



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
POSGRADO EN CIENCIAS DEL MAR Y LIMNOLOGÍA**

**Análisis temporal y espacial del dosel de bosque de manglar
(*Avicennia germinans*, *Laguncularia racemosa*, *Rhizophora mangle*)
en una laguna costera semiárida por medio de herramientas
emergentes de teledetección y algoritmos de aprendizaje
automático.**

TESIS

**QUE PARA OPTAR POR EL GRADO DE:
MAESTRO EN CIENCIAS**

PRESENTA:

EDUARDO TORRES AGUIRRE

TUTOR PRINCIPAL:

Dr. FRANCISCO JAVIER FLORES DE SANTIAGO
(ICML-UNAM)

COMITÉ TUTOR:

Dr. RODOLFO RIOJA NIETO
(UMDI-Sisal-UNAM)

Dr. LUIS HUMBERTO VALDERRAMA LANDEROS
(CONABIO)

Dr. FELIPE AMEZCUA MARTÍNEZ
(ICML-Mazatlán-UNAM)

Dr. FERNANDO ANTONIO GONZÁLEZ FARÍAS
(ICML-UNAM)

CD. MX., FEBRERO, 2022



Universidad Nacional
Autónoma de México

Dirección General de Bibliotecas de la UNAM

Biblioteca Central



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



**Análisis temporal y espacial del dosel de bosque de manglar
(*Avicennia germinans*, *Laguncularia racemosa*, *Rhizophora mangle*)
en una laguna costera semiárida por medio de herramientas
emergentes de teledetección y algoritmos de aprendizaje
automático.**

TESIS

QUE PARA OBTENER EL GRADO ACADÉMICO DE:
MAESTRO EN CIENCIAS

PRESENTA:
EDUARDO TORRES AGUIRRE

TUTOR PRINCIPAL:

Dr. FRANCISCO JAVIER FLORES DE SANTIAGO
(ICML-UNAM)

COMITÉ TUTOR:

Dr. RODOLFO RIOJA NIETO
(UMDI-Sisal-UNAM)
Dr. LUIS HUMBERTO VALDERRAMA LANDEROS
(CONABIO)
Dr. FELIPE AMEZCUA MARTÍNEZ
(ICML- Mazatlán-UNAM)
Dr. FERNANDO ANTONIO GONZÁLEZ FARÍAS
(ICML-UNAM)

MÉXICO, CD. MX., FEBRERO, 2022

Agradecimientos

Agradezco a la Universidad Nacional Autónoma de México por darme la oportunidad de poder estudiar y ampliar mis conocimientos y habilidades profesionales.

Agradezco al Posgrado en Ciencias del Mar y Limnología por el espacio que ocupe como estudiante y pertenecer a este posgrado me enorgullece no solo profesionalmente sino de manera personal. Al personal que labora administrativamente en el posgrado y en especial a la M. en C. Diana Juárez Bustos que me apoyo con las dudas e instrucciones de mis procesos administrativos.

Por otra parte, agradezco especialmente a mi tutor principal, el Dr. Francisco Flores de Santiago por aceptarme y creer en mi capacidad como profesional y ayudarme a desarrollar mis capacidades frente a mis nuevos conocimientos de la maestría, de esta manera agradezco al equipo del laboratorio de Oceanografía Física y Cartografía Satelital que, aunque no pude estar tanto tiempo por la pandemia, es un grupo muy unido y el apoyo multidisciplinario es imprescindible para mi formación.

Agradezco también a mis tutores, al Dr. Rodolfo Rioja Nieto, quien aparte de ayudarme con sus atinadas opiniones en los tutorales me dio su conocimiento como profesor de la maestría. Al Dr. Luis H. Valderrama Landeros quien me ayudo de manera oportuna y dispuso de su tiempo y conocimiento para aclarar mis dudas. Al Dr. Felipe Amezcua Martínez quien con su gran experiencia y conocimiento en ecología costera me indico de manera idónea complementar mi investigación. Al Dr. Fernando A. González Farías quien con su saber en ecología de manglares me ayudo a distinguir otros alcances de mi investigación.

A mis compañeros y amigos de maestría Montserrat, Vania, Vianney y Alfredo, quienes me ayudaron con sus críticas constructivas para mejorar en clase y en mi investigación, así como darse el tiempo para ayudarme a resolver dudas.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT-México) le agradezco la beca recibida durante la maestría (1039859). Investigación realizada gracias al Programa UNAM-PAPIIT (IA100521 y IA100218).

Dedicatoria

A Xochitl por secundar todas mis decisiones con cariño e infundir animo en la lucha por concluir este proceso, a mi hija que sigue mis pasos y es el reflejo de mi esfuerzo.

A mis hermanos, porque somos la reflectancia de nuestras acciones y la apariencia de nuestra familia.

Y, por último, pero de mayor importancia agradezco y les dedico a mis padres por su cariño y apoyo en todo aspecto y que me hicieron la persona que busca plantearse nuevas metas y concluir las, que al enseñarme sus valores y principios busco la justicia y el orden no solo de mi persona sino también de mi ambiente.

*“Lo que sabemos es una gota de agua, lo que ignoramos es el océano”
Isaac Newton (1643-1727).
112;2,24,14,29,12.*

ÍNDICE

INTRODUCCIÓN	1
Bosques de Manglar	1
Percepción Remota	3
Uso de la Percepción Remota en bosque de manglar	4
ANTECEDENTES	6
Percepción remota por medio de VANT	6
Algoritmos de aprendizaje automático	7
Máquina de Soporte Vectorial (MSV)	7
Redes Neuronales (RN)	8
Bosques Aleatorios (BA)	8
HIPÓTESIS	9
OBJETIVOS	9
ÁREA DE ESTUDIO.....	10
Caracterización del bosque de manglar del sistema de Urías.....	11
Efectos antrópicos en la zona de estudio	12
MATERIALES Y METODOS	13
VANT	14
Preprocesamiento de las imágenes y adquisición de datos	18
Plan de Vuelo	18
Procesamiento 2D.....	21
Extracción del polígono de la zona de estudio.....	22
Indices de Vegetación	23
Índice VARI	24
Índice de normalización de color	25
Análisis de Histogramas	25
Clasificación de la imagen	26
Clasificación con algoritmo Bosques Aleatorios.....	26
Clasificación con algoritmo Máquina de Soporte Vectorial.....	26
Clasificación con algoritmo Redes Neuronales	26
RESULTADOS	28
Índices de vegetación	30
Índice de Resistencia Atmosférica Visible	30
Índice de Normalización del color	34

Análisis de histogramas	40
Índice VARI	41
Índice Normalizado de color.....	41
Imagen RGB sin modificación	42
Clasificación con algoritmos de aprendizaje automático	43
Clasificación a partir de imagen RGB	43
Clasificaciones a partir de imagen RGB-Normalizado	45
Exactitud de las tres temporadas.....	52
DISCUSIÓN	55
CONCLUSIÓN	63
BIBLIOGRAFÍA	64
CRÉDITOS DE LAS ILUSTRACIONES	76
ANEXO.....	76

Índice de Figuras

Figura 1. Mapa de localización de la zona de estudio.....	10
Figura 2. Zonación de manglares en base a los niveles topográficos	12
Figura 3. Diagrama de trabajo del método de clasificación con algoritmos de aprendizaje automático.	15
Figura 4. Plan del vuelo en tiempo real del sitio de estudio, generado a partir de Map Pilot.	19
Figura 5. Registro del plan de vuelo en Google Earth (2020)	20
Figura 6. Proceso de generación del ortomosaico a partir de las imágenes de UAV	22
Figura 7. Polígono de extracción de la zona de estudio.....	23
Figura 8. Imágenes VANT de las 3 temporadas en la zona de estudio.....	24
Figura 9. Imagen RGB sin modificaciones con los sitios de entrenamiento; MR: Mangle Rojo, MN: Mangle Negro, MB: Mangle Blanco, MRSM: Marisma.....	29
Figura 10. Imagen VARI en temporada de estiaje.....	31
Figura 11. Imagen VARI en temporada de invierno.	32
Figura 12. Imagen VARI en temporada de lluvias.....	33
Figura 13. Imagen del Índice de normalización de Color con los sitios de entrenamiento.	34
Figura 14. Diagrama de Caja de la temporada de lluvias del índice VARI.	35
Figura 15. Diagrama de Caja de la temporada de estiaje del índice VARI.....	37
Figura 16. Diagrama de Caja de la temporada de invierno del índice VARI.	37
Figura 17. Diagrama de Caja comparativo de las 3 temporadas del índice VARI. .	38
Figura 18. Imagen VARI Reclasificada visualmente temporada de lluvias.....	39
Figura 19. Histograma de la única banda del índice VARI en la zona de estudio, los colores de las clases son los mismos que los sitios de entrenamiento.	41
Figura 20. Histograma de las cuatro clases con el índice normalizado del color. ...	42
Figura 21. Histograma de las cuatro clases de la imagen RGB sin modificación...	42
Figura 22. Comparación de la imagen tomada con VANT y la clasificación con el algoritmo BA.....	43

Figura 23.Comparación de la imagen tomada con VANT y la clasificación con el algoritmo MSV.....	44
Figura 24.Comparación de la imagen tomada con VANT y la clasificación con el algoritmo RN.	44
Figura 25.Comparación de la imagen tomada con VANT y la clasificación con el algoritmo RN.	45
Figura 26.Comparación de la imagen tomada con VANT y la clasificación con el algoritmo BA.....	45
Figura 27.Comparación de la imagen tomada con VANT y la clasificación con el algoritmo MSV.....	46
Figura 28.Comparación de la imagen tomada con VANT y la clasificación con el algoritmo RN.	46
Figura 29.Comparación de la imagen tomada con VANT y la clasificación con el algoritmo RN.	47
Figura 30. Puntos de muestreo para la generación de las matrices de confusión.	49
Figura 31.Comparación de la imagen tomada con VANT y la clasificación con los algoritmos BA, MSV y RN, de la temporada de invierno.	51
Figura 32.Comparación de la imagen tomada con VANT y la clasificación con los algoritmos BA, MSV y RN, de la temporada de estiaje.	52
Figura 33.Grafica comparativa de los valores de exactitud de temporada y algoritmo.....	53

Índice de Tablas

Tabla 1. Parámetros usados en el proceso de clasificación con algoritmos de aprendizaje automático.	27
Tabla 2. Matriz de Confusión Índice VARI en temporada de Lluvias.....	40
Tabla 3. Valores Kappa de la imagen RGB-Normalizada de la temporada de Lluvias.	47
Tabla 4. Comparación de resultados de exactitud global y Kappa entre los dos productos de RGB sin modificación y con índice Normalizado.	50
Tabla 5. Comparación de la exactitud global de los algoritmos de aprendizaje automático en las tres temporadas.	52
Tabla 6. Valores de Coeficiente Tau, de los tres algoritmos de aprendizaje automático en las tres temporadas.	53
Tabla 7. Cálculo de la diferencia significativa entre las clasificaciones de los algoritmos RN, MSV y BA, de las tres temporadas.	54
Tabla 8. Comparación de valores Kappa de los algoritmos BA, MSV y RN de las tres temporadas.	55

INTRODUCCIÓN

Bosques de Manglar

Los manglares son árboles y arbustos halófitos facultativos que se desarrollan a lo largo de la zona intermareal de estuarios y lagunas costeras (Cao et al, 2019). Los bosques de manglar son de gran importancia ecológica y económica debido a su papel ecológico en la reducción de la erosión costera, la protección contra tormentas, el control de la calidad del agua, así como el flujo constante de grandes cantidades de sedimentos ricos en nutrientes (Wang et al, 2020). Además, los bosques de manglar están relacionados con los procesos biogeoquímicos globales y regulan la estructura y función de los ecosistemas costeros circundantes de manera positiva en relación con su limitada cobertura del suelo (Guo et al, 2017). Estos ecosistemas altamente productivos que típicamente dominan las zonas intermareales de las costas tropicales y subtropicales coadyuvan a la producción de varios productores primarios como fuentes de materia orgánica que apoyan a la diversificación de comunidad de peces e invertebrados (Lopez-Enriquez, 2013; Singh & Frazier, 2018; Zimudzi et al., 2021). Así también sirven de refugio para invertebrados y peces, facilitan el sustrato para promover un mejor rendimiento de productores primarios y consumidores, llevando a cabo un eslabón muy importante e indirecto a la red alimentaria. Esto es posible debido a que la productividad de la hojarasca en los manglares persiste durante todo el año pues en contraste con las algas o fitoplancton se producen sólo bajo ciertas condiciones ambientales (Muro-Torres et al, 2020). A pesar de los beneficios de estos bosques, los manglares están bajo constantes amenazas debido a proyectos de desarrollo costero, cambios hidrológicos por represamiento de los ríos y apertura de canales, los cuales ocasionan perjuicios a su estado de salud y conservación (Rioja-Nieto, 2015; Rioja-Nieto, 2017; Lopez-Enriquez, 2013).

A nivel mundial se han descrito 54 especies de mangle, aunque las principales pertenecen a 5 familias: Acanthaceae con el género *Avicennia*; Combretaceae con

los géneros *Laguncularia* y *Lumnitzera*; *Arecaceae* con el género *Nypa*; *Rhizophoraceae* con los géneros *Rhizophora*, *Bruguiera*, *Ceriops*, *Kandelia*; *Lythraceae* con el género *Sonneratia* (Moreno-Casasola & Infante, 2009). En México predominan cuatro especies de mangle: el mangle rojo (*Rhizophora mangle*), el mangle blanco (*Laguncularia racemosa*), el mangle negro (*Avicennia germinans*) y el mangle botoncillo (*Conocarpus erectus*), aunque se han reportado las especies de *Avicennia bicolor* y *Rhizophora harrisoni* en el estado de Chiapas (Agraz-Hernandez, 2006).

Según Lugo (2014), los manglares se encuentran en más de 120 países y su extensión es de aproximadamente 4.5 millones de ha. México está entre los diez países con mayor superficie de manglar representando el 5 % del área global. Cabe mencionar que las especies de manglar se encuentran sujetas a protección especial de acuerdo con la NOM-059-SEMARNAT-2010 en México.

Los bosques de manglar presentan su mayor desarrollo en latitudes tropicales donde abunda la presencia de agua dulce, por el contrario, manglares distribuidos en latitudes subtropicales, tales como regiones áridas y semiáridas, presentan grados de degradación considerables por factores naturales adversos tales como incremento en la salinidad intersticial y una tasa de evaporación mayor (Flores-Verdugo et al., 2018). En estas latitudes intermedias, es común encontrar especies de mangle en diferentes condiciones fisonómicas. Por ejemplo, manglares distribuidos en una comunidad tipo borde presentan hidroperiodos dinámicos y consecuentemente el grado de conservación y desarrollo tiende a ser mucho mayor comparados con la comunidad tipo cuenca donde el hidroperiodo es mucho menor, la salinidad intersticial es mayor y consecuentemente el estrés se incrementa al presentar alturas de dosel y áreas basales mucho menores (Flores-de-Santiago et al., 2018).

De esta manera De la Lanza et al. (2013), menciona que los manglares del Pacífico mexicano pertenecen a la región costera occidental localizados al sur de Sinaloa y

Nayarit, la cual es de origen sedimentario y tiene una longitud de 396 km, aproximadamente. Su clima es cálido subhúmedo con lluvias en verano y precipitaciones anuales entre 800 mm y 1500 mm. Comprende bahías como las de Matanchén y Banderas, al igual que un amplio complejo de lagunas interconectadas como las de Huizache-Caimanero y la de Agua Grande-Agua Brava en Marismas Nacionales, mismas que han sido formadas por los cordones costeros y de los aportes sedimentarios de los principales ríos.

Percepción Remota

La percepción remota puede definirse como la ciencia o arte para obtener información de un objeto o un proceso, a través del análisis de datos obtenidos mediante un instrumento que no está en contacto físico con los objetos (Encinas, 2005). Estas técnicas se basan principalmente en el procesamiento digital de imágenes por medio de radiación electromagnética a partir de una fuente de emisión, recogiendo así los datos de la superficie de la tierra para interpretarla por medio de un análisis visual y digital. Además, son herramientas eficaces para la caracterización, modelación y evaluación de los sistemas naturales. Sin embargo, su efectividad depende de la simplicidad o complejidad de la zona, tipo de estudio y alcances a los que se quiera llegar.

Existen dos tipos de sensores: pasivos y activos, los últimos obtienen estos datos mediante la emisión de su propia energía, sobrevolando los objetos de interés o en órbita. El sensor pasivo es aquel que depende de una fuente de energía como el Sol. De esta manera existen varias formas de percepción remota para obtener datos, algunos son por medio de satélites y otras por medio de plataformas aéreas tripuladas o no tripuladas (Carrasquilla, 2011).

El análisis espacio-temporal en la percepción remota es uno de los aportes más destacados al estudio del medio ambiente, por su capacidad para seguir procesos dinámicos, por medio de imágenes que capta un sensor de forma sistemática (Rioja-

Nieto, 2017). Esto permite evaluar una gran variedad de fenómenos naturales o de origen antrópico. Una de las técnicas más usadas es el análisis de imágenes para categorizar las áreas en diferencias temáticas, esta técnica, se basa en el empleo de métodos de clasificación donde se discriminan las clases y luego son comparadas. Una vez que se tiene la clasificación de cada fecha; la determinación de cambios se hace con base a las clases de cada producto, la ventaja de este análisis es que se puede comparar cambios temporales en la cobertura original (Lozano-Rivera, 2007). Por lo anterior es que el uso de productos de percepción remota nos sirve para hacer análisis mucho más específicos como es la evaluación de la condición de la vegetación que está en algún estatus de riesgo como el bosque de manglar.

Uso de la Percepción Remota en bosque de manglar

Debido a las dificultades logísticas respecto al trabajo de campo en bosque de manglar, varios estudios a nivel mundial han sugerido el uso de plataformas y sensores de percepción remota para adquirir y cuantificar el dosel de dichos ecosistemas costeros (Otero et al, 2018). De acuerdo con Kuenzer et al. (2011), la utilización de estas herramientas de percepción remota permite la caracterización y monitoreo espacial y temporal de una forma rápida, así como los diferentes estados de crecimiento de las unidades de mangle, además de ser uno de los métodos más económicos y de mayor amplitud para la generación de inventarios forestales. Por ejemplo, Pastor-Guzmán et al. (2015) utilizaron técnicas de mapeo basadas en datos satelitales y la concentración de clorofila de las hojas para generar índices de vegetación que pueden emplearse para estimar la concentración de pigmentos fotosintéticos en áreas de manglares extensas.

Otro ejemplo de análisis espacio-tiempo en donde se usan los sensores remotos en conjunto con los Drones o VANT (Vehículo Aéreo No Tripulado) es el empleado por Catalán et al. (2017), que se basa en el uso de imágenes satelitales procesadas específicamente con el software CLASlite y la validación de estos resultados por

medio de VANT. Catalán et al. (2017) se enfoca en el mapeo satelital automatizado para determinar uno de los componentes más importantes de la estructura del bosque tropical: la cobertura fraccional del dosel de vegetación, la vegetación muerta y las superficies descubiertas.

Por lo tanto, la teledetección mediante el uso de VANT ha expandido las fronteras para nuevas fuentes de datos innovando diferentes formas de caracterizar las métricas de vegetación a una resolución espacial muy alta (Tian et al, 2017). Al igual que las imágenes de satélite, existen dos formas principales para obtener datos remotos para el análisis de la vegetación con VANTs. (1) Sensores pasivos, los cuales detectan la radiación que es emitida o reflejada por los objetos bajo observación (e.g., Valderrama-Landeros et al., 2018) y (2) los sensores activos que se encargan de emitir energía hacia el objeto de estudio la cual es retrodispersada nuevamente hacia el sensor (Gupta, 2018). A pesar de cubrir un área considerable, las plataformas satelitales presentan algunas limitaciones tales como incapacidad para obtener información con sensores pasivos a través de las nubes, y generalmente poseen una resolución temporal baja (Tian et al, 2017). Por estos motivos, actualmente se ha incorporado el uso de VANT con la finalidad de analizar bosques de manglar por su facilidad de operación en ambientes intermareales (Li et al., 2019). De esta manera, los VANT son considerados una forma versátil para la obtención de secuencias de imágenes sobre la cobertura del dosel de la vegetación tropical.

A medida que la población sigue creciendo y las actividades comerciales y de desarrollo se intensifican, la gestión de la zona costera cada vez es de mayor importancia para generar y emplear la información para diseñar, monitorear y gestionar sitios de conservación o desarrollo (Adade et al., 2021).

ANTECEDENTES

Percepción remota por medio de VANT

Los drones son vehículos aéreos no tripulados, lo cuales también son conocidos como VANT o RPAs (Remotely Piloted Aircrafts). Los VANT permiten obtener ortoimágenes y modelos digitales de terreno con una resolución espacial ultra alta. Ojeda-Bustamante et al. (2017), menciona que la implementación de clasificaciones forestales por medio de VANT agiliza la toma de datos a alturas relativamente bajas (cerca a los 100 m) ya que se puede capturar hasta 40 ha en 15 minutos. Es por esto por lo que las ventajas del uso de VANT para la obtención de imágenes de las coberturas del suelo no solo son económicas sino también pueden llegar a presentar una resolución temporal muy alta. A pesar de lo anterior, es importante mencionar las desventajas del uso de VANT en trabajos ecológicos tales como la dependencia de una estación de control terrestre, la cual requiere de un rápido barrido de cobertura; el costo inicial de la aeronave y el sensor; la exigencia de mayores recursos informáticos como el volumen de datos y el tiempo de procesamiento, además de la limitante del peso y/o volumen de carga; el tiempo de vuelo mínimo y la normatividad de uso del espacio aéreo para este tipo de vehículos en zonas restringidas (Adade et al., 2021).

Dependiendo de la región, época del año y condiciones donde se desarrollen los mangles, es posible que las expresiones fenológicas difieran dependiendo de la época en que se realice la toma de los datos por el sensor remoto (Valderrama-Landeros et al., 2017). De esta manera es que la variación de las tonalidades en las fotografías o fotogramas puede diferir a lo largo del año y hacen necesario un análisis espacio-temporal para hacer más eficaz la identificación de las diferentes especies (Krause et al, 2004). Es por esto por lo que el uso de los algoritmos de aprendizaje automático puede ser una estrategia para la clasificación de los datos obtenidos por sensores remotos.

Algoritmos de aprendizaje automático

Existen varias formas de clasificar ortomosaicos provenientes de VANT. Recientemente, se ha sugerido el uso de algoritmos de aprendizaje automático para clasificar especies de mangle a nivel de dosel (Flores-de-Santiago et al., 2018). El aprendizaje automático supervisado utiliza un conjunto de datos de varias muestras de las mismas características o atributos para intentar predecir las características o atributos de los datos desconocidos.

La gran diversidad de objetivos y las características especiales de los datos obtenidos de percepción remota han hecho que el uso de las técnicas de aprendizaje automático utilice una gran cantidad de algoritmos que pueden ser usados para la solución de problemas muy complejos ya que no dependen de la distribución de los datos (De Jesús, 2016).

La aplicación de aprendizaje automático por medio de VANT cada vez más se usa en las diferentes investigaciones de clasificación en vegetación, pues nos proporciona una oportunidad para la obtención de imágenes con mayores resoluciones y por lo mismo la generación de datos más exactos, que nos ayuda para ajustar las estimaciones en clasificaciones de vegetación producidas por imágenes satélites, coadyuvando así, a la eficacia de la conservación de los manglares (Hsu et al, 2020; Cao et al, 2019). A continuación, se desglosan las características generales de tres algoritmos de aprendizaje automático comúnmente usados en estudios ambientales:

Máquina de Soporte Vectorial (MSV)

El algoritmo de máquina de soporte vectorial se caracteriza por acotar un hiperplano de N dimensiones, en subespacios y clases que se requieran. De esta manera cada subespacio puede otorgar un máximo margen de seguridad que se entiende como la distancia que existe entre la frontera de separación entre clases y el punto de entrenamiento más cercano a la misma. Y aunque las MSV en un principio se

diseñaron para clasificaciones binarias, últimamente existen otras aplicaciones para clasificaciones múltiples como en el análisis de teledetección (Gandhi, 2018).

Redes Neuronales (RN)

Las redes neuronales artificiales son un sistema para el tratamiento de información, donde las unidades básicas de procesamiento se basan en las células del sistema nervioso humano. Este sistema de redes de elementos simples interconectados masivamente presenta grandes semejanzas con el cerebro humano como son: el aprendizaje, generalización a partir de casos anteriores, abstracción de características esenciales. Las RN están constituidas por una capa de entrada de datos (*input function*) los cuales pasan a una capa oculta (*activation function*) donde los datos tienen un tratamiento de activación y se generan operaciones que dan grados de libertad a la red neuronal que permite representar mejor determinadas características del entorno. Y por último la capa de salida (*output function*) donde el valor resultante es determinado por la función de activación ya que si está por debajo del umbral determinado no permite el paso de valores a la función de salida (Matich, 2001).

Bosques Aleatorios (BA)

El algoritmo de Bosques Aleatorios es un algoritmo de aprendizaje supervisado que crea un bosque o conjunto de valores tomando como base arboles de decisiones que genera tomando la mejor característica de un subconjunto de árboles de decisión. Además, es uno de los algoritmos de clasificación en imágenes que más se usa en la teledetección, ya que es un método no paramétrico, robusto y fácil de interpretar. Su función principal es dar homogeneidad a las particiones o conjuntos en el espacio, buscando siempre el umbral de las variables y valores de estas (Rodríguez-Galiano et al., 2016).

HIPÓTESIS

La presente investigación pretende aportar y aplicar criterios para la propuesta de un método de análisis temporal y espacial de las especies de mangle en la laguna costera de Urías, Sinaloa. Por lo anterior se desglosan las siguientes hipótesis:

- a. Debido a la fenología inherente de las especies de mangle, debe de presentarse una variabilidad en la señal del histograma de frecuencias de los pixeles durante tres temporadas (invierno, estiaje y lluvias).
- b. El uso de índices de vegetación de banda visible como pre-procesamiento coadyuva a la optimización del uso de algoritmos de aprendizaje automático para la clasificación a nivel de especie.
- c. Se espera obtener una exactitud mayor en la clasificación del dosel de bosque de manglar en la temporada donde el hidroperiodo y la salinidad sean óptimos para el desarrollo de las especies.

OBJETIVOS

General:

Desarrollar un método para adquirir secuencia de imágenes obtenidas por medio de VANT y clasificar el dosel de bosque de manglar con algoritmos de aprendizaje automático en una laguna costera semiárida del noroeste de México.

Específicos:

- Determinar el algoritmo de aprendizaje automático ideal para clasificar dosel de manglar con datos RGB.
- Analizar la variabilidad en la exactitud de las clasificaciones de los algoritmos de aprendizaje automático en tres temporadas.

ÁREA DE ESTUDIO

El sitio de estudio se ubica en el municipio de Mazatlán, Sinaloa (Figura 1). La laguna costera de Urias se encuentra dentro de la provincia fisiografica Llanura costera del pacifico y en la subprovincia Llanura costera de Mazatlán. Tiene un clima cálido subhúmedo con lluvias en verano de 800 a 1000 mm. Los principales recursos hidrológicos superficiales del municipio los constituyen los ríos Presidio y Quelite. En cuanto a la vegetacion existe selva baja caducifolia y en la zona costera predomina la vegetación halófila (INEGI, 2017).

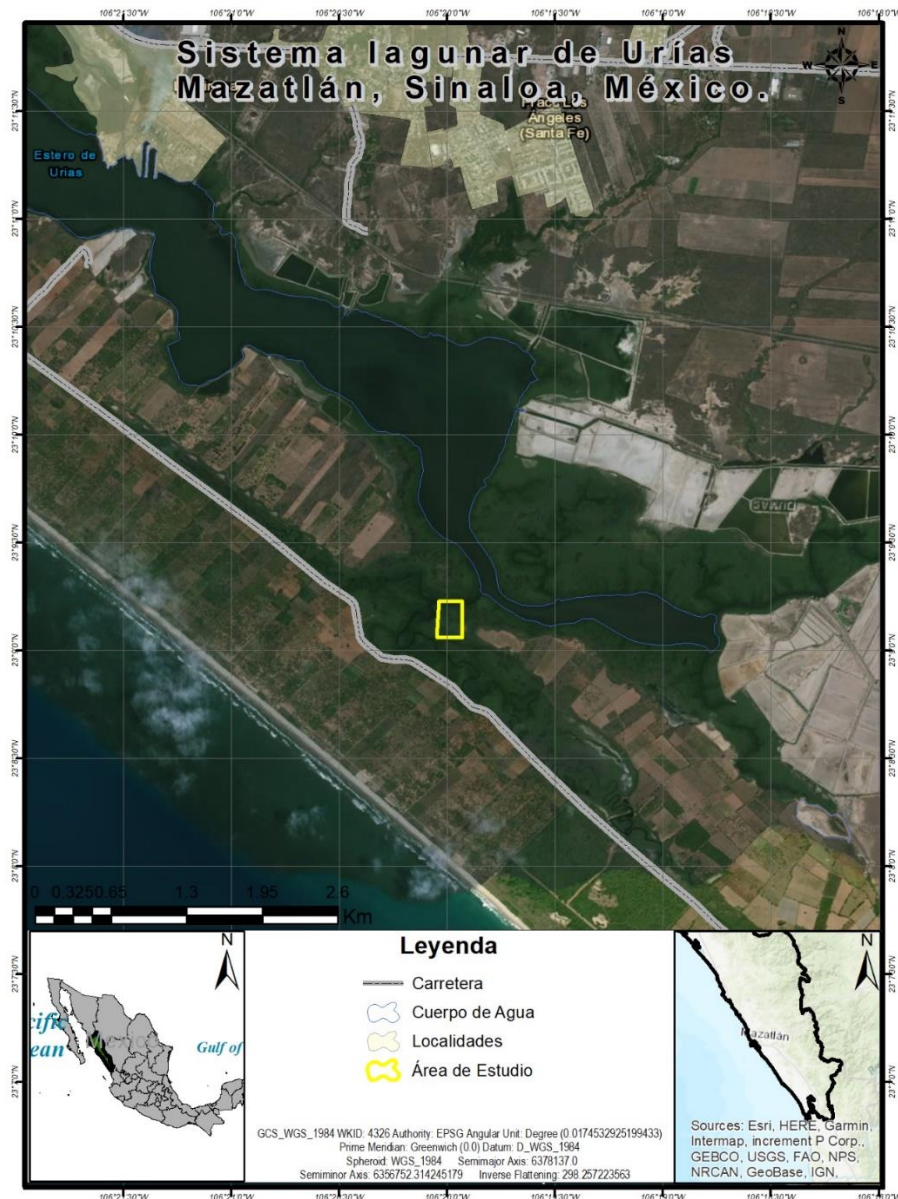


Figura 1. Mapa de localización de la zona de estudio

La tasa de evaporación en el área de estudio excede a la de precipitación durante la mayor parte del año (Flores-de-Santiago et al. 2018), lo que ocasiona un incremento gradual en la concentración de sal intersticial entre el canal de mareas y la parte elevada de la laguna costera (Flores-Verdugo et al., 2018). Sin embargo, la presencia de tormentas tropicales y huracanes durante la temporada de lluvia (junio a septiembre) ocasiona un incremento notable en la precipitación, la cual ocasiona un aumento en el contenido de pigmentos fotosintéticos y reflectancia en las bandas del verde e infrarrojo en el bosque de manglar (Flores-de-Santiago et al. 2018). En esta laguna costera semiárida, donde no existe un aporte de agua dulce constante, la marea juega un papel importante en el hidropereodo (frecuencia, intensidad y duración de la inundación). Como consecuencia, la comunidad de mangle tipo borde se encuentra en una zona donde la frecuencia de inundación es mayor y la salinidad promedio es de 35 en comparación con la zona donde se ubica la comunidad tipo cuenca, donde la salinidad intersticial promedio es de 80.

Caracterización del bosque de manglar del sistema de Urías.

El bosque de manglar del sistema de Urías está influenciado por una gran variedad de factores, sin embargo, la salinidad y el hidropereodo son considerados parte fundamental para la distribución y zonación de las especies (Flores-Verdugo et al., 2007). Con base en el nivel topográfico se puede hacer una distribución y zonación de los manglares en el estero de Urías con respecto al nivel medio del mar (*figura 2*). El intervalo de la distribución total de los individuos va desde los -15.8 cm hasta los 68.2 cm. *R. mangle* usualmente se encuentra en los niveles más bajos entre -15.8 cm y los 55.2 cm, *L. racemosa* está entre 55.2 cm y 60 cm y por último *A. germinans* se ubica en la parte más alta entre 60.7 cm y 68.2 cm (Flores-Verdugo et al., 2007; Agraz-Hernández, 1999).




Figura 2. Zonación de manglares en base a los niveles topográficos (Flores-Verdugo et al., 2007; Agraz-Hernández, 1999).

Efectos antrópicos en la zona de estudio

La ciudad de Mazatlán se encuentra a 10 km en línea recta de la zona de estudio, sin embargo, la interacción de esta urbe con sus alrededores genera repercusiones en el medio ambiente adyacente. El Programa de Manejo para Fomentar acciones para Restablecer el Balance del Ciclo del Agua en Mazatlán del 2018 menciona las actividades económicas más representativas de la zona y describe a la pesca, el turismo y la agricultura dentro de las principales, y al menos las últimas dos generan descargas de aguas residuales municipal que a su vez llegan a descargar al sistema de Urías (SECTUR, 2018).

El sistema de Urías está siendo afectado por el crecimiento de la ciudad, esto genera una alteración de la dinámica hidrológica y daños ecológicos. El estero de

Urías recibe una gran cantidad de nitrógeno de las descargas urbanas y la presencia industrial como el parque industrial Bonfil. Además, otros de los factores que pueden afectar al estero son la termoeléctrica y la terminal de Pemex (PMDU-MS, 2010). De esta manera, Ochoa-Izaguirre & Soto-Jiménez (2013) mencionan que existen altas temperaturas y periodos largos de residencia, lo que genera bajos niveles de oxígeno disuelto, haciendo con esto que el sistema de Urías sea un ambiente altamente eutrofizado.

En términos generales, el bosque de manglar no es un paisaje homogéneo sino un paisaje complejo que muchas veces está fragmentado ya sea por actividades antrópicas o por la orografía del terreno (Pastor-Guzmán, 2018). En la zona de estudio se puede observar la distribución de las especies de mangle (*Figura. 1*), el mangle rojo (MR) se encuentra al borde del canal de mareas, la siguiente zonación se trata del mangle blanco (MB) en la transición entre el mangle rojo y negro (MN), y por último el mangle negro esta más alejado de la influencia de las mareas.

MATERIALES Y METODOS

Se utilizaron imágenes RGB provenientes de un VANT para la clasificación de bosque de manglar por medio de algoritmos de aprendizaje automático supervisado. En la Figura 3 hace referencia al diagrama de flujo el cual consta de cuatro pasos:

- a) Preprocesamiento
- b) Análisis de Histogramas
- c) Clasificación
- d) Evaluación de exactitud

a) El preprocesamiento de las imágenes RGB obtenidas del VANT, se hace con el fin de hacer la corrección radiométrica de las imágenes, para después obtener el mosaico de la zona de estudio.

b) En el análisis de histogramas se generan parcelas de entrenamiento a nuestros productos derivados de los índices de vegetación, así como a la imagen sin modificaciones para obtener los histogramas de frecuencias con la finalidad de observar la separabilidad entre las clases.

c) En este paso se hacen las clasificaciones de los algoritmos de aprendizaje automático supervisado a todos los productos de índices de vegetación y RGB sin modificación.

d) La evaluación de la exactitud se hace por medio de la comprobación de una matriz de confusión que usa datos de puntos de muestreo aleatorio estratificado. Los resultados de las diferentes exactitudes son comparados entre sí, para conocer la significancia de las clasificaciones por medio de la prueba estadística del coeficiente de Tau.

VANT

La plataforma VANT utilizada en este estudio fue un Phantom-4 Advanced de 4 rotores. El sensor emergente tiene despegue vertical de 4 rotores desarrollado por la empresa DJI, este dron cuenta con características especiales para realizar trabajos profesionales tales como estudios ambientales, arquitectura, ingeniería, y filmes fotográficos. Además, son utilizados para la toma de datos de hasta un alcance máximo de transmisión de 5 km. Las especificaciones que el fabricante menciona (DJI,2021), se muestran a continuación. Peso (Batería y Hélices Incluidas) 1368 g, tamaño Diagonal (Hélices Excluidas) 350 mm, velocidad máxima en ascenso 6 m/s, velocidad máxima en descenso 4 m/s, modo GPS/GLONASS, máxima duración de Vuelo es de aproximadamente 25 minutos.

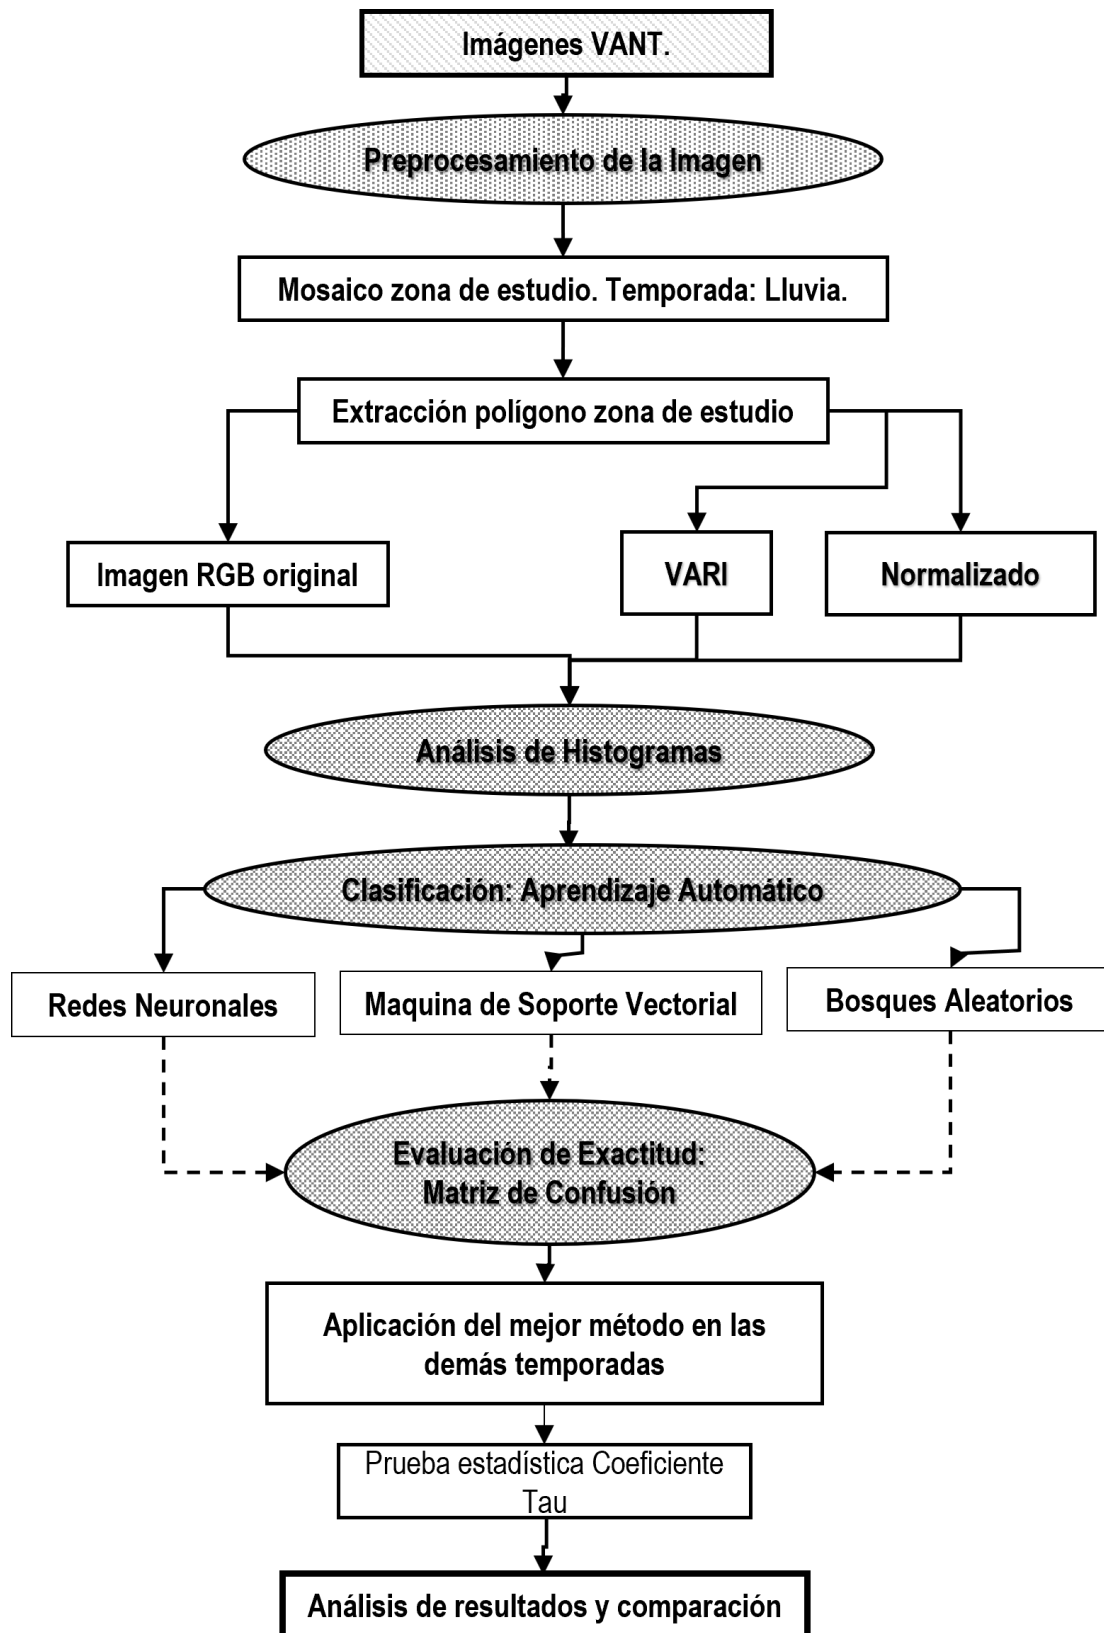


Figura 3. Diagrama de trabajo del método de clasificación con algoritmos de aprendizaje automático.

Cámara:

- Sensor 1" CMOS
- Píxeles efectivos: 20 M
- Lente: FOV 84° 24 mm (35 mm formato equivalente) f/2.8, enfoque a 1m-∞
- Rango ISO: 100-3200 (vídeo) 100-1600 (foto)
- Velocidad Del Obturador: 8s -1/8000s
- Tamaño Máx. de Imagen: 5472×3078
- Tipos de Tarjetas SD Compatibles: Micro SD
- Capacidad Máx.: 64 GB. Clase 10 ó UHS-1 valoración requerida
- Tasa de Bits Máx. de Almacenamiento de Vídeo 60 Mbps
- Formatos de Archivo Admitidos: FAT32 (≤ 32 GB); exFAT (> 32 GB)

El ordenador con el que se realizó el procesamiento presenta las siguientes especificaciones técnicas:

- Sistemas: Windows 10 Pro
- Procesador: Intel (R) Core (TM) i7-2670QM CPU @ 2.20GHz 2.20 GHz
- Memoria: 16 GB
- Tarjeta gráfica: NVIDIA® GeForce® GTX560M/3GB
- Almacenamiento: 1TB HDD 7200

MapPilot

Para el plan de vuelo del Phantom 4 Advanced, se utilizó la aplicación MapPilot que es compatible con equipos DJI, esta aplicación se instaló mediante un sistema iOS.

Algunas de las funciones que podemos utilizar se enlistan a continuación (Maps made easy, 2021).

- Captura automáticamente la imagen de referencia de elevación (imagen de suelo)
- Recopilar datos para crear mapas aéreos de alta resolución
- Inicio y lugar de lanzamiento
- Indicador de línea de visión
- Gestión de la velocidad
- Programar la altitud constante del sobrevuelo
- Planeación de la trayectoria dentro del polígono
- Determinar la superposición de las tomas de imágenes
- Guardar / Editar Misiones de vuelos previos o futuros
- Asistencia de aterrizaje natural
- Determinar el área de cobertura del área deseada

Agisoft PhotoScan

Agisoft PhotoScan es un programa de modelado basado en imágenes, utiliza tecnología de reconstrucción 3D de vistas múltiples, opera con imágenes arbitrarias y se define por ser eficiente tanto en condiciones controladas como no controladas. Generalmente, el objetivo final del procesamiento de imágenes con PhotoScan es construir una superficie 3D, ortomosaicos y DEM (*Modelo Digital de Elevaciones*). A continuación, se enlistan algunos productos que se pueden obtener mediante este programa (Agisoft, 2021).

- Modelos digitales de terreno
- Modelos digitales de superficie georreferenciados
- Generación de modelos 3D
- Medición de, áreas, volúmenes y distancias
- Generación de índices de vegetación (NDVI)
- Clasificación de nube de puntos geométrica

Preprocesamiento de las imágenes y adquisición de datos

Plan de Vuelo

Previo a la toma de datos se investigaron las vías de acceso a la zona de estudio, para poder hacer el vuelo del VANT, después con el programa Map Pilot-DJI, se planificaron las rutas y programó para que de manera automática realizara los vuelos. El software determina la apertura de la cámara a bordo del Phantom 4 Advanced durante el vuelo según las condiciones de luz y velocidad del viento además de la velocidad de vuelo.

Map Pilot nos permite elegir entre cuatro opciones

1. Crear una nueva misión de vuelo
2. Revisar misiones grabadas anteriormente
3. Manual de usuario
4. Ajustar las configuraciones de la aplicación previo al vuelo.

En las configuraciones generales, nos permite trabajar con las unidades que más nos convenga, además de establecer un punto de origen fijo o móvil y fijar un radio máximo de vuelo. Con base en lo anterior, después de hacer las configuraciones generales de vuelo, se elaboraron los planes de vuelo del área de estudio.

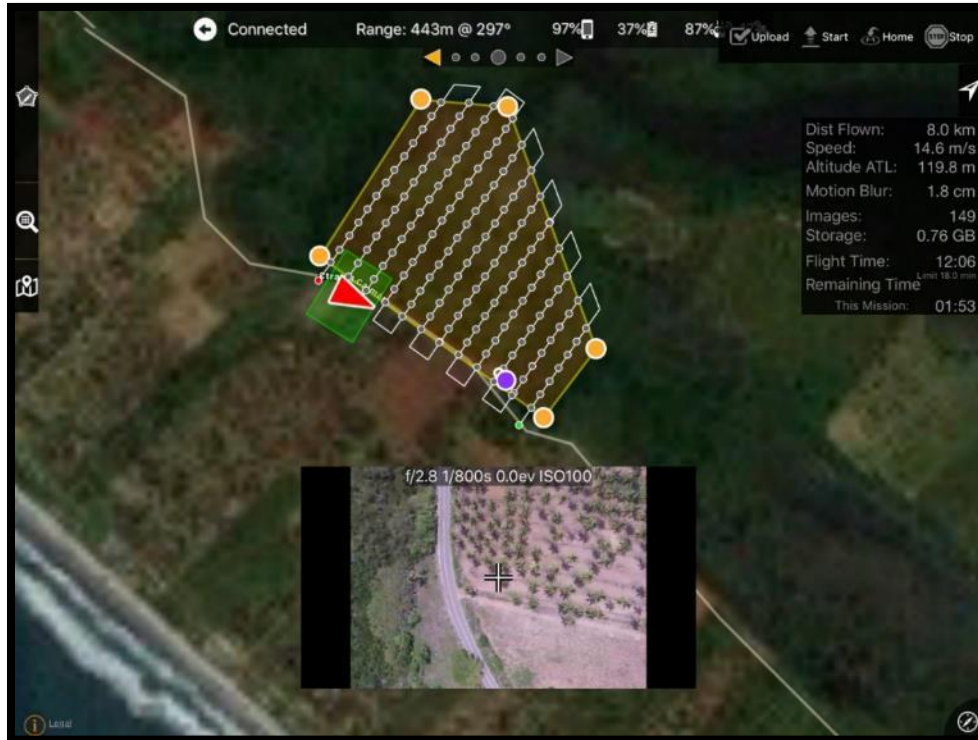


Figura 4. Plan del vuelo en tiempo real del sitio de estudio, generado a partir de Map Pilot (Maps made easy, 2021).

Una vez que los parámetros de vuelo están designados, se hizo el recorrido en campo para reconocer el terreno del área para tomar en consideración todas las características, así como los obstáculos o estructuras altas del sitio. Para delimitar el polígono de estudio, se designaron 5 puntos en el mapa, para después seleccionar la forma del recorrido del dron, las líneas blancas son la ruta que el dron toma desde el despegue y que realiza la toma de las imágenes (figura 4). En la parte inferior del polígono, se marca el punto de despegue de inicio con un punto morado, las líneas que cruzan el polígono son el trayecto registrado, así también la flecha roja es la posición del VANT y con puntos grises las imágenes adquiridas durante el recorrido de la línea de trayecto, por último, los puntos rojo y verde representan el inicio y final del recorrido. Del lado superior izquierdo se establece la velocidad del VANT, la altura de vuelo, la longitud del trayecto, número de imágenes capturada, tiempo de vuelo, cantidad de almacenamiento de la tarjeta de memoria, y tiempo restante del vuelo.



Figura 5. Registro del plan de vuelo en Google Earth (2020)

Los datos se obtuvieron mediante un plan de vuelo en forma de franjas, a una altura de 120 metros y una superficie de 36 ha (*figura 5*). La sobreposición entre las imágenes fue longitudinal de 70% y transversal de 70% evitando así errores de distorsión de acuerdo a los planes de vuelo de Flores-de-Santiago et al. (2020). Las imágenes fueron geotiquetadas durante el vuelo con un GPS integrado en el dispositivo. El geotiquetado de las imágenes RGB recopiladas con un sensor CMOS utilizando la información proporcionada por el registro de telemetría guardado en el dispositivo digital. Después de la toma de los datos anteriores se llevó a cabo un preprocesamiento de 2d que consiste en los siguientes 3 pasos que se describen de manera general;

1. Las imágenes geotiquetadas fueron procesadas y sistematizadas para generar un ortomosaico consistente en información recopilada para bandas RGB.
2. Las imágenes obtenidas del VANT se unieron en un mosaico el cual tiene un sistema de coordenadas geograficas con un datum WGS 84.
3. El ortomosaico georreferenciado se exporto en formato TIFF para despues ser reproyectado en coordenadas UTM WGS 84 para su posterior análisis.

Una vez determinada la configuración del plan de vuelo y programada en la aplicación se dio por finalizada la determinación de los parámetros de la misión y fue cargada al VANT para cotejar el número de baterías necesarias, el número de imágenes que se tomaron y el tamaño del pixel. Los vuelos con el dron se realizaron a lo largo de la parte sur de la laguna costera del sistema de Urías, Sinaloa, durante tres temporadas (estiaje, lluvias e invierno). Tres especies de mangle van a ser seleccionadas: *Laguncularia racemosa* (mangle blanco), *Rhizophora mangle* (mangle rojo) y *Avicennia germinans* (mangle negro).

Procesamiento 2D

Las imágenes obtenidas de cada una de las diferentes temporadas se unieron por separado en un ortomosaico donde se se eliminaron las distorsiones geometricas. El material obtenido mediante el VANT se descargo a un ordenador para poder hacer el procesamiento 2d.

El producto final de este proceso es el ortomosaico (4), el cual consta de la unión de todas las imágenes por misión en un sola imagen que ocupe toda el área de estudio (Hsu et al, 2020). Con el uso del programa Agisoft Photoscan, se agregaron las imágenes de manera manual mediante la herramienta “Workflow”, para cargar las imágenes e inspeccionar las que se usaron y las que no fueron necesarias (1). Una vez que se cubrió el área de estudio, se alinearon las imágenes (2) para generar la malla (3) y con esto se puedo generar el ortomosaico (*Figura 6*) y así exportar en

un formato compatible para los análisis subsecuentes (Flores-de-Santiago et al., 2020).

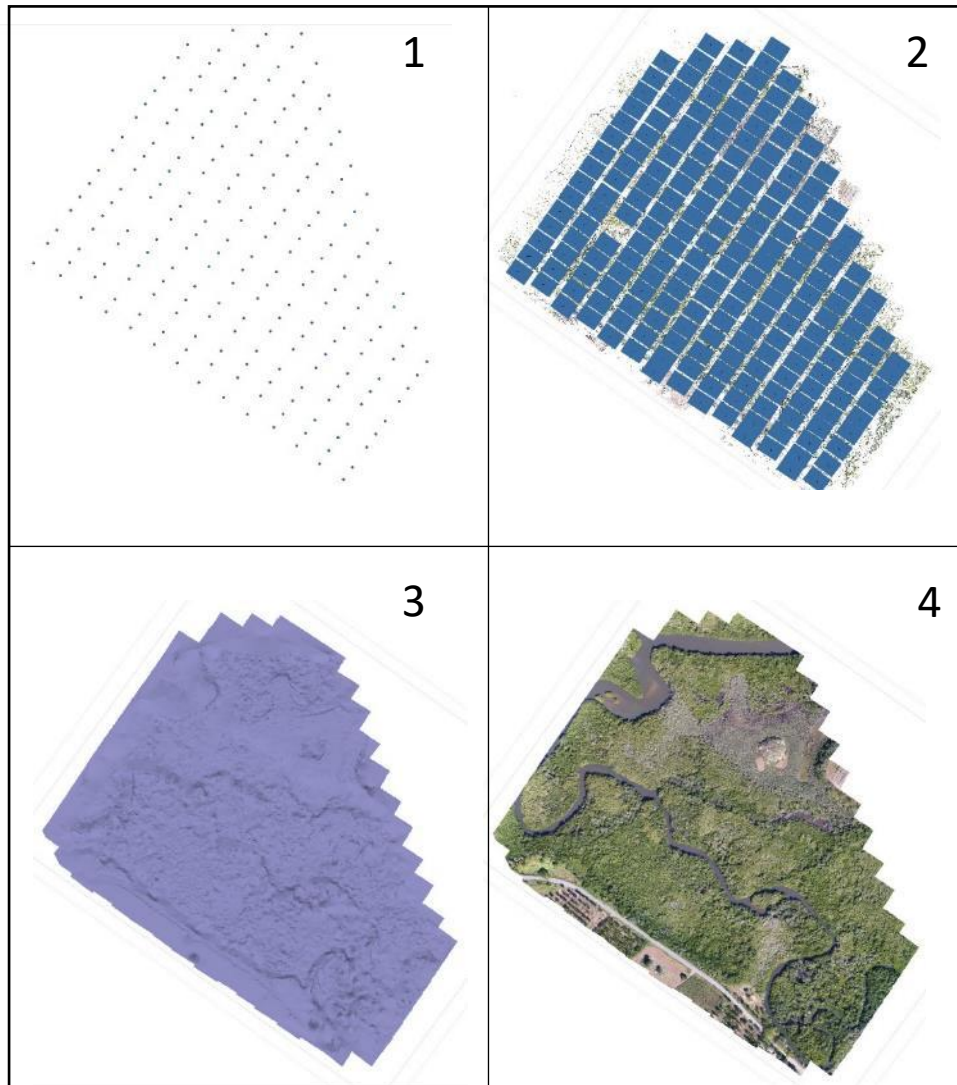


Figura 6. Proceso de generación del ortomosaico a partir de las imágenes de UAV (Agisoft, 2021).

Extracción del polígono de la zona de estudio

La extracción del polígono de la zona de estudio se hizo mediante el programa QGIS 3.14.0-Pi. La imagen de la zona de estudio está conformada por diferentes clases de cobertura como vegetación, marisma y espejo de agua (Figura 7). Además de un oscurecimiento por la sombra generada por el dosel del manglar. Para poder reducir

la cantidad de clases se eliminó el espejo de agua del canal de mareas, extrayendo solamente la parte del bosque de manglar.



Figura 7. Polígono de extracción de la zona de estudio.

El preprocesamiento de los datos se generó para cada una de las temporadas, de esta manera también se hizo la extracción de la zona de estudio de cada mosaico. Se puede observar en la figura 8 el cambio de la coloración de las imágenes de cada temporada, así como el aparente incremento en la densidad de hojas del dosel.

Indices de Vegetacion

La reflectividad de las cubiertas vegetales esta determinada por factores externos como son la atmosfera y la iluminacion asi como por las características ópticas y de distribución espacial de todos sus constituyentes, es por esto que un indice de

vegetacion busca extraer información relacionada con la vegetación minimizando la influencia de perturbaciones debidas a la superficie en que se encuentren y a las condiciones atmosféricas (*figura 8*). Por lo anterior Gilabert et al, (1997) y Muños (2013) definen a un indice de vegetacion como un parámetro calculado a partir de los valores de la reflectividad a distintas longitudes de onda y que es particularmente sensible a la cubierta vegetal.

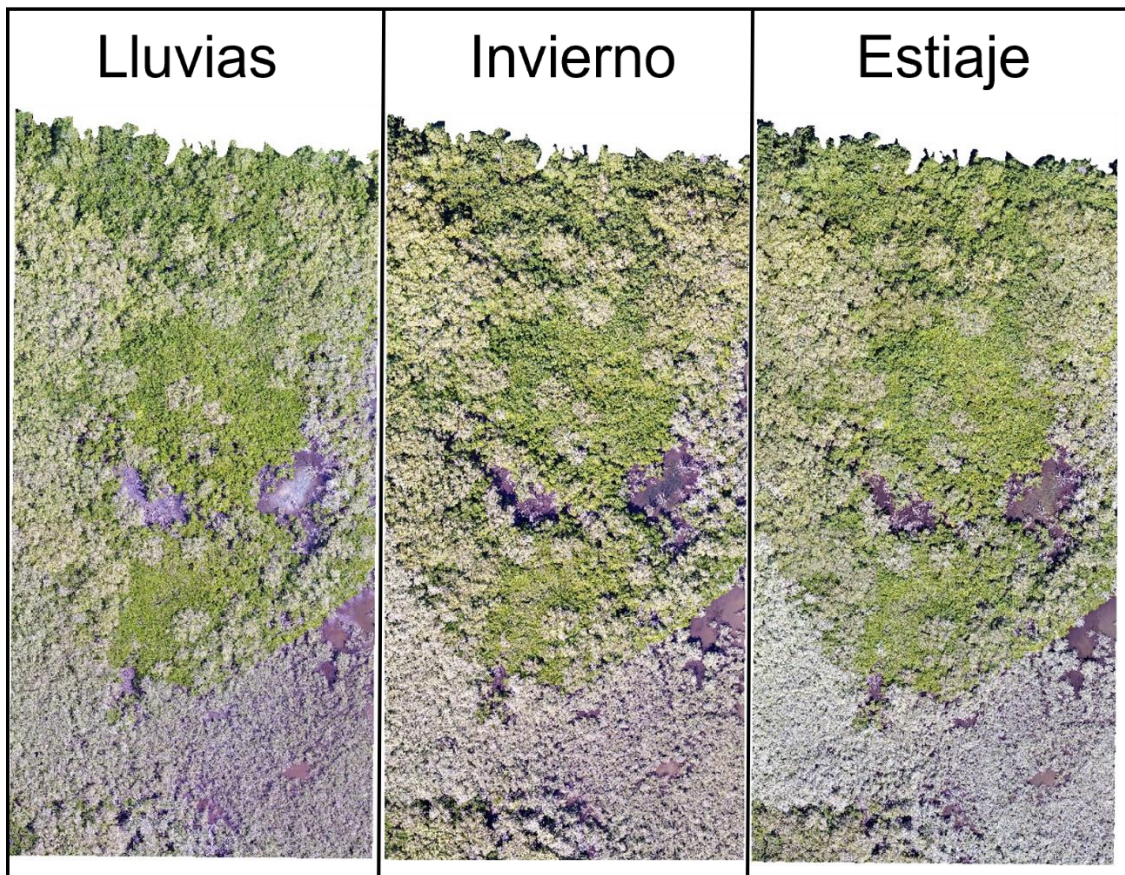


Figura 8 .Imágenes VANT de las 3 temporadas en la zona de estudio.

Indice VARI

El Índice de resistencia visible a la atmósfera (VARI) es un indice de vegetacion que solo usa el espectro visible, este indice se usa comunmente para camaras sin modificar y drones de consumo standard (Yu et al, 2017), este indice fue desarrollado

por la Universidad de Nebraska y busca predecir la fracción de la vegetación y el índice del área foliar (McKinnon & Hoff, 2017).

Este índice se usó como normalización de la imagen original RGB con el fin de optimizar el desempeño de la clasificación de los algoritmos de aprendizaje automático. Su fórmula es:

$$VARI = ((g-r)/(g+r-b))$$

Para analizar los resultados de este índice se usó un análisis de caja con bigote que está basado en el método de Valderrama-Landeros et al. (2018), donde se obtienen muestreos aleatorios estratificados por puntos (*50 por clase*) y estos a su vez se usan para extraer los valores del producto raster del índice VARI con el fin de generar las gráficas.

Índice de normalización de color

Se aplicó una normalización a cada una de las bandas R, G, B. Según Zhang et al., (2019), el siguiente esquema se usó en la imagen del mosaico RGB obtenido por VANT:

$$r = R/(R + G + B); g = G/(R + G + B); b = B/(R + G + B)$$

donde R, G y B son los valores de las bandas roja, verde y azul.

Análisis de Histogramas

En cuanto al análisis de los histogramas de los diferentes productos: Normalización, VARI y RGB (imagen sin modificación). Se realizó un análisis comparativo en cuanto al traslape de las bandas de cada una de las imágenes, con el objetivo de escoger la que tenga más separación entre sus curvas de frecuencia.

Clasificación de la imagen

Clasificación con algoritmo Bosques Aleatorios

El número de muestras de entrenamiento que comúnmente se usan son de 5000 con 200, 500 y 1000 árboles de decisión. Sin embargo (Immitzer et al, 2012), menciona que una iteración de 500 en el número de árboles genera precisiones casi constantes para el uso de clasificación de imágenes (*tabla 1*).

Clasificación con algoritmo Máquina de Soporte Vectorial

Se usó un Kernel de tipo Lineal, ya que Castellon (2015) menciona que es el mejor resultado se obtiene en clasificación de imágenes de percepción remota, el costo o penalización para controlar el intercambio de errores de entrenamiento fue de 100. En cuanto a los niveles de pirámide se dejaron en 0, ya que se procesó la imagen en resolución completa (*tabla 1*). En el umbral o rango de probabilidad de clasificación el valor fue en 0.00 ya que se buscó generalizar la clasificación de todo el conjunto espacial (Üstüner et al., 2015).

Clasificación con algoritmo Redes Neuronales

En este algoritmo se utilizó la activación hiperbólica, ya que Mas & Flores (2008) mencionan que la misma puede ser superior en mapeos de vegetación. En cuanto a la contribución del umbral o rango del entrenamiento fue de 0.15 ó 0.25 (estos intervalos presentan resultados más exactos que los intervalos más amplios), en cuanto a la velocidad de entrenamiento y el momentum de entrenamiento su valor fue de 0 ya que la literatura menciona que si no se usan dichos parámetros es más fácil la propagación de entrenamiento del algoritmo (*tabla 1*).

En cuanto a las capas ocultas solo se usó 1, ya que es la más generalizada en el uso de clasificaciones, aunque dos capas puede solucionar más problemas y ser más eficientes, pero retardan el proceso.

	Bosques Aleatorios	Máquina de Soporte Vectorial	Redes Neuronales
Parámetros	Muestras de entrenamiento: 5000 Arboles de decisión: 200, 500, 1000.	Kernel: Lineal Costo de penalización: 100 Nivel de pirámide: 0.0 Umbral: 0.00	Umbral: 0.15 Velocidad de entrenamiento & momentum: 0 Capas ocultas: 1
Autor	Immitzer et al, (2012)	Castellon (2015) Üstüner et al., (2015)	Mas & Flores (2008)

Tabla 1. Parámetros usados en el proceso de clasificación con algoritmos de aprendizaje automático Generado a partir de Immitzer et al, (2012), Castellon (2015) Üstüner et al., (2015) y Mas & Flores (2008).

Coeficiente Tau

El cálculo del coeficiente Tau se hizo conforme a Ma & Redmond (1995), y este cálculo proporciona una indicación clara de la mejora de una clasificación sobre una asignación aleatoria de píxeles a grupos. Tanto Tau como Kappa se calculan a partir del margen de distribuciones de los datos de referencia; la diferencia entre los dos coeficientes radica en que Tau se basa en probabilidades a priori de pertenencia a un grupo, mientras que Kappa utiliza probabilidades a posteriori.

$$T = \frac{P_0 - P_r}{1 - P_r}$$

Donde:

T= Coeficiente de Tau

$$P_0 = \frac{1}{N} \sum_{i=j}^M n_{ii}$$

$$P_r = \frac{1}{M}$$

Significancia

La significancia de las comparaciones entre las diferentes clasificaciones se obtuvieron con el valor Z con la siguiente fórmula:

$$Z = \frac{P_{01} - P_{02}}{\sqrt{\sigma_1 + \sigma_2}}$$

Los datos se generaron a partir de los valores de P_0 y σ , este último se puede obtener a partir de la matriz de confusión como se muestra a continuación.

$$\sigma = \frac{P_0(1 - P_0)}{N(1 - P_r)^2}$$

Donde:

$$P_0 = \frac{1}{N} \sum_{i=j}^M n_{ii}$$

N = Número de píxeles totales

$$P_r = \frac{1}{M}$$

Resultados

Se generaron cuatro clases que fueron utilizadas como "ROI" que son áreas de interés utilizadas en algunos programas como ENVI y ERDAS. De las clases antes mencionadas 3 pertenecen a las clases de Mangle Rojo, Mangle Blanco, Mangle Negro con un diámetro de 10 metros que son 70 m² y aproximadamente 30,000 píxeles (*figura 9*). Y la última clase es Marisma con un diámetro de 4 metros y 10 m² con aproximadamente 3500 píxeles, esta última tiene un área más pequeña puesto que el sitio no existe marisma con áreas más grandes.




Figura 9. Imagen RGB sin modificaciones con los sitios de entrenamiento; MR: Mangle Rojo, MN: Mangle Negro, MB: Mangle Blanco, MRSM: Marisma.

Índices de vegetación

Índice de Resistencia Atmosférica Visible

El resultado del índice de VARI genera una sola banda, este índice es comúnmente usado para imágenes RGB y se genera a partir de restar la banda verde (G) del rojo (R) y dividir el resultado con la suma de la banda verde y roja, restando la banda azul (B).

Se obtuvieron resultados de cada temporada, los cuales se generaron a partir de 90 puntos de entrenamiento por cada clase (*figuras 10,11 y 12*). Estos datos representan una muestra de la distribución estacional del VARI durante diferentes temporadas del año para cada una de las cuatro categorías de cobertura presentes en el área de estudio (*R. mangle, L. racemosa, A. germinans* y marismas). Se realizó un análisis apoyándose en diagramas de caja para evaluar la capacidad del índice de separar las clases en las tres temporadas (invierno, lluvias y estiaje).




Figura 10. Imagen VARI en temporada de estiaje.

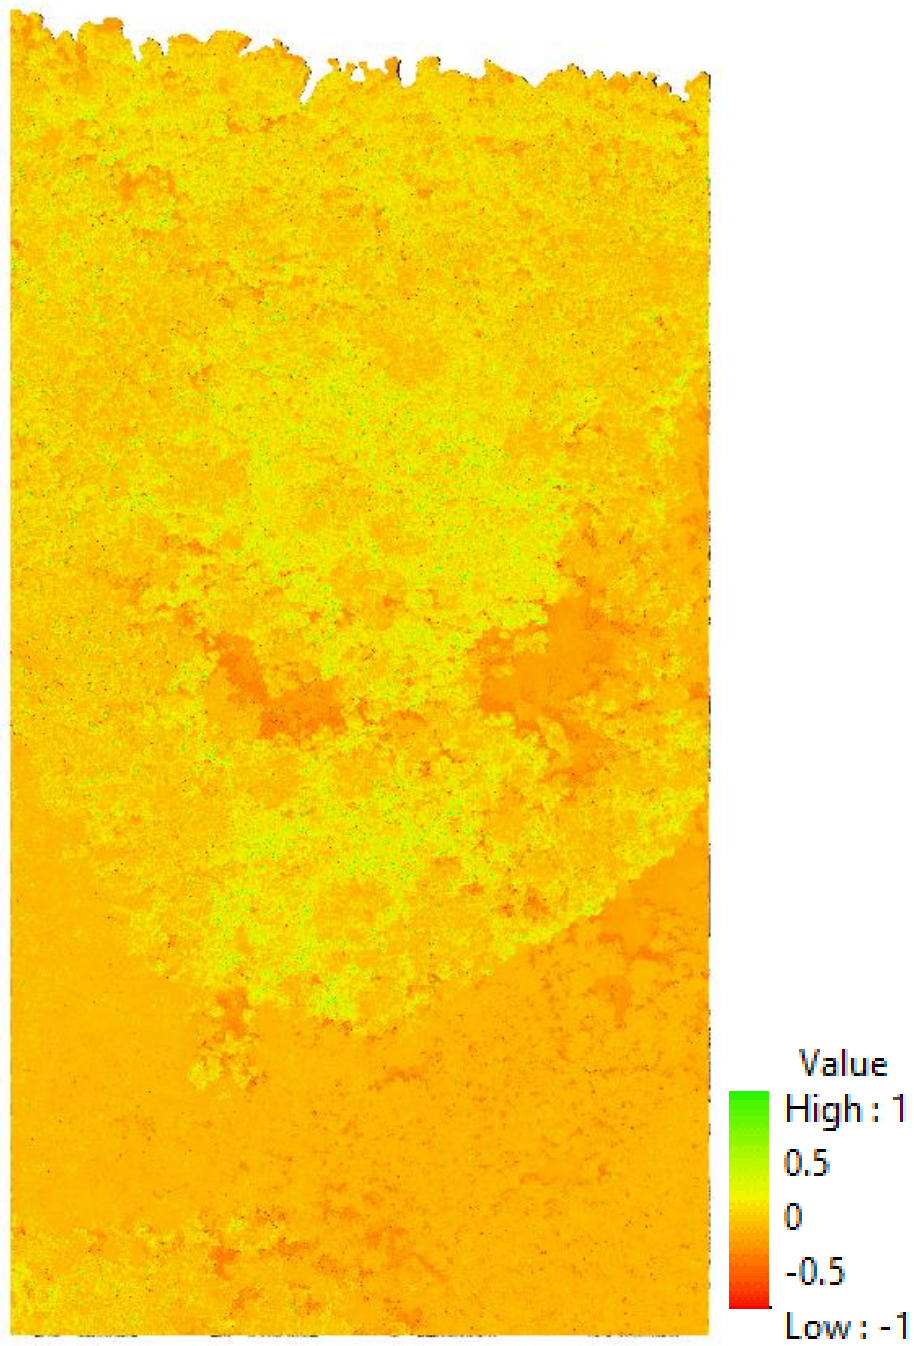


Figura 11. Imagen VARI en temporada de invierno.




Figura 12. Imagen VARI en temporada de lluvias.

Índice de Normalización del color

Este índice se hizo a partir de la metodología de Zhang et al., (2019), y se normalizo cada una de las bandas RGB ($r=R/(R + G + B)$; $g=G/(R + G + B)$; $b = B/(R + G + B)$), una vez separadas se volvieron a unir en una sola imagen para continuar con el procesamiento de clasificación (*figura 13*).




Figura 13. Imagen del Índice de normalización de Color con los sitios de entrenamiento.

Análisis estadístico descriptivo Índice VARI

A pesar de no poder usar los resultados de este índice con algoritmos de aprendizaje automático, se generó un análisis estadístico descriptivo de frecuencias de cada temporada. Como se puede observar en las figuras 10, 11 y 12, los datos de la temporada de lluvias (que es la que exhibe las mayores diferencias) que corresponden a las clases de mangle rojo y mangle blanco muestran un traslape en cuanto sus límites (figura 17). El resultado del índice VARI muestra una diferenciación entre los cuartiles de las clases de marisma (4) y mangle negro (3), además, las clases de mangle rojo (1) y mangle blanco (2) tienden a traslaparse, a pesar de esto el intervalo de mangle blanco tiene valores más altos que mangle rojo.

Los intervalos que señalan los bordes superior e inferior de los diagramas de cajas representan el intervalo de valores que más probablemente serán el de la clase que corresponden. Así mismo, los límites de los valores máximos y mínimos están simbolizados por las barras que son el 1er y 4to cuartil. El 50% de los datos está representado en las cajas que son el 2do y 3er cuartil. De esta manera la línea que separa las cajas (el límite entre el 2do y 3er cuartil) es la mediana (Tu, 2016).




Figura 14. Diagrama de Caja de la temporada de lluvias del índice VARI.

Una separación de clases segura es cuando las cajas no se tocan como es el caso de la marisma y mangle negro (*Figura 14*), por lo que se puede esperar una buena separación de clases o grupos.

Además, en la gráfica anterior (*figura 14*) se puede notar que se consiguen separar 3 grupos sin que haya sobreposición en los valores de las cajas los cuales son:

1-Mangle Rojo-Mangle Blanco

2-Mangle Negro

3-Marisma

Los valores más altos se observan en los grupos de Mangle Rojo y Mangle Blanco, esto debido a que estas especies tienen una mayor reflectancia a tonos más “Verdes” en el intervalo del visible, por otra parte el mangle negro además de estar más disperso la especie es más pálida en su color y con menor matiz que el grupo de mangle rojo y mangle blanco, esto se puede observar en la gráfica de histograma de frecuencias VARI (*Figura 19*), en cuanto a los valores más bajos de los grupos de Mangle Negro y marisma son de menor densidad, pero se observa una mejor separación que las demás clases. De esta manera es que los valores negativos se asocian a píxeles que no tienen tanta reflectancia como es el caso de marismas y sombras, en contraste los valores más altos a aquellos que tienden a reflejar más, como es el caso de las clases de Mangle Rojo y Mangle Blanco (Ritchie, 2003; Brizuela-Amador et al, 2007).

En cuanto a las temporadas de estiaje e invierno podemos observar en las figuras 14 y 15 correspondientes, que los valores de cada clase tienen un traslape considerable, por lo que esta condición genera mayor confusión e incertidumbre en la discriminación de las clases para hacer alguna clasificación, es por esto por lo que el uso de las demás temporadas (estiaje e invierno), no se usaran para obtener la exactitud global.




Figura 15. Diagrama de Caja de la temporada de estiaje del índice VARI.




Figura 16. Diagrama de Caja de la temporada de invierno del índice VARI.

Con base en los datos anteriores se generó una gráfica comparativa de los datos en las 3 temporadas (*Figura 17*).




Figura 17. Diagrama de Caja comparativo de las 3 temporadas del índice VARI.

Validación de exactitud de VARI en temporada de lluvias

Se generó una clasificación con base al análisis de diagramas de caja (*figura 18*), en donde se discriminaron los valores del segundo y tercer cuartil por cada clase tomándolos como límites de umbral. Al ser datos univariados, no fue posible hacer una clasificación con los algoritmos de aprendizaje automático. Los resultados de la exactitud de la temporada de lluvias del índice VARI, se generaron a partir de 90 puntos aleatorios estratificados por cada clase (*tabla 2*).




Figura 188. Imagen VARI Reclasificada visualmente temporada de lluvias

Para obtener la exactitud global de la clasificación se usó una matriz de confusión la cual nos arrojó una exactitud del 42 %.

	Mangle Rojo	Mangle Blanco	Mangle Negro	Marisma	Total
Mangle Rojo	19	67	4	0	90
Mangle Blanco	17	72	1	0	90
Mangle Negro	9	48	31	2	90
Marisma	2	13	45	30	90
Total	47	200	81	32	360
Exactitud	->	->	->	->	0.42222

Tabla 2. Matriz de Confusión Índice VARI en temporada de Lluvias

Análisis de histogramas

El análisis de los histogramas se hace con el fin de analizar la separabilidad de las frecuencias y poder discernir si son viables los sitios de entrenamiento para una buena clasificación.

Índice VARI

El histograma de este índice se formó a partir de la única banda que se genera, por lo que se tiene que hacer un histograma múltiple para poder comparar las frecuencias de cada uno de los sitios de entrenamiento (*figura 19*). Cabe señalar que para este índice no es posible trabajar los algoritmos de aprendizaje automático ya que se requieren de al menos 3 bandas para su proceso.




Figura 19. Histograma de la única banda del índice VARI en la zona de estudio, los colores de las clases son los mismos que los sitios de entrenamiento.

Índice Normalizado de color

El proceso de normalizado de la imagen nos arroja las curvas de las frecuencias de cada uno de los sitios de entrenamiento (*figura 20*), estas curvas muestran que en cuanto el mangle blanco y rojo ascienden con poca separabilidad sin embargo en la parte final tienden a separarse, y en cuanto a las otras clases de mangle negro y marisma no tienen traslape con ninguna.

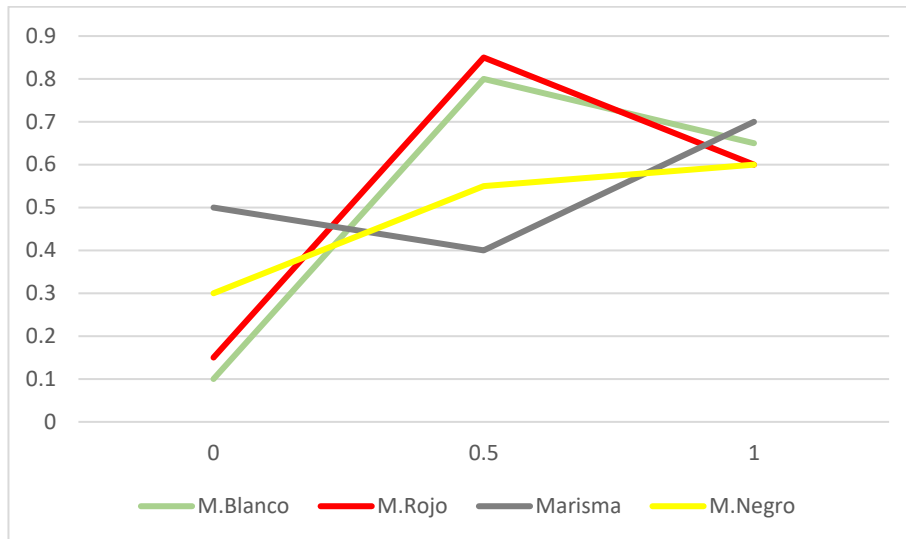


Figura 20. Histograma de las cuatro clases con el índice normalizado del color.

Imagen RGB sin modificación

La imagen RGB muestra una buena separabilidad al inicio con respecto a todas las frecuencias (figura 21), sin embargo, al final muestra traslape de todas las frecuencias.

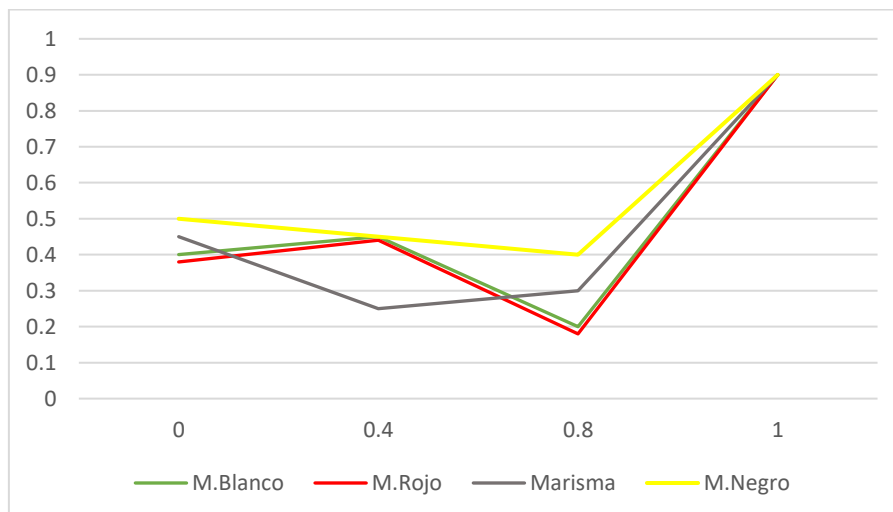


Figura 21. Histograma de las cuatro clases de la imagen RGB sin modificación.

Clasificación con algoritmos de aprendizaje automático

Clasificación a partir de imagen RGB

Bosques aleatorios

En esta clasificación se puede observar que la discriminación de todas las clases se completó, aunque en los bordes de cada uno de los conjuntos de clases tiende a tener confusión (*figura 22*).




Figura 22. Comparación de la imagen tomada con VANT y la clasificación con el algoritmo BA.

Máquina de soporte vectorial

La siguiente clasificación muestra un buen contorno de las clases sin embargo las sombras del dosel generan confusión con la clase del mangle rojo en los resultados (*figura 23*).

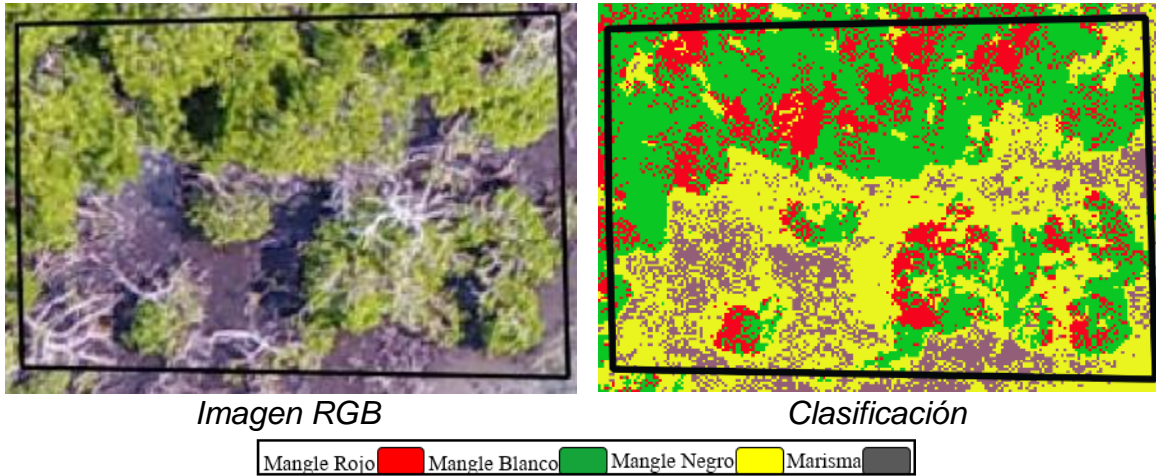


Figura 23. Comparación de la imagen tomada con VANT y la clasificación con el algoritmo MSV.

Redes Neuronales

En esta clasificación se utilizó una iteración de 1000 para el algoritmo, este proceso nos arrojó una buena conjunción en cuanto a las clases de mangle rojo y blanco, sin embargo, tiende a confundir demasiado la clase de marisma con mangle negro (figura 24).

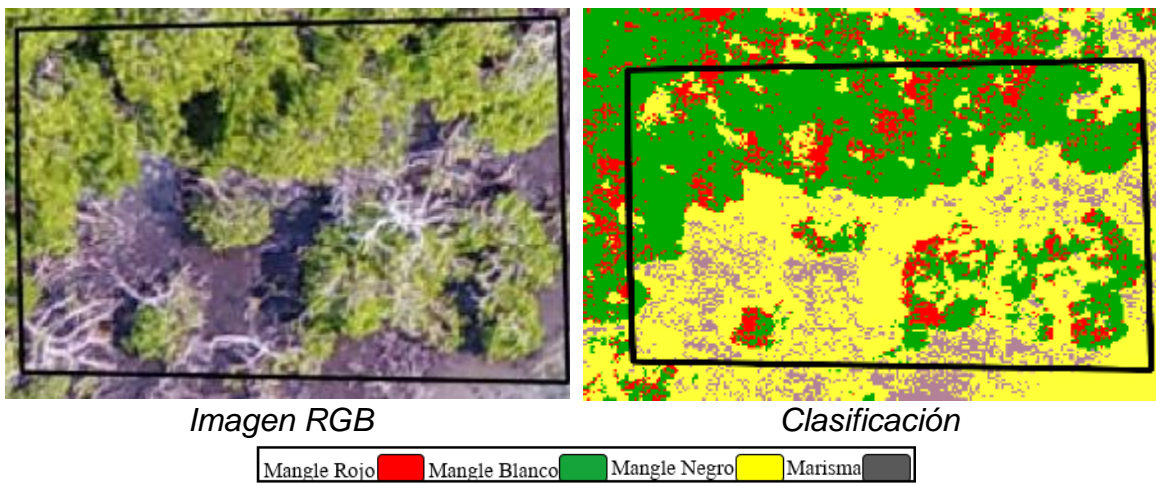


Figura 24. Comparación de la imagen tomada con VANT y la clasificación con el algoritmo RN.

Redes Neuronales

Esta clasificación se generó con 5000 iteraciones lo cual nos dio como resultado mucha confusión en cuanto a todas las clases (*figura 25*).

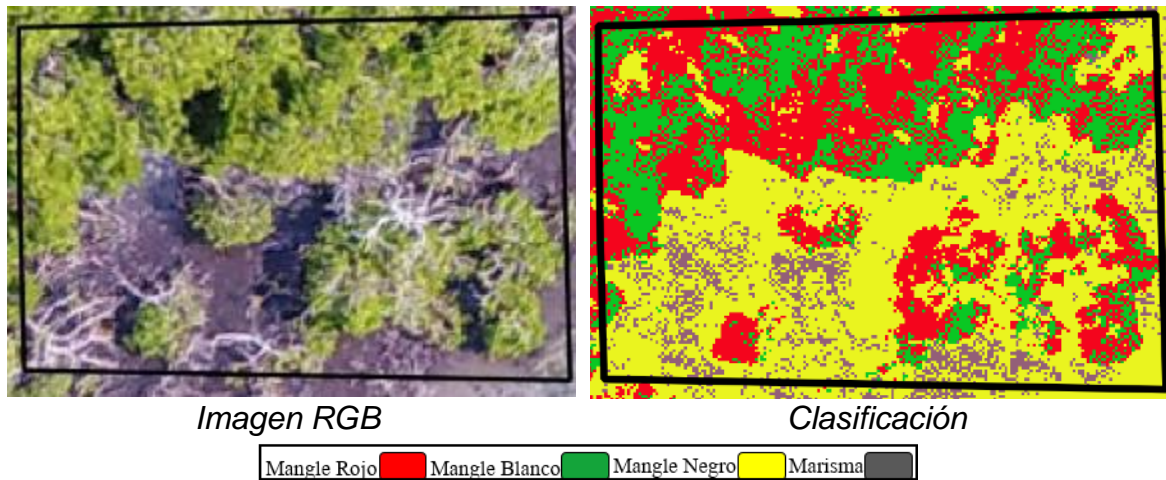


Figura 25. Comparación de la imagen tomada con VANT y la clasificación con el algoritmo RN.

Clasificaciones a partir de imagen RGB-Normalizado

Bosques aleatorios

El resultado de la clasificación con el índice de normalización en contraste con RGB nos genera demasiada confusión en cuanto a las sombras y el mangle rojo (*figura 26*).




Figura 26. Comparación de la imagen tomada con VANT y la clasificación con el algoritmo BA.

Máquina de soporte vectorial

En cuanto la clasificación de MSV en normalizado, tiende a confundir las clases de mangle negro con marisma (*figura 27*).

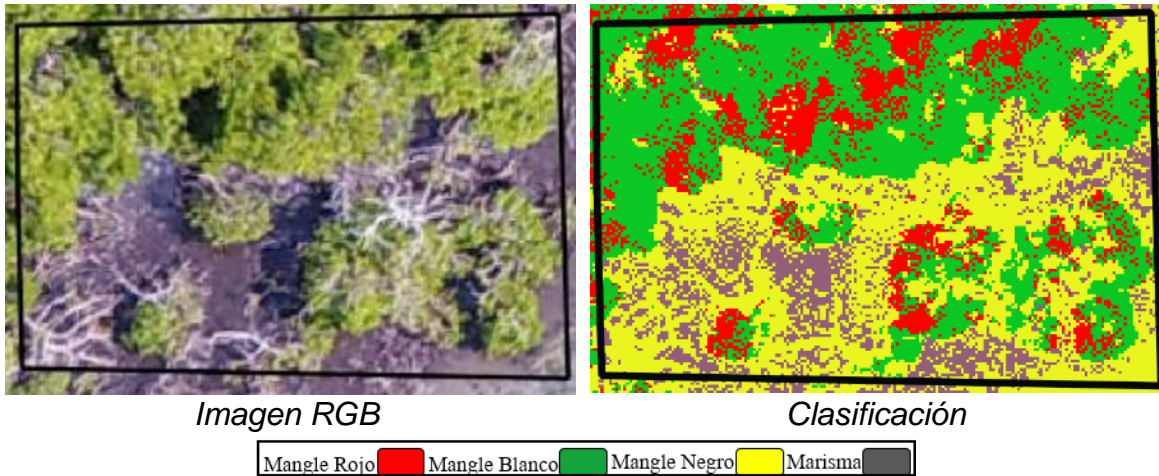


Figura 27. Comparación de la imagen tomada con VANT y la clasificación con el algoritmo MSV.

Redes Neuronales

Para esta clasificación de la misma manera que RGB se utilizó una iteración de 1000, pero este producto no alcanzó a generar la clase de marisma (*figura 28*).




Figura 28. Comparación de la imagen tomada con VANT y la clasificación con el algoritmo RN.

Redes Neuronales

La iteración para esta clasificación fue de 5000 y casi de la misma manera que la anterior casi no alcanzo a formar las clases de marisma (*figura 29*).




Figura 29. Comparación de la imagen tomada con VANT y la clasificación con el algoritmo RN.

Derivado de los resultados anteriores, la normalización de la imagen por el método de Zhang et al, (2019), nos muestra que no proporcione mayor optimización en la clasificación de imágenes, como se muestra en la tabla 4, quedando excluido para continuar con el uso de los algoritmos en las demás temporadas. Aunque su exactitud es más baja que el RGB sin modificaciones, los resultados de este índice no son descartables, puesto que el índice Kappa que obtiene son de .29 a .53. (*tabla 3*).

Algoritmo	Kappa
RN	0.29
BA	0.41
MSV	0.53

Tabla 3. Valores Kappa de la imagen RGB-Normalizada de la temporada de lluvias.

Exactitud de clasificación para temporada de lluvia con índices de vegetación

Se generó una matriz de confusión para la obtención de la exactitud, según Mather (2004) y Akar (2017), se definió el número de puntos necesarios utilizando la siguiente fórmula:

$$PM = ((NB) * (NM) * (NC))$$

Donde:

PM= Puntos de muestreo

NB= Numero de bandas

NM= Numero de muestras

NC= Numero de clases

Los puntos de muestreo para este estudio fueron de 90 por clase (*figura 30*), ya que, según Congalton, (1991) y Mas et al., (2003), recomiendan que el número de puntos de muestreo si son menores de 400,000 ha, por lo menos debe tener 50 por cada clase.



Figura 30. Puntos de muestreo para la generación de las matrices de confusión.

El resultado de la matriz de confusión para las imágenes RGB y RGB Normalizada muestra que los datos obtenidos por RGB son más altos y el algoritmo que obtuvo mayor exactitud es el de máquina de soporte vectorial (*tabla 4*).

Siendo la imagen RGB la que obtuvo mayores valores de exactitud fue la que se utilizó para continuar con las clasificaciones de las siguientes temporadas (invierno y estiaje).

Producto	Alg	Exactitud	Kappa	Alg	Exactitud	Kappa	Alg	Exactitud	Kappa
RGB sin modificación	MSV	0.76111*	0.68148	BA	0.60445*	0.46479	RN	0.58333*	0.44802
RGB Normalizado	MSV	0.64705	0.53372	BA	0.57022	0.41891	RN	0.45786	0.29881

Tabla 4. Comparación de resultados de exactitud global y Kappa entre los dos productos de RGB sin modificación y con índice Normalizado (Zhang et al, 2019), () Valores más altos, (Alg) Algoritmos, (MSV) Máquina de Soporte Vectorial, (BA) Bosques Aleatorios (RN) Redes Neuronales.*

Clasificación con algoritmos de aprendizaje automático de las temporadas invierno y estiaje

Invierno

En cuanto a las clasificaciones todas obtuvieron las 4 clases, aunque los algoritmos MSV y RN tuvieron demasiada confusión entre la clase de mangle rojo y mangle blanco. En cuanto a BA tiene una mejor discriminación entre sus clases, pero aún mantiene la confusión en los bordes de las unidades (*figura 31*).


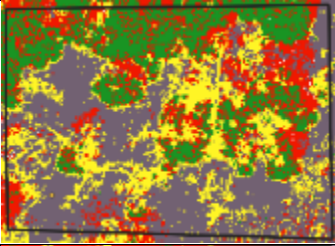
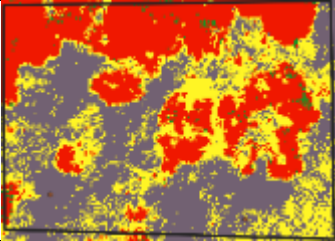
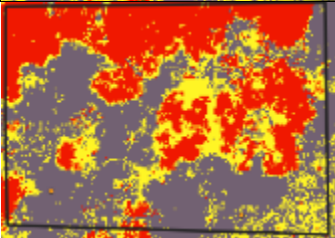

Imagen RGB	Producto	Algoritmo
		BA
		MSV
		RN
		

Figura 31. Comparación de la imagen tomada con VANT y la clasificación con los algoritmos BA, MSV y RN, de la temporada de invierno.

Estiaje

Para la temporada de estiaje también todos los algoritmos obtuvieron las 4 clases, pero en contraste con invierno BA generó una gran dispersión de píxeles llamado efecto de sal y pimienta (Richards & Jia, 2006), mientras que MSV tuvo una gran confusión con la clase de mangle rojo y mangle blanco, así de esta manera RN diferenció mejor la clase de mangle rojo y blanco, pero tuvo confusión con las clases de mangle negro y marisma (figura 32).


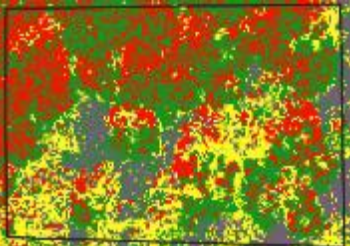
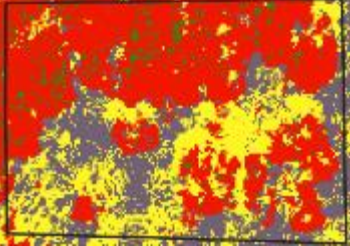
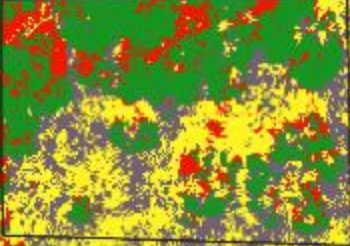

Imagen RGB	Producto	Algoritmo
		BA
		MSV
		RN
		

Figura 32. Comparación de la imagen tomada con VANT y la clasificación con los algoritmos BA, MSV y RN, de la temporada de estiaje.

Exactitud de las tres temporadas

Se utilizó el mismo método de la matriz de confusión para la obtención de la exactitud global, de las temporadas de invierno y estiaje (tabla 5).

Los datos obtenidos muestran que la temporada de lluvias tiene valores más altos de exactitud, seguido la temporada de estiaje y al final la temporada de invierno (figura 33), además el algoritmo que tiene el valor más alto es MSV y el segundo más alto es BA.

Algoritmos	Exactitud Global de cada temporada		
	Invierno	Estiaje	Lluvias
BA	0.57035	0.60644	0.5734
MSV	0.37953	0.41887	0.7041
RN	0.37195	0.55177	0.55015

Tabla 5. Comparación de la exactitud global de los algoritmos de aprendizaje automático en las tres temporadas.

La exactitud más alta fue dada por MSV de lluvias con 0.70, aunque en las demás temporadas bajo de 0.37 en invierno y 0.41 en estiaje, en cuanto RN es baja en invierno con 0.37 y se estabiliza en estiaje y lluvias con 0.55, pero por el contrario BA se mantiene estable de 0.57 invierno, 0.60 en estiaje y 0.57 en lluvias (tabla 5). Por lo anterior el rango en que fluctúan los valores para MSV es de 0.33, para RN es de 0.18 y de BA con 0.03, siendo este último una clasificación que mantiene permanencia en la exactitud en las diferentes temporadas.

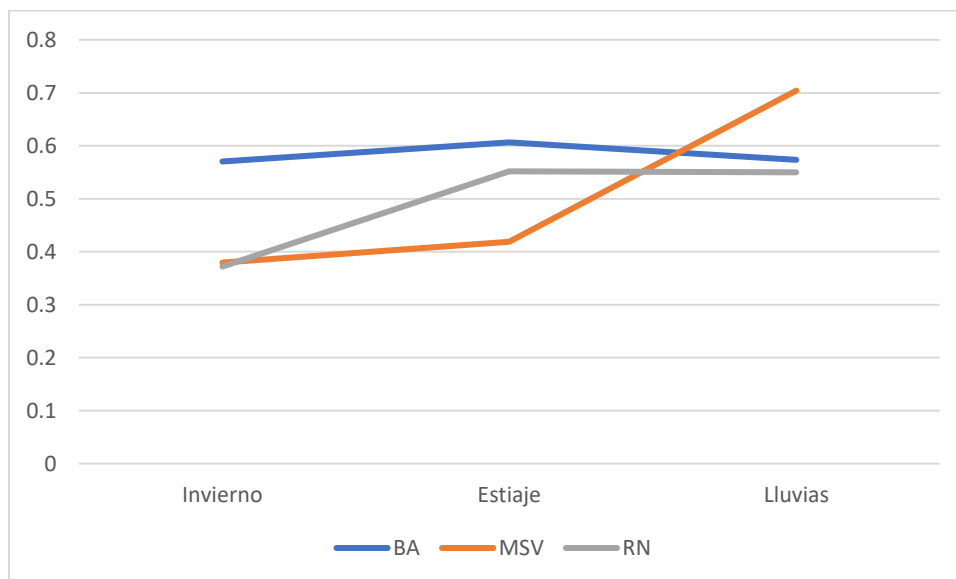


Figura 33. Grafica comparativa de los valores de exactitud de temporada y algoritmo.

Coefficiente Tau

Los datos del coeficiente Tau muestran un valor más alto en MSV de lluvias, seguido por BA con valores en el rango de 0.4, y RN con valores entre 0.1 y 0.4.

	Invierno	Estiaje	Lluvias
RN	0.1851	0.3740	0.4444
MSV	0.1962	0.2444	0.6814
BA	0.4243	0.4837	0.4726

Tabla 6. Valores de Coeficiente Tau, de los tres algoritmos de aprendizaje automático en las tres temporadas.

Los valores del coeficiente Tau (*tabla 6*) se usan para generar el cálculo de la diferencia significativa (*tabla 7*) con un 95% de confianza a 1 grado de libertad, los siguientes datos demuestran la significancia entre dos tipos de clasificación, por ejemplo, en Invierno RN Vs MSV con un valor de .2289, esto nos indica que es un valor no significativo, ya que, según las tablas estadísticas para que sea significativo el valor Z con un .95 de confianza/1gl debe ser mayor a 3.8415.

Invierno			
	RN	MSV	BA
RN	0	0.2289	4.8931*
MSV	0.2289	0	4.6572*
BA	4.8931*	4.6572*	0
Estiaje			
	RN	MSV	BA
RN	0	2.6228	2.2364
MSV	2.6228	0	4.8974*
BA	2.2364	4.8974*	0
Lluvias			
	RN	MSV	BA
RN	0	5.1748*	0.5768
MSV	5.1748*	0	4.5777*
BA	0.5768	4.5777*	0

*Tabla 7. Cálculo de la diferencia significativa entre las clasificaciones de los algoritmos RN, MSV y BA, de las tres temporadas (valores significativos *).*

Prueba de diferencia significativa Tau

La diferencia más significativa fue de 5.17 entre las dos clasificaciones RN y MSV, sin embargo, seguido de este, la clasificación que tuvo más presencia con valores significativos de 4.57 a 4.89 fue la de BA, como se puede observar en la tabla 6, tiende a obtener valores más estables que las demás clasificaciones.

Prueba Kappa

Los resultados de Kappa de los algoritmos en las tres temporadas (*Tabla 8*) arrojaron datos que tienen la misma tendencia que los resultados de la exactitud global, por lo cual, el algoritmo con mayor valor es MSV en lluvias con 0.68 y siguiéndole BA con un valor de 0.46.

Algoritmos	Kappa		
	<i>Invierno</i>	<i>Estiaje</i>	<i>Lluvias</i>
BA	0.42349	0.46466	0.46479
MSV	0.26483	0.30891	0.68148
RN	0.26705	0.37882	0.44802

Tabla 8. Comparación de valores Kappa de los algoritmos BA, MSV y RN de las tres temporadas.

DISCUSIÓN

Es de conocimiento general que la gestión y monitoreo de los recursos naturales costeros es de suma importancia para su conservación y aprovechamiento sustentable. En este sentido, el uso de equipos que nos faciliten el acceso, así como la disminución del tiempo para coleccionar datos de campo es imprescindible (Adade et al., 2021). Como primera fase se realizó una prueba con el ortomosaico procesado durante la temporada de lluvia, ya que se ha reportado previamente por Flores-de-Santiago et al. (2012) que el comportamiento fenológico de manglar semiárido presenta un patrón contrastante en este periodo, asociado a un aumento en el desprendimiento de las hojas y un incremento en el contenido de pigmentos fotosintéticos. Debido a la falta de un conjunto multispectral completo por parte de la cámara utilizada, se generaron los índices de normalización y VARI para ser comparados con la imagen RGB original. A partir de estos índices, se determinó si existía un incremento en el nivel de exactitud de las clasificaciones temáticas. Una

vez analizada la imagen inicial en la época de lluvia, se utilizó el método estandarizado en las temporadas subsecuentes.

El método propuesto en esta tesis se basa en la adquisición de datos espaciales y en la clasificación de dosel de bosque de manglar con estas imágenes de ultra alta resolución espacial, pero con una resolución espectral baja. El método facilita la toma de datos para trabajos de monitoreo de bosque de manglar en zonas donde el acceso a imágenes provenientes de otras plataformas (satélites, aeronaves tripuladas) es limitado o de difícil acceso (e.g., costo, temporalidad). Entre las aplicaciones adicionales se incluye el mapeo de especies de mangle a nivel local (sistemas lagunares-estuarinos independientes) o ampliar el pool de datos para compararlos con patrones fenológicos multiespectrales a partir de plataformas satelitales. Pueden ser utilizados como una fuente de validación de campo, además su ultra alta resolución espacial (cm/pixel) nos permite identificar árboles individuales bajo ciertas condiciones y así se puede tener un primer indicio para conocer la pérdida o ganancia a nivel de especie.

El uso de datos por medio de plataformas digitales emergentes o VANT nos permite tener el control de la temporalidad para la obtención de imágenes. Por ejemplo, los VANT nos permiten obtener secuencias de imágenes equidistantes en diferentes horas del día lo cual es muy importante en sistemas costeros donde la marea juega un papel importante (Flores-de-Santiago et al., 2020) o donde se presenten condiciones de nubosidad variables tales como neblina, ráfagas de lluvia y nubosidad ocasional (Tian et al, 2017).

El tamaño de píxel de las imágenes se puede modificar dependiendo de la resolución de cámara y de la altura a la cual decidamos volar el VANT (Flores-de-Santiago et al., 2020). Si bien, datos como los de las misiones Landsat, MODIS y Sentinel son gratuitos, la resolución espacial de estos productos satelitales es muy gruesa (decenas de m/pixel) para trabajos a nivel local o a escalas muy grandes y no se puede comparar con la ultra alta resolución espacial que proveen los VANT.

Una alternativa pudiera ser los datos provenientes de WorldView, los cuales ofrecen datos multiespectrales a una resolución espacial de hasta 1.8 m/pixel, pero a un costo muy elevado por escena (Tian et al., 2017; Valderrama-Landeros et al., 2018).

Derivado de lo anterior, podemos contrastar el costo inicial de un Sistema de Aeronave no tripulada (UAS) básico, el cual puede oscilar en los \$70,000 MEX si se considera el VANT, 2 baterías y el dispositivo/programa para la navegación automática. Posterior a la inversión inicial, el costo de operación del VANT es mucho menor comparado con la compra periódica de imágenes de satélite multiespectrales de alta resolución espacial. Por ejemplo, WorldView-3 tiene costos que oscila entre los 14 a 29 dólares americanos (~280 a 581 MEX) por kilómetro cuadrado (<http://landinfo.com/satellite-imagery-pricing/>). Otros gestores de venta de imágenes satelitales pueden tener costos más bajos de hasta 10 dólares por kilómetro cuadrado dependiendo de la misión (<https://www.skywatch.com/>). Sin embargo, el área mínima de adquisición para algunos sensores es de 25 a 100 km². Además, cabe señalar que los costos también dependen de la disponibilidad histórica de las imágenes y algunos productos no garantizan que estén exentos de nubosidad. No obstante, cabe señalar que para poder decidir la mejor opción como insumo de VANT o Imágenes satelitales, dependerá del objetivo de trabajo al que se quiera llegar, ya que, si el objetivo es un estudio a escalas grandes y de mejor precisión, el uso de VANT sería la mejor opción y al contrario si son grandes extensiones como trabajos a nivel regional o una resolución temporal por décadas, el uso de los VANT podría no ser el indicado.

Los resultados de la clasificación revelaron que las exactitudes en las tres temporadas arrojan valores que van de 37.19 a 70.41%. Esto es principalmente debido al efecto de sal y pimienta (efecto de dispersión de los píxeles), que se genera por la gran resolución espacial de los ortomosaicos (Cingolani, 2004; Congalton, 1991; Tadeo, 2015). Otro de los factores que probablemente pudieron limitar las exactitudes cuantificadas consiste en la diversidad de coloración por las

características del dosel de algunas especies y/o por la generación de sombras. Por otra parte, la exactitud en los datos de entrenamiento es de vital importancia para obtener resultados significativos (Tadeo, 2015). En cuanto a la separación de las especies, se tuvo una dificultad *entre Rhizophora mangle* y *Laguncularia racemosa*, ya que los valores de los píxeles presentaban intervalos similares en los histogramas. Esta situación particular entre las dos especies no se encontró por Valderrama-Landeros et al. (2018), quienes pudieron separar dichas especies, pero con datos multiespectrales de la misión Sentinel-2. Lo cual pudiera ser factible el uso de cámaras multiespectrales en VANT para poder discriminar estas dos especies de mangle.

Se definieron cuatro clases de cobertura para la zona de estudio, Mangle Rojo, Mangle Negro, Mangle Blanco y Marisma. A partir de los resultados, las clases Mangle Rojo y Mangle Blanco fueron similares por lo que hubo una mayor confusión en el proceso de clasificación, lo anterior puede deberse a la limitante de esta tesis, ya que no se trabajaron con datos multiespectrales sino con la coloración de imágenes RGB del dosel de la vegetación, en este sentido, algunas investigaciones con satélites o con cámaras de drones multiespectrales como Li et al. (2019) y Cao et al. (2019) sí pudieron obtener una separación de clases ideal, sin embargo, actualmente existe una línea de investigación relacionada al uso de cámaras convencionales de VANT con el objetivo de analizar la factibilidad en separar clases de vegetación a nivel de especie únicamente por medio de los contrastes en la coloración del dosel e índices de vegetación visibles (e.g., VARI).

Derivado de lo anterior una de las limitantes de este trabajo es que al ser una imagen RGB de un sensor CMOS (*Semiconductor Complementario De Óxido Metálico*) que solo obtiene información en el intervalo visible del espectro electromagnético y además no tiene el 100% de toda la información reflejada, por lo tanto, los valores que tienen los píxeles están limitados a una cierta cantidad de luz obtenida de una matriz de Bayer. Por lo anterior la separación de la luz verde en RGB no es tan exacta como en las cámaras multiespectrales. Tampoco se cuenta con datos en la

región del infrarrojo cercano, que juega un papel muy importante para poder discriminar el tipo de vegetación, esto limita la capacidad de una imagen RGB para discriminar de forma más eficiente las diferentes tonalidades de cada una de las especies.

Congalton (1991), Mas et al. (2003) y Cingolani (2004) mencionan que al disminuir la cantidad de clases utilizadas aumenta la exactitud. En este estudio la baja exactitud se debe a la naturaleza de las imágenes, ya que sólo 3 bandas RGB brindan poca separabilidad de las frecuencias de los histogramas de algunas especies como el Mangle Rojo y Mangle Blanco.

Los índices de vegetación de banda visible (IVBV) son de gran importancia para discriminar y/o identificar de una manera más eficiente la vegetación en una imagen visible RGB (Costa et al., 2020; Xue & Su, 2017). La ventaja de estos índices consiste en normalizar los valores de los píxeles para hacer más notoria la reflectancia de la vegetación, de esta manera Li et al. (2019) menciona que los IVBV son una opción ideal para bosques de manglar homogéneo debido al contraste en la coloración del dosel entre las especies. Sin embargo, para el caso específico de esta tesis, no potencializó la exactitud en la clasificación de los algoritmos de aprendizaje automático. Esta situación podría deberse a que la fenología de las especies de mangle genera una reflectancia similar con la cámara utilizada, y aunque el bosque de manglar en el sitio de estudio tiene una zonación muy clara, donde existen especies separadas unas de otras, los IVBV no son tan eficaces ya que se genera confusión en los resultados.

El índice VARI fue uno de los IVBV que se intentó analizar en esta tesis con algoritmos de aprendizaje automático, pero no se logró concretar el proceso debido a que uno de los requisitos para usar los algoritmos consiste en proveer al menos tres conjuntos de datos (bandas) y desafortunadamente los datos provenientes del proceso de VARI son univariados. En este sentido, recientemente Zhang et al. (2019) reportó una situación similar al realizar un estudio de agricultura de precisión

con un VANT con cámara visible RGB en campos de diferentes pastizales para forraje.

Sin embargo, los datos que arrojo el índice VARI nos ayudaron a visualizar los cambios estacionales que tienen las especies y las diferencias entre ellas, ya que los cambios en el VARI de cada especie se distribuyeron en forma diferenciada, como se puede observar con las clases de mangle rojo y mangle blanco, las cuales muestran patrones similares, formando una curva en “U” con el valor más bajo en invierno, sin embargo no hay tanta diferencia en los intervalos de valores de cada clase como para poder ser discriminados nítidamente (*Figura 17*). En cambio, el mangle negro muestra una diferencia respecto a las otras dos especies en la temporada de lluvias, ya que la curva de VARI forma una especie de “J”, en contraste con las demás clases que generan una curva en forma de “U”, esto puede deberse a que existen diferencias en el patrón fenológico a nivel del dosel de mangle de algunas especies en la época de lluvias (Bénitez-Pardo et al., 2018).

Por otra parte, en cuanto a la exactitud de un mapa derivado del índice VARI en temporada de lluvias, tal vez se podría aumentar si se juntaran las clases de mangle rojo y mangle blanco, ya que el valor más alto de las clases es el de mangle blanco con 72 casos exactos y el mangle negro con 19 (*Tabla 2*). Además, la suma de estos valores tendería a aumentar, ya que la mayoría de los errores de omisión y de comisión se encuentran dentro de estas mismas clases.

Los cambios fenológicos en la composición del dosel de mangle entre los 3 ortomosaicos tienen una clara diferencia en la coloración, pero esta tiende a ser negativa en el índice de VARI que fue estimado en la zona de estudio además de tener diferencias de reflectancia por la caída de hojarasca, generalmente al final de la estación de secas y temporada de lluvias (Pastor-Guzman et al., 2018). Los resultados de esta tesis indican que la temporada de lluvias es donde hay una mejor exactitud, esto se coincide con Valderrama-Landeros (2021) y Pastor-Guzman et al.

(2018), donde mencionan que la mejor discriminación de especies se da después de la temporada de secas y en la temporada de lluvias.

En esta tesis se observa al igual que Chave et al., (2010), Songsom (2019) y Zhang et al., (2016) que la temporada de lluvias es la que presenta mejores resultados al momento de discriminar especies de mangle, esto puede ser debido al cambio fenológico del mangle que genera una diferencia en la coloración del dosel, ya que también Songsom (2019) menciona en su trabajo una relación inversa en cuanto a la disminución de la producción de hojas debido al estrés por altas temperaturas de otras temporadas.

El algoritmo que tuvo una mayor exactitud fue el MSV en la temporada de lluvias, esto se puede deber a que el algoritmo funciona mejor cuando hay un cambio fenológico en el dosel de mangle como es el caso de *L. racemosa* que presenta una disminución de pigmentos fotosintéticos durante la época de lluvias (Bénitez-Pardo et al., 2018) ya que en las otras dos temporadas obtuvo una exactitud más baja que los otros algoritmos (BA y RN), por lo que este algoritmo (MSV) serviría de una manera más eficiente sólo en temporadas donde exista un cambio fenológico. Y por otra parte el segundo algoritmo que tuvo mejor exactitud fue BA, en donde se mantuvo estable y por lo tanto se podría usar de manera indiscriminada en cualquier época del año.

Con respecto al valor más alto en la exactitud global, es la clasificación de MSV en la temporada de lluvias (70.41%), pero este no mantiene una estabilidad en las demás temporadas (37.95% invierno y 41.88% estiaje). Por el contrario, la clasificación obtenida por BA mantiene una estabilidad en todas las temporadas (57.03% Invierno, 60.64% Estiaje, 57.34% Lluvias), y por último la clasificación de RN la cual obtuvo los valores más bajos (37.19% invierno, 55.17% estiaje, 55.01% Lluvias).

El método empleado en esta tesis se puede utilizar en cualquier otro bosque de manglar, pero se debe de considerar la homogeneidad o heterogeneidad de las especies. Además, se sugiere tomar en cuenta los sitios y las épocas en donde los manglares se encuentran sumergidos por un tiempo mayor debido al incremento en la amplitud de la marea (e.g., verano en el Pacífico mexicano). Por otra parte, también se debe poner atención a la vegetación terrestre adyacente o de frontera, ya que puede generar confusión con las especies de mangle cercanas a la zona terrestre especialmente en la temporada de lluvia (Valderrama-Landeros et al. 2021). Por el contrario, en zonas áridas generalmente existe una zona sin vegetación amplia conocida como marisma hipersalina entre el bosque de manglar y la vegetación terrestre, por lo que generalmente es muy difícil que se presente una malinterpretación entre la zona de selva baja caducifolia y el bosque de mangle negro (Flores-Verdugo et al., 2015).

Debido a que el método empleado se basa en sitios de entrenamiento para poder clasificar los ortomosaicos, es imprescindible conocer previamente la zona de estudio para así poder localizar y seleccionar las clases temáticas a evaluar. Por ejemplo, es poco probable encontrar arbustos de mangle blanco en zonas más áridas del norte de Sinaloa y Sonora. Por el contrario, el mangle negro tiende a ser enano (<1 m altura) en zonas áridas, pero se desarrolla mucho mejor en zonas tropicales lluviosas e incluso puede llegar a alcanzar alturas similares al mangle blanco y rojo.

Un factor adicional por considerar consiste en las temporadas del año de otros sitios. Como ya se mencionó anteriormente, esta tesis se desarrolla en una zona semiárida del Pacífico mexicano con una extensa temporada de estiaje y muy corta temporada de lluvia. Sin embargo, algunas investigaciones mencionan que existen cuatro estaciones del año en la costa central del pacífico mexicano (García-Oliva, 2002), pero también existen regiones donde se presentan patrones temporales muy marcados como es el caso de la Península de Yucatán donde se encuentran épocas

de frentes fríos o en zonas donde la temporada de lluvias es muy amplia y prácticamente no se percibe la época de estiaje.

CONCLUSIÓN

Obtener las diferencias significativas ($\alpha=0.05$) por medio del cálculo del coeficiente Tau de las clasificaciones de algoritmos de aprendizaje automático, permitió determinar que el algoritmo MSV fue el valor más alto y el ideal para la temporada de lluvias. Por lo tanto, se sugiere el uso de MSV para clasificar especies de manglar en esta zona semiárida, si solamente se pueden obtener ortomosaicos con cámaras visibles RGB.

En el caso de esta investigación, el procesamiento con IVBV no optimizó la clasificación de los algoritmos de aprendizaje automático con datos RGB de VANT. Sin embargo, los resultados del análisis de caja del índice VARI nos permiten visualizar y cuantificar que existe una discriminación aceptable de al menos tres grupos para la zona de estudio; mangle rojo & mangle blanco; mangle negro; marisma, así como una exactitud que se encuentra a la par de los algoritmos de Bosques Aleatorios y Redes Neuronales.

En cuanto a la clasificación con algoritmos de aprendizaje automático por temporalidad, se demostró que los datos tomados en época de lluvia proporcionan mayores exactitudes globales con el algoritmo MSV (70.41% y Kappa 0.68). Por otra parte, el algoritmo BA obtuvo resultados más bajos a lo largo de las tres temporadas (Kappa 0.42 a 0.46 y exactitudes de 42.43% a 48.37%). En cuanto a RN su exactitud en la temporada de invierno fue una de las más bajas (37.19%), sin embargo, la exactitud se estabilizó obteniendo el mismo valor para las otras temporadas (55%, Kappa; estiaje 0.37, lluvias 0.44).

De acuerdo con los resultados obtenidos, y haciendo referencia a la hipótesis formulada en esta tesis, *“Se espera obtener una exactitud mayor en la clasificación del dosel de bosque de manglar en la temporada donde el hidropериodo y la salinidad*

sean óptimos para el desarrollo de las especies”, fue valida. Y por el contrario la segunda hipótesis indica que “El uso de índices de vegetación de banda visible como pre-procesamiento coadyuva a la optimización del uso de algoritmos de aprendizaje automático para la clasificación a nivel de especie”, fue rechazada, toda vez que las exactitudes generales de los productos de IVBV fueron menores con respecto a la imagen RGB sin modificación.

Finalmente, se sugiere realizar estudios adicionales en otras áreas semiáridas tomando en cuenta otros factores como especies acompañantes y el efecto de borde con otras unidades vegetales, para corroborar los resultados. Adicionalmente, se sugiere el uso de técnicas de clasificación por objetos, al igual que datos adicionales provenientes de modelos digitales de superficie y modelos digitales de terreno, para así tener información adicional que nos permita analizar la posibilidad de incrementar la exactitud global.

BIBLIOGRAFÍA

Adade, R., Ekumah, B. Aibinu, A.M.. 2021. Unmanned Aerial Vehicle (UAV) applications in coastal zone management—a review. *Environ Monit Assess* 193, 154. <https://doi.org/10.1007/s10661-021-08949-8>

Agisoft. 2021. Agisoft: Features. Consultado el 02/09/2021 en la página: <https://www.agisoft.com/features/professional-edition/>.

Agraz-Hernández, Claudia M. 1999. Reforestación experimental de manglares en ecosistemas lagunares estuarinos de la costa noroccidental de México. Universidad Autónoma de Nuevo León. 37-40pp.

- Agraz-Hernández, C., R. Noriega-Trejo, J. López-Portillo, F. Flores-Verdugo y J. Jiménez-Zacarías. 2006. Guía de campo. Identificación de los Manglares en México. Universidad Autónoma de Campeche. 45 pp.
- Akar, Özlem. 2017. Mapping land use with using Rotation Forest algorithm from UAV images. *European Journal Of Remote Sensing*, Vol. 50, No. 1, 269–279 <https://doi.org/10.1080/22797254.2017.1319252>.
- Brizuela-Amador Pérez, Basilio; Alcántar-González, Gabriel; Sánchez-García, Prometeo; Pea-kalra, Yash; Crumbaugh, Joe; Olive, Curtis; Tijerina-Chávez, Leonardo; Maldonado-Torres, Ranferi. 2007. Establecimiento De Índices Espectrales En El Diagnóstico Nutricional De Nitrógeno En Maíz. *Agrociencia*, vol. 41, núm. 8, pp. 827-835 Colegio de Postgraduados Texcoco, México
- Cao J, Leng W, Liu K, Liu L, He Z, Zhu Y. 2019. Object-Based Mangrove Species Classification Using Unmanned Aerial Vehicle Hyperspectral Images and Digital Surface Models. *Remote Sensing*. 10(1):89. <https://doi.org/10.3390/rs10010089>
- Carrasquilla, M. 2011. Análisis de la cobertura del bosque de manglar y su correlación con la pesca ribereña entre 1993 y 2009 en el sistema lagunar San Ignacio-Navachiste-Macapule, Sinaloa, México. IPN.
- Castellon, Juan. 2015. Análisis comparativo entre ENVI y Orfeo Toolbox SVM. 10.13140/RG.2.1.1991.1844.
- Catalán. S.M., Ávila. M.A., Quezada. M.L. 2017. Determinación de la degradación forestal en el ecosistema de manglar pacífico a través de sensores remotos y el uso de vehículos aéreos no tripulados. Universidad de San Carlos de Guatemala. 6-12.

- Chave, J.; Navarrete, D.; Almeida, S.; Álvarez, E.; Aragão, L.E.O.C.; Bonal, D.; Châtelet, P.; Silva-Espejo, J.E.; Goret, J.Y.; Von Hildebrand, P.; Jiménez, E.; Patiño, S.; Peñuela, M.C.; Phillips, O.L.; Stevenson, P.; Malhi, Y. 2010. Regional and seasonal patterns of litterfall in tropical South America. *Biogeosciences*, 7, 43–55.
- Cingolani, A. 2004. Mapping Vegetation In A Heterogeneous Mountain Rangeland Using Landsat Data: An Alternative Method To Define And Classify Land-Cover Units. *Remote Sensing Of Environment*, 92(1), 84–97.
- Congalton, R. G. 1991. A Review Of Assessing The Accuracy Of Classifications Of Remotely Sensed Data. *Remote Sensing*, 37, 35–49.
- Costa. L., Nunes. L., Ampatzidis. Y. 2020. A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. *Computers and Electronics in Agriculture*. Volume 172. 105334. ISSN 0168-1699.
- De Jesús, Juan. 2016. Técnicas de muestreo para mejorar el rendimiento del algoritmo back-propagation en problemas de desbalance de clases: Un estudio empírico sobre la clasificación en imágenes de percepción remota.
- De la Lanza, E., Ortiz Pérez G., Arturo, M. & Carbajal Pérez, J. L. 2013. Diferenciación hidrogeomorfológica de los ambientes costeros del Pacífico, del Golfo de México y del Mar Caribe. *Investigaciones geográficas*, (81), 33-50.
- DJI. 2021. Phantom 4 Advanced, SZ DJI Technology Co., Ltd: Consultado el 02/09/2021 en la página: <https://www.dji.com/phantom-4-adv>.

- Encinas, Marco. E. 2005. Esquema de segmentación de imágenes de percepción remota: aproximación contextual y de regularización. UNAM. Posgrado Ingeniería. 1-5 pp.
- Flores-de-Santiago F., Kovacs J.M., Flores-Verdugo F. 2012. Seasonal changes in leaf chlorophyll a content and morphology in a sub-tropical mangrove forest of the Mexican Pacific. *Marine Ecology Progress Series* 444, 57-68.
- Flores-de-Santiago, F., Kovacs, J.M. y Flores-Verdugo, F. 2018. Discrimination of 3 dominant mangrove species from the Pacific coast of Mexico by spectroscopy on intact leaves. *Ciencias Marinas*. 44(3): 185-202.
- Flores-de-Santiago, Francisco & Valderrama, Luis & Flores-Verdugo, Francisco & Rodriguez-Sobreyra, Ranulfo. 2020. Assessing the effect of flight altitude and overlap on orthoimage generation for UAV estimates of coastal wetlands. *Journal of Coastal Conservation*. 24. 35. 10.1007/s11852-020-00753-9.
- Flores-Verdugo, Francisco, & Moreno Casasola, Patricia, & Agraz Hernández, Claudia Maricusa, & López Rosas, Hugo, & Benítez Pardo, Daniel, & Travieso Bello, Ana Cecilia. 2007. La topografía y el hidroperíodo: dos factores que condicionan la restauración de los humedales costeros. *Boletín de la Sociedad Botánica de México*, Sup(80),33-47.
- Flores-Verdugo F., Zebadua-Penagos F., Flores-de-Santiago F. 2015. Assessing the influence of artificially constructed channels in the growth of afforested black mangrove (*Avicennia germinans*) within an arid coastal región. *Continental Shelf research*. 160, 113-120.

Flores-Verdugo F., Ramírez-Barrón E., Flores-de-Santiago F. 2018. Hydroperiod enhancement using underground pipes for the efficient removal of hypersaline conditions in a semiarid coastal lagoon. *Continental Shelf research* 162, 39-47.

Gandhi R. 2018. Support Vector Machine: Introduction to Machine Learning Algorithms. Towards Data Science. Recuperado de : <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>.

García-Oliva, Felipe & Camou, A. & Maass, Manuel. 2002. El clima de la región central de la costa del Pacífico mexicano. *Historia Natural de Chamela*. 3-10.

Gilabert, M.A. & Gonzalez-Piqueras, Jose & García-Haro, Javier. 1997. Acerca de los índices de vegetación. *Revista de teledetección: Revista de la Asociación Española de Teledetección*, ISSN 1133-0953, N°. 8, 1997. 8.

Google Earth. 2020. Mapa Satelital. Recuperado el 09 de septiembre de 2020.

Guo, Q., Yanjun Su, Tianyu Hu, Xiaoqian Zhao, Fangfang Wu, Yumei Li, Jin Liu, Linhai Chen, Guangcai Xu, Guanghui Lin, Yi Zheng, Yiqiong Lin, Xiangcheng Mi, Lin Fei & Xugao Wang. 2017. An integrated UAV-borne lidar system for 3D habitat mapping in three forest ecosystems across China, *International Journal of Remote Sensing*, 38:8-10, 2954-2972, DOI: 10.1080/01431161.2017.1285083

Gupta, Sandeep. 2018. Active and Passive Remote Sensing. ResearchGate. https://www.researchgate.net/publication/325382226_Active_and_Passive_Remote_Sensing

Hsu A.J., Kumagai J, Favoretto F, Dorian J, Guerrero Martinez B, Aburto-Oropeza O. 2020. Driven by Drones: Improving Mangrove Extent Maps Using High-

Resolution Remote Sensing. Remote Sensing. 12(23):3986.
<https://doi.org/10.3390/rs12233986>

Immitzer, M.; Atzberger, C.; Koukal, T. 2012. Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data. *Remote Sens.* , 4, 2661-2693.

Instituto Nacional de Estadística y Geografía (México). 2017. Anuario estadístico y geográfico de Sinaloa / Instituto Nacional de Estadística y Geografía.-- México : INEGI, c2017.

Krause, G., Bock, Michael & Weiers, Stefan & Braun, Gerald. 2004. Mapping Land-Cover and Mangrove Structures with Remote Sensing Techniques: A Contribution to a Synoptic GIS in Support of Coastal Management in North Brazil. *Environmental management.* 34. 429-40. 10.1007/s00267-004-0003-3.

Kuenzer, C., Bluemel, A., Gebhardt, S., Quoc, T. V., & Dech, S. 2011. Remote sensing of mangrove ecosystems: a review. *Remote Sensing*, 3(12), 878–928.

Li Z, Zan Q, Yang Q, Zhu D, Chen Y, Yu S. 2019. Remote Estimation of Mangrove Aboveground Carbon Stock at the Species Level Using a Low-Cost Unmanned Aerial Vehicle System. *Remote Sensing.* 11(9):1018

López-Enríquez. J.C., Rosas-Alquicira. E.F., Ramirez. E.J., Cruz. A. 2013. Datos preliminares de la estructura y la formación de las comunidades de manglar en Zipolite, Oaxaca. Condiciones geográficas propicias para el cultivo del café. *Ciencia y Mar* 2013, XX (52): 37-35.

- Lozano-Rivera. P. 2007. Técnicas de percepción remota y sistemas de información geográfica para la delimitación de bosques de manglar. INVEMAR. Colombia. 27-28.
- Lugo, A.E., Medina, E. y McGinley, K. 2014. Issues and Challenges of Mangrove conservation in the Anthropocene. *Madera y Bosques. Especial (20)*: 13-14.
- Ma, Z. y R. L Redmond. 1995. Tau coefficients for accuracy assessment of classification of remote sensing data. *Photogrammetric Engineering and Remote Sensing*, 61:435-439.
- Maps made aesy. 2021. Map Pilot Pro; Superior Data Collection for Professionals. Consultado el 02/09/2021 en la página: https://www.mapsmadeeasy.com/map_pilot/.
- Mas, J. F., Díaz-Gallegos, J. R. & Pérez-Vega, A. 2003. Evaluación De La Confiabilidad Temática De Mapas O De Imágenes Clasificadas: Una Revisión. *Investigaciones Geográficas. Boletín Del Instituto De Geografía De La UNAM*, (51), 53–72.
- Mas, J. F. and Flores, J. J. 2008. 'The application of artificial neural networks to the analysis of remotely sensed data', *International Journal of Remote Sensing*, 29:3, 617 – 663
- Matich, D.J. 2001. *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Grupo de Investigación Aplicada a la Ingeniería Química (GIAIQ). 10-15.
- Mather, P.M. 2004. *Computer Processing Of Remotely Sensed Images: An Introduction (3rd Ed.)*. Chichester: Wiley. ISBN 0-470-84918-5.

- McKinnon, Tom & Hoff P. 2017. Comparing RGB-Based Vegetation Indices With NDVI For Drone Based Agricultural Sensing. AGBX021-17.
- Moreno-Casasola P., y D.M. Infante M. 2009. Manglares y selvas inundables. Instituto de Ecología A.C. CONAFOR y OIMT Xalapa. Ver. México. 150pp.
- Muñoz, Pedro. 2013. Apuntes de Teledetección: Índices de vegetación. Centro de Información de Recursos Naturales. Chile.
- Muro-Torres VM, Amezcua F, Soto-Jiménez M, Balart EF, Serviere-Zaragoza E, Green L, Rajnohova J. 2020. Primary Sources and Food Web Structure of a Tropical Wetland with High Density of Mangrove Forest. *Water*; 12(11):3105. <https://doi.org/10.3390/w12113105>
- NOM-059-SEMARNAT-2010. 2010. Norma Oficial Mexicana NOM-059-SEMARNAT-2010. Protección ambiental-Especies nativas de México de flora y fauna silvestres-Categorías de riesgo y especificaciones para su inclusión, exclusión o cambio-Lista de especies en riesgo.
- Ochoa-Izaguirre, María Julia, & Soto-Jiménez, Martín Federico (2013). Evaluation of nitrogen sources in the Urías lagoon system, Gulf of California, based on stable isotopes in macroalgae. *Ciencias Marinas*, 39(4),413-430.[fecha de Consulta 17 de Septiembre de 2021]. ISSN: 0185-3880. Disponible en: <https://www.redalyc.org/articulo.oa?id=48029963007>
- Ojeda-Bustamante, W., González-Sánchez, A., Mauricio-Pérez, A., & Flores-Velázquez, J. 2017. Applications of unmanned aerial vehicles in hydroagricultural engineering. *Water Technology and Sciences*, 8(4), 157-166.

- Otero, V., Van De Kerchove, R., Behara Satyanarayana, Columba Martínez-Espinosa, Muhammad Amir Bin Fisol, Mohd Rodila Bin Ibrahim, Ibrahim Sulong, Husain Mohd-Lokman, Richard Lucas, Farid Dahdouh-Guebas. 2018. Managing mangrove forests from the sky: Forest inventory using field data and Unmanned Aerial Vehicle (UAV) imagery in the Matang Mangrove Forest Reserve, peninsular Malaysia. *Forest Ecology and Management*. 411. 35-45. ISSN 0378-1127. <https://doi.org/10.1016/j.foreco.2017.12.049>.
- Pastor-Guzman, J. Atkinson, PM. Dash, J. y Rioja-Nieto, R. 2015. Spatiotemporal Variation in Mangrove Chlorophyll Concentration Using Landsat 8. *Remote sensing* 7:14530-14558.
- Pastor-Guzman, Julio & Dash, Jadunandan & Atkinson, Peter. 2018. Remote sensing of mangrove forest phenology and its environmental drivers. *Remote Sensing of Environment*. 205. 10.1016/j.rse.2017.11.009.
- PMDU-MS. 2010. Programa Municipal de Desarrollo Urbano de Mazatlán, Sinaloa. SEDATU, SEDESOL, Gobierno del Estado de Sinaloa.
- Richards, J.A. and Jia, X. 2006. *Remote Sensing Digital Image Analysis: An Introduction*. Springer, Berlin, 207.
- Rioja-Nieto R., J. A. Moreno-Ruíz y J. Gómez-Valdés. 2015. Efecto del manejo de un Área Natural Protegida en el paisaje del bosque de manglar en la Península de Yucatán. *Hidrobiológica* 25 (2): 203-211.
- Rioja-Nieto, Rodolfo & Barrera-Falcón, Eric & Torres-Irineo, Edgar & Mendoza-González, Gabriela & Cuervo-Robayo, Angela. 2017. Environmental drivers of decadal change of a mangrove forest in the North coast of the Yucatan peninsula, Mexico. *Journal of Coastal Conservation*. 21. 10.1007/s11852-016-0486-0.

- Ritchie, L. G. 2003. Use of Ground- Based Canopy Reflectance to Determine Ground Cover, Nitrogen and water Status and Final Yield in Wheat. Utah State University Press. pp: 31-71.
- Rodriguez-Galiano, Victor & Sánchez Castillo, Manuel & Dash, Jadunandan & Atkinson, Peter & Ojeda-Zujar, Jose. 2016. Modelling interannual variation in the spring and autumn land surface phenology of the European forest. *Biogeosciences*. 13. 3305-3317. 10.5194/bg-13-3305-2016.
- SECTUR. 2018. Programa Marco para Fomentar Acciones para Restablecer el Balance del Ciclo del Agua en Mazatlán. Secretaria de Turismo. Secretaría de Turismo Dirección General de Ordenamiento Turístico Sustentable. <https://www.gob.mx/sectur/acciones-y-programas/ordenamiento-turistico-sustentable>
- Singh, K.K., & Frazier, A.E., 2018. A meta-analysis and review of unmanned aircraft system (UAS) imagery for terrestrial applications, *International Journal of Remote Sensing*, 39:15-16, 5078-5098, DOI: 10.1080/01431161.2017.1420941
- Songsom, V; Koedsin, W; Ritchie, RJ; Huete, A. 2019. Mangrove Phenology and Environmental Drivers Derived from Remote Sensing in Southern Thailand. *REMOTE SENSING*, 11(8), 955.
- Tadeo, M. 2015. Heterogeneidad del paisaje y percepción remota. Evaluación de métodos para clasificar la cobertura vegetal en el occidente de México. Centro Universitario de la Costa Sur. Trabajo de Grado. 110: 71-73.
- Tian, J., Le Wang, Xiaojuan Li, Huili Gong, Chen Shi, Ruofei Zhong, Xiaomeng Liu. 2017. Comparison of UAV and WorldView-2 imagery for mapping leaf area index of mangrove forest. *International Journal of Applied Earth Observation*

and Geoinformation. 61.22-31. ISSN 0303-2434.
<https://doi.org/10.1016/j.jag.2017.05.002>.

Tu, Renjin. 2016. Gráfico de caja y bigotes . Enciclopedia Británica. Consultado el 02/09/2021 en la pagina. <https://www.britannica.com/science/box-and-whisker-plot>

Üstüner, Mustafa & Balik Sanli, Fusun & Dixon, Barnali. 2015. Application of Support Vector Machines for Landuse Classification Using High-Resolution RapidEye Images: A Sensitivity Analysis. *European Journal of Remote Sensing*. 48. 403 - 422. 10.5721/EuJRS20154823.

Valderrama-Landeros L., Flores-de-Santiago F., Kovacs J.M., Flores-Verdugo F. 2018. An assessment of commonly employed satellite-based remote sensors for mapping mangrove species in Mexico using an NDVI-based classification scheme. *Environmental, Monitoring and Assessment* 190, 23.

Valderrama-Landeros L., Flores-Verdugo F., Rodríguez-Sobreyra R., Kovacs J.M., Flores-de-Santiago F. 2021. Extrapolating canopy phenology information using Sentinel-2 data and the Google Earth Engine platform to identify the optimal dates for remotely sensed image acquisition of semiarid mangroves. *Journal of Environmental Management*. ISSN 0301-4797

Valderrama-Landeros L. H., Rodríguez-Zúñiga, M. T., Troche-Souza, C., Velázquez-Salazar, S., Villeda-Chávez, E., Alcántara-Maya, J. A., ... Ressler, R. 2017. Manglares de México: actualización y exploración de los datos del sistema de monitoreo 1970/80-2015. Ciudad de México, México: Comisión Nacional Para el Conocimiento y Uso de la Biodiversidad.

Wang, L., Jia, M., Yin, D. y Tian, J. 2019. A review of remote sensing for mangrove forests: 1956–2018. *Continental Shelf research*. 231, 111223.

Wang, D. Bo Wan, Jing Liu, Yanjun Su, Qinghua Guo, Penghua Qiu, Xincan Wu. 2020. Estimating aboveground biomass of the mangrove forests on northeast Hainan Island in China using an upscaling method from field plots, UAV-LiDAR data and Sentinel-2 imagery. *International Journal of Applied Earth Observation and Geoinformation*. 85. 101986. ISSN 0303-2434. <https://doi.org/10.1016/j.jag.2019.101986>.

Xue. J., Su. B. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*. vol. 2017. Article ID 1353691. 17 pages, 2017. <https://doi.org/10.1155/2017/1353691>

Yu Xiang, Qing Liu, Xin Liu, Xiangyang Liu & Yebao Wang. 2017. A physical-based atmospheric correction algorithm of unmanned aerial vehicles images and its utility analysis, *International Journal of Remote Sensing*, 38:8-10, 3101-3112, DOI: 10.1080/01431161.2016.1230291

Zhang, Keqi & Thapa, Bina & Ross, Mike & Gann, Daniel. 2016. Remote sensing of seasonal changes and disturbances in mangrove forest: A case study from South Florida. *Ecosphere*. 7. e01366. 10.1002/ecs2.1366.

Zhang J, Virk S, Porter W, Kenworthy K, Sullivan D and Schwartz B. 2019. Applications of Unmanned Aerial Vehicle Based Imagery in Turfgrass Field Trials. *Front. Plant Sci*. 10:279. doi: 10.3389/fpls.2019.00279.

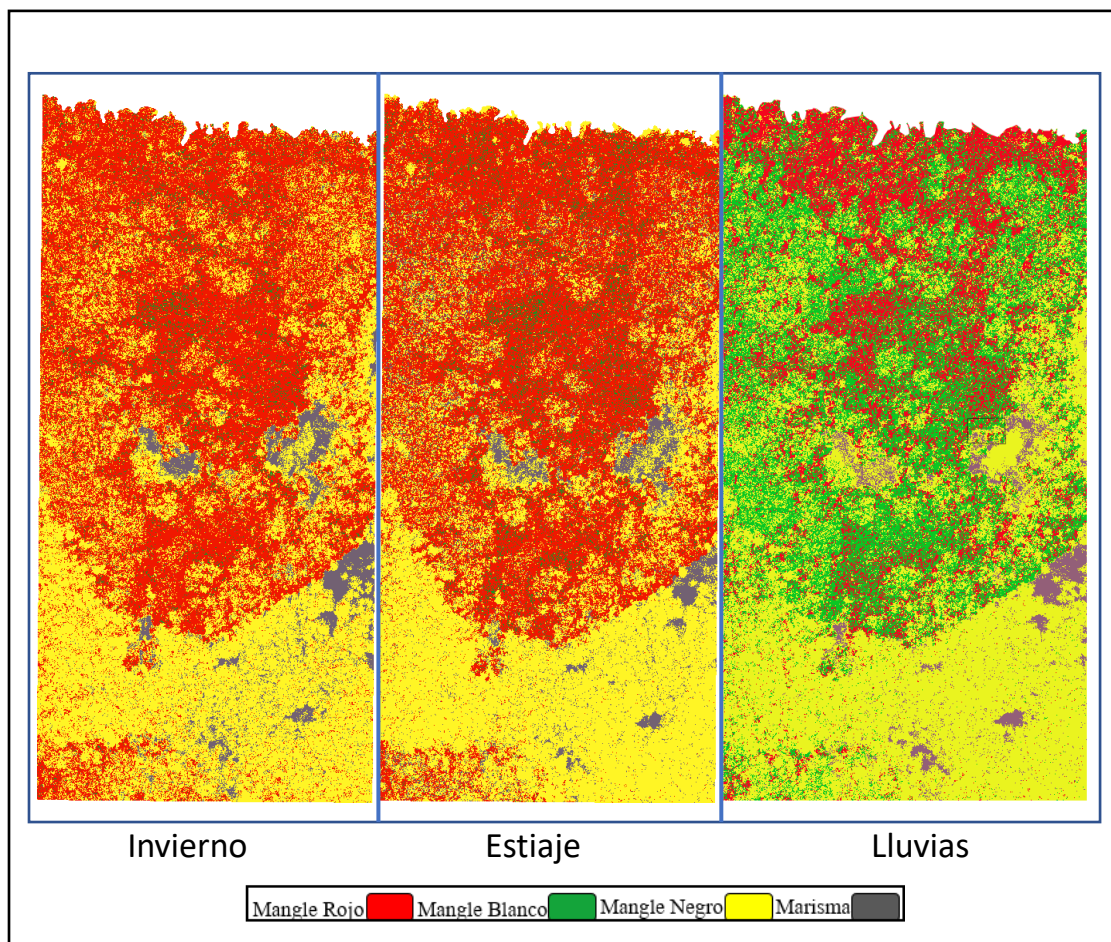
Zimudzi, Edward, Ian Sanders, Nicholas Rollings & Christian W. Omlin. 2021. Remote sensing of mangroves using unmanned aerial vehicles: current state and future directions, *Journal of Spatial Science*, 66:2, 195-212, DOI: 10.1080/14498596.2019.1627252

CRÉDITOS DE LAS ILUSTRACIONES


Figura. 2: Irene Hernandez Pallares, UNAM FAD, Diseño Gráfico, Zonación de manglares en base a los niveles topográficos.

ANEXO

Clasificación de las 3 temporadas con algoritmo Máquina de Soporte Vectorial



Clasificación de las 3 temporadas con algoritmo Bosques Aleatorios



Clasificación de las 3 temporadas con algoritmo Redes Neuronales

