiedades espectrales, como la evaluación de la salud de la vegetación, el follaje, la cobertura, su fenología, entre otras (Glenn et al., 2008; de Alckmin et al., 2021), e inclusive atributos estructurales como la altura del dosel y la biomasa aérea del bosque (Zheng et al., 2008; Baloloy et al., 2018). En este estudio, se utilizaron imágenes Landsat 8 Land Operational Imager (OLI) con path-row: 31–44 y 31–45

para febrero, mayo y agosto de 2019. Considerando que los índices espectrales funcionan con datos de reflectancia (Glenn et al., 2008), los valores numéricos digitales se convirtieron a reflectancia utilizando los coeficientes de escalamiento disponibles en los metadatos de la imagen de satélite. Los índices espectrales derivados de los datos de reflectancia de las imágenes multiespectrales se muestran en la [Tabla 3.1](#).

Tabla 3.1. Índices espectrales evaluados en este estudio. NDVI = Índice de Vegetación de Diferencia Normalizada, GRVI = Índice de Vegetación Verde-Rojo, EVI = Índice Mejorado de Vegetación, LAI = Índice de Área Foliar, GLI = Índice de Hoja Verde, IPVI = Índice de Vegetación de Porcentaje Infrarrojo, RDVI = Índice de Vegetación de Diferencia Re-Normalizada, NDWI = Índice de Agua de Diferencia Normalizado, MNDWI = Índice de Agua de Diferencia Normalizado Modificado. Bandas Landsat OLI (Azul = b2, Verde = b3, Rojo = b4, NIR = b5, SWIR = b6). Coeficientes EVI (L = 1, C1 = 6, C2 = 7.5).

	Acrónimo	Ecuación	Fuente
	NDVI	$\frac{NIR - Red}{NIR + Red}$	Rouse et al., 1974
	GRVI	$\frac{NIR}{Gree}$	Sripada et al., 2005
	EVI	$2.5 \frac{NIR - Red}{NIR + C1 * Red - C2 * Blue + L}$	Huete et al., 2002
Índices de Vegetación	LAI	$3.618 EVI - 0.118$	Boegh et al., 2002
	GLI	$\frac{(Green - Red) + (Green - Blue)}{(2 * Green) + Red + Blue}$	Louhaichi et al., 2001
	IPVI	$\frac{NIR}{NIR + Red}$	Crippen, 1990
	RDVI	$\frac{NIR - Red}{\sqrt{NIR + Red}}$	Roujean and Breon, 1995

	NDWI	$\frac{NIR - SWIR}{NIR + SWIR}$	Gao, 1996
Índices de Agua	NDWI	$\frac{Green - NIR}{Green + NIR}$	Mcfeeters, 1996
	MNDWI	$\frac{Green - SWIR}{Green + SWIR}$	Xu, 2006

Los modelos generados en campo con el proceso fotogramétrico se relacionaron con los índices espectrales anteriores utilizando modelos estadísticos de regresión lineal simple y los mejores modelos se utilizaron para espacializar la altura del dosel en toda el área de manglar en la RBMN. Posteriormente, relacionamos el mejor modelo generado por la metodología SAR con los derivados con imágenes multiespectrales. Cabe mencionar que los cálculos de las ecuaciones lineales se realizaron utilizando solo el 50% de los datos de altura disponibles con el objetivo de utilizar el resto para la validación de los modelos proyectados. Además, proyectamos el valor de altura máxima en RBMN con datos extraídos del Sistema de Monitoreo de carbono de la NASA (Simard et al., 2019). Finalmente, se realizó un análisis estadístico para validar todos los modelos generados.

Resultados

Nuestro mapa temático alcanzó una precisión general del 85% con base en 460 puntos recopilados con la ayuda de una unidad GPS Garmin Montana 680 con una precisión de ~ 1 m (Tabla 3.2). En casi todos los casos, tanto la exactitud del usuario (EU) como la exactitud del productor (EP) fueron $\geq 80\%$.

Tabla 3.2. Evaluación de exactitud para la clasificación de manglares en Marismas Nacionales basada en imágenes Sentinel-2, puntos de control colectados en 2019 y 2020

<i>Coberturas</i>		<i>Datos de Referencia</i>			
		<i>Manglar</i>	<i>No Manglar</i>	<i>Total</i>	<i>EU</i>
Clasificación	<i>Manglar</i>	258	45	303	85%
	<i>No manglar</i>	22	135	157	86%

<i>Total</i>	280	180	Exactitud Global
EP	92%	75%	85%

Se diferenci3 manglar en buen estado de conservaci3n y manglar muerto para ambas fechas analizadas del sensor Sentinel-2 a 10 m de resoluci3n para 2019 (3poca seca y lluvias). El manglar muerto se localiz3 principalmente al este del 3rea de estudio, en la zona conocida como Pescadero, y en menor medida al norte del 3rea de estudio (Arenitas) as3 como al norte de la isla de Mexcaltit3n. La mayor3a de las 3reas adyacentes a cuerpos de agua y alejadas de 3reas pobladas se encontraron en buenas condiciones (Figura 3.2). Se estim3 un total de 51,118 ha de manglares en buen estado para la imagen de la 3poca seca, identificando 9,470 ha como manglares muertos para la misma caracterizaci3n. Para la caracterizaci3n de la 3poca de lluvias, se estimaron 55,812 ha de manglar en buen estado y 5,315 ha de manglar muerto.

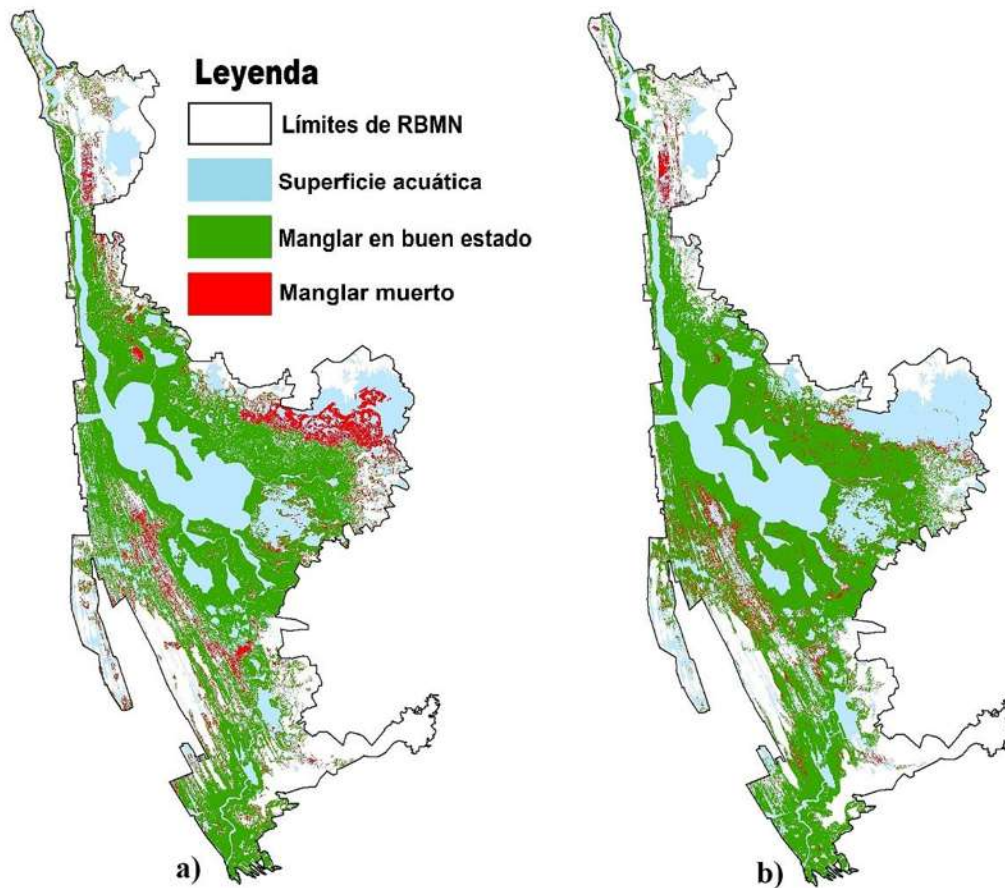


Figura. 3.2. Caracterización de manglar en buen estado de conservación (verde) y muerto (rojo) obtenido mediante la clasificación de imágenes Sentinel-2 (10 m de resolución). **a)** temporada seca; **b)** temporada de lluvia.

Levantamientos fotogramétricos

Del total de 14 levantamientos con dron ([anexo 3.1](#)) distribuidos dentro del área de estudio, se registraron alrededor de 300 árboles individuales con alturas que variaron desde 2.1 m a 13.9 m (± 2.19 m). De acuerdo con los resultados, se detectaron alturas mayores tanto en la zona central como en las zonas sur del área de estudio (en los poblados de Boca de Camichín y Toromocho), mientras que las alturas de manglares más bajas se ubicaron al norte de la isla de Mexcaltitán, y la parte norte del área de estudio (Novillero y Arenitas).

Análisis estadístico

Como parte del proceso, se generó una base de datos con la altura registrada en campo de los individuos identificados ~300 individuos y la altura modelada mediante los MDE. Con estos datos se aplicó un análisis estadístico de regresión lineal que al comparar la altura medida en campo contra la altura modelada proporcionó un valor de $R^2 = 0.9$ por lo que se asume se podrá estimar la altura del dosel de la zona de estudio utilizando imágenes de satélite (Figura 3.3).

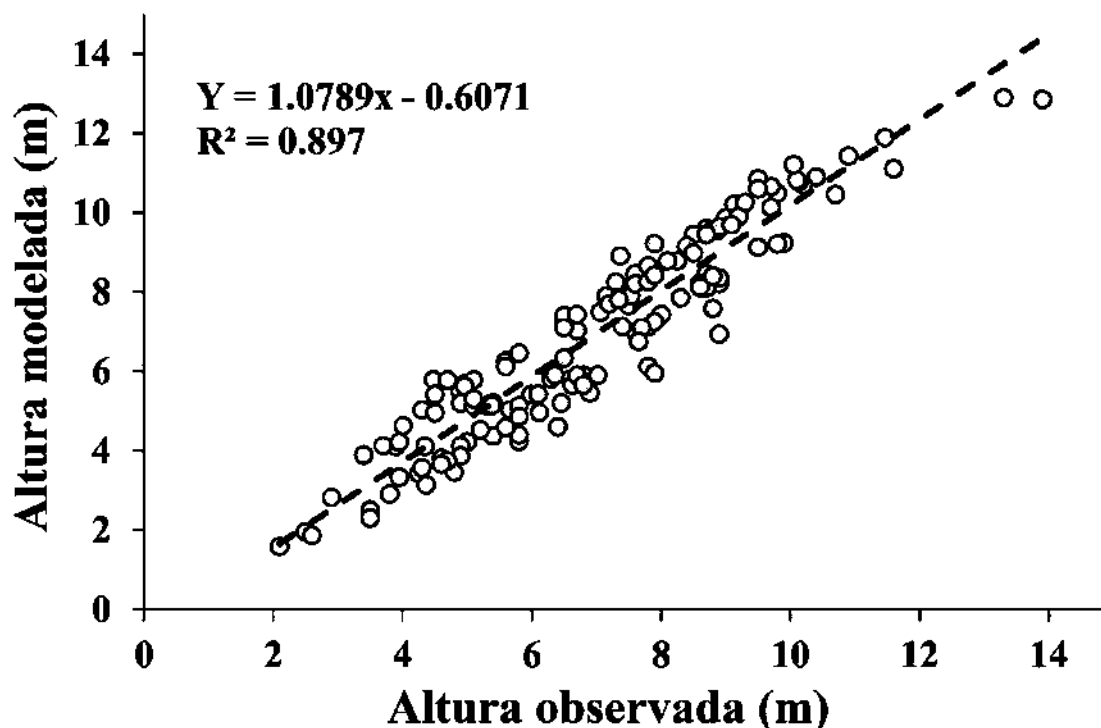


Figura 3.3. Análisis de regresión lineal de la altura medida en campo contra la altura modelada mediante el DEM. y = ecuación de la recta para calcular cualquier punto de altura con base en la altura modelada.

Modelo de Radar de Apertura Sintética (SAR) ALOS-PALSAR

La Figura 3.4 muestra el modelo de superficie digital obtenido a partir de imágenes de radar (banda L). El análisis de regresión lineal entre las alturas detectadas por la banda L y las obtenidas con el dron mostró el grado de confiabilidad o bondad de ajuste visto como un coeficiente de determinación R^2 con un valor de 0.21 y 0.16 para 2007 y 2011,

respectivamente. El MDS proyectado con las escenas del 2011 obtuvo una relación menor, por lo que el MDS del 2007 fue el utilizado para la integración con la proyección de altura (Figura 3.4). La acumulación de valores de altura varió entre 0.3 y 6.41 m para ALOS-PALSAR y entre 2.27 y 14.22 m para SMC. Se obtuvo un valor medio de altura en 3.36 m (± 1.56 m) para el modelo SAR y 8.25 m (± 3.05 m) para el modelo SMC.

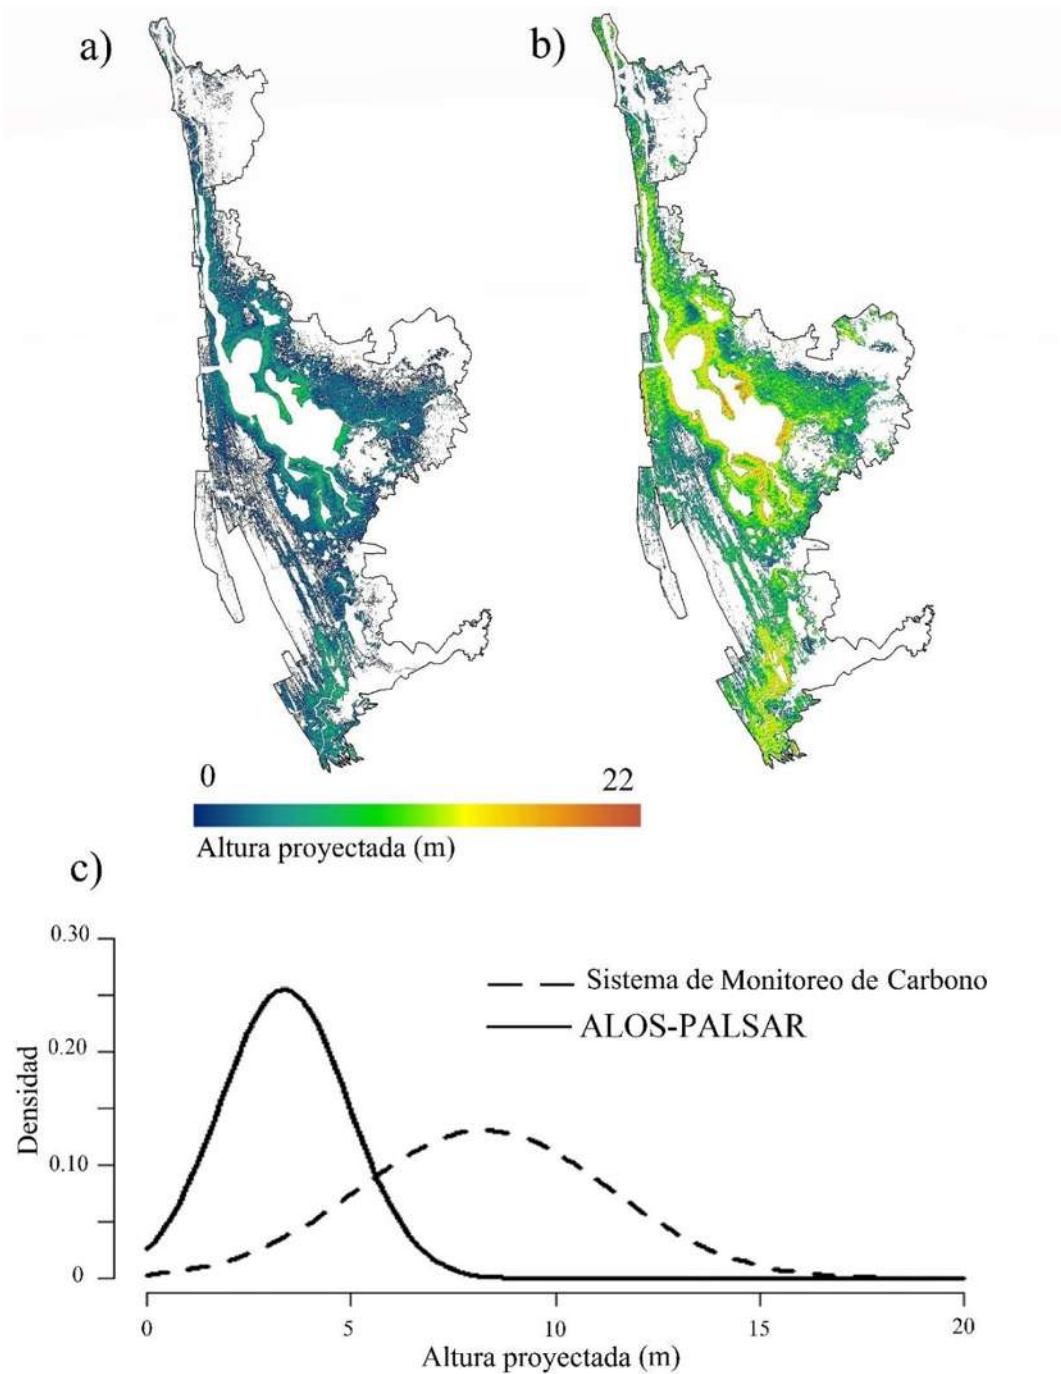


Figura 3.4. Modelo digital de superficie utilizando imágenes de radar. **a)** ALOS-PALSAR; **b)** Proyección del Sistema de Monitoreo de carbono (SMC) de la NASA; **c)** Curvas de densidad normal estimadas para cada una de las proyecciones. Los colores más cálidos identifican alturas más altas, mientras que los colores más fríos indican alturas más bajas.

Evaluación de los índices espectrales

En cuanto a los índices espectrales mencionados anteriormente para aplicar el análisis de regresión, identificamos aquellos altamente correlacionados con las medidas de altura en campo. Debido a que los valores de índices con imágenes Landsat 8 OLI estuvieron mejor relacionados, se optó por utilizarlos en este estudio. Los resultados sugieren que los índices individuales más relacionados con la altura modelada fueron el NDVI, el NDWI (McFeeters) y el GRVI con valores de R^2 entre 0.62 y 0.74 para la imagen de mayo (Figura 3.5), mientras que el índice menos relacionado fue el GLI con un valor R^2 de 0.27 (anexo 3.2).

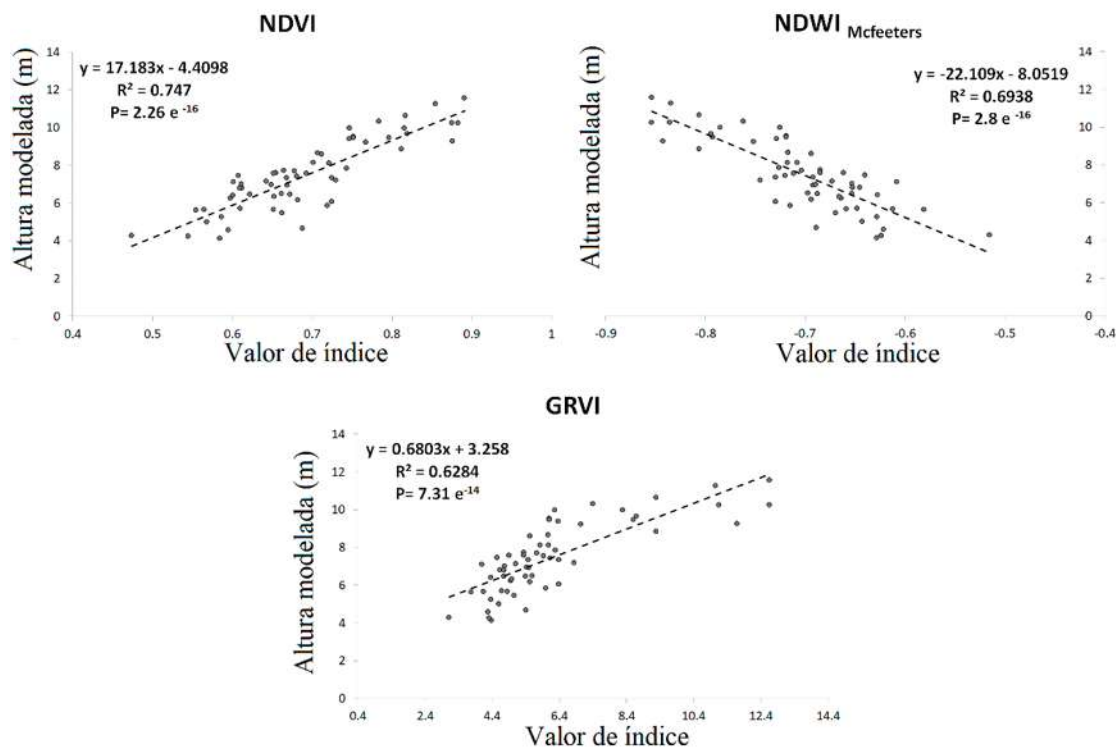


Figura 3.5. Análisis de regresión lineal y línea de tendencia de la altura modelada contra los valores de los índices calculados con mejor relación estadística.

Los coeficientes de determinación (R^2) obtenidos para cada uno de los índices individuales, así como los modelos ajustados con la combinación de varios índices se muestran en [Anexo 3.3](#). Los índices NDVI, GRVI y $NDWI_{McFeeters}$ calculados con escenas de febrero y agosto estuvieron menos correlacionados ([Anexo 3.4](#)), por lo que se utilizaron las escenas de mayo para la proyección de altura. De acuerdo a los resultados, los índices individuales podrían generar un ajuste aceptable, además de tener la ventaja de no estar sobre parametrizados. La combinación de varios índices no aporta un aumento significativo al ajuste del modelo. Con esta información, se eligieron los mejores modelos y se realizaron las proyecciones de la altura máxima a toda la RBMN ([Figura 3.6](#)). Adicionalmente, se obtuvieron las curvas de densidad normal estimadas para cada una de las proyecciones donde se observó la acumulación de valores de altura entre 3.98 y 10 m de altura ([Figura 3.6](#)).

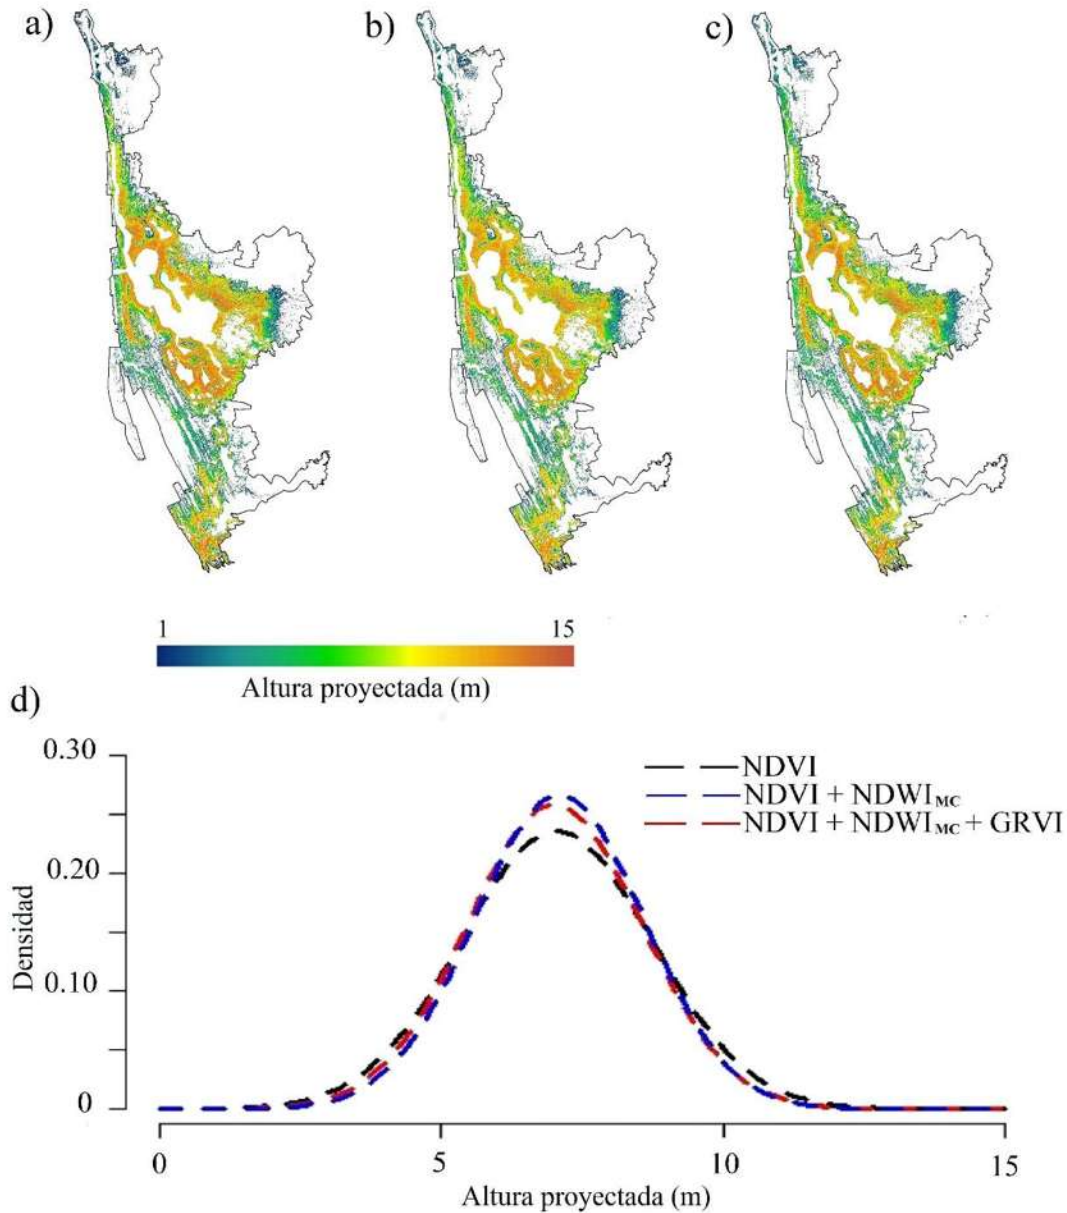


Figura 3.6. Proyecciones de altura máxima para la RBMN; **a)** proyección de alturas con NDVI; **b)** proyección de alturas con NDVI + NDWI_{MC}; **c)** proyección de alturas con GRVI + NDVI + NDWI_{MC}; **d)** curvas de densidad normal estimadas para cada una de las proyecciones. Los colores más cálidos identifican alturas más altas, mientras que los colores más fríos indican alturas más bajas.

Finalmente, se generó una proyección de altura utilizando las condiciones promedio de los modelos previamente calculados haciendo una comparación con la proyección del Sistema de Monitoreo de carbono (SMC) y sus respectivas curvas de densidad estimadas donde la

acumulación de valores de altura resultó entre 4 y 8.53 m para las condiciones promedio y 2.27 y 14.22 m para el SMC (Figura 3.7). En todas los modelos se repitió el patrón de mayor altura en la parte central del área de estudio (bordeando la laguna de Agua Brava) disminuyendo hacia los límites del área de estudio. Los valores de altura promedio fueron 6.26 m (± 1.16 m) y 8.25 m (± 3.05 m) para la condición media y el modelo SMC, respectivamente.

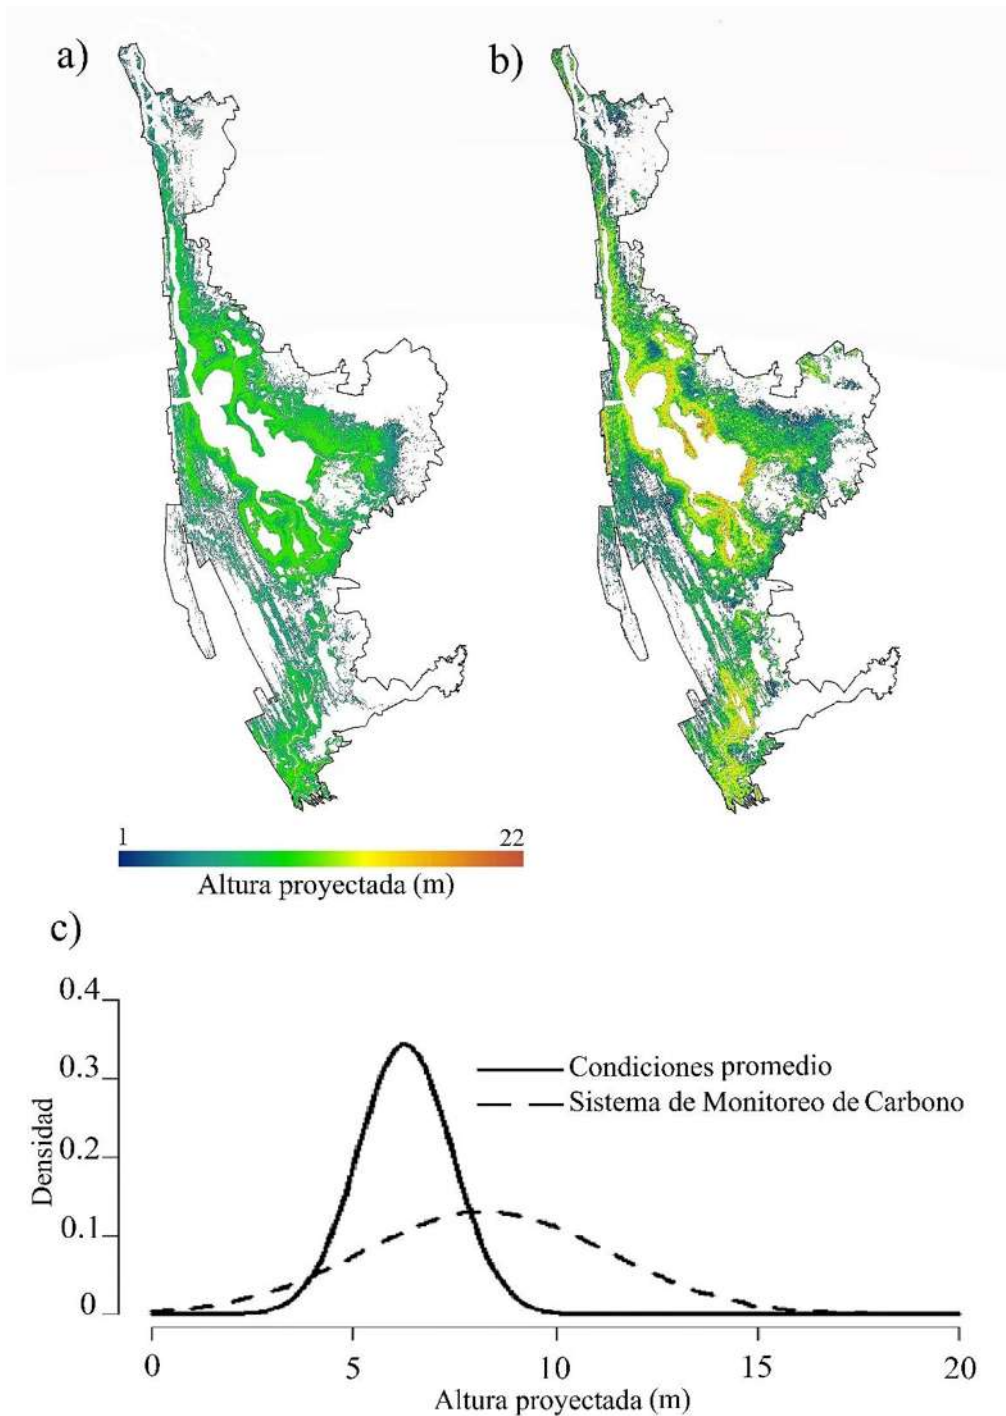


Figura 3.7. Proyecciones de alturas máximas para el área de la RBMN; **a)** condiciones promedio de las diferentes proyecciones calculadas; **b)** proyección del Sistema de Monitoreo de carbono (SMC) de la NASA (Simard et al., 2019); **c)** curvas de densidad normal estimadas para cada una de las proyecciones); Los colores más cálidos identifican alturas más altas, mientras que los colores más fríos indican alturas más bajas.

El análisis estadístico determinó que la configuración del modelo generado con índices espectrales y la altura modelada generada con un proceso de fotogrametría aérea cuentan con una fuerte relación entre sí, teniendo valores de confiabilidad altos de acuerdo con la bondad del ajuste de determinación. Por otro lado, los valores de altura modelados y la altura extraída del Sistema de Monitoreo de carbono no demostraron tener una relación (Tabla 3.3).

Tabla 3.3. Análisis de regresión lineal entre la altura modelada con fotogrametría aérea y la altura proyectada mediante los mejores ajustes de índices espectrales obtenidos adicional los valores extraídos del Sistema de Monitoreo de carbono.

Fuente de correlación	(R²)
<i>Altura modelada vs Sistema de Monitoreo de Carbono (NASA)</i>	0.2282
<i>Altura modelada vs Proyección de altura con NDVI</i>	0.7479
<i>Altura modelada vs Proyección de altura con NDVI+NDWI</i>	0.7526
<i>Altura modelada vs Proyección de altura con NDVI+GRVI+NDWI</i>	0.7426
<i>Altura modelada vs Proyección de las condiciones promedio</i>	0.7064

Discusiones

El presente trabajo estimó una extensión de 51,118 ha y 55,812 ha totales de manglar para la caracterización de la estación seca y lluviosa del 2019, respectivamente. Esta diferencia en la extensión de la cobertura entre estaciones podría estar relacionada con el hecho de que las bandas están fuertemente afectadas por la dinámica del agua, las precipitaciones locales, las variaciones de temperatura, la nubosidad, así como la fenología de la vegetación asociada que se presenta durante la época de lluvias (Pham et al., 2019).

Respecto al área de manglar, Ruiz-Luna et al. (2010) reportaron un total de 56,525 ha para el año 2005, mientras que Valderrama-Landeros et al. (2017) reportaron 55,965 ha para el año 2015; las cifras generales del presente trabajo coinciden con las de esos autores.

Sin embargo, CONABIO (2021) estimó que para 2020, alrededor de 57,570 ha de esta cobertura se ubicaron en esta área. Las diferencias pueden atribuirse a la resolución espacial entre los conjuntos de datos. Para los sensores Landsat, la resolución espacial de 30 m puede agregar información de varios tipos de cubiertas en un mismo píxel, mientras que Sentinel-2 proporciona una mejor resolución espacial y, por lo tanto, puede hacer una contribución importante a la caracterización de los manglares (Pham et al., 2019). Los sensores con una misma resolución espacial pueden atribuir sus diferencias a los criterios con los que se discriminan los diferentes tipos de cobertura (CONABIO, 2021).

La relación entre las alturas observadas y modeladas tuvo un valor de R^2 de 0.90 indicando un excelente desempeño del proceso fotogramétrico. Este resultado concuerda con Lisein et al. (2013) y Krause et al. (2019) quienes reportaron mediciones de la altura de árboles derivadas de datos fotogramétricos con valores de R^2 entre 0.87 y 0.97. Algunos autores destacan importantes ventajas de la tecnología LiDAR, como la obtención de mediciones directas y precisas de la estructura del bosque sin afectaciones por condiciones atmosféricas, mayor confiabilidad en ambientes complejos y una mayor cobertura espacial (Sullivan et al., 2017). Sin embargo, la flexibilidad de los drones junto con el proceso fotogramétrico puede considerarse una alternativa adecuada y rentable para medir la altura de los árboles con un nivel de precisión similar al de LiDAR (Lisein et al., 2013; Balenović et al., 2015).

A pesar de ser menos costoso, más rentable y de mejor calidad, se han identificado algunas limitaciones para el uso de los drones, como su uso en condiciones climáticas particulares (días soleados y libres de nubes) y de una menor cobertura espacial en comparación con los satélites y los sensores aerotransportados. No obstante, Cunliffe et al. (2020) creen que los datos fotogramétricos se pueden relacionar y utilizar para estimar parámetros de la estructura del bosque, como la altura del dosel y la biomasa aérea (Balenović et al., 2015).

Aunque se ha informado que ALOS-PALSAR es útil para realizar estimaciones relacionadas con la estructura del bosque (Morel et al., 2011; Winarso et al., 2017), los resultados sugieren que su incorporación en la proyección de altura máxima no mejora el modelo final. Esto puede deberse a factores como la geomorfología, el tamaño de la unidad de muestreo, el régimen de mareas y las variaciones en la estructura y densidad del bosque

que pueden afectar la retrodispersión (Morel et al., 2011; de Souza-Pereira 2016). Para superar esto, de Souza-Pereira (2016) sugirió probar diferentes polarizaciones, direcciones de vuelo y modos de adquisición de imágenes.

Los resultados reportados aquí sugieren que la combinación de la fotogrametría con los que los índices espectrales NDVI, NDWI_{MC} y GRVI de manera individual son buenos predictores de la altura del dosel con valores de R² entre 0.62 y 0.74. Se encontró que la combinación de dos o más índices no mejora significativamente el modelo final en comparación con los índices individuales. Price et al. (2002) mencionan que la integración de índices de vegetación y bandas espectrales sin procesar no necesariamente mejora las estimaciones de vegetación. Si bien el aumento del número de bandas espectrales podría mejorar el modelo hasta cierto punto, la sobre-parametrización puede disminuir la precisión (Price et al., 2002).

Este estudio produjo una estimación de los valores de altura del dosel en la RBMN que osciló entre 3.98 y 10 m. Estos resultados son consistentes con el rango de 2.27 y 14.22 m reportados por el SMC de la NASA (Simard et al., 2019). Sin embargo, el rango de altura máximo y mínimo estimado con el conjunto de datos de SMC fue entre 1 y 22 m para toda la RBMN. Esto puede atribuirse a diferencias metodológicas y de escala en los estudios, errores por el efecto de borde, así como a la combinación de múltiples conjuntos de datos (Simard et al., 2019). El análisis estadístico reveló que los resultados de este estudio no están estrechamente relacionados con la altura informada por el SMC de la NASA. Sin embargo, todos los modelos generados tienen los mismos patrones de altura del dosel dentro de la RBMN con los valores más altos de altura del dosel hacia el centro del área (Laguna de Agua Brava) y decreciendo hacia los límites de la reserva.

Tradicionalmente, los mapas de altura del dosel se han generado utilizando datos SAR, LiDAR e imágenes ópticas de alta resolución (Lagomasino et al., 2016; Pham et al., 2019). En particular, los sistemas LiDAR aerotransportados se consideran un estándar para estimar la altura del dosel. Sin embargo, estas metodologías suelen ser costosas y limitadas a determinadas regiones (Lagomasino et al., 2016). A pesar de esto, se ha demostrado que el uso de datos de fotogrametría aérea e imágenes multispectrales es útil para estimar modelos de altura del dosel comparables a LiDAR de una manera rentable y conveniente incluso a una escala regional (Lisein et al., 2013).

Aunque se dispone de estimaciones de las reservas mundiales de carbono y AGB de los manglares, la altura del dosel rara vez se considera en estas estimaciones (Simard et al., 2019). Sin embargo, omitir la altura en los cálculos de AGB generalmente resulta en una sobreestimación de la biomasa con importantes implicaciones globales (Feldpausch et al., 2012; Lagomasino et al., 2016).

En términos de monitoreo y estimaciones de la estructura forestal en manglares, la PR presenta varios desafíos y oportunidades futuras, como la elección de datos, sensores y la variedad de enfoques y metodologías disponibles (Cartus et al., 2012; Pham et al., 2019). Actualmente, son necesarios estudios a mayor escala y más completos en términos de cantidad y calidad de datos (Balenić et al., 2015; Krauze et al., 2019). Las direcciones futuras en el estudio de los parámetros de la estructura forestal deben centrarse en la integración de datos de múltiples sensores remotos (Pham et al., 2019). Esto brindará la oportunidad a la integración de diferentes sensores remotos para realizar cálculos de biomasa aérea a gran escala (Pham et al., 2019).

Conclusiones

Se realizó con éxito una caracterización reciente de la cobertura de manglar del área de la RBMN estimando una cobertura estacional (estación lluviosa / estación seca) que alcanza una precisión del 85% para la imagen de la época seca. Las alturas del dosel modeladas mediante una técnica de fotogrametría aérea se calcularon con una precisión del 89% en comparación con las mediciones reales de campo. Los índices multiespectrales derivados de las escenas Landsat 8 (OLI) revelaron al NDVI, NDWI_{MC} y GRVI como los mejores predictores de altura regional, obteniendo valores de coeficiente R^2 entre 0.62 y 0.74. Las escenas de la época seca fueron más adecuadas para calcular índices multiespectrales. La incorporación de datos SAR con índices multiespectrales en la estimación de la proyección de altura no mejora significativamente los resultados del modelo.

Estos resultados pueden ayudar a los tomadores de decisiones en la coordinación de esfuerzos en los programas de monitoreo, así como para la restauración y protección de los ecosistemas de manglares. Sin embargo, deben tomarse con precaución ya que se deben considerar más mediciones de campo o agregar levantamientos fotogramétricos distribuidos homogéneamente.

Referencias

- Adame, M. F., Kauffman, J. B., Medina, I., Gamboa, J. N., Torres, O., Caamal, J. P., Reza, M. & Herrera-Silveira, J.A. 2013. Carbon stocks of tropical coastal wetlands within the karstic landscape of the Mexican Caribbean. *PLoS ONE*, 8: e56569. Doi: 10.1371/journal.pone.0056569
- Alatorre, L. C., Sánchez-Andrés, R., Cirujano, S., Beguería, S., & Sánchez-Carrillo, S. 2011. Identification of mangrove areas by remote sensing: The ROC curve technique applied to the northwestern Mexico coastal zone using Landsat imagery. *Remote Sensing*, 3(8), 1568-1583. Doi: 10.3390/rs3081568
- Alongi, D.M. 2012. Carbon sequestration in mangrove forests. *Carbon Management* 3: 313–322. Doi: 10.4155/cmt. 12.20
- ASF [Alaska Satellite Facility], 2018. How to Create a DEM using Sentinel-1 Data v.1.3. Fairbanks, AK 99775, Alaska, EUA. Disponible en: <https://asf.alaska.edu/how-to/data-recipes/create-a-dem-using-sentinel-1-data/> consultada [25-12-2019].
- Baltzer, H., Rowland, C. S., & Saich, P. 2007. Forestry canopy height and carbon estimation at Monks Wood National Nature Reserve, UK, using dual-wavelength SAR interferometry. *Remote Sensing of Environment*, 108(3), 224-239. Doi: 10.1016/j.rse.2006.11.014
- Balenović, I., Seletković, A., Pernar, R., & Jazbec, A. 2015. Estimation of the mean tree height of forest stands by photogrammetric measurement using digital aerial images of high spatial resolution. *Annals of Forest Research*, 58(1), 125-143. Doi: 10.15287/afr.2015.300
- Baloloy, A. B., Blanco, A. C., Candido, C. G., Argamosa, R. J. L., Dumalag, J. B. L. C., Dimapilis, L. L. C., & Paringit, E. C. 2018. Estimation of mangrove forest aboveground biomass using multispectral bands, vegetation indices and biophysical variables derived from optical satellite imageries: rapideye, planetscope and sentinel-2. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 4(3). Doi: 10.5194/isprs-annals-IV-3-29-2018

- Boegh, E., Soegaard, H., Broge, N., Hasager, C. B., Jensen, N. O., Schelde, K., & Thomsen, A. 2002. Airborne multispectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture. *Remote sensing of Environment*, 81(2-3), 179-193. Doi: 10.1016/S0034-4257(01)00342-X
- Cartus, O., Santoro, M., & Kellndorfer, J. (2012). Mapping forest aboveground biomass in the northeastern United States with ALOS PALSAR dual-polarization L-band. *Remote Sensing of Environment*, 124, 466–478. Doi: 10.1016/j.rse.2012.05.029
- Castillo, J. A. A., Apan, A. A., Maraseni, T. N., & Salmo III, S. G. 2017. Estimation and mapping of above-ground biomass of mangrove forests and their replacement land uses in the Philippines using Sentinel imagery. *ISPRS. Journal of Photogrammetry and Remote Sensing*, 134, 70-85. Doi: 10.1016/j.isprsjprs.2017.10.016
- Comisión Nacional de Áreas Naturales Protegidas (CONANP), 2013. Programa De Manejo Reserva De La Biosfera Marismas Nacionales Nayarit, CONANP, Ciudad de México, Mexico, p. 199p.
- CONABIO [Comisión Nacional para el Conocimiento y Uso de la Biodiversidad]. 2021. Geoportel del Sistema Nacional de Información sobre Biodiversidad. CONABIO. Available at: http://geoportel.conabio.gob.mx/#!=-mx_man20gw:1@m=mixto
- Congalton, R. G., & Green, K. 2019. Assessing the accuracy of remotely sensed data: principles and practices. CRC press.
- Crippen, R. E. 1990. Calculating the vegetation index faster. *Remote Sensing of Environment*, 34, 71–73. Doi: 10.1016/0034-4257(90)90085-Z
- Cunliffe, A. M., Assmann, J. J., Daskalova, G. N., Kerby, J. T., & Myers-Smith, I. H. 2020. Aboveground biomass corresponds strongly with drone-derived canopy height but weakly with greenness (NDVI) in a shrub tundra landscape. *Environmental Research Letters*, 15(12), 125004. Doi: 10.5285/61C5097B-6717-4692-A8A4-D32CCA0E61A9)
- de Alckmin, G. T., Kooistra, L., Rawnsley, R., & Lucieer, A. 2021. Comparing methods to estimate perennial ryegrass biomass: Canopy height and spectral vegetation indices. *Precision Agriculture*, 22(1), 205-225. Doi: 10.1007/s11119-020-09737-z

- De Souza-Pereira, F. R., Kampel, M., & Cunha-Lignon, M. 2016. Mangrove vegetation structure in Southeast Brazil from phased array L-band synthetic aperture radar data. *Journal of Applied Remote Sensing*, 10(3), 036021. Doi: 10.1117/1.JRS.10.036021
- Eastman, J.R. 2016. IDRISI Terrset Manual. Clark Labs-Clark University: Worcester, MA, USA.
- Fayad, I., Baghdadi, N., Guitet, S., Bailly, J.-S., Hérault, B., Gond, V., El Hajj, M. & Tong, D.H.M. 2016. Aboveground biomass mapping in French Guiana by combining remote sensing, forest inventories and environmental data. *International Journal of Applied Earth Observation and Geoinformation* 52, 502-514. Doi: 10.1016/j.jag.2016.07.015
- Feldpausch, T. R., Lloyd, J., Lewis, S. L., Brien, R. J., Gloor, M., Monteagudo Mendoza, A., & Alexiades, M. 2012. Tree height integrated into pantropical forest biomass estimates. *Biogeosciences*, 3381-3403. Doi: 10.5194/bg-9-3381-2012
- Gao, B. 1996. NDWI — A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58, 257–266. Doi: 10.1016/S0034-4257(96)00067-3
- García, M., Saatchi, S., Casas, A., Koltunov, A., Ustin, S.L., Ramirez, C. & Balzter, H. 2018. Extrapolating forest canopy fuel properties in the California rim fire by combining airborne LiDAR and Landsat OLI data. *Remote Sensing* 9 (4), 394. Doi: 10.3390/rs9040394
- Glenn, E. P., Huete, A. R., Nagler, P. L., & Nelson, S. G. (2008). Relationship between remotely-sensed vegetation indices, canopy attributes and plant physiological processes: What vegetation indices can and cannot tell us about the landscape. *Sensors*, 8(4), 2136-2160. Doi: 10.3390/s8042136
- Hernández-Guzmán, R., Ruiz-Luna, A. & Cervantes-Escobar A. 2019. Environmental flow assessment for rivers feeding a coastal wetland complex in the Pacific coast of northwest Mexico. *Water and Environment Journal*, 33(4): 536-546. Doi: 10.1111/wej.12423.
- Huete, A. R., Justice, C., & Liu, H. 1994. Development of vegetation and soil indices for MODIS-EOS. *Remote Sensing of Environment*, 49, 224–234 Doi: 10.1016/0034-4257(94)90018-3

- Kauffman, J.B., D.C. Donato & M.F. Adame. 2013. Protocolo para la medición, monitoreo y reporte de la estructura, biomasa y reservas de carbono de los manglares. Documento de Trabajo 117. Cifor. Bogor.
- Kattenborn, T., Lopatin, J., Förster, M., Braun, A. C., & Fassnacht, F. E. 2019. UAV data as alternative to field sampling to map woody invasive species based on combined Sentinel-1 and Sentinel-2 data. *Remote sensing of environment*, 227, 61-73. Doi:10.1016/j.rse.2019.03.025
- Kearsley, E., De Haulleville, T., Hufkens, K., Kidimbu, A., Toirambe, B., Baert, G., & Beeckman, H., Steppe, K., Boeckx, P., & Verbeeck, H. 2013. Conventional tree height–diameter relationships significantly overestimate aboveground carbon stocks in the Central Congo Basin. *Nature communications*, 4(1), 1-8. Doi: 10.1038/ncomms3269
- Kelleway, J. J., Cavanaugh, K., Rogers, K., Feller, I. C., Ens, E., Doughty, C., & Saintilan, N. 2017. Review of the ecosystem service implications of mangrove encroachment into salt marshes. *Global Change Biology*, 23(10), 3967-3983. Doi: 10.1111/gcb.13727
- Klosterman, S., Melaas, E., Wang, J., Martinez, A., Frederick, S., O’keefe, J., Orwig, D.A., Wang, Z., Sun, Q., Schaaf, C., Friedl, M. & Richardson, A.D. 2018. Fine-scale perspectives on landscape phenology from unmanned aerial vehicle (UAV) photography. *Agricultural and Forest Meteorology* 248: 397-407. Doi: 10.1016/j.agrformet.2017.10.015
- Köhl, M., Magnussen, S. S., & Marchetti, M. 2006. Sampling methods, remote sensing and GIS multiresource forest inventory. Springer Science & Business Media
- Krause, S., Sanders, T. G., Mund, J. P., & Greve, K. 2019. UAV-based photogrammetric tree height measurement for intensive forest monitoring. *Remote sensing*, 11(7), 758. Doi: 10.3390/rs11070758
- Kuenzer, C., Bluemel, A., Gebhardt, S., Quoc, T. V., & Dech, S. (2011). Remote sensing of mangrove ecosystems: A review. *Remote Sensing*, 3(5), 878-928. Doi: Doi: 10.3390/rs3050878
- Kumar, L., Mutanga, O., 2017. Remote sensing of above-ground biomass. *Remote Sens.* 9, 1–8. Doi.org/10.3390/rs9090935

- Laurin, G. V., Balling, J., Corona, P., Mattioli, W., Papale, D., Puletti, N., & Urban, M. 2018. Above-ground biomass prediction by Sentinel-1 multitemporal data in central Italy with integration of ALOS2 and Sentinel-2 data. *Journal of Applied Remote Sensing*, 12(1), 016008. Doi: 10.1117/1.JRS.12.016008
- Lagomasino, D., Fatoyinbo, T., Lee, S., Feliciano, E., Trettin, C., & Simard, M. 2016. A comparison of mangrove canopy height using multiple independent measurements from land, air, and space. *Remote sensing*, 8(4), 327. Doi: 10.3390/rs8040327
- Lithgow, D., de la Lanza, G. & Silva R. 2019. Ecosystem-Based management strategies to improve aquaculture in developing countries: Case study of Marismas Nacionales. *Ecological Engineering*, 130, 296-305. Doi: 10.1016/j.ecoleng.2017.06.039
- Lisein, J., Pierrot-Deseilligny, M., Bonnet, S., & Lejeune, P. 2013. A photogrammetric workflow for the creation of a forest canopy height model from small unmanned aerial system imagery. *Forests*, 4(4), 922-944.
- Louhaichi, M., Borman, M. M., & Johnson, D. E. 2001. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, 16(1), 65-70. Doi: 10.1080/10106040108542184
- Lucas, R. M., Mitchell, A. L., Rosenqvist, A. K. E., Proisy, C., Melius, A., & Ticehurst, C. 2007. The potential of L-band SAR for quantifying mangrove characteristics and change: case studies from the tropics. *Aquatic conservation: marine and freshwater ecosystems*, 17(3), 245-264. Doi: 10.1002/aqc.833
- Lukas, V., Novák, J., Neudert, L., Svobodova, I., Rodriguez-Moreno, F., Edrees, M., & Kren, J. (2016). The combination of UAV survey and landsat imagery for monitoring of crop vigor in precision agriculture. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 8. Doi: 10.5194/isprsarchives-XLI-B8-953-2016
- Maimaitijiang, M., Sagan, V., Sidike, P., Daloye, A. M., Erkbol, H., & Fritschi, F. B. 2020. Crop monitoring using satellite/UAV data fusion and machine learning. *Remote Sensing*, 12(9), 1357. Doi: 10.3390/rs12091357
- McFeeters, S. K. 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International journal of remote sensing*, 17(7), 1425-1432. Doi: 10.1080/01431169608948714

- Menéndez, P., Losada, I. J., Torres-Ortega, S., Narayan, S., & Beck, M. W. 2020. The global flood protection benefits of mangroves. *Scientific Reports*, 10(1): 4404. Doi: 10.1038/s41598-020-61136-6
- Moity, N., Delgado, B., & Salinas-de-León, P. 2019. Mangroves in the Galapagos Islands: Distribution and dynamics. *PloS one*, 14(1), e0209313. Doi: 10.1371/journal.pone.0209313
- Morel, A. C., Saatchi, S. S., Malhi, Y., Berry, N. J., Banin, L., Burslem, D., & Ong, R. C. 2011. Estimating aboveground biomass in forest and oil palm plantation in Sabah, Malaysian Borneo using ALOS PALSAR data. *Forest Ecology and Management*, 262(9), 1786-1798. Doi: 10.1016/j.foreco.2011.07.008
- Mougin, E., Proisy, C., Marty, G., Fromard, F., Puig, H., Betouille, J. L., & Rudant, J. P. 1999. Multifrequency and multipolarization radar backscattering from mangrove forests. *IEEE Transactions on Geoscience and Remote Sensing*, 37(1), 94-102. Doi: 10.1109/36.739128
- Navarro, J. A., Algeet, N., Fernández-Landa, A., Esteban, J., Rodríguez-Noriega, P., & Guillén-Climent, M. L. 2019. Integration of uav, sentinel-1, and sentinel-2 data for mangrove plantation aboveground biomass monitoring in Senegal. *Remote Sensing*, 11(1), 77. Doi: 10.3390/rs11010077
- Navarro, J. A., Young, M., Allan, B., Carnell, P., Macreadie, P., & Ierodiaconou, D. 2020. The application of Unmanned Aerial Vehicles (UAVs) to estimate above-ground biomass of mangrove ecosystems. *Remote Sensing of Environment*, 242, 111747. Doi: 10.1016/j.rse.2020.111747
- Pajares, G. 2015. Overview and current status of remote sensing applications based on unmanned aerial vehicles (UAVs). *Photogrammetric Engineering & Remote Sensing*, 81(4), 281-330. Doi: 10.14358/PERS.81.4.281
- Pham, T. D., Yokoya, N., Bui, D. T., Yoshino, K., & Friess, D. A. 2019. Remote sensing approaches for monitoring mangrove species, structure, and biomass: Opportunities and challenges. *Remote Sensing*, 11(3), 230. Doi: 10.3390/rs11030230
- Price, K. P., Guo, X., & Stiles, J. M. 2002. Optimal Landsat TM band combinations and vegetation indices for discrimination of six grassland types in eastern Kansas.

- International Journal of Remote Sensing*, 23(23), 5031-5042. Doi: 10.1080/01431160210121764
- Purnamasayangasukasih, P. R., Norizah, K., Ismail, A. A., & Shamsudin, I. 2016. A review of uses of satellite imagery in monitoring mangrove forests. In IOP Conference Series: *Earth and Environmental Science* (Vol. 37, No. 1, p. 012034). IOP Publishing. Doi:10.1088/1755-1315/37/1/012034
- Rahman, A. F., & Aslan, A. 2017. The first global-scale 30 m resolution mangrove canopy height map using Shuttle Radar Topography Mission data. arXiv preprint arXiv:1706.09958
- Riel, B., Denbina, M., & Lavalley, M. 2018. Uncertainties in forest canopy height estimation from Polarimetric Interferometric SAR data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3478-3491. Doi: 10.1109/JSTARS.2018.2867789
- Rodríguez-Veiga, P., Saatchi, S., Tansey, K., & Balzter, H. 2016. Magnitude: spatial distribution and uncertainty of forest biomass stocks in Mexico. *Remote Sensing of Environment*, 183, 265-281.
- Rodríguez-Zúñiga, M.T., Villeda Chávez, E., Vázquez-Lule, A.D., Bejarano, M., Cruz-López, M.I., Olguín, M., Villela Gaytán, S.A. & Flores, R. (Coordinadores) 2018. Métodos para la caracterización de los manglares mexicanos: un enfoque espacial multiescala. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. Ciudad de México. 272 pp. Doi: 10.1016/j.rse.2016.06.004
- Romañach, S. S., DeAngelis, D. L., Koh, H. L., Li, Y., Teh, S. Y., Barizan, R. S. R., & Zhai, L. 2018. Conservation and restoration of mangroves: Global status, perspectives, and prognosis. *Ocean & Coastal Management*, 154, 72-82. Doi: 10.1016/j.ocecoaman.2018.01.009
- Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W., Harlan, J.C., 1974. In: NASA/GSFC (Ed.), Monitoring the vernal advancements and retrogradation of natural vegetation-final report. Greenbelt, MD, USA, pp. 1-137
- Roujean, J. L., & Breon, F. M. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of the Environment*, 51, 375-384. Doi: 10.1016/0034-4257(94)00114-3

- Ruiz-Luna, A., Cervantes-Escobar, A. & Berlanga-Robles, C. 2010. Assessing distribution patterns, extent and current condition of Northwest Mexico mangroves. *Wetlands*, 30, 717–723, 2010. Doi: 10.1007/s13157-010-0082-2
- Simard, M., & Denbina, M. 2017. An assessment of temporal decorrelation compensation methods for forest canopy height estimation using airborne L-band same-day repeat-pass polarimetric SAR interferometry. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(1), 95-111. Doi: 10.1109/JSTARS.2017.2761338
- Simard, M., Fatoyinbo, T., Smetana, C., Rivera-Monroy, V.H., Castaneda-moya, E., Thomas, N., & Van der stocken T. 2019. Global mangrove distribution, aboveground biomass, and canopy height. ORNL DAAC, Oak Ridge, Tennessee, USA. Doi: 10.3334/ORNLDAAC/1665
- Simard, M., Fatoyinbo, L., Smetana, C., Rivera-Monroy, V. H., Castañeda-Moya, E., Thomas, N., & Van der Stocken, T. 2019. Mangrove canopy height globally related to precipitation, temperature and cyclone frequency. *Nature Geoscience*, 12(1), 40-45. Doi: 10.1038/s41561-018-0279-1
- Sinha, S., Jeganathan, C., Sharma, L. K., & Nathawat, M. S. 2015. A review of radar remote sensing for biomass estimation. *International Journal of Environmental Science and Technology*, 12(5), 1779-1792. Doi: 10.1007/s13762-015-0750-0
- Sripada, R. P., Heiniger, R. W., White, J. G., & Weisz, R. 2005. Aerial color infrared photography for determining late-season nitrogen requirements in corn. *Agronomy Journal*, 97(5), 1443-1451. Doi: 10.2134/agronj2004.0314
- Stringer, C. E., Trettin, C. C., Zarnoch, S. J., & Tang, W. 2015. Carbon stocks of mangroves within the Zambezi River Delta, Mozambique. *Forest Ecology and Management*, 354, 139-148. Doi: 10.1016/j.foreco.2015.06.027
- Sullivan, F. B., Ducey, M. J., Orwig, D. A., Cook, B., & Palace, M. W. 2017. Comparison of lidar-and allometry-derived canopy height models in an eastern deciduous forest. *Forest Ecology and Management*, 406, 83-94. Doi: 10.1016/j.foreco.2017.10.005
- Téllez-García, C. P., & Valdez-Hernández, J. I. 2012. Caracterización estructural del manglar en el estero Palo Verde, laguna de Cuyutlán, Colima. *Revista Chapingo serie ciencias forestales y del ambiente*, 18(3), 395-408.

- Torres-Sánchez, J., López-Granados, F., Borra-Serrano, I., & Peña, J. M. 2018. Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. *Precision Agriculture*, 19(1), 115-133. Doi: 10.1007/s11119-017-9502-0
- Tuominen, S., Balazs, A., Saari, H., Pölönen, I., Sarkeala, J., & Viitala, R. 2015. Unmanned aerial system imagery and photogrammetric canopy height data in area-based estimation of forest variables. *Silva Fennica*, 49. Doi: 10.14214/sf.1348
- Valderrama-Landeros, L. H., Rodríguez-Zúñiga, M. T., Troche-Souza, C., Velázquez-Salazar, S., Villeda-Chávez, E., Alcántara-Maya, J. A., Vásquez-Balderas, B., Cruz-López, M.I., & Ressler, R. 2017. Manglares de México: actualización y exploración de los datos del sistema de monitoreo 1970/1980-2015. Ciudad de México, *Comisión Nacional para el Conocimiento y Uso de la Biodiversidad*
- Warfield, A. D., & Leon, J. X. 2019. Estimating mangrove forest volume using terrestrial laser scanning and UAV-Derived structure-from-motion. *Drones*, 3(2), 32. Doi: 10.3390/drones3020032
- Winarso, G., Vetruta, Y., Purwanto, A. D., Anggraini, N., Darmawan, S., & Yuwono, D. M. 2017. Mangrove above ground biomass estimation using combination of Landsat 8 and ALOS PALSAR data. *International Journal of Remote Sensing and Earth Sciences (IJReSES)*, 12(2), 85-96. Doi: 10.30536/j.ijreses.2015.v12.a2687
- Xu, H., 2005. A study on information extraction of water body with the Modified Normalized Difference Water Index (MNDWI), *Journal of Remote Sensing*, 9(5):511–517.
- Zhang, C., Kovacs, J., Liu, Y., Flores-Verdugo, F., & Flores-de-Santiago, F. 2014. Separating mangrove species and conditions using laboratory hyperspectral data: A case study of a degraded mangrove forest of the Mexican Pacific. *Remote Sensing*, 6(12), 11673-11688. Doi: 10.3390/rs61211673
- Zheng, D., Rademacher, J., Chen, J., Crow, T., Bresee, M., Le Moine, J., & Ryu, S.-R. 2004. Estimating aboveground biomass using Landsat 7 ETM+ data across a managed landscape in northern Wisconsin, USA. *Remote Sensing of Environment*, 93(3), 402–411. Doi: 10.1016/j.rse.2004.08.008

Anexo 3.1. Levantamientos fotogramétricos.

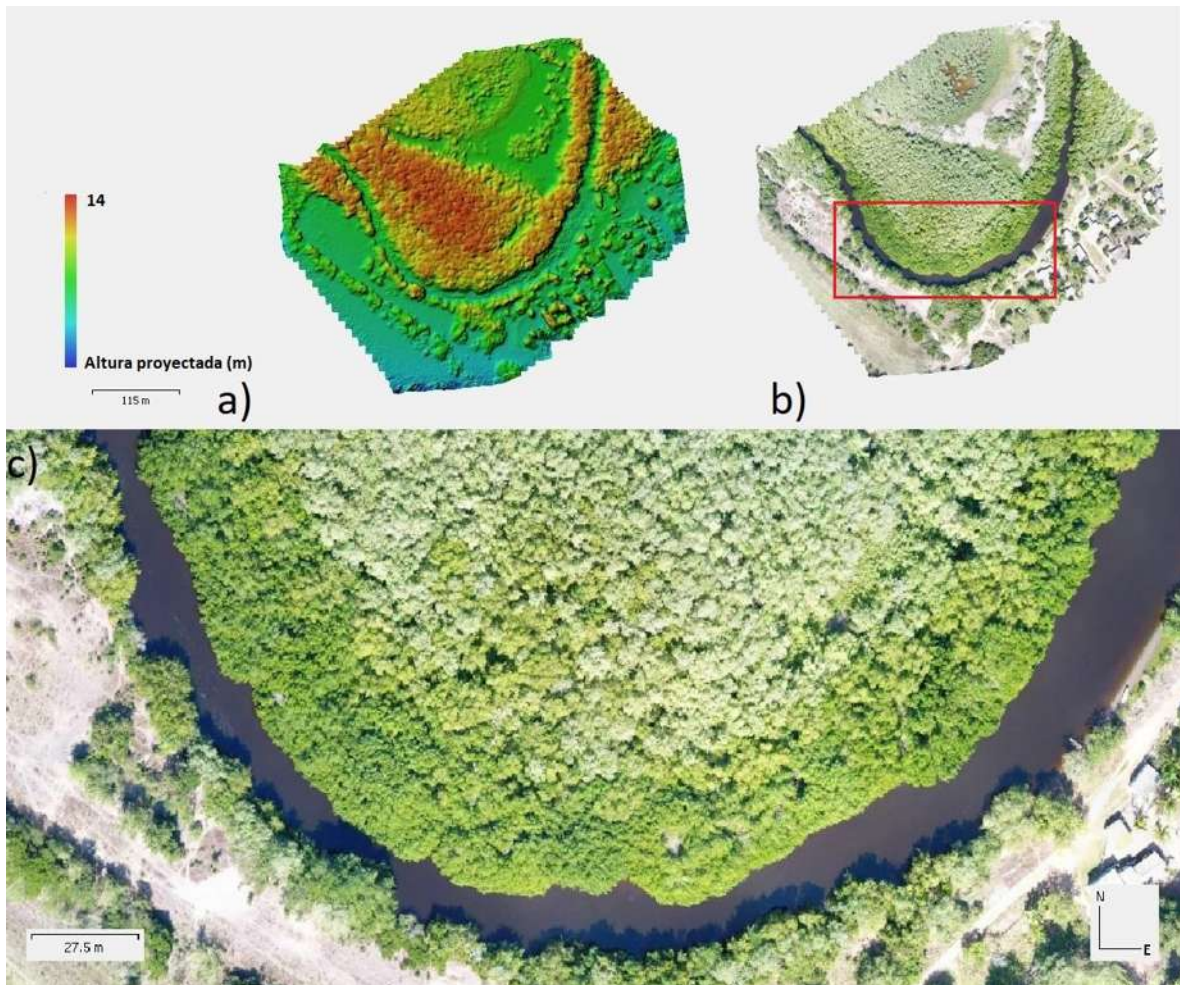


Figura. A3.1.1 Misión cerca de la laguna en Toromocho (21.755125 N, -105.451268 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.

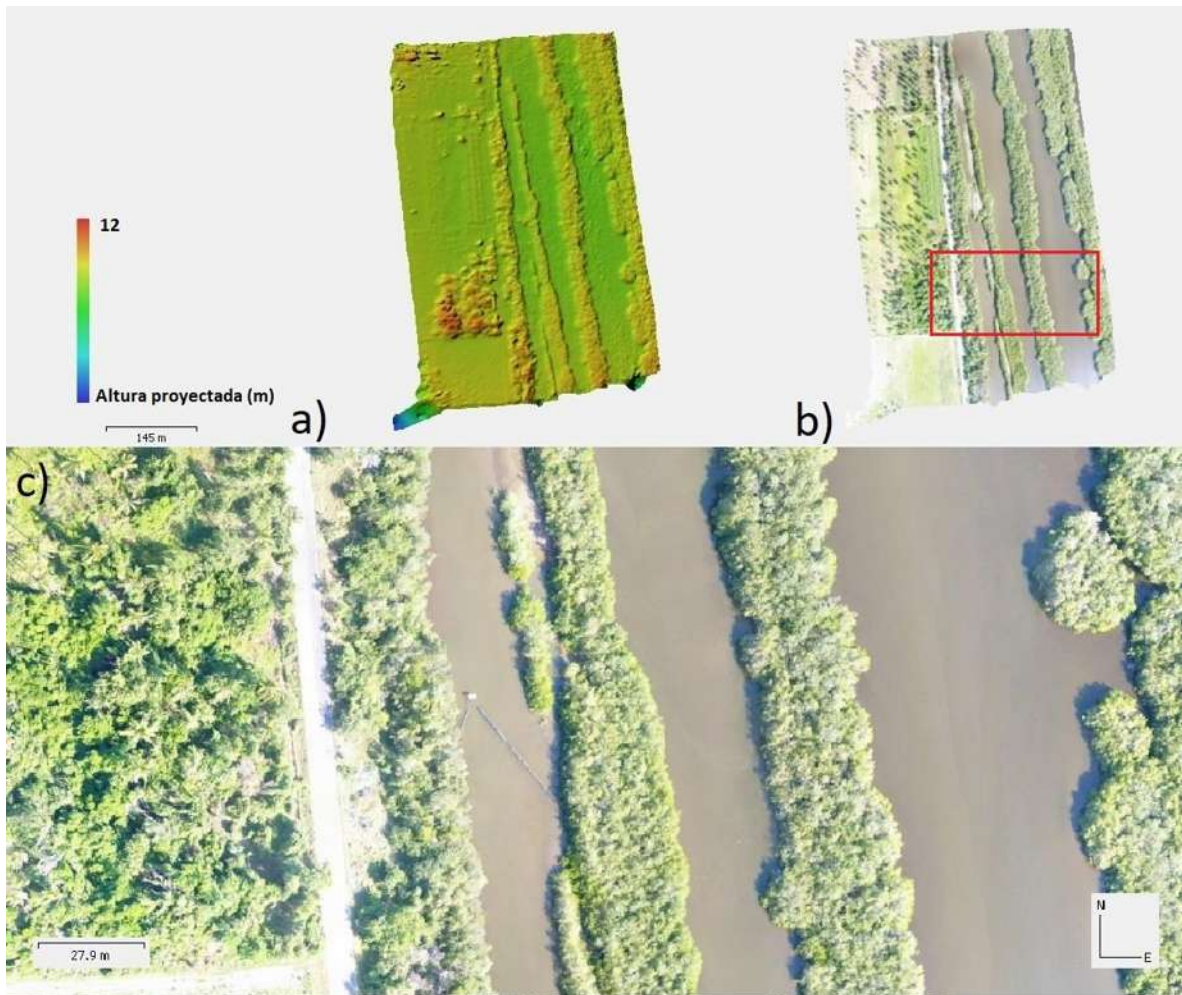


Figura. A3.1.2. Misión cerca del poblado de Palapares (22.099496 N, -105.62896 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/pixel); c) acercamiento del ortomosaico generado.

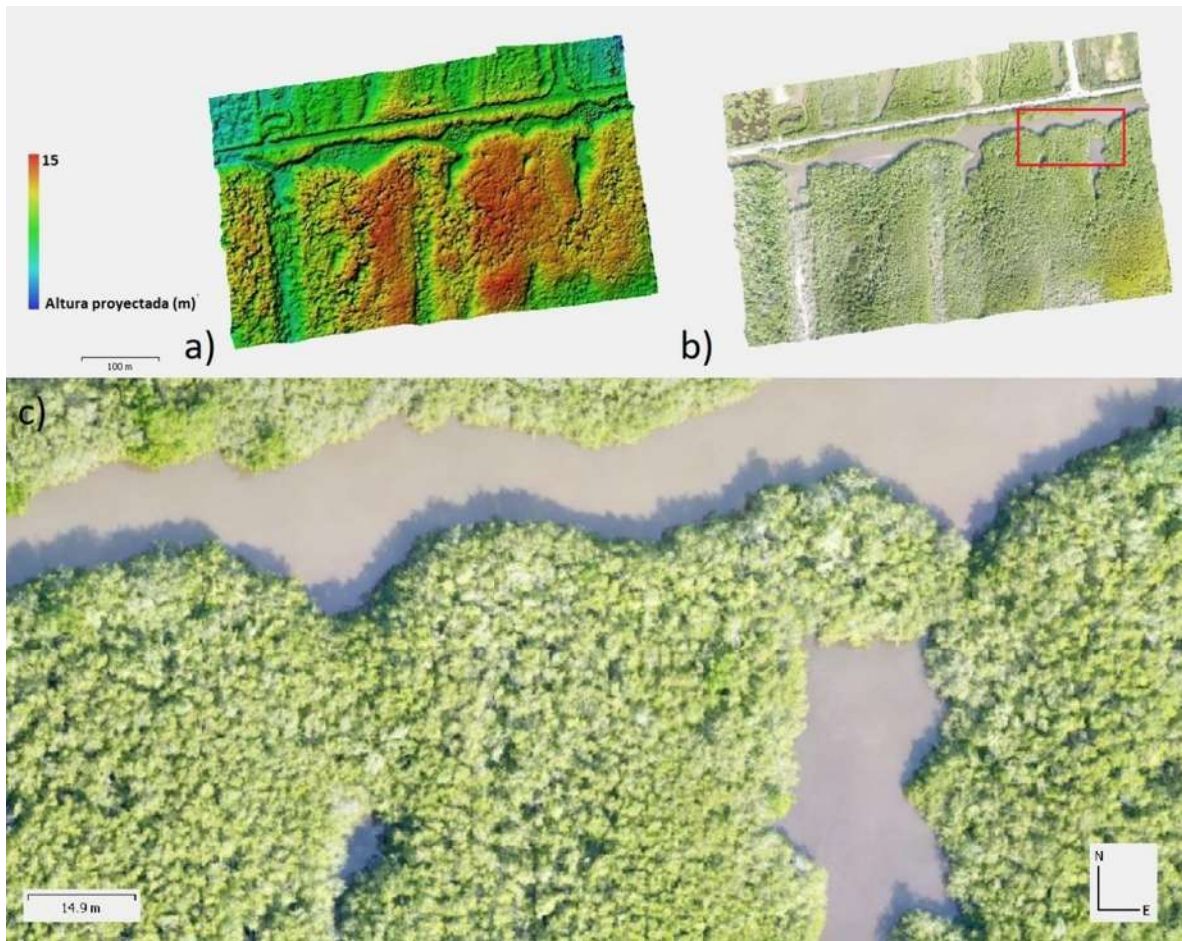


Figura. A3.1.3. Misión en carretera a Novillero (22.387601 N, -105.643472 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.

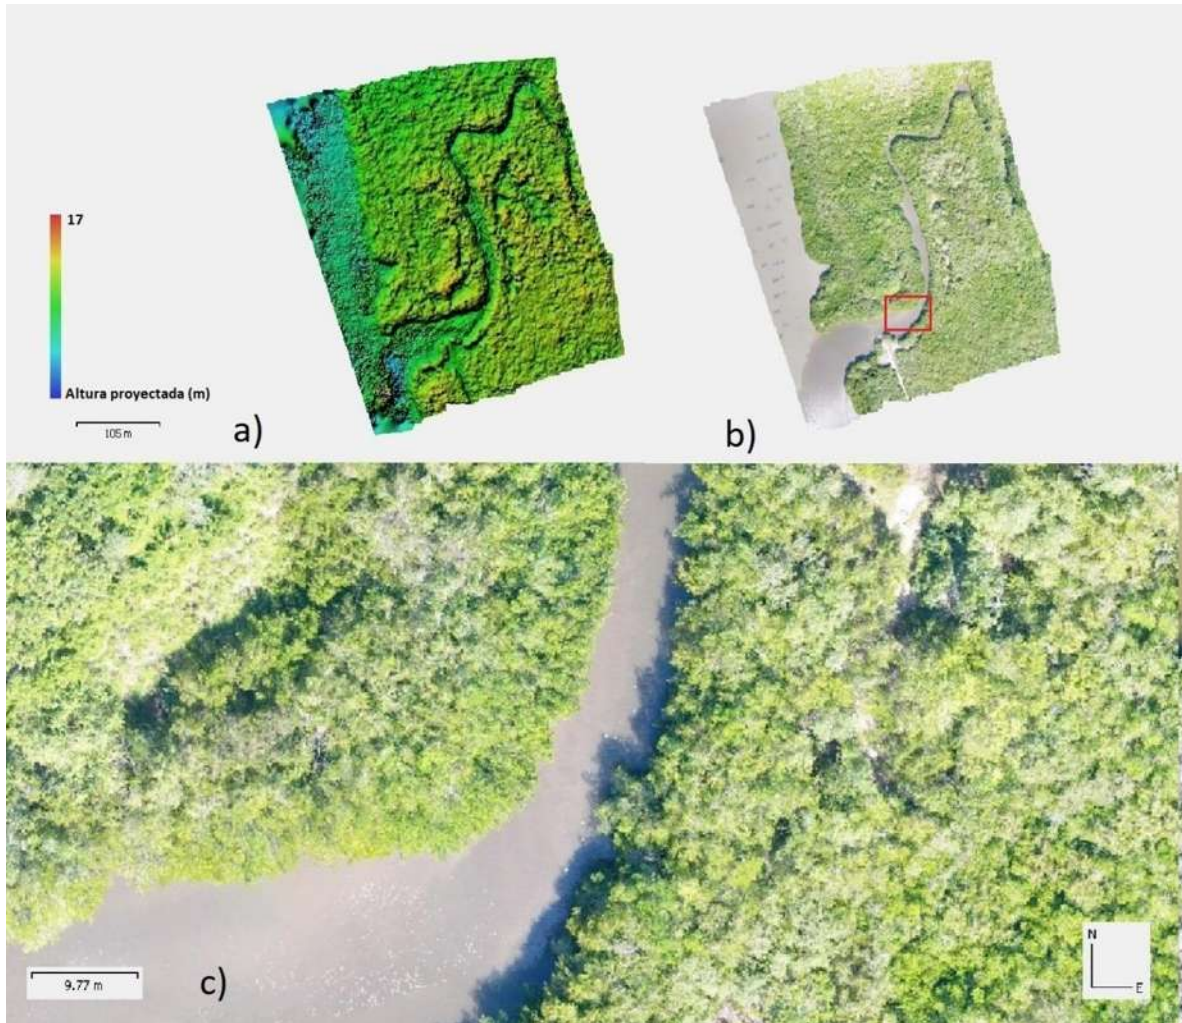


Figura. A3.1.4. Misión cerca de la laguna Bocas de Camichin (21.749239 N, -105.493153 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.

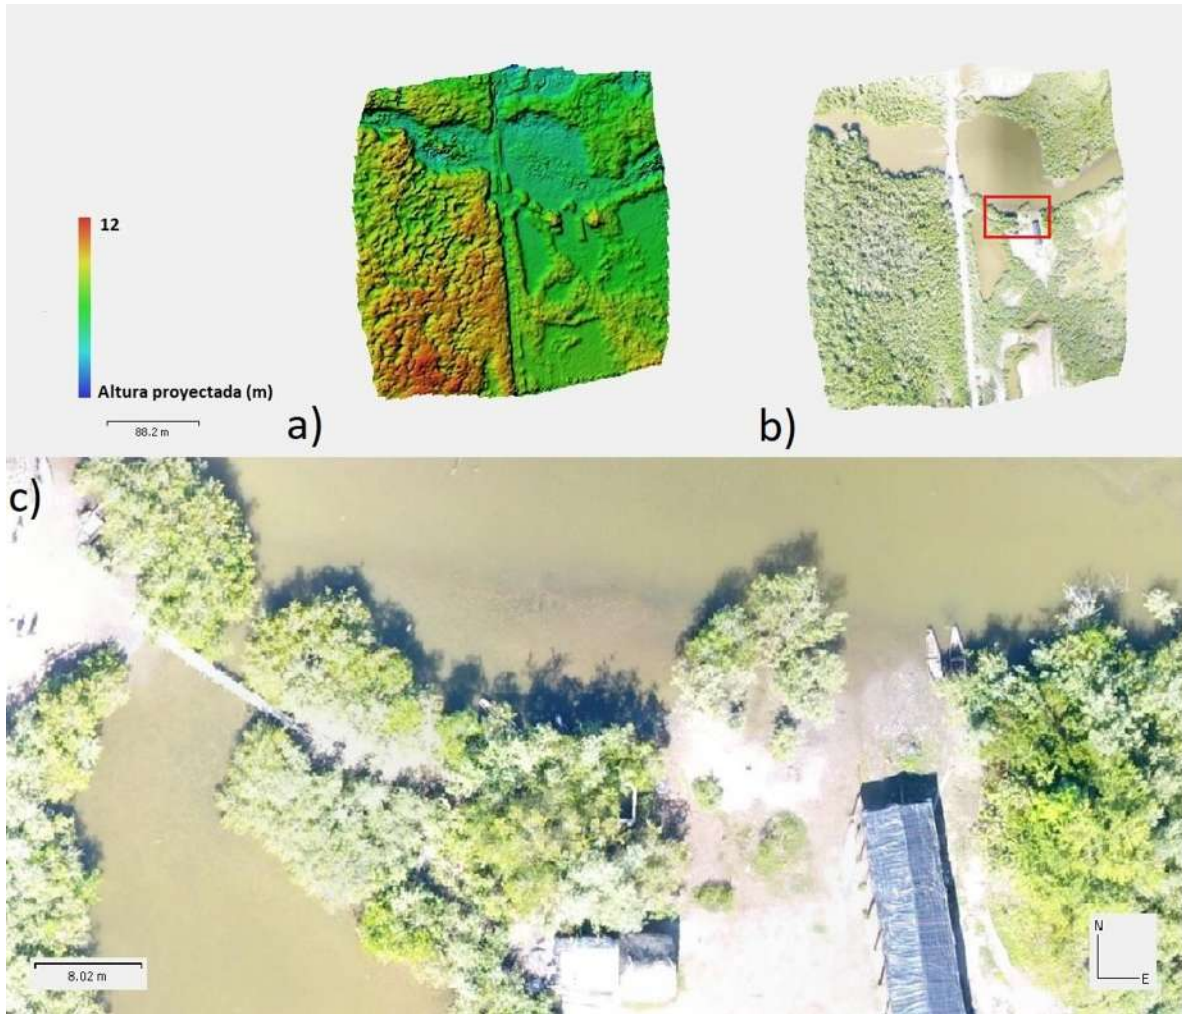


Figura. A3.1.5. Misión cerca al poblado de Arenitas (22.453714 N, -105.639195 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/pixel); c) acercamiento del ortomosaico generado.

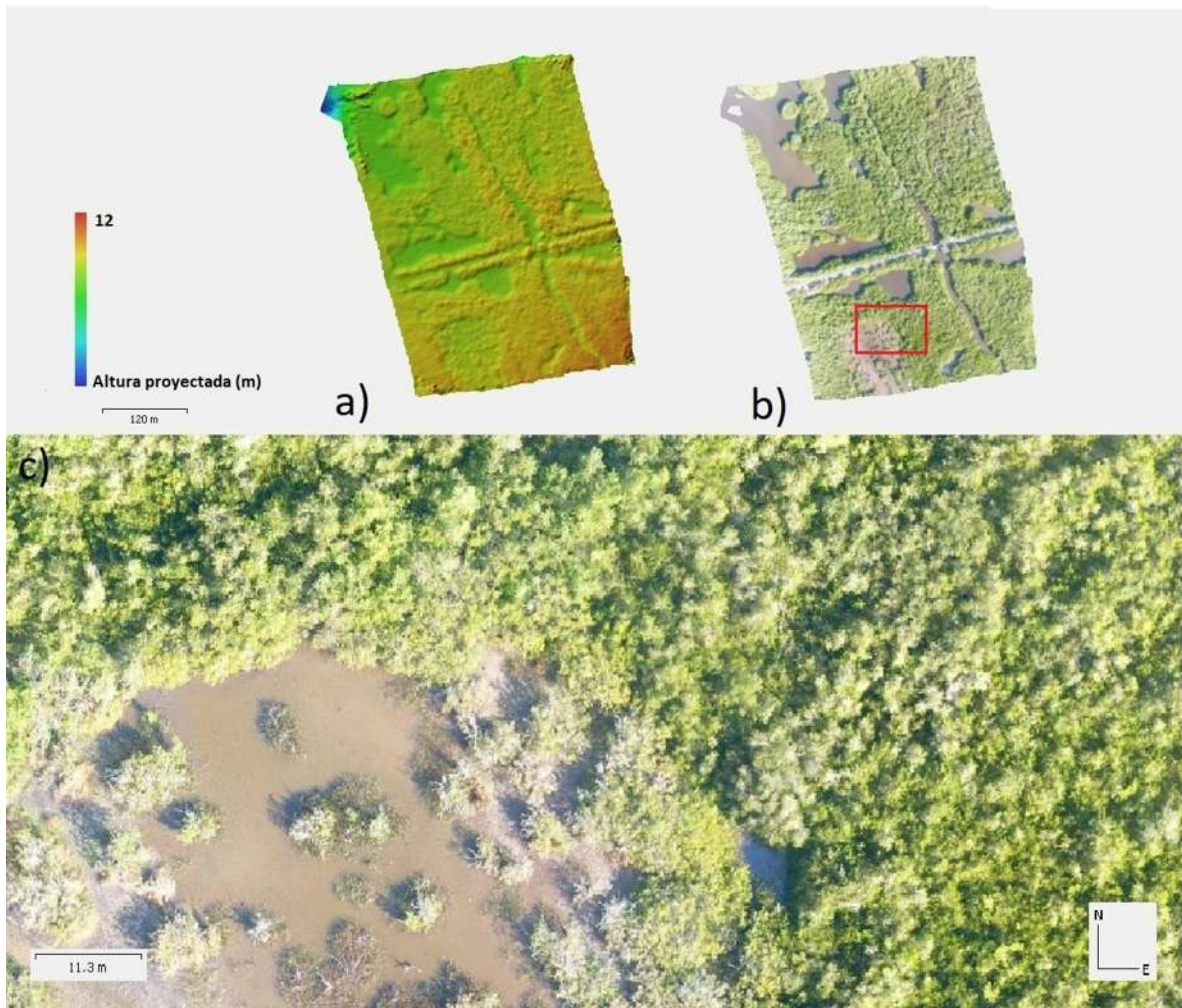


Figura. A3.1.6. Misión en la carretera a Mexcaltitán (21.971204 N, -105.522462 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.

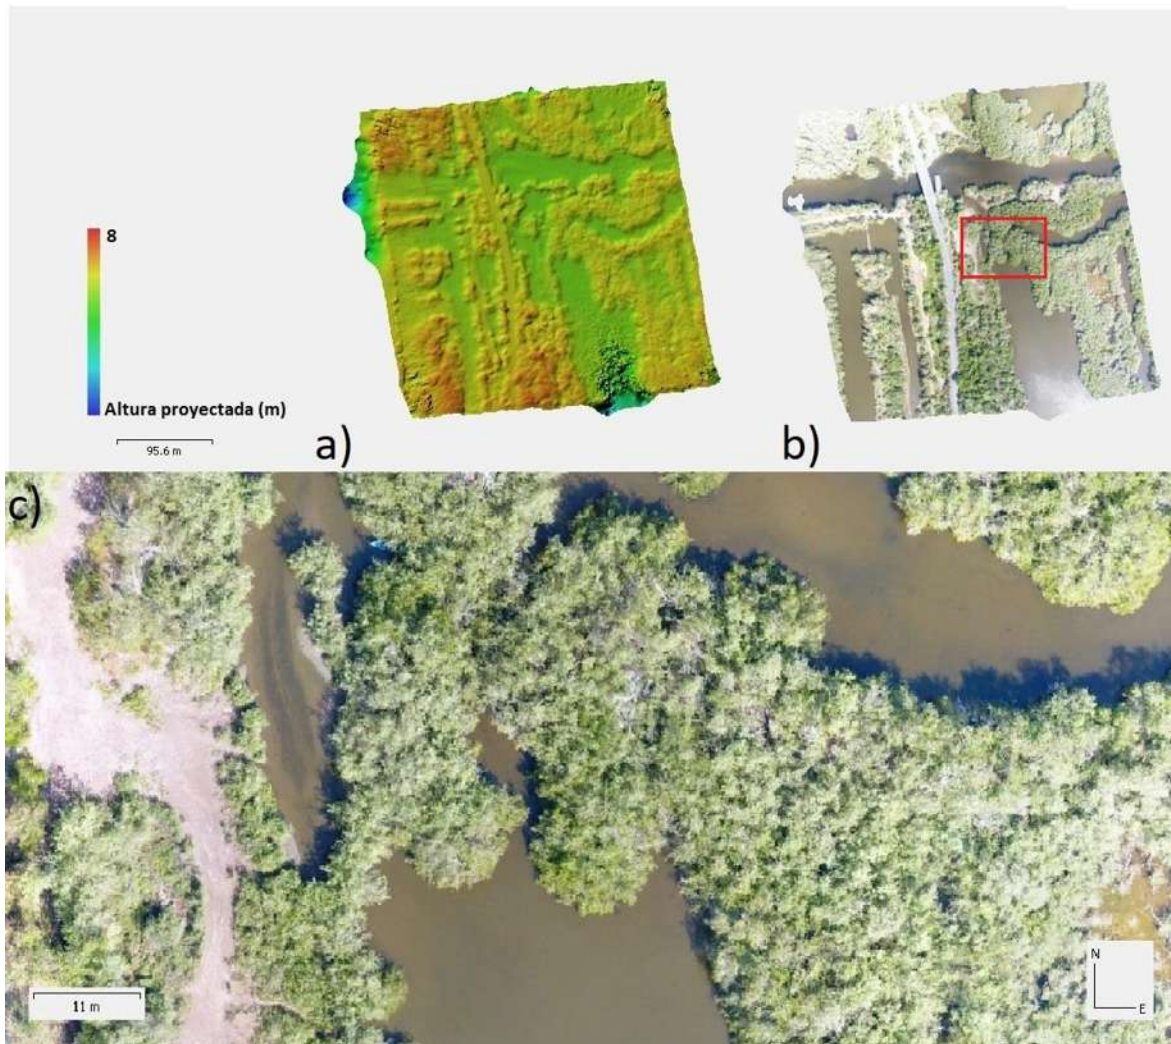


Figura. A3.1.7. Misión cercana al poblado Cuamecate (22.050876 N, -105.622945 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.




Figura. A3.1.8. Misión en la laguna aldeaña a Novillero (22.388223 N, -105.623121 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/pixel); c) acercamiento del ortomosaico generado.

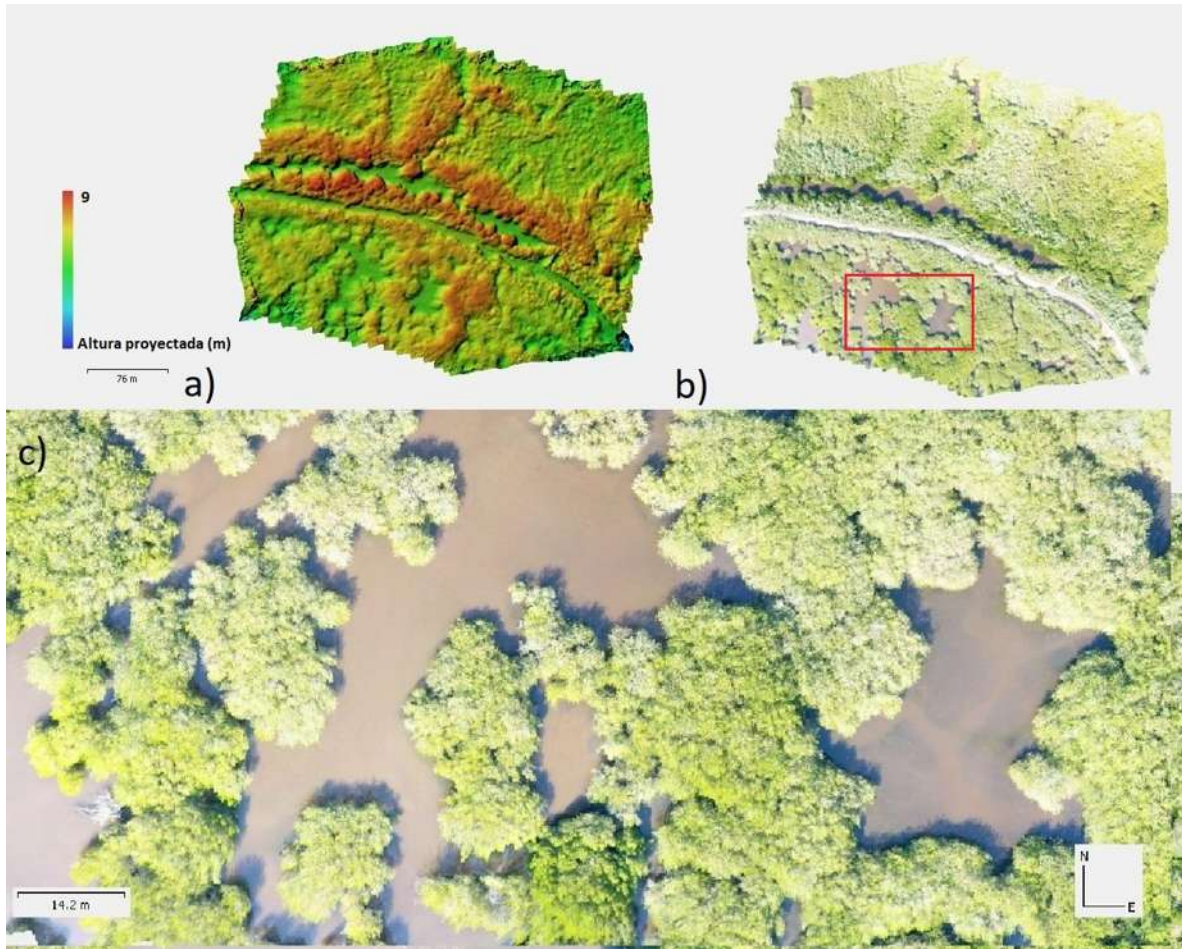


Figura. A3.1.9. Misión en poblado Pimientillo (22.038094 N, -105.430525 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.




Figura. A3.1.10. Misión en área cercana al poblado-zona de pesca Arenitas (22.453714 N, -105.639195 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.

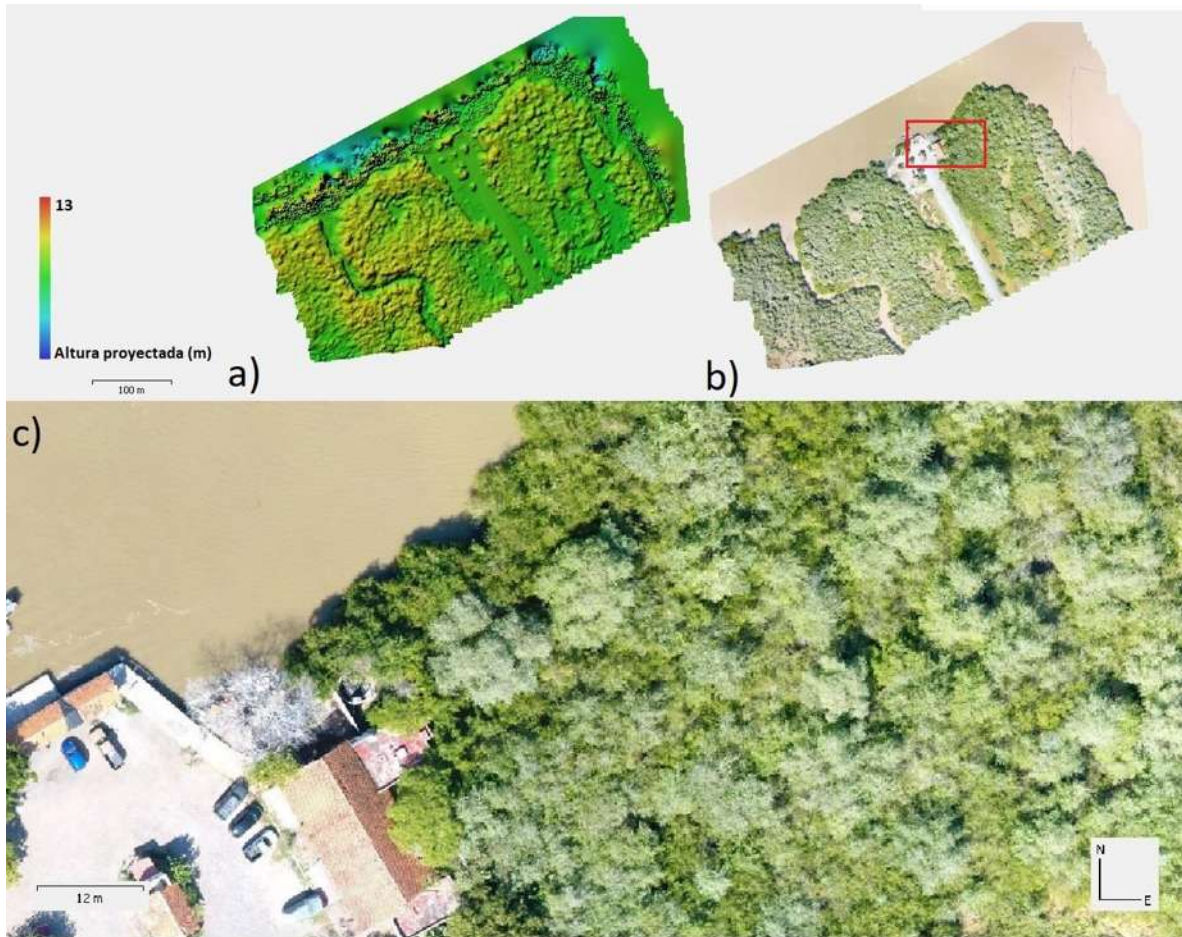


Figura. A3.1.11. Misión en laguna sur de Mexcaltitán (21.887837 N, -105.46197 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.

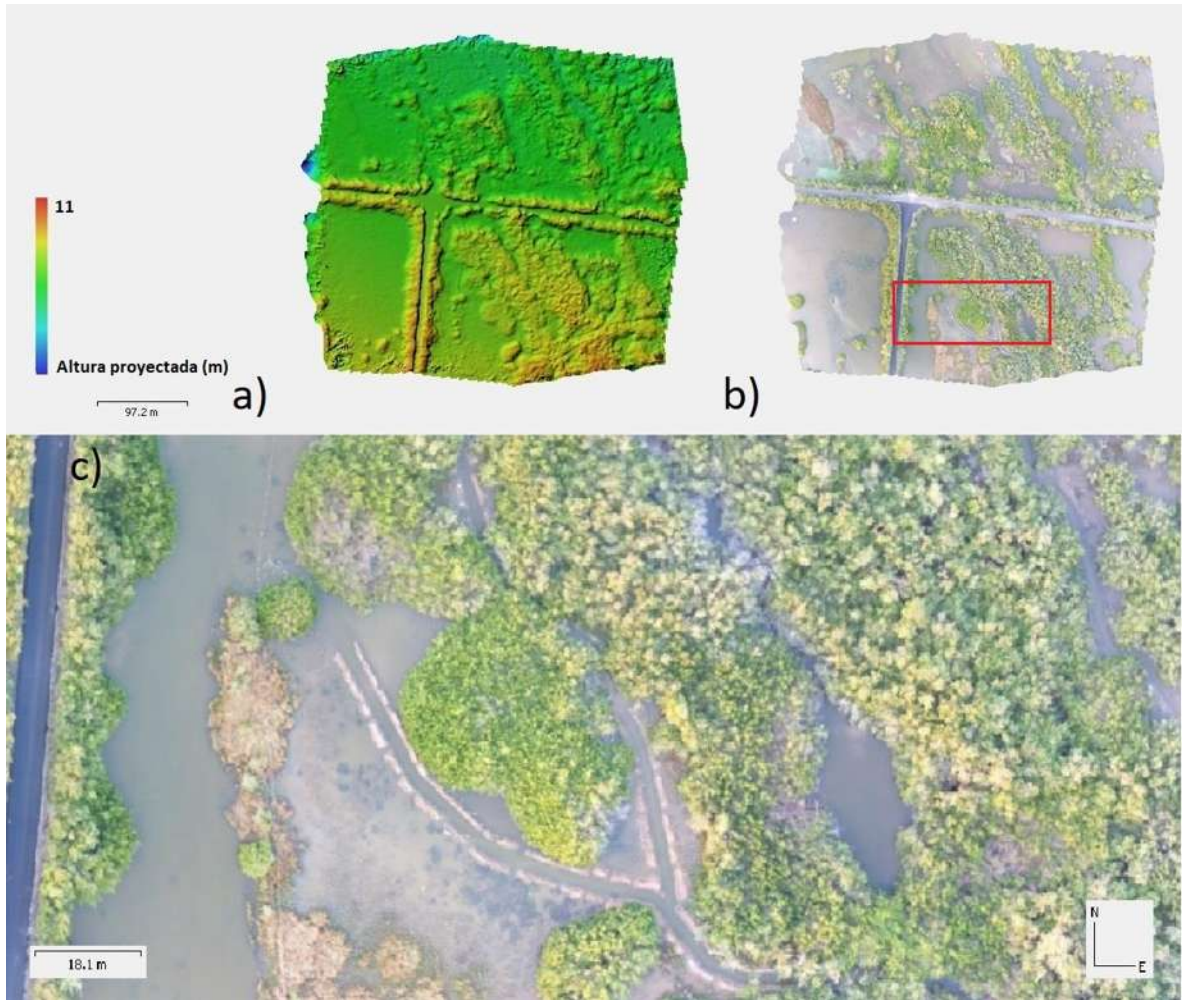


Figura. A3.1.12. Misión en el cruceiro a Mexcaltitán-Santa Cruz (21.972253 N, -105.512211 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/pixel); c) acercamiento del ortomosaico generado.

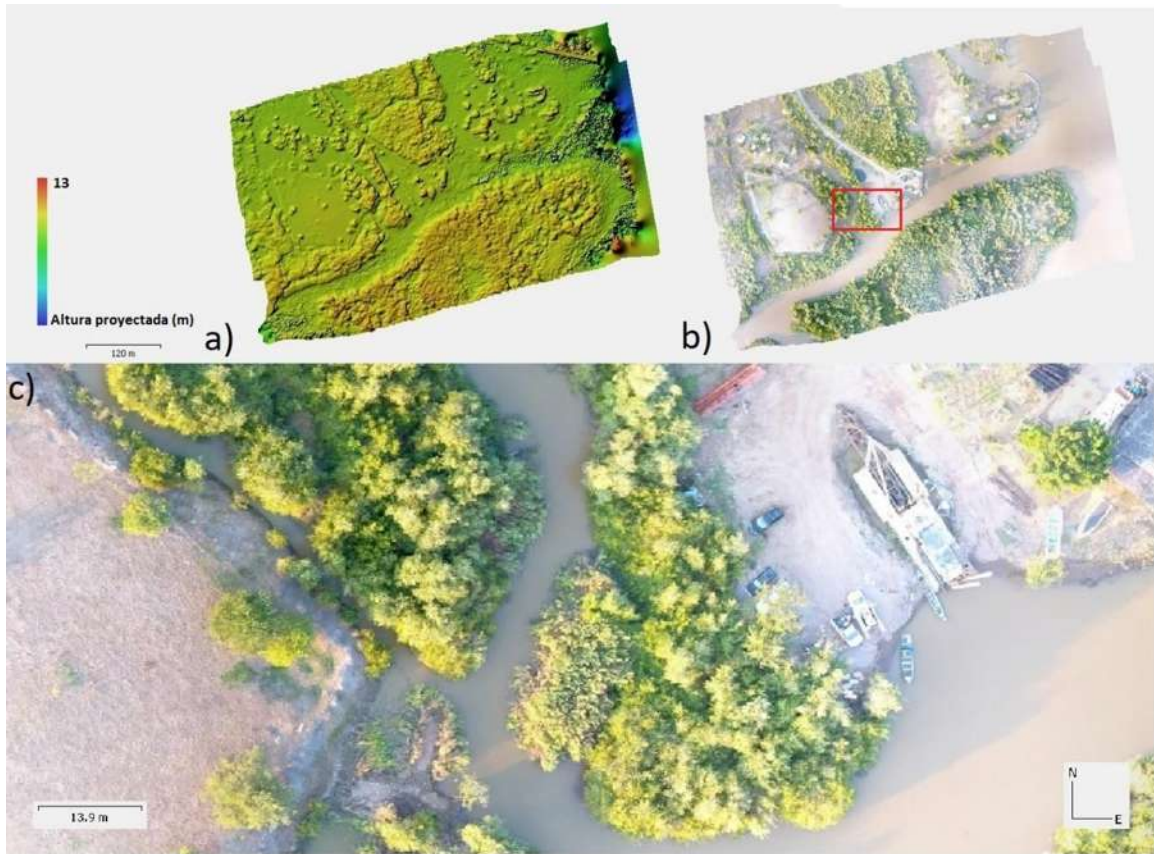


Figura. A3.1.13. Misión en laguna al norte de Mexcaltitán (21.904539 N, -105.480748 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.

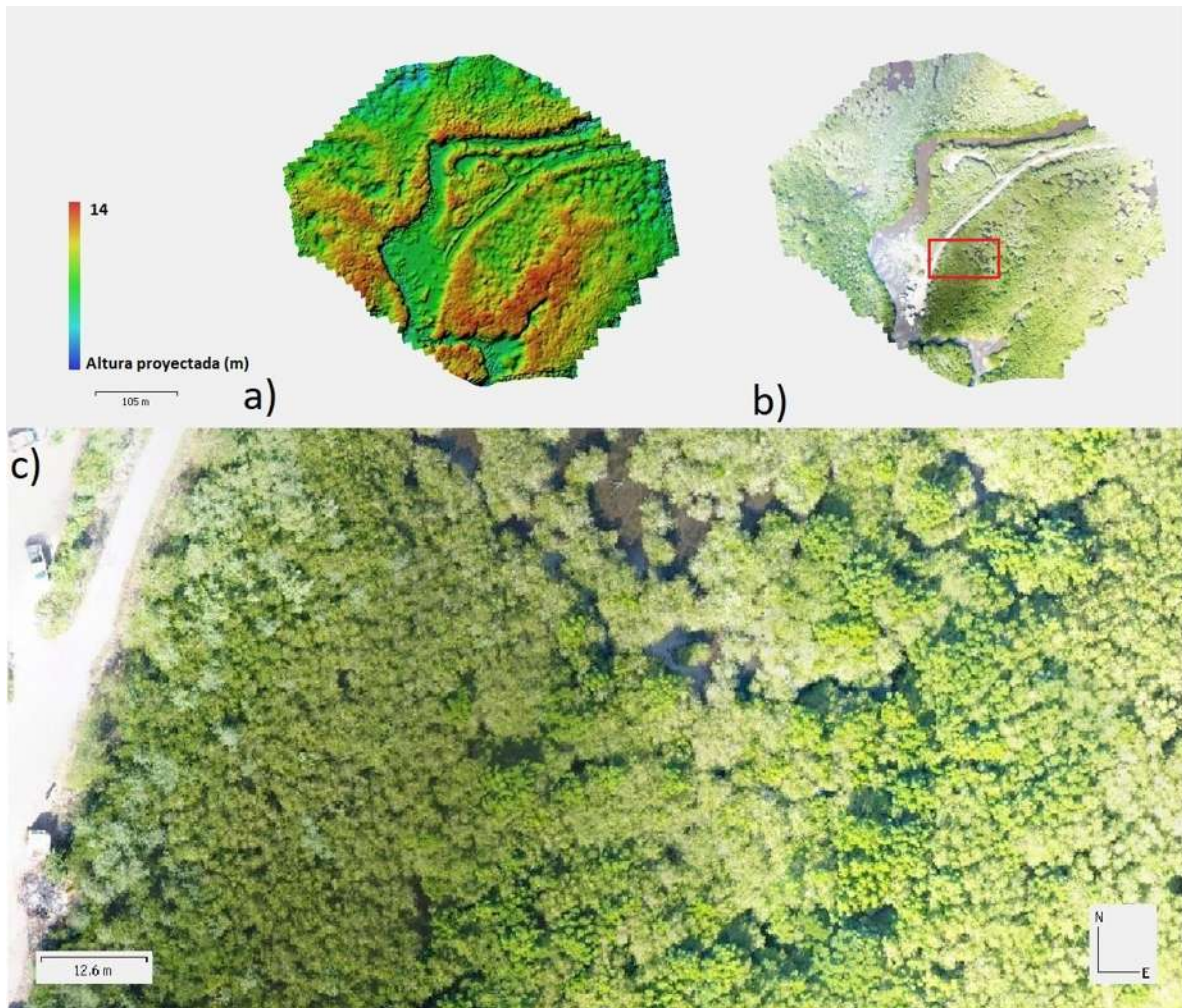

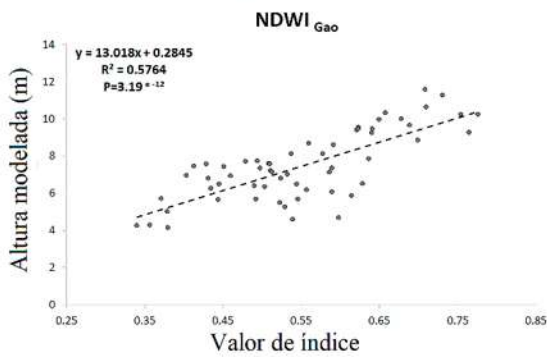


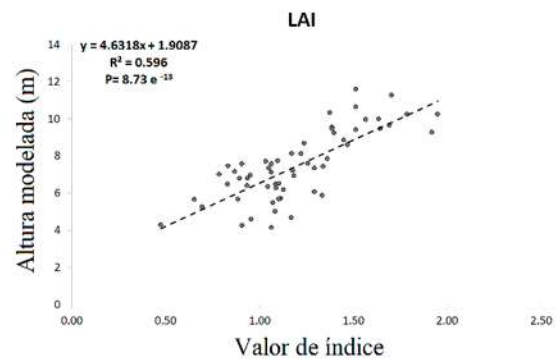
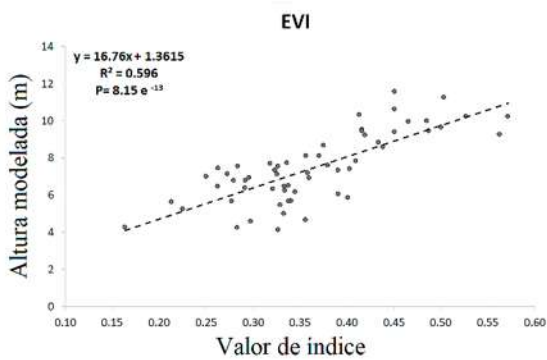


Figura. A3.1.14. Misión en laguna cerca de Pimientillo (22.038094 N, -105.430525 O). a) Modelo digital de elevaciones, colores más cálidos representan las zonas de mayor altura de dosel; b) ortomosaico generado (resolución espacial 4.25 cm/píxel); c) acercamiento del ortomosaico generado.

Anexo. 3.2 Análisis de regresión lineal y línea de tendencia de la altura modelada contra los valores de los índices restantes calculados en el estudio.



Anexo. 3.3 Coeficiente de determinación (R^2) de índices individuales y combinaciones de dos o más índices.

NDVI = Índice de Vegetación de Diferencia Normalizada, GRVI = Índice de Vegetación Verde-Rojo, EVI = Índice Mejorado de Vegetación, LAI = Índice de Área Foliar, GLI = Índice de Hoja Verde, IPVI = Índice de Vegetación de Porcentaje Infrarrojo, RDVI = Índice de Vegetación de Diferencia Re-Normalizada, NDWI = Índice de Agua de Diferencia Normalizado, MNDWI = Índice de Agua de Diferencia Normalizado Modificado. Coeficientes EVI (L = 1, C1 = 6, C2 = 7.5).

Índice	R ²	Ecuación
GLI	0.2769	Y= 28.27 GLI - 0.5101
IPVI	0.5622	Y= -124.07 IPVI + 136.64
NDWI _G	0.5764	Y= 13.018 NDWI _G + 0.2845
RDVI	0.5914	Y= 25.55 RDVI + 3.83
EVI	0.596	Y= 16.73 EVI + 1.3615
LAI	0.5968	Y= 4.6318 LAI + 1.9087
NDWI _{Mc}	0.6938	Y= -22.109 NDWI _{Mc} - 8.0519
GRVI	0.6284	Y= 0.6803 GRVI + 3.25
NDWI _{Mc} + GRVI	0.7082	Y= -1.1173 - 8.50 NDWI _{Mc} + 0.4947 GRVI
NDVI + NDWI _{Mc}	0.7508	Y= -2.831 + 23.81 NDVI + 8.05 NDWI _{Mc}
NDVI	0.747	Y= 17.18 NDVI - 4.40
NDVI + GRVI	0.7475	Y= -4.89 + 18.38 NDVI - 0.05 GRVI
NDVI + NDWI _{Mc} + GRVI	0.7509	Y= -2.52 + 0.022 GRVI + 8.67 NDWI _{Mc} + 23.06 NDVI
NDVI + NDWI _{Mc} + GRVI + IPVI + LAI + RDVI + EVI + NDWI _G	0.761	Y= -19.26 + 19.01 NDVI + 6.03 NDWI _{Mc} - 0.031 GRVI - 35.58 IPVI - 458.57 LAI - 20.02 RDVI + 1650.79 EVI - 2.39 NDWI _G
IPVI + LAI + RDVI + EVI + NDWI _G	0.763	Y= 104.65 - 80.83 IPVI + 188.30 LAI - 52.83 RDVI - 633.5 EVI - 0.198 NDWI
NDVI + NDWI _{Mc} + GRVI + IPVI + LAI + RDVI + EVI + NDWI _G + GNDVI + MNDWI + GLI	0.7658	Y= -48.71 + 9.76 NDVI - 20.54 NDWI _{Mc} - 0.25 GRVI + 35.25 IPVI + 116.59 LAI + 3.58 RDVI - 389.8 EVI + 6.99 NDWI _G - 42.79 GNDVI - 5.88 MNDWI + 0.7751 GLI

Anexo 3.4. Coeficiente de determinación (R^2) de la altura modelada frente a los índices NDVI, GRVI y NDWI_{MC} en tres fechas diferentes. NDVI = Índice de Vegetación de Diferencia Normalizada, GRVI = Índice de Vegetación Verde-Rojo, NDWI_{MC} = Índice de Agua Diferencial Normalizado (Mcfeeters, 1996).

Índice	Fecha	R^2
NDVI	Feb-2019	0.6643
	May-2019	0.747
	Ago-2019	0.107
GRVI	Feb-2019	0.5376
	May-2019	0.6284
	Ago-2019	0.4426
NDWI _{MC}	Feb-2019	0.609
	May-2019	0.6938
	Ago-2019	0.2695