



CENTRO DE INVESTIGACIONES BIOLÓGICAS  
DEL NOROESTE, S.C.

---

Programa de Estudios de Posgrado

MODELO PARA LA IDENTIFICACIÓN DE ESPECIES DE  
MANGLE MEDIANTE FOTOGRAFÍA AÉREA CON VANT Y  
ALGORITMO DE CLASIFICACIÓN RANDOM FOREST, EN  
BAHÍA DE LA PAZ, BCS.

T E S I S

Que para obtener el grado de

**Maestro en Ciencias**

Uso, Manejo y Preservación de los Recursos Naturales  
(Orientación en Ecología de Zonas Áridas )

P r e s e n t a

**Francisco Andrés Roque Sosa**

La Paz, Baja California Sur, febrero de 2021.

## ACTA DE LIBERACIÓN DE TESIS

En la Ciudad de La Paz, B. C. S., siendo las 15 horas del día 19 del Mes de enero del 2021, se procedió por los abajo firmantes, miembros de la Comisión Revisora de Tesis avalada por la Dirección de Estudios de Posgrado y Formación de Recursos Humanos del Centro de Investigaciones Biológicas del Noroeste, S. C., a liberar la Tesis de Grado titulada:

**"Modelo para la identificación de especies de mangle mediante fotografía aérea con VANT y algoritmo de clasificación Random Forest, en Bahía de La Paz, BCS"**

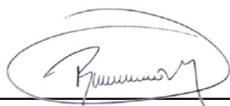
Presentada por el alumno:

**Francisco Andrés Roque Sosa**

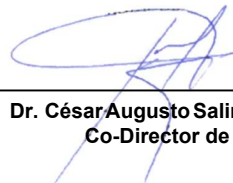
Aspirante al Grado de MAESTRO EN CIENCIAS EN EL USO, MANEJO Y PRESERVACIÓN DE LOS RECURSOS NATURALES CON ORIENTACIÓN EN **Ecología de Zonas Áridas**

Después de intercambiar opiniones los miembros de la Comisión manifestaron su **APROBACIÓN DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

### LA COMISIÓN REVISORA



Dr. Raúl Octavio Martínez Rincón  
Co-Director de Tesis



Dr. César Augusto Salinas Zavala  
Co-Director de Tesis



Dra. Elisa Serviere Zaragoza  
Co-Tutora de Tesis

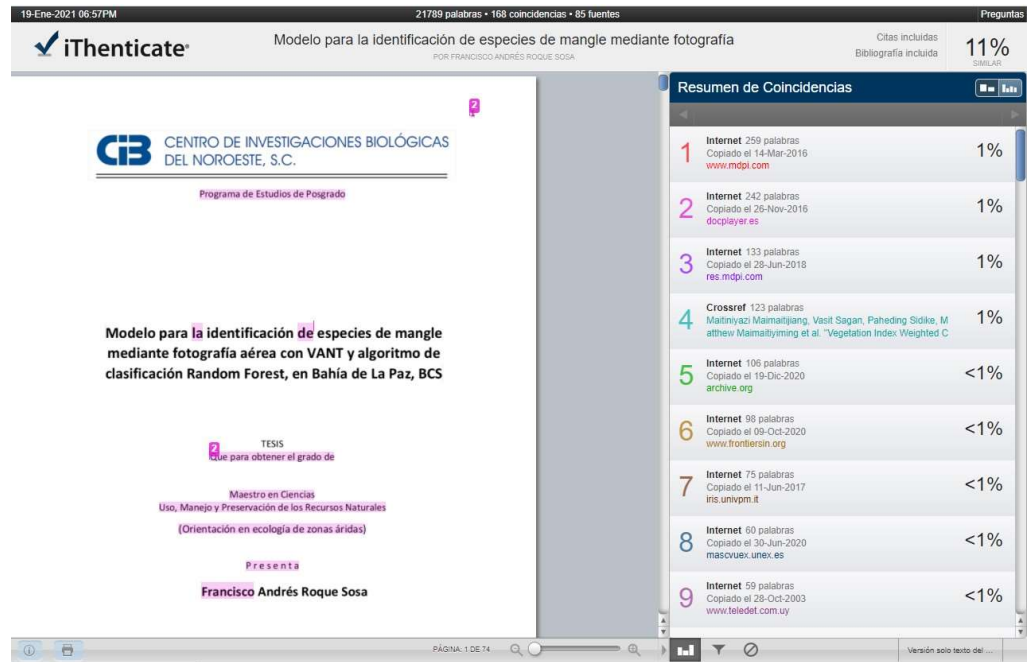


Dra. Gracia Alicia Gómez Anduro,  
Directora de Estudios de Posgrado y  
Formación de Recursos Humanos.

La Paz, Baja California Sur, a 19 de enero de 2021.

Los miembros del comité de tesis del (la) estudiante FRANCISCO ANDRÉS ROQUE SOSA del Programa de MAESTRÍA EN USO, MANEJO Y PRESERVACIÓN DE LOS RECURSOS NATURALES, revisamos el contenido de la tesis y otorgamos el VoBo dado que la tesis no representa un plagio de otro documento como lo muestra el reporte de similitud realizado:

- Herramienta antiplagio: iThenticate
  - Filtros utilizados: Citas y bibliografía
  - Porcentajes de similitud: 11%
- Se muestra captura de pantalla



The screenshot shows the iThenticate interface for a document titled "Modelo para la identificación de especies de mangle mediante fotografía aérea con VANT y algoritmo de clasificación Random Forest, en Bahía de La Paz, BCS". The overall similarity score is 11%. A table of matches is visible on the right side of the screen:

Rank	Source	Words	Matched Words	Similarity %
1	Internet	259	28	1%
2	Internet	242	26	1%
3	Internet	133	14	1%
4	Crossref	123	12	1%
5	Internet	106	10	<1%
6	Internet	98	10	<1%
7	Internet	75	7	<1%
8	Internet	60	6	<1%
9	Internet	59	6	<1%

**Firmas del comité**



Dr. Raúl Octavio Martínez Rincón  
Co-Director de Tesis



Dr. César Augusto Salinas Zavala  
Co-Director



Dra. Elisa Serviere Zaragoza  
Tutora



## **Conformación de Comités**

### **Comité Tutorial**

Dr. Raúl Octavio Martínez Rincón  
Centro de Investigaciones Biológicas del Noroeste, S.C.  
Co-Director de Tesis

Dr. César Augusto Salinas Zavala  
Centro de Investigaciones Biológicas del Noroeste, S.C.  
Co-Director de Tesis

Dra. Elisa Serviere Zaragoza  
Centro de Investigaciones Biológicas del Noroeste, S.C.  
Co-Tutora de Tesis

### **Comité Revisor de Tesis**

Dr. Raúl Octavio Martínez Rincón  
Dr. César Augusto Salinas Zavala  
Dra. Elisa Serviere Zaragoza

### **Jurado de Examen**

Dr. Raúl Octavio Martínez Rincón  
Dr. César Augusto Salinas Zavala  
Dra. Elisa Serviere Zaragoza

### **Suplente**

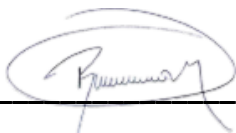
Dra. Blanca Estela Romero López

## Resumen

El manglar es un ecosistema altamente productivo y de gran riqueza biológica que proporciona gran variedad de recursos y servicios ambientales. En la península de Baja California, los manglares se encuentran en el límite norte de su distribución, por lo que presentan diferencias en su estructura y morfología con respecto a manglares en otras localidades más cercanas al ecuador donde estos se alcanzan tallas y abundancias más altas. Al mismo tiempo, su manejo y monitoreo ha sido intermitente, careciendo de información básica para su conservación. Esta investigación tiene como objetivo principal establecer un método para la identificación de especies de mangle en ecosistemas semiáridos basado en fotogrametría aérea y modelos de clasificación supervisada (Random Forest). Además, contempla la descripción de índices de vegetación (IV) basados tanto en la parte visible de la luz (RGB), como en el infrarrojo cercano (IRC). Los resultados de este trabajo sugieren que los IV por sí solos y basados en la parte visible de la luz, no muestran mejor desempeño en la identificación de las especies de mangle, que aquellos basados en el IRC (Precisión: RGB = 54.82 %, IRC = 60.98 %). Sin embargo, sí se incluye la altura de la vegetación, obtenida mediante fotogrametría, los IV basados en RGB obtienen mejores resultados de precisión que los basados en el IRC (Precisión: RGB = 95.09%; IRC = 61.63%). Al integrar todos los IV y la altura de la vegetación, fue posible clasificar correctamente a las 3 especies de mangle, con una precisión de 97.51% y 92.84%, usando los IV basados en el RGB o en el IRC, respectivamente. A partir del mejor modelo (usando todos los IV basados en el RGB y la altura) se generó un mosaico temático con las clases analizadas (*A. germinans*, *B. maritima*, *L. racemosa*, Matorral halófilo, *R. mangle* y Suelo), y se estimó que las especies de mangle, *Avicennia germinans*, *Laguncularia racemosa* y *Rhizophora mangle*, ocupan el 7.6%, 2.3% y 0.8 % de la superficie del área de estudio, respectivamente. Los resultados obtenidos de este trabajo muestran el alto potencial que tiene la fotogrametría aérea en conjunto con los métodos de clasificación supervisada para evaluar de manera remota la distribución espacial y el porcentaje de cobertura de las especies de mangle en ecosistemas semiáridos, información esencial para desarrollar planes de manejo para este tipo de vegetación.

**Palabras Claves:** índices de vegetación, espectro de luz visible, infrarrojo cercano, fotogrametría aérea, Random Forest.

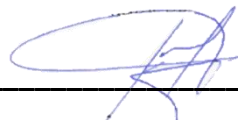
**ORCID:** 0000-0001-5165-1469



---

**Vo.Bo. Dr. Raúl Octavio Martínez Rincón**

**Co-Director de Tesis**



---

**Vo.Bo. Dr. César Augusto Salinas Zavala**

**Co-Director de Tesis**

## Summary

The mangrove is a highly productive ecosystem with great biological richness, which provides a great variety of resources and environmental services. In the Baja California peninsula, mangroves are found at the northern limit of their distribution, so they present differences in their structure and morphology with respect to mangroves in other locations closer to the equator. At the same time, its management and monitoring has been intermittent, lacking basic information for its conservation. The main objective of this research is to establish a method for the identification of mangrove species in semi-arid ecosystems, based on aerial photogrammetry and supervised classification models. In addition, it contemplates the description of vegetation indices (VI) based on both the visible part of light (RGB) and the near infrared (NIR). The results of this work suggested that the VIs by themselves and in the visible part of the light, did not show better performance in the identification of mangrove species, than those based on the NIR (Precision: RGB = 54.82%, NIR = 60.98%). However, if the height of the vegetation is included, obtained by photogrammetry, the VIs based on RGB obtain better precision results than those based on the NIR (Precision: RGB = 95.09%; NIR = 61.63%). By integrating all the VIs and the Canopy Height Model (CHM), it was possible to correctly classify the three mangrove species, with a precision of 97.51% and 92.84%, using the VIs based on RGB or NIR, respectively. From the best model (Random Forest using all the VI based on RGB and CHM) a thematic mosaic was generated with the analyzed classes (*A. germinans*, *B. Maritime*, *L. racemosa*, Halophilic scrub, *R. mangle* and Soil), and it was estimated that *Avicennia germinans*, *Laguncularia racemosa* and *Rhizophora mangle* occupy 7.6%, 2.3% and 0.8% of the surface of the study area, respectively. The results obtained from this work show the CHM potential of aerial photogrammetry, in conjunction with supervised classification methods, to evaluate remotely the spatial distribution and the percentage of cover of mangrove species in semi-arid ecosystems, essential to develop management plans for this type of vegetation.

**Key words:** Vegetation indices, visible light spectrum, near infrared, aerial photogrammetry, Random Forest.

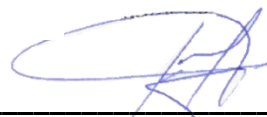
**ORCID:** 0000-0001-5165-1469



---

**Vo.Bo. Dr. Raúl Octavio Martínez Rincón**

**Co-Director de Tesis**



---

**Vo.Bo. Dr. César Augusto Salinas Zavala**

**Co-Director de Tesis**

**Dedicatoria**

*A mis padres, Mirna y Carlos...*

## Agradecimientos

Este estudio fue desarrollado con el apoyo económico del Proyecto 60086 Red de Monitoreo Fenológico del Noroeste de México.

A CONACYT, por la beca 936966 asignada

A CIBNOR, por todo el conocimiento adquirido, el uso de las instalaciones, equipo utilizado en esta investigación y al personal que, amablemente, me tendieron una mano en todo procedimiento o requerimiento. Un magnífico lugar para estudiar y para hablar de ciencia.

A mi comité tutorial, Dr. Raúl Martínez, Dra. Elisa Serviere y Dr. César Salinas, no solo fue el conocimiento, las correcciones, las firmas y la tesis, también agradezco sus historias, su apoyo, sus risas en las reuniones de comité y los buenos momentos en los cursos recibidos con ustedes, al igual que la amistad que ahora queda consecuencia de una grata relación.

A mi familia en Guatemala, mis hermanos Pablo y Juan Carlos y a mis primos Marvin y Neney, por el apoyo y motivación que me dieron.

A mis padres Mirna y Carlos, por ser esa fuerza y voluntad inmensa que nace en mí en cada momento de mi vida y ante cualquier situación, este logro también es suyo. Mamá, esta vez el teléfono nos acortó distancias y también alargó nuestras conversaciones.

A David y Judith, por lo divertido que puede llegar a ser el trabajo en campo cuando cuentas con personas como ustedes, gracias por los buenos momentos, sus historias, sus anhelos, risas, chismes y ciencia compartida.

A mis amigos de maestría, doctorado y de La Paz. Las clases, CIBNOR y la Ciudad, no hubiesen sido las mismas sin ustedes, pero sobre todo a Yutzil, Lupita, Tito, Paco, Daniela, Juan, Ana, Daniel, Ale, Licea, Hamza, María y Adair.



A mi equipo de futbol "Avengers", en especial a Josymar, Yoshio, Roy y Marco, por los buenos momentos, el jogo bonito y el alivio de estrés que se siente al jugar el deporte más hermoso del mundo.

A los cosmonautas, Jenny, Katharina, Erick y Osman, por los buenos momentos y su invaluable aporte a mi estado emocional.

A Paco y Kerobel, su invaluable compañía hizo que mis momentos de alegría se duplicaran y los momentos de tristeza se esfumaran.

A la Sixteen, mis amigos para siempre, gracias por su visita, a pesar de estar tan lejos, en todas partes, el amor sigue uniéndonos y los cyberlibes siguen siendo fuente de alegría, risas y buenos momentos.

Especial agradecimiento a Mariana y Joselyn, nada de esto hubiese sido lo mismo sin ustedes dos, las risas, los buenos momentos, los malos, los alegres, todo fue mejor con ustedes, las llevaré en mi corazón con mucho cariño siempre.

## Contenido

Resumen .....	i
Summary .....	ii
Dedicatoria.....	iii
Agradecimientos .....	iv
Contenido.....	vi
Lista de figuras .....	viii
Lista de tablas .....	x
1. INTRODUCCIÓN.....	1
2. ANTECEDENTES .....	6
3. JUSTIFICACIÓN .....	11
4. HIPÓTESIS.....	12
5. OBJETIVOS.....	13
5.1. Objetivo general: .....	13
5.2. Objetivos particulares: .....	13
6. MATERIALES Y MÉTODOS.....	14
6.1 Área de estudio.....	14
6.2 Imágenes aéreas .....	14
6.3 Línea de vuelo .....	15
6.4 Ortomosaicos.....	16
6.5 Creación de clases respecto a la cobertura del suelo.....	22
6.6 Estimación de los índices de vegetación.....	24
6.7 Evaluación del desempeño de los índices de vegetación.....	26
6.8 Evaluación del desempeño de los IV implementando el MDD.....	28
6.9 Mapas temáticos .....	28
6.9.1 Postprocesamiento del mapa temático.....	29
7. RESULTADOS .....	31
7.1 Resultados previo a las evaluaciones de los IV.....	31
7.1.2 Valores de reflectancia por bandas (RGB y GRN) y clases. ....	31
7.2. Evaluación de los IV .....	34
7.2.1 Evaluación de los IV RGB .....	34
7.2.2 Evaluación de los IV GRN.....	36
7.3 Clasificación supervisada del ortomosaico RGB .....	37
7.3.1 Desempeño de clasificación usando el mejor IV RGB .....	37
7.3.2 Desempeño de clasificación usando el mejor IV RGB para dos clases .....	40

7.3.3 Desempeño de clasificación usando el mejor IV RGB + MDD .....	42
7.3.4 Desempeño de clasificación usando todos los IV- <b>RGB</b> .....	44
7.3.5 Desempeño de clasificación usando todos los IV <b>RGB + MDD</b> .....	47
7.4 Clasificación supervisada del ortomosaico <b>GRN</b> .....	50
7.4.1 Desempeño de clasificación usando el mejor IV <b>GRN</b> .....	50
7.4.2 Desempeño de clasificación usando el mejor IV <b>GRN para dos clases</b> .....	53
7.4.3 Desempeño de clasificación usando el mejor IV <b>GRN + MDD</b> .....	55
7.4.4 Desempeño de clasificación usando todos los <b>IV-GRN</b> .....	57
7.4.5 Desempeño de clasificación usando todos los <b>IV GRN + MDD</b> .....	60
7.5 Cobertura por clase .....	62
7.5.1 Mapas temáticos (corrección con polígonos de agua) .....	62
8. DISCUSIÓN .....	65
8.1 Análisis del desempeño de los IV en el espectro de luz visible, el infrarrojo cercano y la implementación del <b>MDD</b> .....	65
8.2. Cobertura por clase .....	69
9. CONCLUSIONES .....	70
10. LITERATURA CITADA .....	71

## Lista de figuras

<b>Figura 1.</b> Localización del sitio de estudio.....	14
<b>Figura 2.</b> Captura de pantalla de la aplicación DJI GS Pro con la línea de vuelo diseñada para el área de estudio.....	16
<b>Figura 3.</b> Ortomosaico RGB.....	19
<b>Figura 4.</b> Ortomosaico GRN.....	20
<b>Figura 5.</b> Modelo digital del dosel. A) raster del modelo digital del dosel, los colores verdes simbolizan una menor altura, los colores amarillos a rojos una mayor altura. B) Modelo digital del dosel con el ortomosaico RGB como capa superior.....	21
<b>Figura 6.</b> Ejemplo de extracción de valores de píxeles por puntos geográficos dentro de un buffer. Matriz de 12 x 12 representando píxeles de una capa, banda o imagen raster. Los puntos azules representan los puntos geográficos tomados con la estación RTK para cada una de las clases (colores), los círculos rojos son los buffers alrededor de cada punto, los píxeles que delimita el buffer fueron los valores extraídos para cada una de las clases.....	24
<b>Figura 7.</b> Resumen estadístico de los valores de los píxeles por cada banda y clase del mosaico RGB. Las líneas verticales representan mínimos y máximos, o 1.5 veces el rango intercuartílico $\pm$ la mediana en presencia de valores atípicos (puntos). Las cajas representan los cuartiles 25 y 75%. Las líneas horizontales representan las medianas.....	32
<b>Figura 8.</b> Resumen estadístico de los valores de los píxeles por cada banda y clase del mosaico GRN. Las líneas verticales representan mínimos y máximos, o 1.5 veces el rango intercuartílico $\pm$ la mediana en presencia de valores atípicos (puntos). Las cajas representan los cuartiles 25 y 75%. Las líneas horizontales representan las medianas.....	34
<b>Figura 9.</b> Clasificación de píxeles (en porcentaje) por clase usando el IV EXG. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).....	40
<b>Figura 10.</b> Clasificación de píxeles (en porcentaje) vegetación/no vegetación usando el IV EXG. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).....	41
<b>Figura 11.</b> Clasificación de píxeles (en porcentaje) por clase usando el IV EXG + MDD. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).....	44
<b>Figura 12.</b> Clasificación de píxeles (en porcentaje) por clase usando todos los IV obtenidos del ortomosaico RGB. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).....	47
<b>Figura 13.</b> Clasificación de píxeles (en porcentaje) por clase usando todos los IV obtenidos del ortomosaico RGB y el MDD. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).....	50
<b>Figura 14.</b> Clasificación de píxeles (en porcentaje) por clase usando el IV GRNDVI. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).....	53

- Figura 15.** Clasificación de píxeles (en porcentaje) vegetación/no vegetación usando el IV GRNDVI. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos). .....54
- Figura 16.** Clasificación de píxeles (en porcentaje) por clase usando el IV GRNDVI + MDD. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos). .....57
- Figura 17.** Clasificación de píxeles (en porcentaje) por clase usando todos los IV obtenidos del ortomosaico GRN. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).59
- Figura 18.** Clasificación de píxeles (en porcentaje) por clase usando todos los IV obtenidos del ortomosaico GRN y el MDD. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos). .....62
- Figura 19.** Mapa temático final incluyendo la clase Agua.....64

## Lista de tablas

<b>Tabla 1.</b> Especificaciones técnicas de los equipos. ....	15
<b>Tabla 2.</b> Clases o tipos de coberturas diferentes y número de puntos por cada clase georreferenciados en campo. ....	23
<b>Tabla 3.</b> Índices de vegetación aplicados al ortomosaico RGB. ....	25
<b>Tabla 4.</b> Índices de vegetación aplicados al ortomosaico GRN. ....	26
<b>Tabla 5.</b> Ejemplo de una matriz de confusión. ....	27
<b>Tabla 6.</b> Desempeño de IV obtenidos a partir del ortomosaico RGB en la clasificación de las 6 clases. En negritas el IV con el mejor desempeño. ....	35
<b>Tabla 7.</b> Cantidad de puntos y píxeles evaluados únicamente para las clases vegetación y no vegetación. ....	35
<b>Tabla 8.</b> Desempeño de IV obtenidos a partir del ortomosaico RGB en la clasificación de vegetación/no vegetación. En negritas el IV con el mejor desempeño. ....	36
<b>Tabla 9.</b> Desempeño de IV obtenidos a partir del ortomosaico GRN en la clasificación de las 6 clases. En negritas el IV con el mejor desempeño. ....	36
<b>Tabla 10.</b> Desempeño de IV obtenidos a partir del ortomosaico GRN en la clasificación de vegetación/no vegetación. En negritas el IV con el mejor desempeño. ....	37
<b>Tabla 11.</b> Matriz de confusión del modelo RF con el IV EXG. Los números representan el número de píxeles. ....	39
<b>Tabla 12.</b> Matriz de confusión del modelo RF con el IV EXG para dos clases. Los números representan el número de píxeles. ....	41
<b>Tabla 13.</b> Matriz de confusión del modelo RF con el IV EXG + MDD. Los números representan el número de píxeles. ....	43
<b>Tabla 14.</b> Matriz de confusión del modelo RF con todos los IV derivados del ortomosaico RGB. Los números representan el número de píxeles. ....	46
<b>Tabla 15.</b> Matriz de confusión del modelo RF con todos los IV derivados del ortomosaico RGB y el MDD. Los números representan el número de píxeles. ....	49
<b>Tabla 16.</b> Resultados de la matriz de confusión para el IV GRNDVI. ....	52
<b>Tabla 17.</b> Resultados de la matriz de confusión para el IV GRNDVI con dos clases. ....	54
<b>Tabla 18.</b> Resultados de la matriz de confusión para el modelo GRNDVI + MDD. ....	56
<b>Tabla 19.</b> Resultados de la matriz de confusión para el modelo que incluye a todos los IV-GRN. ....	59
<b>Tabla 20.</b> Resultados de la matriz de confusión para el modelo todos los IV-GRN + MDD. ....	61
<b>Tabla 21.</b> Cobertura por clase por el modelo RF con todos los IV RGB y MDD. Las dos columnas de la derecha muestran los valores de cobertura después de aplicar el ajuste con los polígonos de agua. ....	63

## 1. INTRODUCCIÓN

Los manglares son ecosistemas de gran biodiversidad y se desarrollan como un ecotono entre el mar y la tierra a lo largo de las costas de la zona intertropical. La vegetación de estos ecosistemas está dominada por árboles y arbustos tolerantes a la inundación y a la salinidad, denominados mangles y generalmente crecen en ambientes caracterizados por la influencia de las mareas y descargas de agua dulce proveniente de ríos o arroyos [1]. En el noroeste de México, existen manglares que se desarrollan en su límite septentrional, otorgando a estos, diferencias en sus características estructurales y morfológicas, comparados con manglares ubicados en zonas más tropicales [2]. Dentro de las características estructurales es posible mencionar, cambios en altura, debido a la cantidad de precipitación y a la temperatura, por otro lado, el área foliar promedio de *Rhizophora mangle*, se incrementa con la disminución de la latitud (incrementa de norte a sur), siendo este un ejemplo de los cambios en las características morfológicas a lo largo de las distintas regiones de la distribución de los manglares en México [3].

Dentro del territorio mexicano, es posible observar diferencias regionales entre los manglares que se distribuyen en el sur de Chiapas hasta Baja California y los que se encuentran en el Golfo de México y Caribe, que van desde Quintana Roo hasta Tamaulipas. En Tamaulipas, los manglares están dominados por una sola especie, la cual presenta alturas máximas de tres a cuatro metros, alcanzando, en algunos individuos, los seis metros y careciendo a su vez de epifitas y trepadoras [4]. Por otro lado, en el sur de Veracruz, los manglares se componen de diversas especies, con alturas desde los 10 a 30 metros, los cuales presentan una gran variedad de epifitas [4]. Para poder obtener las medidas exactas de las características morfológicas y estructurales de los mangles, es necesario contar con ciertos métodos adecuados para el estudio de estos organismos.

Los métodos tradicionales de monitoreo forestal, según el Korea Forest Conservation Movement en 2007, involucran inventarios y censos como las técnicas más utilizadas. Estas técnicas contemplan el uso de parcelas permanentes de muestreo, descripción *in situ* y el uso de imágenes satelitales. Sin embargo, estas técnicas requieren conocimientos técnicos y

requieren de la participación de varias personas dependiendo de la extensión que se desee monitorear. Actualmente, los sistemas de monitoreo han sido modificados por herramientas que facilitan el proceso, como los propuestos por el sistema de monitoreo de los manglares de México, que involucran un componente espacial y un componente experimental [5]. El componente espacial incluye la realización de mapas de distribución y extensión de los manglares, con el respectivo análisis de cobertura del suelo y la extensión, como también de su distribución espacial y temporal. El componente experimental se refiere a la utilización de sitios piloto para realizar pruebas de parámetros e indicadores que contribuyan al monitoreo de manglares a través del tiempo, este componente incluye mediciones de la estructura vegetal de la comunidad de manglar, estimaciones de biomasa vegetal *in situ* y la exploración de variables biofísicas con índices de vegetación, área foliar y de biomasa con la ayuda de imágenes satelitales [5]. Las nuevas técnicas de monitoreo involucran imágenes adquiridas con sensores remotos (percepción remota), probando ser esenciales en el monitoreo y mapeo de manglares [6]. Estos sensores remotos pueden capturar características de reflectancia de la superficie de los objetos en la superficie.

La percepción remota como tal, puede definirse como la ciencia y arte de obtener información de un objeto, analizando los datos adquiridos mediante algún dispositivo que no está en contacto físico con dicho objeto, desde el ojo humano en cierta forma, hasta cámaras multispectrales de última generación [7]. El resultado de la percepción remota, son imágenes, éstas pueden ser obtenidas mediante sensores de percepción remota que, de acuerdo a la plataforma donde se ubique el sensor, puede ser: percepción remota espacial (satélites autónomos, estaciones orbitales o naves espaciales tripuladas) o percepción remota aérea (desde globos aerostáticos, aviones, helicópteros, drones, entre otros) [7].

Para el análisis de la información a partir de imágenes se utiliza la fotogrametría, que, etimológicamente, la palabra significa la métrica de lo escrito con luz, en esencia, es la ciencia que utiliza fotografías para hacer medidas y su aplicación es extensiva a numerosas áreas del conocimiento [8]. La fotogrametría es una técnica que tiene como objetivo estudiar y definir con



precisión la forma, dimensiones y posición en el espacio de un objeto, utilizando medidas hechas sobre una o varias fotografías [8].

Actualmente, la fotogrametría se auxilia de fotografías que son tomadas ya sea por medio de sensores remotos espaciales o aéreos. Las ventajas básicas que ofrece la técnica de utilizar sensores remotos aéreos son [7]:

- Permite tener una vista de los detalles de la superficie (en el contexto espacial), a una menor escala que las imágenes satelitales (percepción remota espacial), esto la transforma en una herramienta muy útil para trabajar en áreas pequeñas.
- Flexibilidad al usar plataformas aéreas (actualmente, vehículo aéreo no tripulado, UAV por sus siglas en inglés), es muy fácil rediseñar el plan de trabajo según sean las necesidades que vayan surgiendo.
- La fotografía resultante nos da una visión instantánea de procesos bajo condiciones dinámicas como cobertura (estacionalidad), inundaciones, tráfico, incendios forestales, etc.

Actualmente, los softwares de sistemas de información geográfica, aunados a la fotogrametría, nos ayudan en el análisis y procesamiento de las imágenes digitales. Uno de los resultados de la fotogrametría con imágenes digitales y el uso de softwares de sistemas de información geográfica, son los índices de vegetación, los cuales se definen como operaciones matemáticas aplicadas a los valores de los píxeles en dos o más bandas espectrales de la misma imagen [9]. Su empleo se justifica para mejorar la discriminación entre suelos y vegetación, y para reducir el efecto de la pendiente y orientación en la caracterización espectral de las distintas coberturas [9].

Generalmente, los valores de índices de vegetación bajos (cercaos a 0 o por debajo), indican vegetación poco vigorosa, mientras que los valores altos (mayores a 0) indican vegetación saludable o muy vigorosa [10]. Estos índices usan el cociente de la reflectancia, usualmente el infrarrojo cercano (NIR) y el rojo, debido al alto contraste que presenta la clorofila-a asociada a

los centros de actividad de los complejos moleculares llamados fotosistemas, que absorben la luz durante la fotosíntesis [11].

Así mismo, el índice de vegetación perfecto "...es aquel particularmente sensible a la cubierta vegetal, insensible al brillo y color del suelo y poco afectado por diferentes tipos de perturbaciones ambientales..." (Jackson, 1983). Esto último, se convierte en uno de los factores clave al momento de utilizar VANT e índices de vegetación en ambientes de climas semiáridos, debido a la gran cantidad de suelo desnudo, la poca representatividad de la vegetación, el exceso en el brillo de las imágenes y la presencia de sombras que también forman parte de los píxeles de una fotografía aérea.

Los índices de vegetación únicamente discriminan el vigor de la vegetación o ciertos patrones de reflectancia que están dados por la estructura y composición foliar (área foliar, pigmentos vegetales, contenido de agua, etc.) [11], por lo tanto, para realizar una clasificación más precisa y en el caso de esta investigación, a nivel de especie, es necesario utilizar métodos de clasificación supervisada. Los métodos de clasificación supervisada involucran el uso de datos de un área de entrenamiento y que se consideran representativas de cada unidad superficial a ser clasificada. El método basado en píxeles con máxima verosimilitud, es uno de los algoritmos más usados, en donde la entrada de las clases se establece desde el área de entrenamiento y estos son usados para calcular las estadísticas apropiadas y la probabilidad de la función. Cada píxel del área es analizado para determinar la clase a la cual es más probable que pertenezca [12].

Existen muchos métodos de clasificación supervisada, sin embargo, Campomanes (2016) menciona que, Random Forest tiene un mejor desempeño en la clasificación de mangle, ya que se obtienen mejores resultados en los estadísticos utilizados. Random Forest, consiste en un número grande de árboles individuales de decisión (más de 100), que operan como un conjunto. Cada árbol nos da una predicción de clase y la clase con la mayor cantidad de votos se vuelve en nuestra predicción del modelo [13]. Esta clasificación trabaja bien debido a que utiliza un número relativamente grande de árboles que no están correlacionados, los cuales, al operar

en conjunto, superan cualquiera de los modelos individuales, ya que promueven a los árboles exitosos, dándoles peso extra a los niveles predichos por los predictores anteriores [14]. Es por esto que este método de clasificación es de los más utilizados, teniendo otras ventajas como ser un algoritmo de carácter no paramétrico, posee un nivel alto de precisión y tiene la habilidad de determinar variables importantes y predecir los valores faltantes [12].

En este contexto, el uso de VANT e índices de vegetación para el estudio de la cobertura en los manglares, particularmente de la Bahía de La Paz, se vuelve crucial la creación de un modelo que logre discernir entre especies de mangle, con el fin de aportar información adecuada a la cobertura ocupada por cada especie y que puede ser utilizada para el monitoreo y conservación de estos ecosistemas.

## 2. ANTECEDENTES

Los métodos tradicionales de monitoreo forestal, según Bechtold y colaboradores (2007), involucran inventarios y censos como las técnicas más utilizadas. Estas técnicas contemplan el uso de parcelas permanentes de muestreo, descripción *in situ* y el uso de mediciones alométricas como diámetro a la altura del pecho, altura del dosel, área basal y densidad de individuos por unidad de área, generalmente, hectáreas [15]. Sin embargo, estas técnicas requieren conocimientos técnicos y de la participación de varias personas dependiendo de la extensión que se desee monitorear y el tiempo que se tenga para generar la información.

Actualmente, los sistemas de monitoreo han sido modificados por herramientas que facilitan el proceso, como los propuestos por el sistema de monitoreo de los manglares de México, que involucran un componente espacial y un componente experimental [5]. El componente espacial incluye la realización de mapas de distribución y extensión de los manglares, con el respectivo análisis de cobertura del suelo y la extensión, como también de su distribución espacial y temporal. El componente experimental se refiere a la utilización de sitios piloto para realizar pruebas de parámetros e indicadores que contribuyan al monitoreo de manglares a través del tiempo, este componente incluye mediciones de la estructura vegetal de la comunidad de manglar, estimaciones de biomasa vegetal *in situ* y la exploración de variables biofísicas con índices de vegetación, área foliar y de biomasa con la ayuda de imágenes satelitales [5]. Las nuevas técnicas de monitoreo involucran imágenes adquiridas con sensores remotos (percepción remota), probando ser esenciales en el monitoreo y mapeo de manglares [6]. Estos sensores remotos pueden capturar características de reflectancia de la superficie de los objetos en la superficie.

En este contexto, Ochoa (2019) realizó una investigación con métodos tradicionales de muestreo, sobre la dinámica del carbono orgánico y productividad primaria neta en manglares de la Bahía de La Paz, llevando a cabo tres parcelas circulares, de tres metros de radio, en cada uno de sus sitios de estudio. Todas las parcelas fueron realizadas tomando en cuenta la distancia al cuerpo de agua y todos los individuos dentro de las parcelas, fueron tomadas sus

medidas de diámetro del fuste, altura, densidad, área basal y biomasa, entre otras [16]. El estudio concluye en que la dinámica del carbono dentro de los sistemas es rápida y eficiente por unidad de área, obteniendo alta productividad, alta descomposición, alto reciclamiento de nutrientes, alto almacenamiento y rápida respuesta en la producción primaria neta.

Siguiendo esta línea, las investigaciones sobre biomasa en mangle, tradicionalmente utilizan técnicas establecidas de inventarios forestales, las cuales involucran la colección manual y laboriosa de medidas alométricas, como altura, área de la copa y diámetro a la altura del pecho, para ser utilizadas posteriormente en ecuaciones alométricas que relacionan estas medidas no destructivas de los árboles para obtener la biomasa superficial [17]. Cabe mencionar que, por conocimiento del área de estudio en esta investigación, la capacidad de introducirse al manglar para la toma de medidas alométricas, se hace complicado debido a las condiciones de alta densidad de individuos por unidad de área y a que algunos parches de mangle son matorrales.

Actualmente, se han utilizado ampliamente los sensores remotos, como parte de las nuevas metodologías para la investigación y monitoreo de manglares, probando que son una herramienta esencial [6]. Al mismo tiempo, la percepción remota incluye el uso de Vehículos Aéreos No Tripulados o Drones, los cuales permiten [18]:

- Inventarios de hábitat (determinación de la cobertura de especies, su composición y salud).
- Detección de cambios y monitoreo (uso de la tierra, cobertura, conservación y éxito de la regeneración natural, silvicultura y desarrollo de la acuicultura).
- Como apoyo a la evaluación del ecosistema.
- Estimación de biomasa.
- Estimación de la capacidad de regeneración.
- Solicitudes de gestión (pesquerías, acuicultura, conservación, etc.)
- Calidad del agua.
- Información para manejo de desastres naturales.

Estas nuevas metodologías aplicadas a manglares, pueden utilizarse en el monitoreo de este ecosistema ante fenómenos naturales, mediante series temporales de imágenes satelitales para demostrar cambios en su cobertura, como lo realizado por Salas en 2019 [19], en Nicaragua, para evaluar el impacto sobre la cobertura de manglar en los Cayos Miskitus, después del paso del huracán Felix, categoría 5, en el año 2007. Estos investigadores, evaluaron las condiciones recientes y las tendencias de cambio, estimando una reducción de aproximadamente 1,783.2 hectáreas del bosque de mangle, para el período 2006 – 2017, utilizando imágenes Landsat de los años 2006, 2012 y 2017.

Así mismo, Bunting y colaboradores (2018) presentaron una nueva línea base global de la extensión de los manglares para ese año y fue el primer resultado de la iniciativa “Global Mangrove Watch” (GMW). Ellos utilizaron imágenes satelitales para mapear manglares alrededor del mundo, identificando una extensión global de 137,600 km<sup>2</sup>, siendo Asia el continente con mayor proporción de manglares del total (38.7%), mientras que América Latina y el Caribe sigue con el 20.3%, África con 20.0%, Oceanía con 11.9%, Norte América con 8.4% y los territorios Europeos de Ultramar el 0.7% [20]

Aunado a estas nuevas metodologías, y como parte del análisis de la vegetación, se han realizado numerosos métodos que utilizan la reflectancia del espectro de luz o firmas espectrales de las plantas, con el fin de evaluar la salud vegetal [21]. Esto es debido a que las características texturales y espectrales del dosel y las hojas, son las principales características utilizadas para distinguir entre comunidades de manglares [6,22]. Sin embargo, la firma espectral de una especie, está definida por la edad, vitalidad y características fisiológicas y fenológicas [23].

Al momento de utilizar distintos rangos de reflectancia del espectro de luz sobre la cobertura vegetal, se comienza a hacer uso de índices de vegetación (IV) [11] y aunque se han elaborado y trabajado con muchos IV propuestos en las últimas décadas, siempre se busca utilizar el que más se ajuste a nuestros sitios de estudio, a la vegetación del sitio y al sensor remoto utilizado.

Cabe mencionar que, a pesar de muchos estudios, es común encontrar una dificultad en la determinación precisa de lo que expresa un IV [24].

Estos IV pueden utilizarse para obtener medidas de cobertura de mangle a partir de imágenes satelitales o con dron, sin embargo, el tipo de suelo puede influir en la respuesta y precisión de estos [25]. Blackburn y colaboradores (2003), estudiaron el efecto de la variación espectral del fondo (suelo), con distintos IV. Ellos investigaron la relación que existe en la variación del porcentaje de cobertura, con varios IV que utilizan la banda del Rojo e Infrarrojo Cercano y distintos tipos de fondos o suelos, demostrando qué tan sensibles son los IV a estos cambios. Parte de sus resultados indican que, IV como el NDVI, SAVI y TSAVI, fueron moderadamente afectados por los distintos contrastes de los fondos (suelos), mientras que los menos afectados fueron IV como el DVI, PVI e IV derivados de otros como el 1DL\_DGVI, 1DZ\_DGVI y el 2DZ\_DGVI. Ellos concluyen que, el IV DVI parece ser el mejor para estimar propiedades biofísicas de manglares cuando se presentan distintos tipos y porcentajes de suelo desnudo en diferentes sitios de estudio.

También los IV pueden utilizarse para discriminar entre especies, como lo propuesto por Yaney-Keller y colaboradores (2019). Ellos realizaron un estudio sobre dos estuarios en Costa Rica, utilizando técnicas tradicionales alométricas de medición *in situ* de manglares y también nuevas metodologías utilizando drones e IV. El fin del estudio era determinar la estructura forestal del bosque de manglar mediante ambas técnicas y demostrar si el NDVI era capaz de discriminar entre especies de mangle en ambos sitios y en temporada húmeda y seca, obteniendo como parte de sus resultados la capacidad del NDVI para discriminar entre especies de mangle *A. germinans* y *Rhizophora racemosa*. Cabe mencionar, que estas dos especies son las más abundantes en los sitios de estudio. Dentro de sus resultados plantean que, cuando utilizan resoluciones muy altas (10cm/pixel), se obtienen diferencias significativas de la altura del dosel, entre las medias de las mediciones *in situ* y las medias de los modelos de elevación del dosel (MDD) hechos a partir de las imágenes con el dron [26].

Dentro del uso de imágenes capturadas mediante percepción remota, ya sea satelital o con dron e IV, también es posible identificar distintos tipos de coberturas entre sí e incluso a nivel

de especie, esto haciendo uso de algoritmos de clasificación [27]. Estos algoritmos de clasificación se pueden separar en enfoques paramétricos y no paramétricos. Los métodos paramétricos requieren de una estimación de la distribución de los datos y, por el contrario, los métodos no paramétricos, pueden utilizar distribuciones de datos opcionales y sin asumir que la forma de la estructura de datos subyacente es identificable. Como resultado, son muy utilizados para fines de clasificación [28].

En 2019, Toosi y colaboradores, compararon cuatro algoritmos de clasificación para monitorear mangle en el sureste de Irán. Esto con el propósito de detectar cambios en la cobertura de mangle desde 1985 a 2017, utilizando imágenes Landsat. Los cuatro algoritmos utilizados fueron, Random Forest, Linear Support Vector Machines, Radial Support Vector Machines y Regularization in Discriminant Analysis. De estos métodos de clasificación, encontraron que, para su sitio de estudio, Random Forest obtenía los mejores resultados de Precisión y valor de Kappa de Cohen para cada año comparado (1985, 1998 y 2017), 92.6 %, 91.3% y 93.9%; y 0.909, 0.895 y 0.929, respectivamente. Este estudio detectó cambios positivos en la cobertura de mangle entre los años 1998 y 2017, ellos concluyen que este hecho fue a causa que, en 2003, se implementó un plan de desarrollo de bosques de manglar [27].



### **3. JUSTIFICACIÓN**

La teledetección mediante imágenes satelitales es utilizada ampliamente para el análisis de la vegetación, sin embargo, a una menor escala y con mayor detalle de imágenes, comienza a presentar problemas por los distintos parámetros (ambientales, edáficos, topográficos, entre otros) que deben ser considerados al momento de analizar la vegetación con fotografías aéreas. Al respecto, los índices de vegetación se han utilizado para disminuir los errores en el análisis de la vegetación, sin embargo, estos no pueden ser utilizados para identificar a nivel de especie por sí solos. Es por esto que, en los manglares de la Bahía de La Paz, es importante encontrar una metodología que involucre modelos de reconocimiento de vegetación a nivel de especie y que se adecúen a ambientes de zonas semiáridas. Esto permitirá cuantificar la cobertura en área de los manglares por especie, resultados que podrían ser implementados en diferentes manglares para realizar comparaciones que permitan a su vez evaluar la salud de estos ecosistemas.

### **PREGUNTA DE INVESTIGACIÓN**

¿Es posible diferenciar las principales especies de mangle presentes en ecosistemas semiáridos con el uso de índices de vegetación obtenidos a partir de fotografías aéreas mediante la aplicación modelos de clasificación supervisada?

#### **4. HIPÓTESIS**

Dado que los métodos tradicionales de percepción remota (imágenes de satélite) han sido utilizados en manglares de zonas tropicales y a gran escala, estos podrían generar resultados imprecisos al momento de monitorear manglares de clima semiárido debido a la diferencia espectral superficial y su distribución por parches, por lo que el uso de índices de vegetación y modelos de elevación obtenidos a partir de imágenes aéreas de alta resolución espacial en conjunto con modelos de clasificación supervisada, permitirá una descripción y cuantificación detallada de las diferentes especies de mangle.

## **5. OBJETIVOS**

### **5.1. Objetivo general:**

Establecer un modelo de identificación de especies de mangle en ambientes semiáridos mediante imágenes aéreas capturadas con un vehículo aéreo no tripulado (VANT).

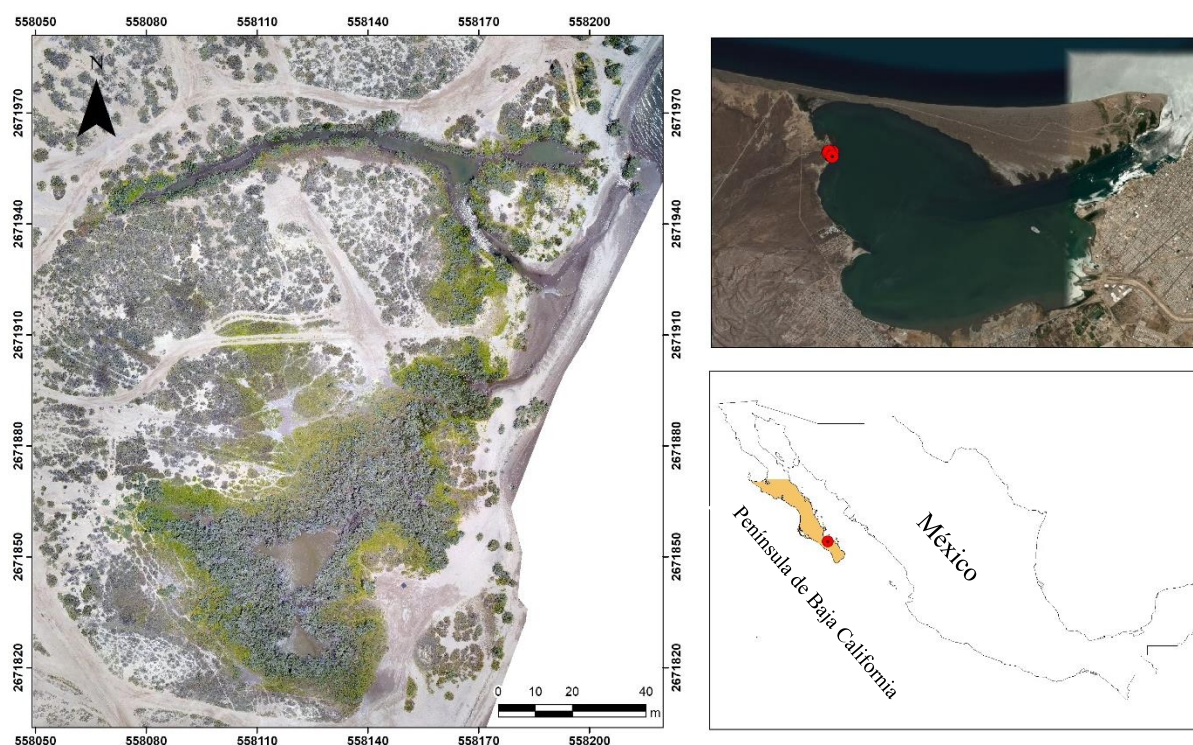
### **5.2. Objetivos particulares:**

- Estimar índices de vegetación a partir de los datos de reflectancia en las bandas azul, verde, rojo e infrarrojo cercano.
- Evaluar el desempeño de índices de vegetación en el espectro de luz visible y con el infrarrojo cercano en manglares de zonas semi-áridas.
- Evaluar el desempeño de los índices de vegetación implementando el modelo de elevación del dosel.

## 6. MATERIALES Y MÉTODOS

### 6.1 Área de estudio

El sitio de estudio (Fig. 1) se encuentra dentro de los humedales de la Ensenada de La Paz,  $110.4274^{\circ}\text{O}$  y  $24.1584^{\circ}\text{N}$ . Tiene un área aproximada de 2.7 hectáreas, en la cual se presentan tres especies de mangle (*A. germinans*, *L. racemosa* y *R. mangle*), así como también especies asociadas a humedales o marismas como *Batis maritima*, *Salicornia pacifica* y *Allenrolfea spp.* Cuenta además con áreas importantes de suelos sin vegetación, característico de zonas semiáridas.



**Figura 1.** Localización del sitio de estudio.

### 6.2 Imágenes aéreas

Para la captura de las imágenes aéreas se utilizó un vehículo aéreo no tripulado (VANT) con dos cámaras montadas: 1) Cámara con sensor para la parte visible de la luz (rojo, verde y azul) – Cámara RGB (por sus siglas en inglés) y 2) Cámara con sensor para el verde, rojo e infrarrojo

cercano – Cámara GRN (por sus siglas en inglés). El VANT utilizado fue el Phantom IV 4 Pro de la empresa DJI. En la tabla 1 se muestran los detalles técnicos del VANT, de ambas cámaras, así como de los GPS. La cámara GRN es montada en la parte inferior del VANT mediante una estructura de sujeción manufacturada por la empresa MAPIR. Ambas cámaras poseen un sistema de posicionamiento global (GPS) con una precisión de  $\pm 3$  metros.

**Tabla 1.** Especificaciones técnicas de los equipos.

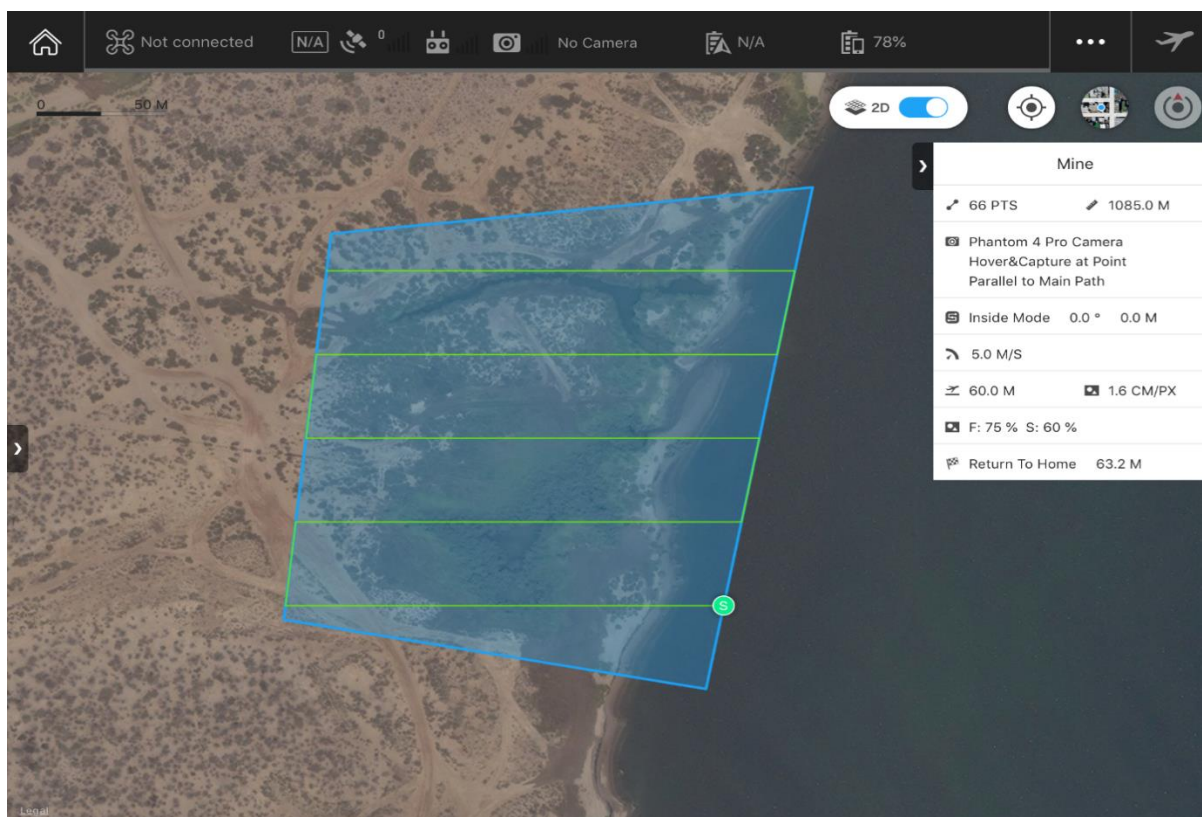
Equipo	Modelo/Sensor	Marca	Descripción
VANT	Phantom 4 pro	DJI	Vel. Max: 72 k/h Tiempo de vuelo: 30 minutos Sensores: para detección y evasión de obstáculos Peso (dron, batería y hélices): 1388g
Cámara RGB	CMOS 1"	DJI	Bandas: Rojo, verde y azul Formatos de imagen: 3:2: 5472 × 3648 4:3: 4864 × 3648 16:9: 5472 × 3078 Formato de video: 4k/60fps Resolución espacial: 1.6 cm/px a 60 m
Cámara GRN	Survey 3W RGN	MAPIR	Bandas: Verde, rojo e infrarrojo cercano Formatos de imagen: Formato de video: 1080/60fps Resolución espacial: 2.75 cm/px GSD a 60 m
GPS	Survey3 Standard GPS Receiver	MAPIR	$\pm 3$ m

### 6.3 Línea de vuelo

Se realizó una línea de vuelo el 5 de mayo del año 2019 entre las 11:30 y 13:00 horas para la minimización de sombras y tratar de obtener las mejores condiciones de iluminación. La línea de vuelo se diseñó con el software *DJI GS Pro* [29], con el fin de optimizar la duración de la batería y traslape de las imágenes. Este software controla la velocidad, altura e inclinación del VANT. Los siguientes parámetros fueron definidos con el software: a) el traslape frontal fue del

75% y lateral del 60%, b) velocidad máxima de 5 m/s, c) altura de 60m y una inclinación perpendicular a la horizontal del suelo ( $90^\circ$ ). La velocidad máxima fue limitada para que el movimiento del VANT no afectara las fotos de la cámara GRN, ya que esta no cuenta con estabilizador ni es controlada por DJI GS Pro. Debido a esto, la cámara GRN fue programada para tomar fotos con una frecuencia de 5 segundos.

La figura 2, muestra una captura de pantalla del plan de vuelo generado con el software DJI GS Pro, en la cual se muestra la línea de vuelo sobre el área de estudio y todas las características del vuelo autónomo realizado.



**Figura 2.** Captura de pantalla de la aplicación DJI GS Pro con la línea de vuelo diseñada para el área de estudio.

## 6.4 Ortomosaicos

Una ortofoto es una fotografía con una escala espacial constante y tiene propiedades de una proyección ortogonal, formándose mediante la toma de una fotografía en proyección central,

en la cual los objetos ocupan sus posiciones reales sobre el suelo, por lo que una medición realizada sobre la ortofoto (a escala constante), obtendrá los mismos resultados que una medición realizada *in situ* [30]. Sin embargo, en muchas ocasiones, no es posible abarcar una cantidad de área y tener la resolución espacial deseada, por lo que es necesario capturar una mayor cantidad de ortofotos, con el fin de lograr cubrir toda el área en cuestión. Cuando se hace este procedimiento, es necesario la creación de un mosaico de las ortofotos para poder trabajarlas como una única imagen en un software de Sistemas de Información Geográfica. A la unión de todas las ortofotos en un único mosaico, se le denomina ortomosaico [31].

Los ortomosaicos de las cámaras RGB y GRN fueron creados utilizando el software Agisoft Metashape Professional version 1.6.1. La secuencia de trabajo de este software fue la siguiente:

1. **Alineación de fotos:** luego de cargar todas las imágenes del sitio el software realiza una alineación mediante la posición geográfica y orientación de cada fotografía. Durante esta fase, el software también construye una nube de puntos dispersos. Esto le da un valor de altura a cada pixel. Se utilizó calidad media en este proceso.
2. **Nube de puntos densa:** este es un modelo que visualiza una densificación de la nube de puntos, basado en las estimaciones de la posición de la cámara, calculando la información respecto a la profundidad de cada pixel. Se utilizó calidad media en este proceso.
3. **Modelo digital de superficie (MDS):** este modelo es la altura aproximada de cada objeto (incluyendo las superficies) en la fotografía, con respecto al nivel medio del mar. Durante este paso, también puede generarse el modelo digital del terreno (MDT), el cual es la altura únicamente del suelo. Para este paso, es necesario clasificar la nube de puntos denso. Este proceso se realizó mediante las herramientas del sistema. El MDT es el resultado de la elevación de todos los pixeles clasificados como suelo, los que no fueron clasificados como suelo son removidos e interpolados por el proyecto.
4. **Ortomosaico:** posteriormente a todos los pasos antes mencionados, el software realiza una corrección ortogonal de las imágenes, calculando la posición exacta provista por los metadatos de posición geográfica incrustados en el archivo de imagen. Al realizar este


procedimiento de cada imagen, se crea la cantidad de ortofotos correspondiente a la misma cantidad de fotografías. Al mismo tiempo, el software realiza una combinación de todas las ortofotos para concluir con la unión de las mismas en una sola imagen u ortomosaico.

Debido a las características de resolución de las cámaras (20 y 12 MP para RGB y GRN, respectivamente), los ortomosaicos derivados de ambas cámaras presentaron diferencias en su resolución espacial, es por esto, que ambos productos fueron exportados con una resolución de 6.4 cm y valores de reflectancia por cada una de las bandas (rojo, verde, azul e infrarrojo cercano) de 0 a 255.

Posteriormente se calculó el Modelo Digital del Dosel (MDD), a partir de la diferencia entre el MDS y el MDT. Este proceso se realizó en el software QGIS [32]. El MDD representa una aproximación de la altura de la vegetación.

Los productos finales de este proceso fueron los siguientes: 1) Ortomosaico RGB (cámara del dron), 2) Ortomosaico GRN (cámara MAPIR), 3) MDS, 4) MDT y 5) MDD. Sin embargo, para los análisis siguientes se descartaron MDS y MDT, debido a que ninguno tiene una implicación directa en la clasificación de las especies de mangle, ni de otras clases. Los ortomosaicos RGB y GRN, al igual que el MDD se presentan en las figuras 3, 4 y 5.





**Figura 3.** Ortomosaico RGB.

El ortomosaico GRN (Fig. 4) muestra los valores de las bandas verde, rojo e infrarrojo cercano, en el mismo orden mencionado. Es por esto que en la imagen se observa la vegetación de color azul, debido a que los valores de la banda del infrarrojo cercano, se encuentran ubicados en la posición donde debería estar la banda del azul en el software Qgis 3.0 Madeira.


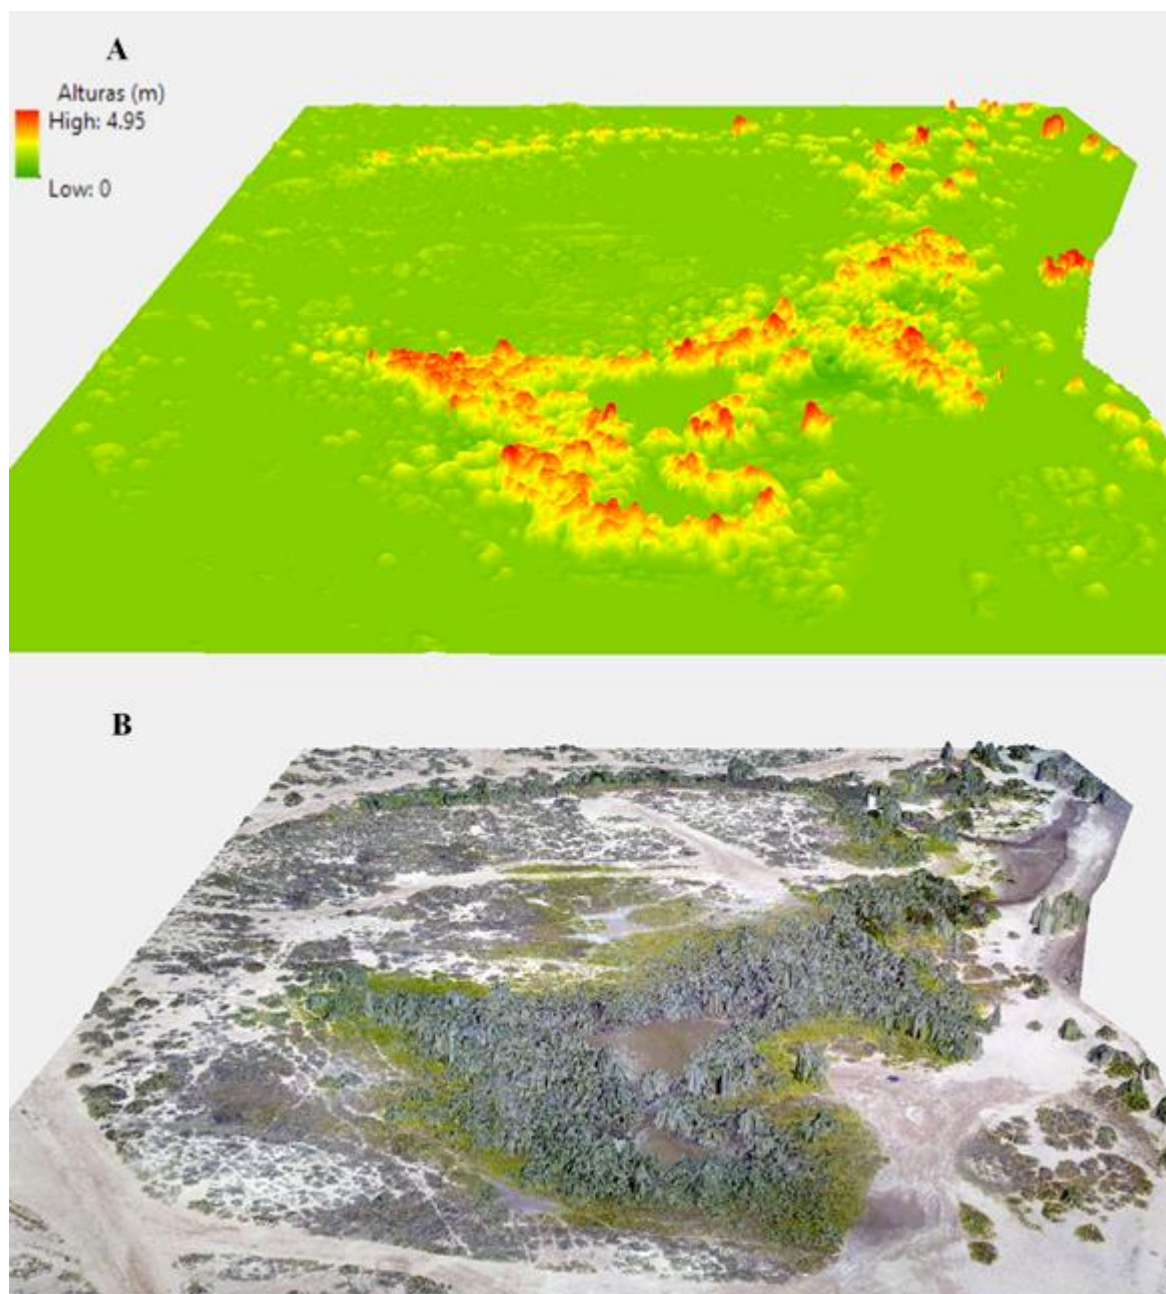


Figura 4. Ortomosaico GRN.



**Figura 5.** Modelo digital del dosel. A) raster del modelo digital del dosel, los colores verdes simbolizan una menor altura, los colores amarillos a rojos una mayor altura. B) Modelo digital del dosel con el ortomosaico RGB como capa superior.

## 6.5 Creación de clases respecto a la cobertura del suelo

En el lugar de estudio puede definirse a grandes rasgos y a simple vista, como un sitio con dos tipos de cobertura: suelo desnudo y vegetación. Pero dentro de la cobertura con vegetación, existen varias especies que son características de zonas semiáridas y al mismo tiempo, son especies que se asocian a manglares. Según Romero-López y colaboradores (2006), las especies que se asocian a árboles de manglar de las especies, *A. germinans*, *L. racemosa* y *R. mangle* en la zona de la Ensenada de La Paz, específicamente, en el sitio de la barra El Mogote (que se encuentra a 2 kilómetros aproximadamente del sitio de estudio), son: *Abronia maritima*, *Allenrolfea occidentalis*, *Batis maritima*, *Monanochloe littoralis*, *Salicornia bigelovii*, *Salicornia virginica*, *Salicornia subterminalis* y *Sporobolus virginicus*. De estas especies, *A. occidentalis*, *B. maritima*, *M. littoralis*, *S. bigelovii*, *S. subterminalis*, se encuentran en el sitio de estudio, y se pudo observar que *B. maritima*, se encuentra inmediatamente después a la cobertura por árboles de manglar.


Mencionado lo anterior, se decidió hacer una clase por cada especie de mangle, una clase para *B. maritima*, con el fin de identificar el final de la zona cubierta por árboles y arbustos de mangle, una clase para identificar a todas las demás especies asociadas al manglar y que se le dio el nombre de "Matorral halófilo" y una última clase para identificar al suelo. Los detalles de estas clases se presentan a continuación en la tabla 2. *B. maritima* fue separada de las demás especies ya que por su coloración y tamaño es fácilmente identificable en las fotografías aéreas. También en la tabla 2, se muestra la cantidad de píxeles utilizados por cada una de las clases y su metodología de extracción se explica posteriormente en la figura 6.

**Tabla 2.** Clases o tipos de coberturas diferentes y número de puntos por cada clase georreferenciados en campo.

No.	Clase	Puntos / clase	Valores / clase
1	<i>Avicennia germinans</i>	8	985
2	<i>Batis maritima</i>	7	875
3	<i>Laguncularia R. racemosa</i>	4	488
4	Matorral halófilo	9	1,113
5	<i>Rhizophora mangle</i>	7	851
6	Suelo	14	1,706
<b>Total:</b>		<b>49</b>	<b>6,018</b>

Para el geoposicionamiento de los puntos de cada clase se utilizó una estación RTK (Real Time Kinematics, por sus siglas en inglés), marca EMLID, modelo REACH RS+, la cual es una herramienta utilizada para obtener puntos geográficos con una precisión de hasta  $\pm 0.01$  m. La estación RTK también fue utilizada para georreferenciar puntos de control en tierra, mediante tapetes colocados sobre el suelo. Estos sirvieron para georrectificar las imágenes capturadas con el Dron y así lograr una mayor precisión del mosaico final.

Con estos puntos y los ortomosaicos georrectificados, se realizó la extracción de datos mediante la aplicación de un buffer con radio de 40cms alrededor de cada uno de los 49 puntos pertenecientes a todas las clases. Este buffer sirvió como delimitación para la extracción de los valores de los pixeles de cada una de las bandas de las cámaras RGB y GRN, los índices de vegetación (ver más adelante) y MDD. Todas estas capas fueron combinadas (apiladas) a manera de Raster Stack en el software R. Un ejemplo de esto se muestra en la figura 6. Estos valores fueron representados en gráficas de caja y bigotes (boxplots) para describir la dispersión de los valores de las clases en cada una de las bandas de las cámaras (RGB y GRN).



**Figura 6.** Ejemplo de extracción de valores de píxeles por puntos geográficos dentro de un buffer. Matriz de 12 x 12 representando píxeles de una capa, banda o imagen raster. Los puntos azules representan los puntos geográficos tomados con la estación RTK para cada una de las clases (colores), los círculos rojos son los buffers alrededor de cada punto, los píxeles que delimita el buffer fueron los valores extraídos para cada una de las clases.

## 6.6 Estimación de los índices de vegetación

Los índices de vegetación (IV) son valores que resultan de fórmulas algebraicas en las cuales se utiliza la reflectancia de determinadas bandas espectrales. Estas fórmulas son el resultado de intentos de crear mejores índices, tomando en cuenta factores como la reflectancia del suelo, la atmósfera y la densidad de la vegetación [24]. En este sentido, se calcularon un total de 25 índices de vegetación (17 para el ortomosaico RGB y 8 para el ortomosaico GRN).

Los IV utilizados se escogieron a partir de investigaciones realizadas para la identificación de características propias de la vegetación, como vigor o salud, dinámica del desarrollo, tamaño de copas, estimaciones de parámetros biofísicos y bioquímicos y área foliar [34–36]. Para calcular estos índices, se utilizó la librería *raster* [37] del software de programación R [38]. Los IV se

presentan en las tablas 3 y 4 para el ortomosaico RGB y para el ortomosaico GRN, respectivamente.

**Tabla 3.** Índices de vegetación aplicados al ortomosaico RGB.

No.	Nombre del índice de vegetación	Ecuación aplicada	Fuente
1		$NR = R/(R+G+B);$	
2	RGB normalizado en sus bandas	$NG = G/(R+G+B);$	Maimaitijiang <i>et al.</i> (2019)
3		$NB = B/(R+G+B)$	
4	Green Red Ratio Index (GRR)	$GRR = G/R$	Maimaitijiang <i>et al.</i> (2019)
5	Green Blue Ratio Index (GBRI)	$GBRI = G/B$	Maimaitijiang <i>et al.</i> (2019)
6	Red Blue Ratio Index (RBRI)	$RBRI = R / B$	Maimaitijiang <i>et al.</i> (2019)
7	Green-Red Vegetation Index (GRVI)	$GRVI = (G-R) / (G+R)$	Tucker (1979)
8	Woebbecke index (WI)	$WI = (G-B)/(R-G)$	Woebbecke <i>et al.</i> (1995)
9	Kawashima index (IKAW)	$IKAW = (R-B)/(R+B)$	Kawashima and Nakatani (1998)
10	Green Leaf Index	$GLI = ((2*G)-R-B)/((2*G)+R+B)$	Louhaichi <i>et al.</i> (2001)
11	Color Intensity Index (INT)	$INT = (R+G+B) / 3$	Ahmad and Reid (1996)
12	Normalized Difference Index (NDI)	$NDI = (rn-gn)/(rn+gn+0.01)$	Woebbecke <i>et al.</i> (1992)
13	Visible atmospherically index (VARI)	$VARI = (G-R)/(G+R-B)$	Gitelson <i>et al.</i> (2002)
14	Excess red vegetation index (ExR)	$EXR = 1.4 \times rn - gn$	Mao <i>et al.</i> (2003)
15	Excess green vegetation index (ExG)	$EXG = 2 \times gn - rn - bn$	Mao <i>et al.</i> (2003)
16	Excess blue vegetation index (ExB)	$EXB = 1.4 \times bn - gn$	Mao <i>et al.</i> (2003)
17	Principal component analysis index (IPCA)	$IPCA = 0.994 \times  R - B  + 0.961 \times  G - B  + 0.914 \times  G - R $	Saberioon <i>et al.</i> (2014)

Nota: <sup>1</sup>Tomado de [34,39,40]

**Tabla 4.** Índices de vegetación aplicados al ortomosaico GRN.

No.	Nombre del índice de vegetación	Ecuación aplicada	Fuente
1	Normalized Difference Vegetation Index (NDVI)	$NDVI = (NIR - R) / (NIR + R)$	Tucker (1979)
2	Soil Adjusted Vegetation Index (SAVI)	$SAVI = ((NIR - R) / (NIR + R + L)) \times (1 + L)$	Huete (1988)
3	Green Normalized Difference Vegetation Index (GNDVI)	$GNDVI = (NIR - G) / (NIR + G)$	Ahamed (2011)
4	Ratio Vegetation Index (RVI)	$RVI = NIR / R$	Ehammer <i>et al.</i> (2011)
5	Green ratio Vegetation Index (GVI)	$GVI = NIR / G$	Lee (2010)
6	Green-Red Normalized Difference Vegetation Index (GRNDVI)	$GRNDVI = (NIR - G + R) / (NIR + G + R)$	Russell <i>et al.</i> (2011)
7	Chlorophyll Vegetation Index (CVI)	$CVI = (NIR \times R) / (G^2)$	Hunt (2011)
8	Enhanced Vegetation Index (2) (EVI2)	$EVI2 = (2.5 \times (NIR - R)) / (NIR + (2.4 \times R + 1))$	Miura <i>et al.</i> (2008)

Nota: tomado de [34,41]

### 6.7 Evaluación del desempeño de los índices de vegetación

Para evaluar el desempeño de los IV se crearon dos macro clases: Suelo y Vegetación, utilizando las clases descritas en la tabla 2. Estas dos macro clases se utilizaron como variable dependiente y el IV de interés como variable independiente en modelos Random Forest (Liaw y Wiener, 2002) y su desempeño se evaluó mediante el uso de matrices de confusión [43]. La librería *RandomForest* (Liaw y Wiener, 2002) se utilizó para construir este tipo de modelos, mientras que la librería *Caret* [43] se utilizó para evaluar las matrices de confusión. Ambas del lenguaje de programación R [38]. La función “ConfussionMatrix” de la librería *Caret* utiliza una matriz de confusión para generar los siguientes estadísticos: 1) Sensibilidad, 2) Especificidad, 3) Precisión e 4) Índice de Kappa de Cohen.

Se le llama matriz de confusión porque esta resume el rendimiento de clasificación de un clasificador respecto a los datos de una muestra (que tanto se confunde o comete errores el clasificador) (Moreno-Casasola e Infante, 2013). La tabla 5 expone un ejemplo de una matriz de confusión y como estas son utilizadas para obtener estadísticos que expresan la capacidad predictiva del clasificador.



**Tabla 5.** Ejemplo de una matriz de confusión.

Observados	Predicción	
	Evento	No evento
Evento	A	B
No evento	C	D

A y D: Se consideran los valores de predicción correcta, aciertos o verdaderos positivos y negativos, respectivamente.

B y C: Se consideran los valores de predicción errónea o falsos positivos.

A + B: Indica la cantidad de objetos que pertenecen a que haya habido el evento, por lo que un clasificador perfecto, obtendrá objetos (valores) únicamente en A.

C + D: Indica la cantidad de objetos que pertenecen a que NO haya habido evento (No evento), por lo que un clasificador perfecto, obtendrá objetos (valores) únicamente en D.

A partir de estas métricas se calculan los estadísticos mencionados anteriormente:

**Precisión o Accuracy** =  $\left(\frac{A+D}{n}\right) * 100$ ; es el porcentaje de aciertos con respecto de n.

**Índice de Kappa de Cohen** =  $\frac{Pr(a) - Pr(e)}{1 - Pr(e)}$

$$Probabilidad\ de\ aciertos\ Pr(a) = \frac{A+D}{n}$$

$$Probabilidad\ de\ error\ Pr(e) = (Pr(A1) * Pr(B1) + Pr(A2) * Pr(B2))$$

$$Pr(A1) = (A + B) / n$$

$$Pr(B1) = (A + C) / n$$

$$Pr(A2) = (C + D) / n$$

$$Pr(B2) = (B + D) / n$$

**Sensibilidad** =  $\frac{A}{(A+C)}$  Es la proporción de verdaderos positivos que fueron correctamente identificadas.

**Especificidad** =  $\frac{D}{(B+D)}$  Es la proporción verdaderos negativos que fueron correctamente identificadas.

Se decidió utilizar Random Forest (Liaw y Wiener, 2002) para realizar la evaluación de los índices de vegetación, ya que ha demostrado consistentemente su habilidad para el mapeo de vegetación utilizando varios tipos de datos [45]. Este clasificador construye un conjunto de árboles individuales de decisión, a partir de los cuales se realiza una predicción final utilizando un esquema de votación mayoritaria [46]. Esta votación, es el promedio de todos los árboles de decisión y que se asemejan al que mejor realizó la clasificación, y en el caso de esta investigación, la correcta separación de las seis clases creadas que se mencionaron anteriormente.

### **6.8 Evaluación del desempeño de los IV implementando el MDD**

La implementación del MDD se utilizó únicamente con el IV que obtuvo los mejores resultados de Precisión, índice de Kappa de Cohen, Sensibilidad y Especificidad durante su evaluación, esto para los IV derivados del sensor RGB y GRN respectivamente, debido a que era necesario evaluar si el MDD producía mejores resultados que el IV por sí solo.

Posteriormente, y con el fin de mejorar los modelos añadiendo más variables de entrada al algoritmo, se llevó a cabo una evaluación en los modelos utilizando todos los IV RGB y GRN respectivamente, e incluyendo al MDD. En estos casos, los modelos fueron comparativos, entre los que usan el espectro de luz visible o RGB, contra los que utilizan la longitud de onda del verde, rojo e infrarrojo cercano o GRN, los cuales quedaron nombrados de la siguiente manera:

1. Mejor IV RGB + CHM
2. Mejor IV GRN + CHM
3. Todos los IV-RGB + CHM
4. Todos los IV-GRN + CHM

### **6.9 Mapas temáticos**

Según la Asociación Internacional de Cartografía (2014), un mapa temático es aquel que está diseñado para mostrar características o conceptos particulares. En el caso de esta investigación,

se realizó un mapa temático cualitativo de las clases que se realizaron, *A. germinans*, *B. maritima*, *L. racemosa*, Matorral halófilo, *R. mangle* y Suelo, esta muestra la extensión que cubre cada una de las clases sobre el plano en dos dimensiones del área de estudio.

Para la elaboración de los mapas temáticos, se utilizó el mejor modelo RGB (Todos los IV-RGB + MDD) y el mejor modelo GRN (Todos los IV-GRN + MDD), así como todas las capas de los RasterStack con los productos derivados de la cámara RGB y GRN, respectivamente. La función “predict” de la librería *raster* se empleó para generar los ráster con las predicciones de cada modelo. El software libre QGIS 3.0 fue utilizado para estilizar los raster con las predicciones y así generar los mapas temáticos finales.

Para estimar el área de cobertura por clase, se contabilizó el número total de píxeles pertenecientes a cada una de las clases y se multiplicó por la resolución espacial (en área), finalmente se convirtió este resultado a hectáreas. La resolución espacial de los productos es de 6.4 cm, lo que implica que cada píxel tiene una resolución de 40.96 cm<sup>2</sup>. Para estimar el porcentaje de cobertura, se dividió la cantidad de píxeles pertenecientes a cada clase, dentro del total de píxeles del ortomosaico (6,632,666 píxeles) y este resultado se multiplicó por 100.

### **6.9.1 Postprocesamiento del mapa temático**

Debido a que no se incluyó la clase agua en los modelos de clasificación supervisada, los mapas temáticos originales no cuentan con esta clase, además de que esto genera una pequeña sobre estimación de algunas clases. Debido a esto, se crearon polígonos, de manera manual en el software QGIS 3.0, para delimitar a los pequeños cuerpos de agua o zonas inundables presentes en el área de estudio. Posteriormente, los polígonos se utilizaron para aplicar una máscara (cambiar valores) a los raster con las predicciones de las clases. Para esto se utilizó la función “mask” del paquete *raster* [37]. A esta máscara se le otorgó el valor de 7, con el que se representó una séptima clase, llamada “Agua”. Este ejercicio de postprocesamiento, se unió al raster final, cambiando los valores de los píxeles que se encontraban dentro de la delimitación de las áreas con agua, esto mediante la función “merge” también del paquete “raster” en el software R [38].

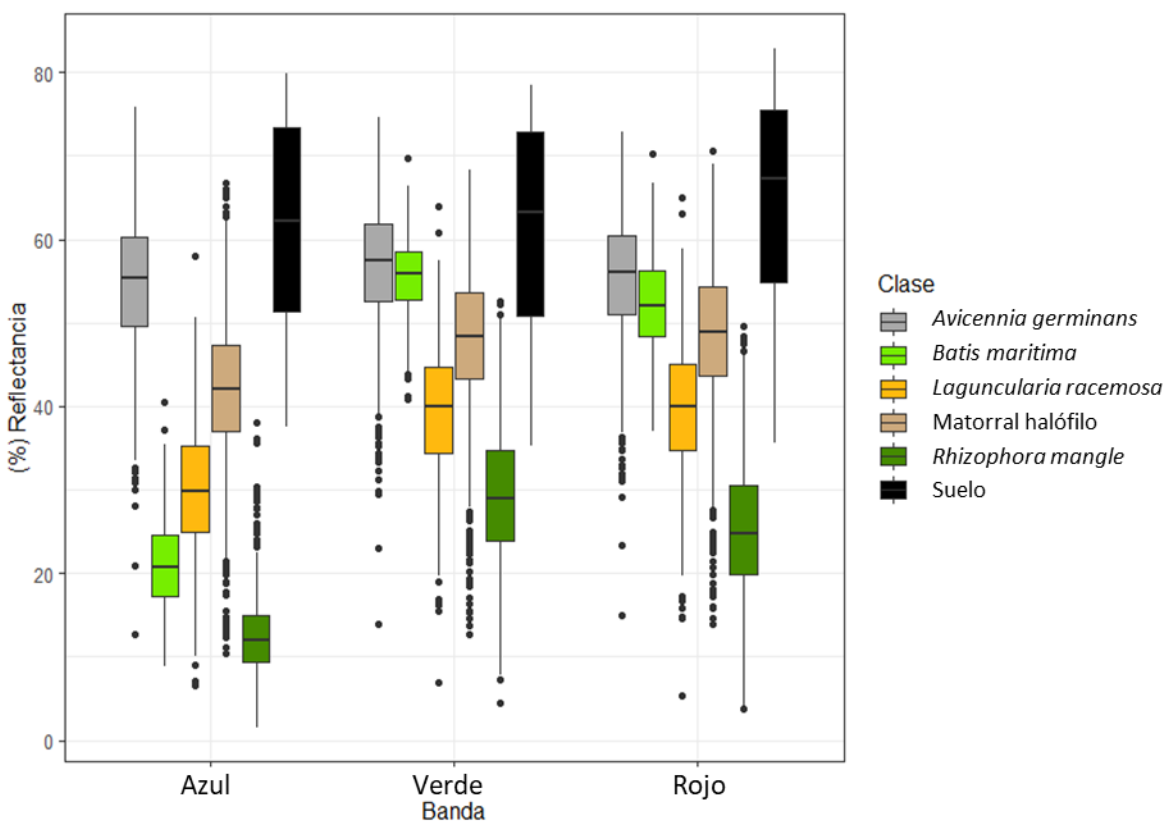
Para finalizar el postprocesamiento del mapa temático, se utilizó el software QGIS 3.0 Madeira, para representar mediante colores, todas las clases creadas y su ubicación dentro del sitio de estudio, con el fin de cuantificar la cantidad de píxeles y transformarlos a unidad de área (ha). Con este paso final, se obtuvo el área de cobertura por cada una de las especies y demás clases y su porcentaje de cobertura dentro del sitio de estudio.

## 7. RESULTADOS

### 7.1 Resultados previo a las evaluaciones de los IV

#### 7.1.2 Valores de reflectancia por bandas (RGB y GRN) y clases.

Los valores de los píxeles por banda (rojo, verde y azul) y por categoría de clase se muestran gráficamente a manera de resumen estadístico en la figura 7. Al respecto se aprecia que, la mayor variación de valores la presentan las clases matorral halófilo y *A. germinans*. Los valores mínimos de la clase matorral halófilo son 13.87%, 12.72% y 10.39%, mientras que los valores máximos son 70.51%, 68.33% y 66.81%, para las bandas rojo, verde y azul, respectivamente. La clase *A. germinans*, tiene valores mínimos de 15.01%, 14% y 12.75% y máximos de 72.87%, 74.68% y 75.83%. En términos de reflectancia en la parte visible de la luz, las clases suelo y *R. mangle* fueron las más contrastantes, debido a que la primera presenta valores muy altos de reflectancia, por el contrario, la segunda tiene valores bajos debido a su coloración (verde oscuro). Las medianas de la clase suelo por banda son 67.27%, 63.16% y 62.33%. Por el contrario, las medianas de la clase *R. mangle* son 24.82%, 29.02% y 12.05%. Las medianas de las otras clases varían entre sí, excepto por *A. germinans* y *B. maritima* dentro de las bandas verde y azul. Estas presentan medianas similares en las bandas verde y rojo, con reflectancias de 57.50%, 56.03% para *A. germinans* y, 55.81%, 52.08% para *B. maritima*, respectivamente. Por otra parte, los rangos intercuartílicos para *L. racemosa* muestran que el 50% de sus valores en las bandas RGB se encuentran en porcentajes de reflectancia diferentes a las demás clases, excepto en las bandas verde y rojo, en donde los valores altos del rango intercuartílico, se traslapa con los valores bajos del rango intercuartílico de la clase Matorral halófilo, sin embargo, no es así con el otro 50% de sus valores en la banda del azul. Los máximos y mínimos de esta clase son similares en las tres bandas RGB, con mínimos de 5.40%, 6.9% y 6.59% y máximos de 64.95, 63.99% y 58.09%.




**Figura 7.** Resumen estadístico de los valores de los píxeles por cada banda y clase del mosaico RGB. Las líneas verticales representan mínimos y máximos, o 1.5 veces el rango intercuartílico  $\pm$  la mediana en presencia de valores atípicos (puntos). Las cajas representan los cuartiles 25 y 75%. Las líneas horizontales representan las medianas.

Por otra parte, los valores de los píxeles del ortomosaico GRN, presentan algunas características diferentes a las del RGB, una de ellas, es la profundidad del píxel, ya que a diferencia de los 8bits del ortomosaico RGB, el ortomosaico GRN tiene una profundidad del píxel de 16bits, haciendo que las escalas de valores para cada una de las bandas, tomen valores de 0 a 65,535. La figura 8 muestra el resumen estadístico de los valores de reflectancia de los píxeles de cada una de las bandas y clase del ortomosaico GRN. En esta figura se observa que las medianas son muy parecidas entre clases para cada una de las bandas, exceptuando la del infrarrojo cercano. Cabe mencionar, que todos los valores en porcentajes de reflectancia, para este sensor, se encuentran por debajo del 50 %, mientras que los del sensor RGB y en el caso particular de la clase "Suelo", supera el 80 %.

Los valores de los píxeles que se encuentran en el rango intercuartílico de la banda del verde de todas las clases, son mayores a los valores de los rangos intercuartílico de la banda del rojo y el infrarrojo cercano. La clase Suelo tiene los valores más bajos en la banda del infrarrojo cercano, con 7.26 %, así mismo, el valor más elevado, también pertenece a esta clase, con 48.41 % en la banda del verde.

La banda del rojo tiene valores con rangos de porcentaje de reflectancia muy parecidos entre clases, al igual que sus medianas (*A. germinans* 6.16%, *B. maritima* 6.89%, *L. racemosa* 6.62%, Matorral halófilo 6.37%, *R. mangle* 6.16% y Suelo 6.76%), la mediana con valor más alto en porcentaje de reflectancia es para la clase Suelo, *A. germinans* y *R. mangle* las más bajas, sin embargo, la clase Suelo es la que mayor variación tiene en sus valores.

Por otra parte, en el caso de la banda del infrarrojo cercano, denota una mayor variación entre las medianas de las clases (*A. germinans* 8.65%, *B. maritima* 8.07%, *L. racemosa* 9.97%, Matorral halófilo 6.64%, *R. mangle* 14.53% y Suelo 4.51%), obteniendo el valor más bajo de reflectancia la clase Suelo y el valor más alto la clase *R. mangle*. Es importante mencionar que, a mayor diferencia de los valores de los píxeles entre clases, sugiere una mejor capacidad de la banda espectral para poder identificar las diferentes clases.



**Figura 8.** Resumen estadístico de los valores de los píxeles por cada banda y clase del mosaico GRN. Las líneas verticales representan mínimos y máximos, o 1.5 veces el rango intercuartílico  $\pm$  la mediana en presencia de valores atípicos (puntos). Las cajas representan los cuartiles 25 y 75%. Las líneas horizontales representan las medianas.

## 7.2. Evaluación de los IV

### 7.2.1 Evaluación de los IV RGB

A partir de los IV basados en el RGB, se observa que valores más altos de precisión, índice de Kappa de Cohen, especificidad y sensibilidad, son para el índice de vegetación de Exceso de Verde (EXG), con 54.82%, 0.4426, 52.37% y 42.4%, respectivamente. Sin embargo, otros índices de vegetación como el GLI y NG obtuvieron valores muy cercanos al EXG (tabla 6).



**Tabla 6.** Desempeño de IV obtenidos a partir del ortomosaico RGB en la clasificación de las 6 clases. En negritas el IV con el mejor desempeño.

No.	IV	Precisión %	Kappa	Especificidad %	Sensibilidad %
1	NR	45.65	0.3300	71.11	53.45
2	NG	54.8	0.4424	52.37	42.37
3	NB	50.55	0.3896	57.11	33.3
4	GRR1	42.19	0.2868	33.41	32.39
5	GBRI	52.86	0.4186	55.76	35.69
6	RBRI	51.15	0.3980	62.46	44.06
7	GRVI	42.19	0.2868	33.37	32.36
8	WI	51.6	0.4032	52.69	35.14
9	IKAW	51.21	0.3988	62.5	44.11
10	GLI	54.8	0.4425	52.37	42.39
11	INT	50.55	0.3912	36.59	40.85
12	NDI	41.84	0.2836	32.53	30.15
13	VARI	41.39	0.2772	31.04	28.64
14	EXR	32.8	0.1708	14.99	32.89
<b>15</b>	<b>EXG</b>	<b>54.82</b>	<b>0.4426</b>	<b>52.37</b>	<b>42.4</b>
16	EXB	51.43	0.4016	52.73	37.13
17	IPCA	51.66	0.4040	94.51	36.84

Para poder evaluar la capacidad que tienen los IV en la identificación de la vegetación, se utilizaron únicamente dos clases: vegetación y no vegetación, reclasificando todas las clases creadas para el área de estudio en función si pertenecen o no a la clase vegetación, de no pertenecer se clasificaron como no vegetación. El número de puntos y píxeles por clase se muestra en la tabla 7. Al igual que en la evaluación de los IV con 6 clases, el EXG fue el que mejores resultados obtuvo para discriminar vegetación y no vegetación (tabla 8). Sin embargo, la precisión, el índice de Kappa de Cohen, especificidad y sensibilidad, aumentaron drásticamente, 90.26%, 0.76, 93.29% y 82.67% respectivamente.

**Tabla 7.** Cantidad de puntos y píxeles evaluados únicamente para las clases vegetación y no vegetación.

No.	Clase	Puntos/clase	Píxeles/clase
<b>1</b>	<b>Vegetación</b>	27	4,312
<b>2</b>	<b>No vegetación</b>	22	1,706
	<b>Total</b>	<b>49</b>	<b>6,018</b>

**Tabla 8.** Desempeño de IV obtenidos a partir del ortomosaico RGB en la clasificación de vegetación/no vegetación. En negritas el IV con el mejor desempeño.

No.	IV	Precisión	Kappa	Esp.	Sen.
1	NR	72.67	0.3263	80.88	51.80
2	NG	90.25	0.7603	93.28	82.62
3	NB	79.21	0.4914	85.78	63.07
4	GRR1	76.82	0.4313	83.97	59.01
5	GBR1	83.91	0.6045	88.83	71.55
6	RBRI	78.66	0.4729	84.95	62.51
7	GRVI	76.77	0.4300	83.93	58.93
8	WI	83.67	0.5980	88.61	71.18
9	IKAW	78.66	0.4729	84.95	62.51
10	GLI	90.26	0.7606	93.29	82.67
11	INT	82.39	0.5686	87.96	68.63
12	NDI	77.09	0.4318	83.69	59.82
13	VARI	78.70	0.4769	85.25	62.33
14	EXR	68.61	0.2291	78.18	44.68
<b>15</b>	<b>EXG</b>	<b>90.26</b>	<b>0.7606</b>	<b>93.29</b>	<b>82.67</b>
16	EXB	82.67	0.5713	87.67	69.74
17	IPCA	75.19	0.3892	82.68	56.25

### 7.2.2 Evaluación de los IV GRN

De los IV basados en el GRN, el GRNDVI fue el que tuvo el mejor desempeño alcanzando un 61.63% de precisión (tabla 9). El IV con el peor desempeño fue el CVI con un 45% de precisión. De modo comparativo se aprecia que el GRNDVI obtiene mejores resultados que su contraparte en el RGB.

**Tabla 9.** Desempeño de IV obtenidos a partir del ortomosaico GRN en la clasificación de las 6 clases. En negritas el IV con el mejor desempeño.

No.	IV	Precisión %	Kappa	Especificidad %	Sensibilidad %
1	NDVI	60.3	0.5104	45.53	37.8
2	SAVI	60.25	0.5098	45.76	37.18
3	GNDVI	58.47	0.4879	31.68	34.52
4	RVI	60.3	0.5104	45.53	37.8
5	GVI	58.47	0.4879	31.68	34.52
<b>6</b>	<b>GRNDVI</b>	<b>61.63</b>	<b>0.5268</b>	<b>34.43</b>	<b>39.53</b>
7	CVI	45.05	0.3222	24.11	26.27
8	EVI2	60.25	0.5098	45.82	37.19

En la tabla 10, se muestran los resultados de Precisión, índice de Kappa de Cohen, Especificidad y Sensibilidad, resultado de la evaluación de todos los IV en el GRN utilizando únicamente dos clases, vegetación y no vegetación. Como se puede observar, los índices de vegetación que utilizan el infrarrojo cercano, obtienen mejores resultados de índice de Kappa de Cohen, que los que utilizan el espectro de luz visible RGB y que se mostraron en el apartado anterior, logrando valores de 0.7356 para el IV CVI, siendo este el resultado más bajo. Cabe mencionar, que de igual forma que al utilizar las seis clases, el IV GRNDVI, es el que mejores resultados obtiene, con Precisión, índice de Kappa de Cohen, Especificidad y Sensibilidad de 96.48 %, 0.9133, 97.52 % y 93.84 % respectivamente. También, este IV logra mejores resultados que el NDVI, al igual que al utilizar las seis clases.

**Tabla 10.** Desempeño de IV obtenidos a partir del ortomosaico GRN en la clasificación de vegetación/no vegetación. En negritas el IV con el mejor desempeño.

No.	IV	Precisión	Kappa	Especificidad	Sensibilidad
1	NDVI	94.93	0.8752	96.45	91.09
2	SAVI	94.92	0.8748	96.45	91.03
3	GNDVI	95.71	0.8942	96.88	92.74
4	RVI	94.92	0.8748	96.45	91.03
5	GVI	95.71	0.8942	96.88	92.74
<b>6</b>	<b>GRNDVI</b>	<b>96.48</b>	<b>0.9133</b>	<b>97.52</b>	<b>93.84</b>
7	CVI	89.27	0.7356	92.47	81.14
8	EVI2	94.92	0.8748	96.45	91.03

### 7.3 Clasificación supervisada del ortomosaico RGB

#### 7.3.1 Desempeño de clasificación usando el mejor IV RGB

Como se había mencionado anteriormente, el IV RGB con mejores resultados para el ortomosaico RGB fue el EXG. Los resultados de la matriz de confusión pueden observarse en la tabla 11, mientras que los errores de clasificación por cada clase y el porcentaje de precisión por clase se muestran en la figura 9. Este índice de vegetación obtuvo 3,295 píxeles correctamente clasificados (aciertos) de un total de 6,018.

*A. germinans*, tuvo una precisión de 43.35%; con 427 aciertos de 985 píxeles evaluados para esta clase. De los 558 falsos positivos, 77 fueron clasificados como *L. racemosa*, 347 como Matorral halófilo, 1 como *R. mangle* y 133 como Suelo. También obtuvo píxeles pertenecientes a otras clases que son clasificados como *A. germinans*, estos reciben el nombre de falsos negativos y en este sentido, *L. racemosa* incrementa a *A. germinans* con 88 píxeles, Matorral halófilo con 362, *R. mangle* con 2 y Suelo con 131.

La clase *B. maritima* obtuvo una precisión de 51.77% y 453 aciertos de un total de 875 píxeles evaluados para esta clase. De los 422 píxeles evaluados como falsos positivos, 18 fueron erróneamente clasificados como *L. racemosa*, 1 como Matorral halófilo y 403 como *R. mangle*. Esta clase también fue incrementada por errores de otras clases, *L. racemosa* aportó 16 píxeles, Matorral halófilo 2 y *R. mangle* 394.

*L. racemosa* fue la clase con menor precisión y cantidad de aciertos, 33.40% y 163 de un total de 488 píxeles evaluados para esta clase respectivamente. De los 325 falsos positivos, 88 fueron clasificados como *A. germinans*, 16 como *B. maritima*, 172 como Matorral halófilo, 29 como *R. mangle* y 143 como Suelo. Los incrementos proporcionados por otras clases clasificadas erróneamente como *L. racemosa* suman 310, de los cuales 77 fueron aportados por *A. germinans*, 18 por *B. maritima*, 170 por Matorral halófilo, 29 por *R. mangle* y 16 por la clase Suelo.


La precisión de la clase Matorral halófilo fue de 37.92%, con 422 aciertos de un total de 1,113 píxeles evaluados para esta clase. Esta clase obtuvo 691 falsos positivos, de los cuales 362 fueron clasificados como *A. germinans*, 2 como *B. maritima*, 170 como *L. racemosa*, 14 como *R. mangle* y 143 como la clase Suelo. Por otra parte, 674 píxeles fueron aportados por otras clases como falsos negativos incrementando la cantidad de píxeles clasificados como Matorral halófilo, siendo estos 347 píxeles aportados por la clase *A. germinans*, 1 por *B. maritima*, 172 por *L. racemosa*, 11 por *R. mangle* y 143 por la clase Suelo.

La clase *R. mangle* fue la segunda clase mejor clasificada con una precisión de 48.65% y 414 aciertos de 851 píxeles evaluados para esta clase. Sin embargo, obtuvo 437 falsos positivos de los cuales, 2 píxeles fueron evaluados como *A. germinans*, 394 como *B. maritima*, 29 como *L. racemosa*, 11 como Matorral halófilo y 1 píxel clasificado como Suelo. Las clases que aportan píxeles a *R. mangle* fueron *A. germinans* con 1, *B. maritima* con 403, *L. racemosa* con 29 y Matorral halófilo con 14 píxeles.

Por último, la precisión de la clase suelo fue de 83%, siendo esta la mejor precisión de todas las clases y que corresponde a 1,416 aciertos de un total de 1,706 píxeles evaluados para esta clase. Los 290 píxeles clasificados como falsos positivos fueron 131 para *A. germinans*, 16 para *L. racemosa* y 143 para Matorral halófilo. Cabe mencionar, que esta clase es la que menor confusión realizó, clasificando erróneamente parte de sus píxeles únicamente con las clases *A. germinans*, *L. racemosa* y Matorral halófilo. Por otra parte, todas las clases aportaron inflación a la clase Suelo, *A. germinans* aportó 133 píxeles, *L. racemosa* 20, Matorral halófilo 143 y *R. mangle* solo 1 píxel.

**Tabla 11.** Matriz de confusión del modelo RF con el IV EXG. Los números representan el número de píxeles.

n = 6,018	Matorral					
	<i>A. germinans</i>	<i>B. maritima</i>	<i>L. racemosa</i>	halófilo	<i>R. mangle</i>	Suelo
<i>A. germinans</i>	427	0	77	347	1	133
<i>B. maritima</i>	0	453	18	1	403	0
<i>L. racemosa</i>	88	16	163	172	29	20
Matorral halófilo	362	2	170	422	14	143
<i>R. mangle</i>	2	394	29	11	414	1
Suelo	131	0	16	143	0	1416



**Figura 9.** Clasificación de píxeles (en porcentaje) por clase usando el IV EXG. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).


### 7.3.2 Desempeño de clasificación usando el mejor IV RGB para dos clases

Los resultados de la clasificación de píxeles del IV EXG se presentan en la tabla 12, mientras que los porcentajes de precisión por clase y su error se observan en la figura 10. De esta forma, la clase que contempla la cobertura sin vegetación (No veg) obtuvo una precisión del 83% y 1,416 píxeles evaluados correctamente (aciertos) de un total de 1,706 evaluados para esta clase, realizando 290 falsos positivos clasificados como cobertura con vegetación. Así mismo, a esta clase le fue aportado 297 píxeles clasificados como falsos negativos por parte de la cobertura con vegetación. Para la cobertura con vegetación, su precisión de clase fue del 93.11% y 4,015 aciertos de un total de 4,312 píxeles evaluados para esta clase, por lo que 297 píxeles fueron evaluados como falsos positivos como cobertura sin vegetación y al mismo tiempo, 290 píxeles

fueron aportados como falsos negativos a esta clase por parte de la clase cobertura sin vegetación.

**Tabla 12.** Matriz de confusión del modelo RF con el IV EXG para dos clases. Los números representan el número de píxeles.

n = 6,018	Vegetación	No vegetación
Vegetación	4,015	297
No vegetación	290	1,416



**Figura 10.** Clasificación de píxeles (en porcentaje) vegetación/no vegetación usando el IV EXG. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).

### 7.3.3 Desempeño de clasificación usando el mejor IV RGB + MDD

Para esta clasificación, se creó un modelo que incluye al IV RGB que obtuvo mejores resultados para la clasificación de las 6 clases creadas y el modelo digital del dosel, por lo que el modelo es el IV EXG + MDD. Este modelo el MDD hace una mejora evidente en la capacidad de clasificación, ya que los valores de Precisión, índice de Kappa de Cohen, Especificidad y Sensibilidad fueron de 96.94%, 0.9623, 100% y 96.99% respectivamente.

Las precisiones por clase aumentaron drásticamente (Fig. 11), 98.07% para *A. germinans*, 99.89% para *B. maritima*, 80.53% para *L. racemosa*, 96.86% para Matorral halófilo, 95.65% para *R. mangle* y una clasificación del 100% para la clase Suelo. En la tabla 13 se muestran los resultados de la matriz de confusión para este modelo, en donde la clase *A. germinans* obtuvo 966 aciertos de un total de 985 píxeles evaluados para esta clase, los 19 píxeles mal clasificados como falsos positivos se desglosan en 15 píxeles clasificados como *L. racemosa*, 3 como Matorral halófilo y 1 píxel como *R. mangle*. Esta clase, tiene 29 píxeles de aportes mal clasificados por otras clases (falsos negativos) como *A. germinans*, entre estos, 26 son de *L. racemosa*, 2 de Matorral halófilo y 1 píxel de *R. mangle*.

*B. maritima* es la segunda clase mejor clasificada, con una precisión de 99.86% (Fig. 12), que equivale a 874 aciertos de un total de 875 píxeles evaluados para esta clase. Un único píxel es mal clasificado como falso positivo y fue en la clase Matorral halófilo. Algo importante de esta clase es que todas las demás, no cometen errores de clasificación con *B. maritima*, por lo que no hay aportes de falsos negativos hacia esta clase y que incrementen la cobertura.

La precisión de la clase *L. racemosa* fue de 80.53%, obteniendo 393 aciertos de un total de 488 píxeles evaluados para esta clase. De los 95 falsos positivos mal clasificados por el modelo, 26 fueron clasificados como *A. germinans*, 41 como Matorral halófilo y 28 píxeles como *R. mangle*. Esta clase obtiene una cierta inflación por parte de las otras clases, en total 85 píxeles fueron mal clasificados como falsos negativos para esta clase, de los cuales 15 son de *A. germinans*, 31 de Matorral halófilo y 35 de *R. mangle*.




Matorral halófilo obtuvo una precisión de 96.86%, con 1,078 aciertos y clasificando erróneamente como falsos positivos 35 píxeles, de los cuales 2 fueron como *A. germinans*, 31 como *L. racemosa* y 2 como Suelo, esto de un total de 1, 113 píxeles evaluados para esta clase. A pesar de la alta precisión, esta clase fue la que obtuvo mayor cantidad de aportes mal clasificados por parte de las otras clases, 46 píxeles erróneamente clasificados como falsos negativos en esta clase de los cuales 3 fueron aportados por *A. germinans*, 1 por *B. maritima*, 41 por *L. racemosa* y 1 píxel por *R. mangle*.

La precisión de la clase *R. mangle* fue de 95.65%, con 814 aciertos positivos de un total de 851 píxeles evaluados para esta clase. Este modelo confundió píxeles con las otras dos especies de mangle y también con Matorral halófilo. De los 37 píxeles mal clasificados, 1 píxel fue falso positivo como *A. germinans*, 35 como *L. racemosa* y también 1 píxel como Matorral halófilo. Así mismo, las clases que aportaron píxeles como falsos negativos a esta clase fueron *A. germinans* y *L. racemosa*, con 1 y 28 píxeles respectivamente.

Por último, la clase Suelo obtuvo una precisión del 100%, por lo que no hubo errores de clasificación por parte del modelo, el total de los píxeles evaluados para esta clase (1,706) fueron clasificados correctamente (aciertos), sin embargo, dos píxeles proporcionados por la clase Matorral halófilo incrementaron la cantidad de píxeles evaluada para esta clase por lo que la clase Suelo tuvo una sobreestimación de 2 píxeles.

**Tabla 13.** Matriz de confusión del modelo RF con el IV EXG + MDD. Los números representan el número de píxeles.

n = 6,018 p/e	<i>A. germinans</i>	<i>B. maritima</i>	<i>L. racemosa</i>	Matorral halófilo	<i>R. mangle</i>	Suelo
<i>A. germinans</i>	966	0	15	3	1	0
<i>B. maritima</i>	0	874	0	1	0	0
<i>L. racemosa</i>	26	0	393	41	28	0
Matorral halófilo	2	0	31	1078	0	2
<i>R. mangle</i>	1	0	35	1	814	0
Suelo	0	0	0	0	0	1706



**Figura 11.** Clasificación de píxeles (en porcentaje) por clase usando el IV EXG + MDD. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).

### 7.3.4 Desempeño de clasificación usando todos los IV-RGB

El presente modelo involucra el uso de los 17 IV obtenidos a partir del ortomosaico RGB en el modelo RF. Los resultados de los estadísticos de Precisión, índice de Kappa de Cohen, Especificidad y Sensibilidad fueron: 88.65%, 0.8598, 97.96% y 85.33%.

En este caso, los resultados de la matriz de confusión (tabla 14) muestran que la clase *A. germinans*, obtuvo una precisión de 84.47% (Fig. 12), indicando que, de los 985 píxeles en total evaluados para esta clase, 832 fueron aciertos positivos y 153 píxeles fueron mal clasificados como falsos positivos distribuidos en 10 píxeles como *L. racemosa*, 120 como Matorral halófilo y 23 como Suelo, como se puede observar en la tabla 14. Así mismo, otras clases clasificaron erróneamente sus píxeles como *A. germinans*, en total 143 píxeles, de los cuales 13 fueron

aportados por la clase *L. racemosa*, 109 por Matorral halófilo, 1 pixel por *R. mangle* y 20 aportados por la clase Suelo.

La clase *B. maritima* fue la segunda clase mejor clasificada por el modelo, con una precisión de 98.86% y 865 aciertos de un total de 875 pixeles evaluados para esta clase, por lo que 10 pixeles fueron mal clasificados como falsos positivos distribuidos en 2 pixeles como *L. racemosa*, 1 como Matorral halófilo y 7 como *R. mangle*. Así mismo, esta clase obtuvo 18 pixeles que la incrementan por parte de otras dos clases, 1 pixel por parte de *L. racemosa* y 17 por parte de *R. mangle*. Cabe mencionar, que es la clase con menor cantidad de falsos negativos.

*L. racemosa* obtuvo una precisión de 59.63%, siendo esta menor al modelo que utiliza el IV EXG y el MDD, y recordando que esta es una de las especies de interés de esta investigación. De los 488 pixeles evaluados para esta clase, 291 fueron aciertos positivos y 197 fueron falsos positivos distribuidos en 13 pixeles como *A. germinans*, 1 pixel como *B. maritima*, 156 como Matorral halófilo, 24 como *R. mangle* y 3 pixeles como Suelo. Esta clase también obtuvo inflación por parte de las otras clases, 151 pixeles en total aportados 10 por *A. germinans*, 2 por *B. maritima*, 107 por Matorral halófilo y 32 por *R. mangle*.

La clase Matorral halófilo presenta una precisión de 78.62% y 875 aciertos positivos de un total de 1,113 pixeles evaluados. Esta clase cuenta con 238 pixeles con errores de clasificación o falsos positivos distribuidos en 109 pixeles como *A. germinans*, 107 como *L. racemosa*, 2 como *R. mangle* y 20 pixeles como suelo. De igual forma, los pixeles aportados por otras clases a Matorral halófilo suman 292, de los cuales 120 son por parte de *A. germinans*, 1 por parte de *B. maritima*, 156 por *L. racemosa*, 9 por *R. mangle* y 6 por la clase Suelo.


*R. mangle* obtuvo una precisión de 93.07%, con 792 aciertos de un total de 851 pixeles evaluados. Los 59 pixeles erróneamente clasificados como falsos positivos se distribuyen en 1 pixel para la clase *A. germinans*, 17 para la clase *B. maritima*, 32 como *L. racemosa* y 9 como Matorral halófilo, por lo que no presenta confusión con la clase Suelo. Por otra parte, los falsos negativos o pixeles que fueron aportados por otras clases a *R. mangle* suman un total de 33 y fueron aportados 7 por la clase *B. maritima*, 24 por *L. racemosa* y 2 pixeles por la clase Matorral

halófilo. De las especies de interés, *R. mangle* fue la que mejores resultados de clasificación obtuvo en este modelo.

La clase Suelo obtuvo una precisión de 98.48% y 1,680 píxeles correctamente clasificados de un total de 1,706. Los 26 píxeles que fueron mal clasificados como falsos positivos, se distribuyeron en 20 píxeles para la clase *A. germinans* y 6 como Matorral halófilo.

**Tabla 14.** Matriz de confusión del modelo RF con todos los IV derivados del ortomosaico RGB. Los números representan el número de píxeles.

n = 6,018 p/e	<i>A. germinans</i>	<i>B. maritima</i>	<i>L. racemosa</i>	Matorral halófilo	<i>R. mangle</i>	Suelo
<i>A. germinans</i>	832	0	10	120	0	23
<i>B. maritima</i>	0	865	2	1	7	0
<i>L. racemosa</i>	13	1	291	156	24	3
Matorral halófilo	109	0	107	875	2	20
<i>R. mangle</i>	1	17	32	9	792	0
Suelo	20	0	0	6	0	1680



**Figura 12.** Clasificación de píxeles (en porcentaje) por clase usando todos los IV obtenidos del ortomosaico RGB. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).

### 7.3.5 Desempeño de clasificación usando todos los IV RGB + MDD

Este modelo no obtuvo precisión del 100% en ninguna de las clases clasificadas a diferencia del modelo EXG + MDD, sin embargo, la Precisión general, el índice de Kappa de Cohen y Sensibilidad tuvieron valores superiores, 97.51%, 0.9693, 100% y 98.39%, respectivamente.

Dentro de los resultados de la matriz de confusión para este modelo (tabla15), la clase *A. germinans* tiene una precisión de 98.88% (Fig. 13), clasifica correctamente como aciertos positivos 975 píxeles de un total de 985 para esta clase. Los 10 píxeles erróneamente clasificados fueron falsos positivos ubicados en la clase *L. racemosa*, por lo que el modelo no

comete errores con otras clases. Por otra parte, otras clases si clasificaron parte de sus pixeles como *A. germinans*, con un total de 16 pixeles clasificados como falsos negativos para esta clase, incrementando la cantidad de sus pixeles. De los 16 pixeles mal clasificados, 15 fueron por la clase *L. racemosa* y 1 pixel por la clase Matorral halófilo.

*B. maritima* obtuvo una precisión de 99.77% con 873 pixeles correctamente clasificados de un total de 875 pertenecientes a esta clase. Los únicos dos pixeles mal clasificados fueron falsos positivos para la clase Matorral halófilo. Cabe mencionar que esta clase no obtuvo incrementos en sus pixeles por parte de otras clases, por lo que el modelo no generó falsos positivos.

*L. racemosa* es la clase con mayor cantidad de errores de clasificación, por lo que su precisión de clase fue de 87.91%, clasificando como aciertos positivos a 429 pixeles de un total de 488. De los 59 falsos positivos, 15 pixeles fueron erróneamente clasificados como *A. germinans*, 24 como Matorral halófilo y 20 como *R. mangle*. Al mismo tiempo, esta clase fue la que más aportes tuvo por parte de otras clases (falsos negativos) con un total de 82 pixeles de los cuales, 10 fueron por parte de *A. germinans*, 36 por Matorral halófilo y otros 36 pixeles por parte de la clase *R. mangle*.


Matorral halófilo obtuvo una precisión de 96.59% con 1,075 aciertos de un total de 1,113 pixeles que fueron evaluados para esta clase. Los 38 pixeles que fueron mal clasificados como falsos positivos se distribuyeron en 1 pixel clasificado como *A. germinans*, 39 como *L. racemosa* y 1 como Suelo. Esta clase obtuvo incrementos en la cantidad de sus pixeles que fueron erróneamente clasificados por otras clases como Matorral halófilo exceptuando a la clase *A. germinans*, por lo que las otras clases aportaron 2 pixeles por la clase *B. maritima*, 24 por *L. racemosa*, 3 por *R. mangle* y 2 por la clase Suelo.

*R. mangle* obtuvo una precisión de 95.42% con 812 aciertos positivos de 851 pixeles evaluados por el modelo. De los 39 pixeles mal clasificados como falsos positivos, 36 fueron para la clase *L. racemosa* y 3 para la clase Matorral halófilo. Esta clase tuvo incrementos en los pixeles debido a que *L. racemosa* clasificó erróneamente 20 de sus pixeles como *R. mangle*.

Suelo fue la que mejores resultados obtuvo, con una precisión de 99.88%, confundiendo únicamente dos pixeles como Matorral halófilo, de los 1,706 pixeles pertenecientes a esta clase. Así mismo, la única clase que tuvo confusión en su clasificación con esta clase fue Matorral halófilo con un único pixel mal clasificado.

**Tabla 15.** Matriz de confusión del modelo RF con todos los IV derivados del ortomosaico RGB y el MDD. Los números representan el número de pixeles.

n = 6,018 p/e	<i>A. germinans</i>	<i>B. maritima</i>	<i>L. racemosa</i>	Matorral halófilo	<i>R. mangle</i>	Suelo
<i>A. germinans</i>	975	0	10	0	0	0
<i>B. maritima</i>	0	873	0	2	0	0
<i>L. racemosa</i>	15	0	429	24	20	0
Matorral halófilo	1	0	36	1075	0	1
<i>R. mangle</i>	0	0	36	3	812	0
Suelo	0	0	0	2	0	1704



**Figura 13.** Clasificación de píxeles (en porcentaje) por clase usando todos los IV obtenidos del ortomosaico RGB y el MDD. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).

## 7.4 Clasificación supervisada del ortomosaico GRN

### 7.4.1 Desempeño de clasificación usando el mejor IV GRN

Como se mencionó en la evaluación de los IV GRN, el GRNDVI fue el IV que obtuvo mejores resultados para identificar a las seis clases que se realizaron, la matriz de confusión y los resultados de precisión por clase se muestran en la tabla 16 y figura 14, respectivamente. Este IV obtuvo 3,709 aciertos positivos de un total de 6,018 píxeles evaluados pertenecientes a las seis clases (tabla 16). Para *A. germinans* 391 de 985 píxeles fueron correctamente clasificados



obteniendo un 39.7% de precisión de clase y de los 594 píxeles mal clasificados como falsos positivos, 154 fueron píxeles identificados como *B. maritima*, 197 píxeles como *L. racemosa*, 205 como Matorral halófilo, 36 como *R. mangle* y 2 píxeles como Suelo. También, esta clase tuvo incrementos obtenidos por los errores de clasificación de las demás clases, en total 598 píxeles de los cuales 161 fueron aportados por *B. maritima*, 200 por *L. racemosa*, 207 por Matorral halófilo, 29 por *R. mangle* y 1 píxel por la clase Suelo.

La siguiente clase evaluada fue *B. maritima*, obteniendo una precisión de clase de 33.49%, la más baja de las seis clases con 293 aciertos de un total de 875 píxeles evaluados para esta clase. De los 582 falsos positivos, 161 fueron erróneamente clasificados como *A. germinans*, 37 como *L. racemosa*, 363 como Matorral halófilo y 21 como Suelo. Aparte, 557 píxeles fueron aportados por errores de clasificación de otras clases hacia *B. maritima*, de los cuales 154 fueron aportados por *A. germinans*, 26 por *L. racemosa*, 355 por Matorral halófilo y 22 por la clase Suelo. Esta clase no tuvo errores de clasificación con la clase *R. mangle* ni esta proporcionó errores de clasificación hacia *B. maritima*.

*L. racemosa* obtuvo una precisión de 39.55% y 193 aciertos de un total de 488 píxeles evaluados y pertenecientes a esta clase. De los 295 píxeles como falsos positivos, 200 fueron erróneamente clasificados como *A. germinans*, 26 como *B. maritima*, 42 como Matorral halófilo, 26 como *R. mangle* y 1 píxel como Suelo. Así mismo, las demás clases clasificaron erróneamente parte de sus píxeles como *L. racemosa*, 294 en total, de los cuales 197 fue por parte de *A. germinans*, 37 por *B. maritima*, 34 por Matorral halófilo, 25 por *R. mangle* y 1 píxel por parte de la clase Suelo. Esta clase tuvo la precisión más baja de las tres especies de interés.

Continuando con los resultados de evaluación, Matorral halófilo obtuvo una precisión de 39.17% con 436 aciertos de un total de 1,113 píxeles evaluados pertenecientes a esta clase, los 677 píxeles catalogados como falsos positivos, se distribuyeron en 207 para la clase *A. germinans*, 355 como *B. maritima*, 34 como *L. racemosa* y 81 como la clase Suelo. Las demás clases exceptuando a *R. mangle*, aportaron 693 píxeles erróneamente clasificados como


Matorral halófilo de los cuales 205 fueron mal clasificados por parte de *A. germinans*, 363 por *B. maritima*, 42 por *L. racemosa* y 83 por la clase Suelo.

La clase *R. mangle* fue la que obtuvo mejores resultados de clasificación por parte del IV GRNDVI, con una precisión de 93.65% y 797 aciertos de un total de 851 píxeles pertenecientes a esta clase. Los 54 píxeles mal clasificados como falsos positivos se distribuyeron únicamente en las otras dos especies de mangle, 29 píxeles como *A. germinans* y 25 píxeles como *L. racemosa*. De igual forma, las únicas dos clases que aportaron errores de clasificación como *R. mangle*, fueron *A. germinans* y *L. racemosa*, con 36 y 26 píxeles respectivamente.

Para finalizar la evaluación de este IV, la clase Suelo fue la que obtuvo mejores resultados con una precisión cercana a la clase anterior (*R. mangle*) de 93.73% y 1,599 aciertos de un total de 1,706 píxeles evaluados para esta clase. 107 píxeles fueron mal clasificados como falsos positivos y se distribuyen en 1 píxel mal clasificado para *A. germinans*, 22 para *B. maritima*, 1 para *L. racemosa* y 83 como Matorral halófilo. Por otra parte, las clases que cometieron errores de clasificación y que aportaron a la clase Suelo fueron *A. germinans* con 2 píxeles, *B. maritima* con 21, *L. racemosa* con 1 y Matorral halófilo con 81 píxeles.

**Tabla 16.** Resultados de la matriz de confusión para el IV GRNDVI.

n = 6,018 p/e	Matorral					
	<i>A. germinans</i>	<i>B. maritima</i>	<i>L. racemosa</i>	halófilo	<i>R. mangle</i>	Suelo
<i>A. germinans</i>	391	154	197	205	36	2
<i>B. maritima</i>	161	293	37	363	0	21
<i>L. racemosa</i>	200	26	193	42	26	1
Matorral halófilo	207	355	34	436	0	81
<i>R. mangle</i>	29	0	25	0	77	0
Suelo	1	22	1	83	0	1599



**Figura 14.** Clasificación de píxeles (en porcentaje) por clase usando el IV GRNDVI. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).


#### 7.4.2 Desempeño de clasificación usando el mejor IV GRN para dos clases

Del mismo modo en el que el IV RGB (EXG) que obtuvo mejores resultados fue evaluado para diferenciar la vegetación de lo que no es vegetación, también se realizó el mismo procedimiento para el mejor IV GRN. En este caso el GRNDVI fue el IV utilizado y los píxeles fueron separados de la misma forma (tabla 8). Los resultados de la matriz de confusión se muestran en la tabla 17 y las precisiones por clase en la figura 15. Para empezar, la clase que integra a la cobertura sin vegetación obtuvo una precisión de 93.73% y 1,599 aciertos de un total de 1,706, los 107 píxeles evaluados como falsos positivos fueron clasificados como cobertura con vegetación. Por otra parte, la cobertura con vegetación obtuvo mejores resultados, con una precisión de clase de

97.56%, por lo que 4,207 píxeles fueron correctamente clasificados y 105 píxeles fueron clasificados como cobertura sin vegetación.

**Tabla 17.** Resultados de la matriz de confusión para el IV GRNDVI con dos clases.

n = 6,018 p/e	Vegetación	No vegetación
Vegetación	4,207	105
No vegetación	107	1,599



**Figura 15.** Clasificación de píxeles (en porcentaje) vegetación/no vegetación usando el IV GRNDVI. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).

### 7.4.3 Desempeño de clasificación usando el mejor IV GRN + MDD


Este es un modelo que involucra al GRNDVI y el MDD. Los resultados de Precisión, índice de Kappa de Cohen, Especificidad y Sensibilidad se incrementaron sustancialmente a pesar de utilizar las seis clases creadas con 92.09%, 0.9025, 83.89% y 93.11% respectivamente, pero se puede señalar que los resultados de estos estadísticos se encuentran por debajo de su modelo contraparte en la longitud de onda de luz visible IV EXG + MDD. Los resultados de la matriz de confusión de este modelo se exponen en la tabla 18 y los porcentajes de las precisiones por clase y sus respectivos errores de clasificación se muestran en la figura 16. En base a sus resultados, la clase *A. germinans* obtuvo una precisión de 91.98% y 906 aciertos de 985 píxeles pertenecientes a esta clase por lo que sus 79 píxeles erróneamente clasificados como falsos positivos se distribuyeron en las clases *L. racemosa*, Matorral halófilo y *R. mangle*, con 66, 4 y 9 píxeles respectivamente. A esta clase le aportaron un total de 67 píxeles por parte de errores de clasificación de otras dos clases, *L. racemosa* con 62 y *R. mangle* con 5 píxeles.

La clase *B. maritima* logró 92.23% de precisión con 807 aciertos de 875 píxeles pertenecientes a esta clase y de los 68 errores de clasificación o falsos positivos, 66 fueron clasificados como Matorral halófilo y 2 píxeles como suelo. Cabe resaltar que esta clase solo obtuvo 155 píxeles que fueron aportes por errores de clasificación de la clase Matorral halófilo. Continuando con la clase *L. racemosa*, esta obtuvo la precisión más baja con 75.82% y 370 aciertos de 488 píxeles. De los 118 píxeles que fueron falsos positivos, 62 fueron clasificados como *A. germinans*, 31 como Matorral halófilo y 25 como *R. mangle*. Los aportes por errores de clasificación de otras clases como *L. racemosa* suman 115 píxeles y fueron por parte de las clases *A. germinans*, Matorral halófilo y *R. mangle* con 66, 20 y 29 píxeles respectivamente. La siguiente clase fue Matorral halófilo, que obtuvo una precisión de 84.19% y 937 aciertos de 1,113 píxeles pertenecientes a esta clase. De los 176 píxeles que resultaron como falsos positivos, 155 fueron clasificados como *B. maritima*, 20 como *L. racemosa* y un único píxel como *R. mangle*. Esta clase obtuvo 102 píxeles por aportes de errores de clasificación de las otras clases exceptuando a Suelo, 4 por parte de la clase *A. germinans*, 66 por parte de *B. maritima*, 31 por *L. racemosa* y 1 píxel por parte de *R. mangle*. Posteriormente se encuentra la clase *R. mangle*, la cual fue la que obtuvo la mejor precisión de las especies de mangle, 95.89% y 816 aciertos positivos de 851

pixeles. De los 35 falsos positivos, 5 pixeles fueron clasificados como *A. germinans*, 29 como *L. racemosa* y un pixel como Matorral halófilo. Por otra parte 35 pixeles fueron sumados a *R. mangle* como errores de clasificación de otras clases, de los cuales 9 fueron aportados por *A. germinans*, 25 por *L. racemosa* y 1 pixel por la clase Matorral halófilo. Para finalizar la evaluación de este modelo, la clase Suelo fue clasificada perfectamente, con 100% de precisión por lo que la totalidad de sus pixeles fueron correctamente clasificados, sin embargo, obtuvo un incremento de dos pixeles que fueron aportados por la clase *B. maritima*.

**Tabla 18.** Resultados de la matriz de confusión para el modelo GRNDVI + MDD.

n = 6,018 p/e	<i>A. germinans</i>	<i>B. maritima</i>	<i>L. racemosa</i>	Matorral halófilo	<i>R. mangle</i>	Suelo
<i>A. germinans</i>	906	0	66	4	9	0
<i>B. maritima</i>	0	807	0	66	0	2
<i>L. racemosa</i>	62	0	370	31	25	0
Matorral halófilo	0	155	20	937	1	0
<i>R. mangle</i>	5	0	29	1	816	0
Suelo	0	0	0	0	0	1706



**Figura 16.** Clasificación de píxeles (en porcentaje) por clase usando el IV GRNDVI + MDD. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).

#### 7.4.4 Desempeño de clasificación usando todos los IV-GRN

En este modelo se utilizaron al mismo tiempo los 8 IV GRN, cabe resaltar que, a diferencia de su contraparte en el RGB, este modelo no presenta mejores resultados al momento de incrementar las variables de entrada al algoritmo, ya que sus estadísticos de Precisión, índice de Kappa de Cohen, Especificidad y Sensibilidad, 0.87%, 0.6405, 55.97% y 47.89% respectivamente y no son sustancialmente mejores que los resultados de la utilización individual del IV GRNDVI. En este sentido, los resultados de la matriz de confusión y los porcentajes de precisión por clase se presentan en la tabla 19 y en la figura 17 respectivamente.

Comenzando con la clase *A. germinans*, esta obtuvo una precisión de 49.64% la cual se ve reflejada con más errores de clasificación o falsos positivos que sus aciertos positivos, 496 y 489 respectivamente, de un total de 985 píxeles. De los 496 falsos positivos, 130 fueron clasificados

como *B. maritima*, 159 como *L. racemosa*, 182 como Matorral halófilo, 22 como *R. mangle* y 3 pixeles como suelo. Los pixeles aportados por errores de clasificación de las demás clases suman 532 pixeles, de los cuales 108 fueron por parte de la clase *B. maritima*, 200 por *L. racemosa*, 198 de Matorral halófilo, 24 de *R. mangle* y 2 pixeles por parte de la clase Suelo.

La clase *B. maritima* obtuvo una precisión de 59.43% y 520 aciertos de un total de 875 pixeles. De los 355 falsos positivos, 108 fueron clasificados como la clase *A. germinans*, 12 como *L. racemosa*, 233 como Matorral halófilo y 2 pixeles como Suelo. Así mismo, los aportes por otras clases a *B. maritima* suman 409, de los cuales 130 fueron aportes por la clase *A. germinans*, 18 por parte de *L. racemosa*, 259 por Matorral halófilo y 2 por la clase Suelo. La clase evaluada con la precisión más baja es *L. racemosa* y fue de 45.7% con 223 aciertos de un total de 488 pixeles. Los 265 pixeles que fueron falsos positivos se distribuyen en 200 para la clase *A. germinans*, 18 para *B. maritima*, 28 para Matorral halófilo y 19 para *R. mangle*. De igual forma, las demás clases exceptuando a Suelo, aportaron pixeles a *L. racemosa*, en total 220, de los cuales 159 fueron por parte de *A. germinans*, 12 por *B. maritima*, 23 por Matorral halófilo y 26 por parte de la clase *R. mangle*.


El modelo obtuvo 51.75% de precisión para la clase Matorral halófilo, con 576 aciertos y 198 falsos positivos clasificados como *A. germinans*, 259 como *B. maritima*, 23 como *L. racemosa* y 57 como la clase Suelo, sumando un total de 537 falsos positivos de un total de 1,113 pixeles evaluados en esta clase. Las clases *A. germinans*, *B. maritima*, *L. racemosa* y Suelo, realizaron aportes por errores de clasificación hacia Matorral halófilo, 182, 233, 28 y 46 respectivamente, sumando en total 489 pixeles mal clasificados como Matorral halófilo. Sin embargo, la clase *R. mangle* fue la especie mejor clasificada, con una precisión de 94.12% y 801 aciertos de un total de 851 pixeles. De los 50 pixeles falsos positivos, el modelo los clasificó como las otras dos especies de mangle, 24 como *A. germinans* y 26 como *L. racemosa*. De igual forma, las últimas clases mencionadas fueron las únicas que aportaron pixeles mal clasificados a *R. mangle*, con 22 y 19 respectivamente. Por último, la clase Suelo fue la que mejores resultados obtuvo por el modelo, clasificando con una precisión del 97.07% a los 1,706 pixeles, por lo que 1656 pixeles



fueron correctamente clasificados y 50 falsos positivos distribuidos en las clases *A. germinans*, *B. maritima* y Matorral halófilo, 2, 2 y 46 respetivamente.

**Tabla 19.** Resultados de la matriz de confusión para el modelo que incluye a todos los IV-GRN.

n = 6,018 p/e	<i>A. germinans</i>	<i>B. maritima</i>	<i>L. racemosa</i>	Matorral halófilo	<i>R. mangle</i>	Suelo
<i>A. germinans</i>	489	130	159	182	22	3
<i>B. maritima</i>	108	520	12	233	0	2
<i>L. racemosa</i>	200	18	223	28	19	0
Matorral halófilo	198	259	23	576	0	57
<i>R. mangle</i>	24	0	26	0	801	0
Suelo	2	2	0	46	0	1656



**Figura 17.** Clasificación de píxeles (en porcentaje) por clase usando todos los IV obtenidos del ortomosaico GRN. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).

#### 7.4.5 Desempeño de clasificación usando todos los IV GRN + MDD


Este modelo utilizó todas las variables de entrada obtenidas con la cámara GRN, los 8 IV GRN y el MDD. Los resultados de Precisión, índice de Kappa de Cohen, Especificidad y Sensibilidad fueron 92.84%, 0.9117, 87.26% y 92.91% respectivamente. Los resultados de la matriz de confusión y los porcentajes de precisión por clase se exponen en la tabla 20 y la figura 18.

Comenzando con la clase *A. germinans*, esta obtuvo una precisión de 93.2% con 918 aciertos positivos de 985 píxeles pertenecientes a esta clase. De los 67 falsos positivos por este modelo, 57 fueron clasificados como *L. racemosa*, 4 como Matorral halófilo y 6 píxeles como la clase *R. mangle*. Además, 70 píxeles fueron mal clasificados por otras clases como *A. germinans*, de los cuales 65 fueron erróneamente clasificados por parte de *L. racemosa*, 1 píxel por parte de Matorral halófilo y 4 píxeles más aportados por *R. mangle*. Siguiendo con el orden alfabético, la clase *B. maritima* obtuvo una precisión de clase de 93.14% con 815 aciertos de un total de 875 píxeles propios de esta clase. Los errores de clasificación como falsos positivos suman un total de 60 píxeles y se distribuyeron en 54 píxeles como la clase Matorral halófilo y 6 como la clase Suelo, así mismo, las clases *A. germinans* y *L. racemosa* fueron las que aportaron errores de clasificación de sus píxeles como *B. maritima* con 6 y 27 píxeles respectivamente, sumando un total de 33 píxeles. La siguiente clase evaluada fue *L. racemosa*, la cual obtuvo una precisión de 74.18% con 362 aciertos positivos de un total de 488 píxeles. Esta clase no tiene errores de clasificación con *B. maritima* y Suelo, pero el modelo clasificó erróneamente 65 píxeles como *A. germinans*, 34 como Matorral halófilo y 27 como *R. mangle*, sumando un total de 127 falsos positivos. De igual forma, las últimas clases mencionadas fueron las que otorgaron píxeles a *L. racemosa* por parte de sus errores de clasificación, 57 por parte de *A. germinans*, 17 Matorral halófilo y 32 *R. mangle*, sumando un total de 106 aportes por errores de clasificación de otras clases. Posteriormente se evaluó la clase Matorral halófilo y logró una precisión de 87.69% con 976 aciertos de un total de 1,113 píxeles pertenecientes a esta clase. De los 137 falsos positivos, 1 píxel fue mal clasificado como *A. germinans*, 117 como *B. maritima*, 17 como *L. racemosa* y 2 píxeles como Suelo. A esta clase le aportan errores de clasificación todas las demás, sumando en total 95 píxeles aportados a Matorral halófilo, 4 aportados por *A. germinans*, 54 por *B. maritima*, 34 *L. racemosa*, 1 píxel *R. mangle* y 2 píxeles la clase Suelo.

De las especies de interés, *R. mangle* fue la que mejores resultados obtuvo, con 95.65% de precisión de clase y 814 aciertos positivos de 851 píxeles. El modelo cometió errores de clasificación con *A. germinans* y Matorral halófilo, 65 y 34 píxeles respectivamente, por lo que suman un total de 99 falsos positivos. Es de resaltar que las únicas clases que aportan píxeles a *R. mangle* por errores de clasificación son las otras dos especies de mangle, *A. germinans* con 6 y *L. racemosa* con 27 píxeles, por lo que se suman 33 píxeles a esta clase. Para finalizar la evaluación del modelo, la clase Suelo es la que mejores resultados obtuvo, 99.77% de precisión de clase, por lo que sólo cuatro píxeles fueron mal clasificados por el modelo de un total de 1,706, distribuidos en dos y dos para las clases *B. maritima* y Matorral halófilo. Se puede observar, que la clase *B. maritima* comete más errores de clasificación con la clase Suelo, 6 en total, que aportan incrementos en la cantidad de píxeles a la clase y únicamente dos píxeles por la clase Matorral halófilo.

**Tabla 20.** Resultados de la matriz de confusión para el modelo todos los IV-GRN + MDD.

n = 6,018 p/e	<i>A. germinans</i>	<i>B. maritima</i>	<i>L. racemosa</i>	Matorral halófilo	<i>R. mangle</i>	Suelo
<i>A. germinans</i>	918	0	57	4	6	0
<i>B. maritima</i>	0	815	0	54	0	6
<i>L. racemosa</i>	65	0	362	34	27	0
Matorral halófilo	1	117	17	976	0	2
<i>R. mangle</i>	4	0	32	1	814	0
Suelo	0	2	0	2	0	1702



**Figura 18.** Clasificación de píxeles (en porcentaje) por clase usando todos los IV obtenidos del ortomosaico GRN y el MDD. Los números de cada color es la precisión (verdaderos positivos) por clase en porcentaje. Las barras sin número muestran el porcentaje de píxeles mal clasificados (falsos positivos).

## 7.5 Cobertura por clase

### 7.5.1 Mapas temáticos (corrección con polígonos de agua)

Al agregar la clase denominada Agua (usando los polígonos creados manualmente), la cobertura por clase predicha por el modelo todos los IV-RGB + MDD cambió para algunas de estas. La tabla 21 muestra el área (en hectáreas y porcentaje) de cada una de las clases usadas en el modelo RF, así como el área de cada una de las clases después del ajuste con los polígonos de agua. A partir de estos resultados, se aprecia que el Suelo es la clase con mayor cobertura, seguido por el Matorral halófilo, *A. germinans*, *B. maritima*, Agua, *L. racemosa*, y por último *R. mangle*.

**Tabla 21.** Cobertura por clase por el modelo RF con todos los IV RGB y MDD. Las dos columnas de la derecha muestran los valores de cobertura después de aplicar el ajuste con los polígonos de agua.

Clase:	Cobertura predicha		Cobertura predicha (ajustada)	
	Área (ha)	Área (%)	Área (ha)	Área (%)
<i>A. germinans</i>	0.21	7.58	0.21	7.55
<i>B. maritima</i>	0.10	3.71	0.10	3.71
<i>L. racemosa</i>	0.06	2.33	0.06	2.33
Matorral halófilo	1.03	37.84	0.98	36.03
<i>R. mangle</i>	0.02	0.80	0.02	0.8
Suelo	1.30	47.73	1.27	46.62
Agua	0.0000	0.00	0.08	2.95
<b>Área total:</b>	<b>2.72</b>	<b>100</b>	<b>2.72</b>	<b>100</b>

El mapa temático final, resultado de la predicción del modelo y el ajuste con los polígonos de los cuerpos de agua se muestra en la figura 19. En este mapa podemos apreciar que la distribución de los manglares coincide con lo observado en campo. Así mismo, el modelo logra predecir la ubicación de las tres especies de mangle, como también a *B. maritima* y las clases Matorral halófilo y Suelo. No se obtuvieron datos en campo sobre cobertura del dosel ni de las demás clases, por lo que no fue posible comparar con los resultados de cobertura del modelo. Los errores en los que incurre el modelo, se pueden apreciar como pixeles de una clase dentro de otra que domina y ocupa un área más grande y bien definida.




Figura 19. Mapa temático final incluyendo la clase Agua.

## 8. DISCUSIÓN

En este trabajo se evaluó el uso de imágenes aéreas para la identificación de especies de manglar en un ecosistema semiárido en el noroeste de México mediante el uso de técnicas de clasificación supervisada. Los resultados muestran que esta técnica tiene una precisión general del 97.51% en la identificación las tres especies de mangle que comúnmente se encuentran en la zona de estudio y sus alrededores (*A. germinans*, *L. racemosa* y *R. mangle*), siendo estos resultados mejores que previos estudios en los que utilizaron imágenes satelitales ( Heenkenda 2014; Wang, 2018) y métodos de clasificación supervisada en manglares. La matriz de confusión del mejor modelo muestra que los errores de clasificación de cada clase son mínimos, confirmando que la técnica utilizada puede ser utilizada para clasificar y caracterizar manglares de ecosistemas semiáridos.

### 8.1 Análisis del desempeño de los IV en el espectro de luz visible, el infrarrojo cercano y la implementación del MDD

Los resultados de la evaluación de los modelos usando IV derivados RGB y GRN, indican que, para obtener resultados aceptables, no es fundamental contar con un sensor que detecte el infrarrojo cercano, ya que los sensores RGB pueden otorgar buenos resultados e incluso mejores a los proporcionados por modelos que involucran al infrarrojo cercano, sin embargo, hay que tomar en cuenta la metodología de clasificación de los píxeles y el tipo y cantidad de variables que se utilizan, como lo propone Campomanes y colaboradores en 2016 y que se presenta más adelante en este análisis.

En 2015, Jhonnerie y colaboradores, utilizaron imágenes de Landsat 5 y ALOS PALSAR, para evaluar la precisión del algoritmo de clasificación Random Forest y los resultados los compararon con el algoritmo común de clasificación basado en píxeles con máxima verosimilitud. Estos autores no crean distinción entre especies, pero si entre cobertura de manglar de otros tipos de cobertura en el río Kambung, Isla Bengkalis, Indonesia. También utilizaron el índice de Kappa de Cohen para identificar el mejor modelo, ya que usaron diferentes modelos creados a partir de las imágenes de Landsat 5, ALOS PALSAR, y diferentes índices de vegetación (NDVI, NDWI y NDBI). Parte de sus resultados indican que una mayor

cantidad de variables de ingreso produjo un modelo con mayor precisión general e índice de Kappa, al igual que en este estudio, lo que sugiere que la precisión de los modelos se incrementa en función del número de variables utilizadas, sin embargo, esto podría generar problemas de “sobre-parametrización” del modelo, tal como se sugiere en métodos de regresión.

Otros autores como Campomanes y colaboradores (2016), realizaron un estudio comparativo entre dos algoritmos de clasificación, Support Vector Machine (SVM) y Random Forest. Ambos algoritmos fueron utilizados para clasificar automáticamente bosques de manglar, utilizando imágenes LiDAR y productos derivados de estos (ortomosaicos y MDD). Estos autores crearon únicamente 4 clases (manglar, otros árboles, construcciones y caña de azúcar), sin embargo, se utilizó una mayor cantidad de puntos para cada clase, aproximadamente 120, para entrenar a los modelos de ambos algoritmos y 30 puntos para la validación. Esto difiere de nuestro estudio, porque la cantidad de puntos para las seis clases creadas es menor. Sin embargo, la investigación realizada por Campomanes y colaboradores, no presenta resultados del índice de Kappa, solo precisión y sensibilidad. Ambos estadísticos utilizan los aciertos positivos y la cantidad total de píxeles evaluados para cada clase, por lo que sus resultados obtienen porcentajes muy cercanos a 100 aunque el modelo presente errores. Algo muy importante y que Campomanes y colaboradores detallan en su estudio, es que los algoritmos SVM y RF, presentan errores en lugares donde no se habían adquirido imágenes RGB, o imágenes faltantes del ortomosaico, en donde manifiestan que el algoritmo RF obtiene mejores resultados que el SVM, al poder manejar una mayor cantidad de datos para el entrenamiento, en este caso los 120 puntos. Estos resultados pueden ser comparados con nuestro modelo, ya que, a mayor cantidad de puntos para cada clase, obtuvimos mejores resultados individuales.

Siguiendo la línea de investigación del algoritmo de clasificación Random Forest, Intarat y colaboradores (2019) también intentan comparar este algoritmo con otras metodologías de clasificación y al igual que Jhonnerie, con la metodología de clasificación basada en píxeles con máxima verosimilitud, en la provincia de Nakhon Si Thammarat, en Tailandia. En este estudio, a diferencia del realizado por Campomanes y colaboradores, no introdujeron más variables al modelo, es decir, utilizaron únicamente los valores de los píxeles de las imágenes del sensor de



percepción remota satelital Quickbird, para la evaluación de ambos modelos. Sin embargo, Intarat y colaboradores realizaron modificaciones a la profundidad y cantidad de los árboles de regresión y a la cantidad de nodos, con el fin de encontrar el mejor modelo del algoritmo Random Forest. Dentro de sus resultados, el algoritmo de clasificación Random Forest obtuvo mejores resultados con valores de Precisión de 78 % y de índice de Kappa de Cohen de 0.72, mientras que el método de clasificación basado en píxeles con máxima verosimilitud obtuvo resultados de 56% y 0.44, respectivamente. En este caso, nuestros resultados presentan valores más altos de Kappa y Precisión que los estudios antes mencionados, posiblemente debido a que utilizamos una mayor cantidad de variables de ingreso en el modelo.

Los autores mencionados anteriormente realizaron sus investigaciones en zonas tropicales, en ecosistemas de manglar, entre los 0 y 12° de latitud norte, pero las propiedades estructurales y morfológicas no son las mismas a los manglares de nuestra zona de estudio (24° latitud norte), por ejemplo, Rico-Gray y Palacios-Ríos (1996), demuestran un cambio en el área de la hoja de *R. mangle* en México, disminuyendo su tamaño respecto al aumento de la latitud, aun así, los análisis estadísticos y comparativos entre modelos, que los autores mencionados realizaron, indican que el algoritmo de clasificación Random Forest, ha sido el mejor para las zonas de estudio entre los 0 y 12° de latitud. Esto podría deberse a que, en lugares más cercanos al ecuador, el área foliar es mayor, por lo que, los sensores remotos pueden percibir mejor la reflectancia de las hojas.

Por otra parte, nuestro estudio presenta que, al momento de involucrar al MDD, los valores de Kappa y los demás estadísticos aumentan sustancialmente, debido a que las alturas son relativamente homogéneas por cada tipo de vegetación (matorral, arbustos, árboles de mangle, etc.) por lo que la utilización de este producto, es de gran importancia para lograr una correcta clasificación.

El algoritmo de clasificación utilizado en esta investigación, también ha sido utilizado para diferenciar otros tipos de coberturas de vegetación, a nivel de especie y en ambientes controlados. En la investigación llevada a cabo por Fletcher (2016), utiliza Random Forest, en su versión de inferencia condicional del algoritmo, para diferenciar tres especies de maleza de hoja ancha (*Amaranthus palmeri*, *Amaranthus retroflexus* y *Abutilon theophrasti*), del cultivo de Soya

en dos invernaderos, aplicando doce índices de vegetación de diferencia normalizada derivados de sensores multiespectrales para alimentar los datos de entrada utilizados por el algoritmo. Esta versión el algoritmo distinguió fácilmente la Soya y *Abutilon theophrasti*, de las dos especies del género *Amaranthus* y entre sí, con precisiones de clasificación que van del 93.3% al 100%. Sin embargo, al igual que Campomanes y colaboradores (2016) y a diferencia de nuestro estudio, Fletcher (2016) no presenta los resultados de los valores del índice de Kappa de Cohen, por lo que los porcentajes presentados en su investigación no expresan los resultados integrados de precisión y errores de clasificación por el modelo.

Por otra parte, la mayoría de los estudios comparativos presentados anteriormente, utilizan sensores de percepción remota satelital a diferentes resoluciones. Esta investigación propuso el uso de imágenes adquiridas desde VANTS, con los que se obtuvieron mejores resultados. Sin embargo, existen limitaciones para ambas tecnologías. Por ejemplo, para los sensores de percepción remota satelital la resolución espacial es baja, se pierden datos por la presencia de nubes y el periodo de revisita está definido por la trayectoria del satélite y no puede ser editado, mientras que, con los VANTS, el usuario define el momento de captura, la nubosidad está por encima del sensor (es) y la resolución es mejor. Así mismo, Sandino y colaboradores (2018), exponen que es necesario crear nuevos métodos para monitorear y obtener cuantificaciones más precisas de la cobertura vegetal, siendo este estudio una herramienta para satisfacer dichas necesidades.

Algo importante de señalar en esta investigación es que se utiliza técnicas innovadoras, refiriéndose al uso de algoritmos computacionales inteligentes denominados Machine Learning, los cuales son métodos de clasificación que pueden ser utilizados en diferentes ramas de la ciencia. Para continuar con la línea de investigación, se proporciona un modelo de clasificación supervisada que, en conjunto con índices de vegetación y modelos de elevación digital, generan resultados satisfactorios para la identificación de la cobertura vegetal en manglares a nivel de especie. Sin embargo, y como recomendaciones para próximos estudios, se pueden incluir a las variables de ingreso al algoritmo, aquellas que proporcionen información relacionada con el sitio de estudio, como la fisiografía, especie del suelo, salinidad, estructura del suelo, pH, materia orgánica, nutrimentos, hidroperíodo, distancia al cuerpo de agua, microtopografía,

capacidad óxido-reducción, capacidad de intercambio catiónico, etc., las cuales son variables que afectan la distribución y desarrollo de los manglares [1].

## **8.2. Cobertura por clase**

Las técnicas de post-procesamiento de imágenes ayudaron a mejorar la precisión del mejor modelo con respecto a la cobertura por cada clase. Como se mencionó anteriormente y a pesar de que el mejor modelo obtuvo muy buenos resultados, este también generó sub y sobreestimaciones en las clases creadas. Al respecto, Huang y colaboradores (2014) mencionan que el uso de técnicas de post-procesamiento de imágenes para mejorar la precisión de modelos de clasificación, no han recibido la suficiente atención, otra razón por la cual, esta investigación involucra esta técnica para reducir errores de cobertura. Al momento de realizar los polígonos que definieron los cuerpos de agua, se redujo la cantidad de píxeles que fueron erróneamente clasificados por el modelo, sin embargo, los cambios en la cobertura en área fueron mínimos.

Para finalizar, es necesario mencionar que los trabajos con los que se comparó esta investigación no realizaron post-procesamiento, sin embargo, como lo menciona la Fundación para el Manejo del Bosque y Control de Producción (2019), después de realizar una clasificación de cobertura, los algoritmos de clasificación no producen mapas completamente apegados con la realidad, por lo que existen parches de píxeles que no corresponden a sus clases y es necesario realizar trabajos de post-procesamiento.

## 9. CONCLUSIONES

1. Los IV, por sí solos no son buenos para identificar las especies de mangle debido a que otras especies vegetales tienen firmas espectrales similares.
2. Los IV basados en el NIR tienen un mejor desempeño en la identificación de especies de mangle debido a que maximiza las diferencias en las firmas espectrales de las diferentes especies vegetales.
3. Los modelos de clasificación supervisada, especialmente Random Forest, tienen un mejor desempeño cuando se incrementan el número de variables utilizadas, particularmente en este estudio se observó que debido a un mayor número de IV derivados del RGB, el modelo basado en estos productos tuvo un desempeño superior al basado en GRN.
4. La inclusión de la altura de la vegetación, derivada de la fotogrametría, incrementa considerablemente el desempeño de los modelos de clasificación supervisada.
5. El post-procesamiento de los mapas temáticos generados a partir de la predicción espacial de los modelos de clasificación supervisada, puede ser considerado como un paso esencial para la obtención de un producto más apegado a la realidad.

## 10. LITERATURA CITADA

1. Alfredo J, Silveira H, Recursos D De. Mangrove characterization : Yucatan and Quintana Roo. 2016. doi:10.13140/RG.2.1.5043.1121
2. Félix Pico EF, Serviere Zaragoza E, Riosmena Rodríguez R, León de la Luz JL. Los Manglares de la Península de Baja California. Félix Pico EF, Serviere Zaragoza E, Riosmena Rodríguez R, León de la Luz JL, editors. 2011.
3. Rico-Gray V, Palacios-Rios M. Leaf area variation in *Rhizophora mangle* L (Rhizophoraceae) along a latitudinal gradient in Mexico. *Glob Ecol Biogeogr Lett.* 1996;5: 30–35. doi:10.2307/2997468
4. López-Portillo J, Ezcurra E. Los manglares de México: Una revisión. *Madera y Bosques.* 2002;Vol. 8: 27–51.
5. Troche-Souza C, Rodríguez-Zúñiga MT, Márquez-Mendoza JD, Vázquez-Balderas B, Cruz-López MI, Ressi R. Manglares de México: Extensión, distribución y monitoreo. México D.F.: CONABIO; 2013.
6. Kuenzer C, Bluemel A, Gebhardt S, Quoc TV, Dech S. Remote sensing of mangrove ecosystems: A review. *Remote Sensing.* 2011. doi:10.3390/rs3050878
7. Camara Sanchez AO. Método Contextual Para Fusión De Datos. 2005; 178.
8. Quirós E. Introducción a la Fotogrametría y Cartografía aplicadas a la Ingeniería Civil. 2014.
9. Emilio Chuvieco. Fundamentos de teledetección espacial. Ediciones RIALP, S.A.; 1995. p. 449. Available: [https://upload.wikimedia.org/wikipedia/commons/thumb/4/44/Flavonoide\\_Lacke.svg/710px-Flavonoide\\_Lacke.svg.png](https://upload.wikimedia.org/wikipedia/commons/thumb/4/44/Flavonoide_Lacke.svg/710px-Flavonoide_Lacke.svg.png)
10. Muñoz P. Apuntes de Teledetección: Índices de vegetación. *Cent Inf Recur Nat.* 2013; 15. Available: <http://bibliotecadigital.ciren.cl/bitstream/handle/123456789/26389/Tema>

Indices de vegetación%2C Pedro Muñoz A.pdf?sequence=1&isAllowed=y

11. Gilabert MA, González-Piqueras J, García-Haro J. Acerca de los índices de vegetación. Rev Teledetección. 1997.
12. Jhonnerie R, Siregar VP, Nababan B, Prasetyo LB, Wouthuyzen S. Random Forest Classification for Mangrove Land Cover Mapping Using Landsat 5 TM and Alos Palsar Imageries. Procedia Environ Sci. 2015;24: 215–221. doi:10.1016/j.proenv.2015.03.028
13. Cutler A, Cutler DR, Stevens JR. Ensemble Machine Learning. Ensemble Mach Learn. 2012. doi:10.1007/978-1-4419-9326-7
14. Liaw A, Wiener M. Classification and Regression by randomForest. R News. 2002;2: 18–22.
15. Bechtold W, Tkacz B, Kurt T. The historical background, framework, and application of forest health monitoring in the United States. International symposium on forest health monitoring; 2007 January 30-31; Seoul; Republic of Korea Available from Korea Forest Conservation Movement. Seoul, Republic of Korea; 2007. pp. 19–40. Available: <https://www.fs.usda.gov/treearch/pubs/27570>
16. Ochoa J. Dinámica del carbono orgánico en manglares de zonas áridas del suroeste del Golfo de California. Centro de Investigaciones Biológicas del Noroeste. 2019.
17. Jones AR, Raja Segaran R, Clarke KD, Waycott M, Goh WSH, Gillanders BM. Estimating Mangrove Tree Biomass and Carbon Content: A Comparison of Forest Inventory Techniques and Drone Imagery. Front Mar Sci. 2020;6: 1–13. doi:10.3389/fmars.2019.00784
18. Colomina I, Molina P. Unmanned aerial systems for photogrammetry and remote sensing: A review. ISPRS J Photogramm Remote Sens. 2014;92: 79–97. doi:10.1016/j.isprsjprs.2014.02.013
19. Salas T RA, Olivas Castro WJ, Williamson Cuthbert M. Análisis multitemporal de la cobertura de manglar en la Reserva Cayos Miskitos, 2006-2017. Rev Univ del Caribe.

- 2019;22: 61–68. doi:10.5377/ruc.v22i1.8419
20. Bunting P, Rosenqvist A, Lucas RM, Rebelo LM, Hilarides L, Thomas N, et al. The global mangrove watch - A new 2010 global baseline of mangrove extent. *Remote Sens.* 2018;10. doi:10.3390/rs10101669
  21. Lumenera. How To Perform Vegetation Analysis With a Single Camera. 2020 [cited 7 May 2020] pp. 1–6. Available: [www.lumenera.com](http://www.lumenera.com)
  22. Ramsey E, Jensen J. Remote Sensing of Mangrove Wetlands: Relating Canopy Spectra to Site-Specific Data. *Photogramm Eng Remote Sensing.* 1996;62: 939–948. Available: [https://www.asprs.org/wp-content/uploads/pers/1996journal/aug/1996\\_aug\\_939-948.pdf](https://www.asprs.org/wp-content/uploads/pers/1996journal/aug/1996_aug_939-948.pdf)
  23. Blasco F, Gauquelin T, Rasolofoharinoro M, Denis J, Aizpuru M, Caldairou V. Recent advances in mangrove studies using remote sensing data. *Mar Freshw Res.* 1998;49: 287–296. doi:10.1071/mf97153
  24. Sobieraj A, Mróz M. Comparison of several vegetation indices calculated on the basis of a seasonal SPOT XS time series, and their suitability for land cover and agricultural crop identification. *Tech Sci / Univ Warm Maz Olsztyn.* 2004; 39–66.
  25. Blackburn GA, Di BM. Remote sensing of mangrove biophysical properties : evidence from a laboratory simulation of the possible effects of background variation on spectral vegetation indices. *Int J Remote Sens.* 2003; 53–73. doi:10.1080/01431160110115852
  26. Yaney-Keller A, Tomillo PS, Marshall JM, Paladino F V. Using unmanned aerial systems (Uas) to assay mangrove estuaries on the pacific coast of Costa Rica. *PLoS One.* 2019;14: 1–20. doi:10.1371/journal.pone.0217310
  27. Toosi NB, Soffianian AR, Fakheran S, Pourmanafi S, Ginzler C, Waser LT. Comparing different classification algorithms for monitoring mangrove cover changes in southern Iran. *Glob Ecol Conserv.* 2019;19. doi:10.1016/j.gecco.2019.e00662
  28. Omran MGH, Engelbrecht AP. Self-adaptive differential evolution methods for

- unsupervised image classification. 2006 IEEE Conf Cybern Intell Syst. 2006; 966–973. doi:10.1109/ICCIS.2006.252239
29. DJI. DJI GS PRO User Manual. 2017. pp. 1–18.
  30. Icc E, Datum E, Transversa U. V . Cartografía de imagen. In: ICC [Internet]. 2004 pp. 0–1. Available:  
[https://www.icgc.cat/es/content/download/4898/18287/version/1/file/dcomercial\\_carto\\_imagen\\_ortos.pdf](https://www.icgc.cat/es/content/download/4898/18287/version/1/file/dcomercial_carto_imagen_ortos.pdf)
  31. ESRI. Introducción a la representación cartográfica de ortofotos. 2019 [cited 15 Jul 2020] p. 1. Available: <https://pro.arcgis.com/es/pro-app/help/data/imagery/introduction-to-ortho-mapping.htm>
  32. QGIS.org. QGIS Sistema de Información Geográfica. Proyecto de Fundación Geoespacial de Código Abierto. 2018. Available: <http://qgis.org>
  33. Romero-López BE, León de la Luz JL, Pérez JL, De la Cruz G. Estructura y composición de la vegetación de la barra El Mogote, baja California Sur, México. Boletín la Soc Botánica México. 2006;79: 21–32. Available: <https://www.redalyc.org/pdf/577/57707903.pdf>
  34. Saberioon MM, Amin MSM, Anuar AR, Gholizadeh A, Wayayok A, Khairunniza-Bejo S. Assessment of rice leaf chlorophyll content using visible bands at different growth stages at both the leaf and canopy scale. Int J Appl Earth Obs Geoinf. 2014;32: 35–45. doi:10.1016/j.jag.2014.03.018
  35. Maimaitijiang M, Ghulam A, Sidike P, Hartling S, Maimaitiyiming M, Peterson K, et al. Unmanned Aerial System (UAS)-based phenotyping of soybean using multi-sensor data fusion and extreme learning machine. ISPRS J Photogramm Remote Sens. 2017;134: 43–58. doi:10.1016/j.isprsjprs.2017.10.011
  36. Xue J, Su B. Significant remote sensing vegetation indices: A review of developments and applications. J Sensors. 2017;2017. doi:10.1155/2017/1353691
  37. Hijmans RJ. Geographic Data Analysis and Modeling. R package. 2019. p. S/N. Available:



<https://cran.r-project.org/package=raster>

38. R Core Team. A language and environment for statistical computing. R foundation for statistical computing. Vienna; 2018. p. S/N. Available: <https://www.r-project.org/>
39. Saberioon MM, Gholizadeh A. Novel approach for estimating nitrogen content in paddy fields using low altitude remote sensing system. *Int Arch Photogramm Remote Sens Spat Inf Sci - ISPRS Arch.* 2016;2016-Janua: 1011–1015. doi:10.5194/isprsarchives-XLI-B1-1011-2016
40. Maimaitijiang M, Sagan V, Sidike P, Maimaitiyiming M, Hartling S, Peterson KT, et al. Vegetation Index Weighted Canopy Volume Model (CVM VI ) for soybean biomass estimation from Unmanned Aerial System-based RGB imagery. *ISPRS J Photogramm Remote Sens.* 2019;151: 27–41. doi:10.1016/j.isprsjprs.2019.03.003
41. Wang F, Huang J, Tang Y, Wang X. New Vegetation Index and Its Application in Estimating Leaf Area Index of Rice. *Rice Sci.* 2007;14: 195–203. doi:10.1016/s1672-6308(07)60027-4
42. Liaw A, Wiener M. Classification and Regression by randomForest. New York; 2002. pp. 1–5. Available: <https://cran.r-project.org/doc/Rnews/>
43. Aulianida D, Liestyasari SI, Ch SR. Classification and Regression Training. *Journal of Chemical Information and Modeling.* 2019. pp. 1689–1699. Available: <https://cran.r-project.org/package=caret>
44. Moreno-Casasola P, Infante DM. Manglares y selvas inundables. Primera ed. CONAFOR, OIMT, editors. CONAFOR. 2013. doi:10.1017/CBO9781107415324.004
45. Barrett B, Raab C, Cawkwell F, Green S. Upland vegetation mapping using Random Forests with optical and radar satellite data. *Remote Sens Ecol Conserv.* 2016;2: 212–231. doi:10.1002/rse2.32
46. Breiman L. Random forests. *Mach Learn.* 2001;45: 5–32. doi:10.1201/9780367816377-11
47. Rystedt B, Ormeling F, Buckley A, Kagawa A, Coetzee S, Fairbairn D, et al. The World of

Maps. Ormeling F, Rystedt B, editors. 2014.

48. Heenkenda MK, Joyce KE, Maier SW, Bartolo R. Mangrove species identification: Comparing WorldView-2 with aerial photographs. *Remote Sens.* 2014;6: 6064–6088. doi:10.3390/rs6076064
49. Wang D, Wan B, Qiu P, Su Y, Guo Q, Wang R, et al. Evaluating the performance of Sentinel-2, Landsat 8 and Pléiades-1 in mapping mangrove extent and species. *Remote Sens.* 2018;10. doi:10.3390/rs10091468
50. Campomanes F, Pada AV, Silapan J. Mangrove classification using support vector machines and random forest algorithm: a comparative study. 2016; 2–6. doi:10.3990/2.385
51. Intarat K, Sillaparat S. Tropical Mangrove Species Classification Using Random Forest Algorithm and Very High-Resolution Satellite Imagery. *Burapha Sci J.* 2019;24: 742–753.
52. S. Fletcher R. Using Vegetation Indices as Input into Random Forest for Soybean and Weed Classification. *Am J Plant Sci.* 2016;07: 2186–2198. doi:10.4236/ajps.2016.715193
53. Sandino J, Gonzalez F, Mengersen K, Gaston KJ. UAVs and machine learning revolutionising invasive grass and vegetation surveys in remote arid lands. *Sensors (Switzerland).* 2018;18. doi:10.3390/s18020605
54. Huang X, Lu Q, Zhang L, Plaza A. New postprocessing methods for remote sensing image classification: A systematic study. *IEEE Trans Geosci Remote Sens.* 2014;52: 7140–7159. doi:10.1109/TGRS.2014.2308192
55. GCCA, CI. GCCA + Suriname Adaptation Project Setting up a mangrove biodiversity Monitoring System. 2019.