



CENTRO DE INVESTIGACIONES BIOLÓGICAS
DEL NOROESTE, S.C.

Programa de Estudios de Posgrado

**FOTOGRAMETRÍA AÉREA APLICADA A ENCINOS
(*Quercus* spp.) EN SIERRA LA LAGUNA, B.C.S.
RECOMENDACIONES PARA SU IDENTIFICACIÓN
Y CONSERVACIÓN.**

T E S I S

Que para obtener el grado de

Maestro en Ciencias

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

P r e s e n t a

Mariana Ramírez Vargas

La Paz, Baja California Sur, octubre de 2020.

ACTA DE LIBERACIÓN DE TESIS

En la Ciudad de La Paz, B. C. S., siendo las 15 horas del día 25 del Mes de septiembre del 2020, se procedió por los abajo firmantes, miembros de la Comisión Revisora de Tesis avalada por la Dirección de Estudios de Posgrado y Formación de Recursos Humanos del Centro de Investigaciones Biológicas del Noroeste, S. C., a liberar la Tesis de Grado titulada:

"Fotogrametría aérea aplicada a encinos (*Quercus* spp.) en Sierra La Laguna, B.C.S. Recomendaciones para su identificación y conservación"

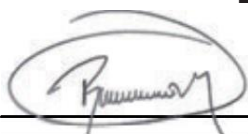
Presentada por el alumno:

Mariana Ramírez Vargas

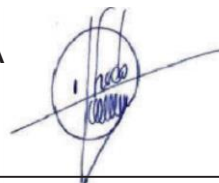
Aspirante al Grado de MAESTRO EN CIENCIAS EN EL USO, MANEJO Y PRESERVACIÓN DE LOS RECURSOS NATURALES CON ORIENTACIÓN EN **Ecología de Zonas Áridas**

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

LA COMISIÓN REVISORA



D. Raúl Octavio Martínez Rincón
Co-Director



Dr. Alfredo Ortega Rubio
Co-Director



M en C. Joel Cuauhtémoc Rosas Ávila
Co-Tutor



Dr. Alfonso Medel Narváez
Co-Tutor



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

Conformación de Comités

Comité tutorial

Dr. Raúl Octavio Martínez Rincón

Centro de Investigaciones Biológicas del Noroeste, S. C.

Co-Director de tesis

Dr. Alfredo Ortega Rubio

Centro de Investigaciones Biológicas del Noroeste, S. C.

Co-Director de tesis

M. en C. Joel Cuauhtémoc Rosas Ávila

Instituto Politécnico Nacional

Co-Tutor de tesis

Dr. Alfonso Medel Narváez

Centro de Investigaciones Biológicas del Noroeste, S. C.

Co-Tutor de tesis

Comité Revisor de Tesis

Dr. Raúl Octavio Martínez Rincón

Dr. Alfredo Ortega Rubio

M. en C. Joel Cuauhtémoc Rosas Ávila

Dr. Alfonso Medel Narváez

Jurado de Examen

Dr. Raúl Octavio Martínez Rincón

Dr. Alfredo Ortega Rubio

M. en C. Joel Cuauhtémoc Rosas Ávila

Suplente

Dr. Alfonso Medel Narváez

Resumen

El monitoreo de la vegetación resulta imprescindible para diseñar estrategias referentes al manejo y conservación forestal. Como alternativa eficiente se han desarrollado métodos precisos como sensores multiespectrales aerotransportados, que mediante fotogrametría procesan imágenes para conocer la forma, tamaño y posición de los objetos sin estar en contacto con ellos. Esta opción implica beneficios para el monitoreo de la vegetación ya que aunada a la estimación de índices de vegetación (IV) es posible evaluar a las especies vegetales gracias a la firma espectral que las identifica. En este sentido, el objetivo principal de este trabajo fue implementar un modelo de clasificación supervisada utilizando imágenes aéreas de alta resolución para identificar y estimar la cobertura y la altura de los encinos en San Antonio de la Sierra, B.C.S, localidad en la que se desarrollan tres especies del género *Quercus*. La metodología se aplicó en un polígono de 20.9 hectáreas, en el que se geo-posicionaron e identificaron los encinos; con un hipsómetro se midió la altura del 30% de los encinos. Para lo anterior, se obtuvieron imágenes con un vehículo aéreo no tripulado, equipado con dos sensores para medir la reflectancia en la parte visible de la luz (RGB) y en el infrarrojo cercano (NIR). A partir de las imágenes aéreas se estimaron los IV en la temporada seca y de lluvias. Además de los mosaicos creados de cada sensor, se construyó el Modelo digital de superficie, de terreno y a partir de estos el modelo de elevación del dosel (MED) que contenía los datos de altura de los encinos. Los resultados sugieren que por sí solos los IV basados en las bandas RGB en la temporada de estiaje, muestran un mejor desempeño (precisión 50%, kappa 0.25) que aquellos basados en el NIR (precisión 53%, kappa 0.15) o en la temporada de lluvias con IV RGB (precisión 47%, kappa 0.18). Al integrar los datos de altura de la vegetación, obtenidos mediante los modelos fotogramétricos, el desempeño mejora al evaluar un IV RGB en época seca (precisión 72.7%, kappa 0.59) a diferencia del modelo con un IV basado en el NIR (precisión 62.4%, kappa 0.40) o en época lluviosa con un IV RGB (precisión 66.3%, kappa 0.44). Una vez que se incluyen al algoritmo de clasificación todos los índices de vegetación (RGB y NIR) y el modelo digital de elevación, se logra con los IV RGB una precisión del 81% en temporada de estiaje contra el 74% obtenido en temporada húmeda y el 71% con los IV basados en el NIR. Utilizando el mejor modelo de clasificación obtenido, se estimó que los encinos cubren 4.16 hectáreas de las 20.9 ha, *Q. albocincta*, *Q. tuberculata* y *Q. devia* cubren el 0.29%, 19.9% y 1.44%, respectivamente. Con relación a la estimación de la altura de los encinos, se obtuvo una baja relación lineal entre la observada y la estimada por el MED ($r^2=0.29$). Separando por especies, la mayor relación lineal se encontró para *Q. albocincta* con $r^2=0.46$. Los resultados obtenidos demuestran que la fotogrametría y la clasificación supervisada con índices basados en el RGB son eficientes para identificar encinos en la temporada seca en la cual los cambios fenológicos favorecen su identificación, principalmente de *Q. tuberculata* y *Q. devia*. Asimismo, el modelo de elevación del dosel es una herramienta que mejora el desempeño de los modelos de clasificación, sin embargo, no es un buen estimador de la altura debido a la cobertura foliar y al abrupto relieve. Se concluye que esta metodología puede ser replicada en otras localidades de Sierra La Laguna y con ello ampliar el conocimiento actual de la distribución y cobertura del género *Quercus*.

Palabras clave. Espectro de luz visible, infrarrojo cercano, fotogrametría aérea, clasificación supervisada, modelo de elevación del dosel.



Dr. Raúl Octavio Martínez Rincón
Co-Director de Tesis



Dr. Alfredo Ortega Rubio
Co-Director de Tesis

Summary

Vegetation monitoring is essential to design strategies for forest management and conservation. As an efficient alternative for monitoring, precise methods have been developed such as airborne multispectral sensors, which process images through photogrammetry, technique which determines the shape, size and position of objects without being in contact with them. This option implies multiple benefits for vegetation monitoring because joined with vegetation indexes (VIs) estimation, it is possible to evaluate vegetation species thanks to the spectral signature that identifies each of them. The main objective of this work was to implement a supervised classification model using high resolution aerial images to identify and estimate the coverage and height of San Antonio oaks in BCS, where three species of *Quercus* develop. The methodological framework is applied in a 20.9 hectares polygon in which oaks were geopositioned and identified, the height of 30% of the oaks was measured using an hypsometer. The imagery was acquired with an unmanned aerial vehicle equipped with two sensors to measure reflectance in the visible part of light (RGB) and in the near infrared (NIR). From the aerial images, VIs were estimated in the dry and rainy season. Besides the mosaics created with each sensor, the Digital Surface and Terrain Model were built and from those, the canopy height model (CHM), which contains the oak's height data was built. The results suggest that by their own, VIs based on RGB bands on the dry season, show better performance (accuracy 50%, Kappa 0.25) than those based on the NIR band (accuracy 53%, kappa 0.15) or in the rainy season with an RGB index (accuracy 47%, kappa 0.18). Integrating the CHM to the algorithm, performance improves when it was evaluated by a VI based on RGB in the dry season (accuracy 72.7%, kappa 0.59), unlike the model with an NIR index (accuracy 62.4%, kappa 0.40) or in the rainy season with an RGB index (accuracy 66.3%, kappa 0.44). Once all the vegetation indexes (RGB and NIR) and the CHM are included in the classification algorithm, the RGB model achieves an accuracy of 81% in the dry season against the 74% obtained in the rainy season model and also the 71% with all the NIR indexes in the dry season. Using the classification model with the highest accuracy, the oak's cover was estimated on 4.16 hectares of 20.9 hectares of the study area, *Q. albocincta* covers 0.29%, *Q. tuberculata* covers 19.9% and *Q. devia* covers 1.44%. Regards on height estimation, a low linear relationship was obtained between the observed and estimated height by the CHM ($r^2 = 0.29$). Separated by species, the highest linear relationship was found for *Q. albocincta* with $r^2 = 0.46$. Results indicate that photogrammetry and supervised classification with an RGB sensor, are tools that improve oak identification in the dry season, mainly for *Q. tuberculata* and *Q. devia*, in which phenological changes favor their identification. Likewise, the CHM enhances the classification performance on the resulting models, but it was not a good estimator of the oak's height due to leaf coverage and terrain slope. It is concluded that this methodology can be replicated in another localities of Sierra La Laguna and thereby expand current knowledge of the coverage and distribution of *Quercus* genus.

Key words. Visible light spectrum, near infrared, aerial photogrammetry, supervised classification, canopy height model.



Dr. Raúl Octavio Martínez Rincón
Co-Director de Tesis



Dr. Alfredo Ortega Rubio
Co-Director de Tesis

Dedicatoria

A mi hermana Gaby...

Agradecimientos

En primer lugar, extiendo mis agradecimientos al Centro de Investigaciones Biológicas del Noroeste, S.C. por permitirme realizar mis estudios de Maestría.

Asimismo, agradezco al CONACYT por la beca de manutención otorgada: 924125

Al Dr. Raúl Octavio Martínez Rincón quien confió en mí para integrarme a su grupo de trabajo, por los valiosos conocimientos proporcionados, así como la guía y apoyo constante, además de brindarme su gran amistad que aprecio y valoro en demasía.

Al Dr. Alfredo Ortega Rubio por su apoyo y aportes a la investigación y además contagiarme de su optimismo.

Al C. a Dr. Joel C. Rosas Ávila por las invaluable observaciones y aportaciones realizadas a la tesis, las cuales mejoraron la investigación en gran medida.

Al Dr. Alfonso Medel Narváez por el gran apoyo, préstamo de equipo y aportaciones realizadas tanto en campo como en el escrito, además de brindarme su amistad, confianza y sin fin de consejos.

A mi mamá y hermana, que siempre me dieron su amor y apoyo incondicional, ustedes me dan el coraje para seguir con dedicación toda meta, las amo.

A mi papa por su apoyo.

A Sara y Temo, que adoro como mi familia y que siempre me alientan a mejorar.

A Juan y mis amigos Alberto, Mari, Denisse, Rous, Karla, Ale y Liz, siempre están ahí pese a la lejanía.

A Francisco, Joselyn, David, Judith, Daniel, Jennifer y Alfonso, quienes me apoyaron en campo a pesar de las difíciles condiciones en las que íbamos a medir y contar encinos.

A mis compañeros con quienes viví este difícil camino, en especial a Roque, Betzy, Daniel, Joselyn, Adriana, Lupita, Lili, Estela y Ana, gracias infinitas por su amistad, enseñanzas y apoyo. Fue un gusto haberlos conocido y haber compartido tantos momentos inolvidables.

A Mariana, que conocí durante este proceso y me brindó su amistad y enseñó tenacidad ante las dificultades.

A la Dra. Gracia Gómez y Dr. Ortega, por su perseverancia y convicciones que influyeron en las mejoras continuas realizadas en el Programa de Posgrado.

Al Lic. Horacio Sandoval Gómez, por todo el apoyo técnico brindado durante la maestría.

Este estudio fue desarrollado con el apoyo económico del Proyecto 60086 Red de Monitoreo Fenológico del Noroeste de México; con el apoyo de la Red Temática de Áreas Naturales Protegidas (RENANP-CONACyT) y con el apoyo económico del Proyecto 251919 de Ciencia Básica de CONACYT.

Contenido	
Resumen	i
Summary	ii
Dedicatoria	iii
Agradecimientos	iv
Contenido	v
Lista de figuras	vii
Lista de tablas	ix
Abreviaturas	x
1. INTRODUCCIÓN	1
2. ANTECEDENTES	4
3. JUSTIFICACIÓN	13
4. HIPÓTESIS	15
5. OBJETIVOS	16
5.1 Objetivo general	16
5.2 Objetivos particulares	16
6. MATERIALES Y MÉTODOS	17
6.1 Área de estudio	17
6.2 Geoposicionamiento de encinos	23
6.3 Imágenes aéreas	24
6.4 Procesamiento de imágenes y obtención de ortomosaicos	27
6.5 Estimación de índices de vegetación	28
6.6 Clasificación Supervisada	30
6.7 Evaluación de la Clasificación supervisada	32
6.8 Estimación de la cobertura de encinos	35
6.9 Desempeño del Modelo de elevación del dosel (MED)	35
7. RESULTADOS	36
7.1 Reflectancia de los pixeles en bandas RGB y GRN	36
7.2 Clasificación supervisada – Desempeño de un Índice de vegetación	38
7.3 Clasificación supervisada – Desempeño de Índice de vegetación + MED	44
7.4 Clasificación supervisada – Modelo de precisión general	50
7.5 Cobertura de encinos	55
7.6 Estimación de la altura de encinos mediante el Modelo de Elevación del dosel	57
7.6.1 Estimación de la altura de encinos por especie	58
8. DISCUSIÓN	60
8.1 Modelos de clasificación supervisada con el mejor índice RGB o NIR	61
8.2 Modelo de clasificación supervisada integrando el mejor índice + MED	65
8.3 Evaluación del modelo de precisión general	67
8.4 Análisis de cobertura por especie	70
8.5 Evaluación del desempeño del MED para estimar alturas	73
9. CONCLUSIONES	75
10 LITERATURA CITADA	77
11 ANEXOS	94
Anexo A	94
Anexo B	95

Anexo C	97
Anexo D	98
Anexo E	100

Lista de figuras

Figura 1. Curva espectral de la vegetación saludable y estresada.....	5
Figura 2. Respuesta espectral del comportamiento de la vegetación en tres etapas de desarrollo foliar (Fuente, <i>Yengoh et al., 2015</i>).....	6
Figura 3. Área de estudio en San Antonio de la Sierra. Elaboración propia.....	17
Figura 4. Climograma de la temperatura y precipitación media anual registrada en el periodo 1998-2017 por la estación Agua de San Antonio. <i>Fuente SMN.</i>	18
Figura 5. Aspecto de las hojas de los encinos en la temporada seca (columna izquierda) y la temporada de lluvias (columna derecha). a) <i>Q. tuberculata</i> , b) <i>Q. albocincta</i> y c) <i>Q. devia</i> . Fuente: Trabajo en campo.....	21
Figura 6. Apariencia de las tres especies de encinos en la temporada seca (a y c) y temporada de lluvias (b y d). Imágenes panorámicas con dos individuos de <i>Q. tuberculata</i> en la parte central (a y b). Imágenes con <i>Q. albocincta</i> a la izquierda y <i>Q. devia</i> a la derecha (c y d). Nótese la senescencia en <i>Q. albocincta</i> en la época seca. Fuente: <i>Trabajo en campo</i>	22
Figura 7. Geoposicionamiento de las 3 especies de encinos en el polígono de estudio. Elaboración propia.	23
Figura 8. Ortomosaico RGB generado con imágenes obtenidas en la temporada seca (abril). El recuadro amarillo corresponde al polígono de 20.9 hectáreas en donde se geoposicionaron los encinos.....	25
Figura 9. Ortomosaico generado con imágenes obtenidas en la temporada seca (abril) con el sensor GRN.....	26
Figura 10. Ortomosaico generado con imágenes obtenidas en la temporada de lluvias (septiembre). El recuadro amarillo corresponde al polígono de 20.9 hectáreas en donde se geoposicionaron los encinos.	27
Figura 11. Diagrama de flujo de la metodología empleada. Elaboración propia.....	34
Figura 12. Valor de reflectancia obtenida por clase en las banda RGB en temporada seca.	37
Figura 13. Valor de reflectancia por clase, en las bandas GRN en temporada seca.....	37
Figura 14. Valor de reflectancia obtenida por clase, en las bandas RGB en temporada húmeda.	38
Figura 15. Diagramas circulares que muestran el comportamiento de clasificación de los pixeles basado en los modelos RGB y GRN al emplear el mejor índice de vegetación aplicado a las 9 clases. Cada clase es representada por un color. En Anexo B se encuentran las matrices de confusión numéricas que generaron los diagramas.	43
Figura 16. Diagramas circulares que muestran el comportamiento de la clasificación de los pixeles basado en los modelos RGB y GRN con el mejor desempeño al emplear el mejor índice de vegetación + MED aplicado a las 9 clases. En Anexo D se encuentran las matrices de confusión numéricas que generaron cada diagrama.....	49

- Figura 17.** Diagramas circulares que muestran el comportamiento de la clasificación de los pixeles basado en los modelos que evaluaron todos los índices de vegetación + MED.53
- Figura 18.** Mapa de predicción generado al remover el efecto “sal y pimienta”, a partir del mejor modelo de clasificación supervisada en la temporada seca al integrar los IV sensibles al espectro visible y el MED. Notese que en el cuadrante superior derecho(región noreste) donde se desarrolla *Q. albocincta*, el modelo no identifica a la especie (elaboración propia). 54
- Figura 19.** Mapa booleano de las especies de encinos en el área de estudio creado a partir del modelo de clasificación supervisada con mejor desempeño. Elaboración propia...56
- Figura 20.** Gráfico de cajas y bigotes de la altura observada y altura estimada de los encinos 57
- Figura 21.** Gráfico del modelo de regresión lineal de la altura registrada in situ y la altura estimada por el MED. 57
- Figura 22.** Gráfico del modelo de regresión lineal de la altura de *Q. tuberculata* registrada in situ y la altura estimada por el MED. 58
- Figura 23.** Gráfico del modelo de regresión lineal de la altura de *Q. devia* registrada in situ y la altura estimada por el MED. 59
- Figura 24.** Gráfico del modelo de regresión lineal de la altura de *Q. albocincta* registrada in situ y la altura estimada por el MED. 59

Lista de tablas

Tabla I. Características de los mosaicos creados a partir de los diferentes sensores empleados.	28
Tabla II. Índices de vegetación calculados basados en el espectro visible (RGB).	29
Tabla III. Índices de vegetación basados en las bandas GRN.	30
Tabla IV. Indicadores para evaluar el desempeño de clasificación.	33
Tabla V. Desempeño de los diferentes índices de vegetación en la clasificación vegetación y no vegetación para la temporada de lluvias (septiembre) y seca (abril).	39
Tabla VI. Matriz de confusión correspondiente a los 3 modelos aplicados a las 2 macro clases.	40
Tabla VII. Desempeño de los diferentes índices de vegetación en la clasificación de 9 clases, en la temporada de lluvias (septiembre) y seca (abril).	41
Tabla VIII. Desempeño de los diferentes índices de vegetación en la clasificación de vegetación y no vegetación integrando el MED, en la temporada húmeda (septiembre) y seca (abril).	45
Tabla IX. Matriz de confusión resultante de las 3 predicciones de clasificación al incorporar el MED para identificar a la vegetación.	46
Tabla X. Desempeño de los diferentes índices de vegetación en la clasificación de 9 clases, integrando el MED, en la temporada húmeda (septiembre) y seca (abril).	47
Tabla XI. Comparación de los resultados del índice Kappa y de desempeño general (Precisión) de los modelos de clasificación integrando los IV y MED para evaluar a las 9 clases.	50
Tabla XII. Cobertura por categorías resultado del mejor modelo de clasificación supervisada en la temporada seca.	55
Tabla XIII. Número de encinos por hectárea (ind ha^{-1}) presentes en el sitio de estudio.	56

Abreviaturas

ANP	Área Natural Protegida
BCS	Baja California Sur
BTC	Bosque Tropical Caducifolio
CHM	Canopy height model
GNSS	Global Navigation Satellite System
GRN	Bandas espectrales verde, rojo e infrarrojo cercano (<i>del inglés green, red and Near Infrared</i>)
GSP	Ground Station Pro
IV	Índice de vegetación
IV's	Índices de vegetación
LIDAR	Light Detection and Ranging
MDS	Modelo digital de superficie
MDT	Modelo digital de terreno
MED	Modelo de elevación del dosel
NIR	Infrarrojo cercano (<i>del inglés Near Infrared</i>)
REBIOSLA	Reserva de la Biosfera Sierra La Laguna
RGB	Bandas espectrales rojo, verde y azul (<i>del inglés red, green and blue</i>)
RTK.	Real Time Kinematic
SBC	Selva Baja Caducifolia
VANT	Vehículo aéreo no tripulado

1. INTRODUCCIÓN

La diversidad biológica de México ha contribuido al diseño, generación e implementación de diferentes estrategias que garanticen el manejo y conservación de los ecosistemas y con ello de las comunidades vegetales (Halffter, 2011). Numerosos monitoreos *in situ* se han realizado con la finalidad de generar información detallada referente a las características y variaciones de la cubierta vegetal en diferentes ecosistemas, sin embargo este tipo de monitoreos pueden resultar costosos, exhaustivos, limitados a un área en específico y en algunos casos comprometer la seguridad del personal quien los realiza (Mohan *et al.*, 2017).

Como alternativa para evaluar y caracterizar a la vegetación de manera local, regional y global, se han desarrollado métodos de gran precisión como los sistemas de percepción remota o teledetección (Grenzdörffer *et al.*, 2008; Chianucci *et al.*, 2016; Mohan *et al.*, 2017; Tay *et al.*, 2018) los cuales permiten adquirir información sobre algún objeto o fenómeno a distancia sin tener contacto directo con él (Chuvienco, 1995).

La percepción remota, es una herramienta tecnológica de monitoreo terrestre basada en sensores multiespectrales aerotransportados, que permite obtener información de un objeto mediante fotogrametría, la cual es una técnica utilizada para conocer la forma, dimensión y posición de objetos con medidas realizadas sobre una o más fotografías con puntos de referencia topográficos como medio fundamental para la medición (Bonneval, 1972). Posteriormente la información obtenida es procesada y analizada en sistemas de información geográfica (Chuvienco, 1995, 2002).

Los primeros sensores empleados para la teledetección se ubicaron en plataformas espaciales que obtenían información a partir de la interacción electromagnética existente entre la tierra y el sensor (Chuvienco, 1995), de forma que, las primeras imágenes satelitales se convirtieron en una fuente valiosa de información para evaluar los procesos dinámicos de la vegetación (Alonso *et al.*, 1999; Soria y Granados, 2005; Gonzaga, 2014).

A pesar de los múltiples usos de las imágenes satelitales, estas se limitan a suministrar información temporal discontinua, de baja resolución espacial (≥ 30 m por pixel) y con presencia significativa de nubosidad (Austin, 2010; Ramírez Chavez *et al.*, 2013; Van Der Wal *et al.*, 2013; Wahab *et al.*, 2018), por lo tanto, durante su procesamiento, se restringe la obtención de mapas a escala fina y de imágenes de alta resolución espacial y espectral (Reuter, 2009; Quirós R, 2014; Ojeda-Bustamante *et al.*, 2017).

Ante la necesidad de fotografías de alta definición, se desarrollaron plataformas independientes, como la percepción remota aérea, la cual se distingue de la espacial porque el sensor puede ubicarse en globos, helicópteros, aviones (Camara, 2005) o de gran auge en vehículos aéreos no tripulados (VANT), mayormente conocidos como drones (Austin, 2010), alternativa confiable en la adquisición de imágenes aéreas para el reconocimiento del terreno, mapeo y modelado en 3D (Nex y Remondino, 2014).

De esta forma, el uso de drones ha permitido múltiples beneficios sobre el uso de aviones tripulados o imágenes satelitales ya que capturan imágenes aéreas con una elevada resolución, poseen flexibilidad en la frecuencia y al momento de la adquisición de los datos, logran sobrevolar áreas a baja altura o inaccesibles y además, evitan la presencia de nubes, que en algunas latitudes pueden ocupar el 80% de una imagen satelital (Ramírez Chavez *et al.*, 2013; Matese *et al.*, 2015; Mohan *et al.*, 2017). Asimismo, a diferencia de los vehículos aéreos tripulados, esta tecnología provee una alternativa de bajo impacto ambiental al no generar emisiones contaminantes durante su vuelo (Harriman y Muhlhausen, 2013; Ivošević *et al.*, 2015).

Con base en lo anterior, las imágenes multiespectrales obtenidas con un VANT, son ampliamente utilizadas para el monitoreo cualitativo y cuantitativo de la vegetación mediante la estimación de índices de vegetación (IV) (Bannari *et al.*, 1995; Soria y Granados, 2005; Chianucci *et al.*, 2016; Kharuf-Gutierrez *et al.*, 2018; Komárek *et al.*, 2018). Lo anterior, se consigue gracias a que los índices de vegetación son parámetros calculados a partir de los valores de reflectancia de las plantas a diferentes longitudes de onda y estos valores dependen del comportamiento espectral de la vegetación (Jackson, 1983).

Por lo que, factores como la especie, el estado de desarrollo en el que se encuentre la vegetación, el ambiente donde crece y los impactos a los que está sometida, influyen en el valor resultante de los IV (Chuvienco, 1995). Esto indica que la vegetación mantiene una firma espectral que la identifica y en consecuencia, la cantidad de radiación reflejada será diferente dependiendo de la especie y de los diversos componentes del ambiente (Tucker, 1979; Xue y Su, 2017).

De esta manera, la estimación de IV a partir de imágenes adquiridas con sensores remotos de alta resolución, es empleada para identificar especies vegetales a nivel local (Riggins *et al.*, 2011; Prieto *et al.*, 2013; Baena *et al.*, 2017). Investigadores como Gini *et al.* (2014); Lisein *et al.* (2015) y Michez *et al.* (2016), coinciden en que los cambios estacionales que presenta la vegetación pueden ser detectados a través de la percepción remota y estimados mediante índices de vegetación. Además, Lisein *et al.* (2015) y Michez *et al.* (2016) concluyen que la clasificación de diferentes especies deciduas ha resultado precisa, gracias a la diferencia en la señal radiométrica reflejada durante cada fase fenológica en la que el follaje cambia su forma y coloración.

En este contexto, se pretende desarrollar un método con fotogrametría aérea y una técnica de clasificación supervisada que permita diferenciar por su fenología a 3 especies encinos que coexisten en San Antonio de la Sierra en la Reserva de la Biósfera Sierra La Laguna en Baja California Sur.

2. ANTECEDENTES

Una de las aplicaciones más importantes de la teledetección es el seguimiento de los procesos que ocurren en la tierra, lo anterior como resultado del dramático impacto de las actividades antropogénicas sobre los ecosistemas (Chapin *et al.*, 2011). Desde el lanzamiento de la serie LANDSAT en 1972, se han dirigido múltiples estudios para el monitoreo de la cobertura vegetal, esto al ser el primer programa de percepción remota satelital (Chuvieco, 1995).

Pese al continuo uso de la percepción satelital por su capacidad de observar la dinámica terrestre desde el espacio, el empleo de VANTs como plataformas de percepción remota, ha ganado una creciente atención sobre las técnicas de teledetección tradicionales ya que esta permite transportar sensores multispectrales, detectar información de forma remota y obtener información con una alta resolución espacial y temporal lo que representa una de sus grandes ventajas (Austin, 2010).

Para efectuar el monitoreo vegetal a través de la percepción remota satelital o aérea, es preciso detectar la energía radiante en función de su longitud de onda, radiación distribuida en las bandas del espectro electromagnético, las cuales conforman longitudes de onda continuas que en conjunto componen la luz (Chuvieco, 2002). Por su parte, la luz visible, es una porción pequeña del espectro de la cual suelen distinguirse 3 bandas elementales, azul (400 -500 nm), verde (500-600 nm) y rojo (600-700 nm), para las cuales el ojo humano está adaptado. Fuera del espectro de luz visible, se encuentra la banda infrarrojo cercano (700-1300 nm), la cual es de gran importancia para el monitoreo vegetal gracias a su capacidad para distinguir el comportamiento foliar por su respuesta radiométrica (Chuvieco, 2002).

El comportamiento espectral de la vegetación depende principalmente de la estructura de sus hojas, ya que éstas determinan la interacción con la luz solar, la cual es usada como fuente de energía durante el proceso de la fotosíntesis, por lo que en las distintas capas del tejido foliar, las plantas absorben y reflejan radiación solar en las bandas rojo, verde y azul, dependiendo de la cantidad de pigmentos presentes (Roy, 1989).

De manera general, la curva de reflectancia de la vegetación saludable o vigorosa en la banda azul y rojo, situadas en la longitud de onda cerca de los 445 nm y de los 645 nm, respectivamente, absorbe fuertemente la luz gracias al efecto de la clorofila a y b, xantofila y β -caroteno, pigmentos encargados de la actividad fotosintética. De forma contraria, en la banda verde del espectro alrededor de los 555 nm, el efecto absorbente es menor y mayor es la reflectancia, de ahí el color verde de la vegetación ante el ojo humano (Araque y Jiménez., 2009). Asimismo, en el infrarrojo cercano, se presenta una elevada reflectividad al no producirse absorción, esto desde el límite fuera de nuestra visión, valores que son interpretados como vegetación vigorosa (Roy, 1989; Chuvieco, 1995, 2002; Yengoh *et al.*, 2015) (Fig. 1).

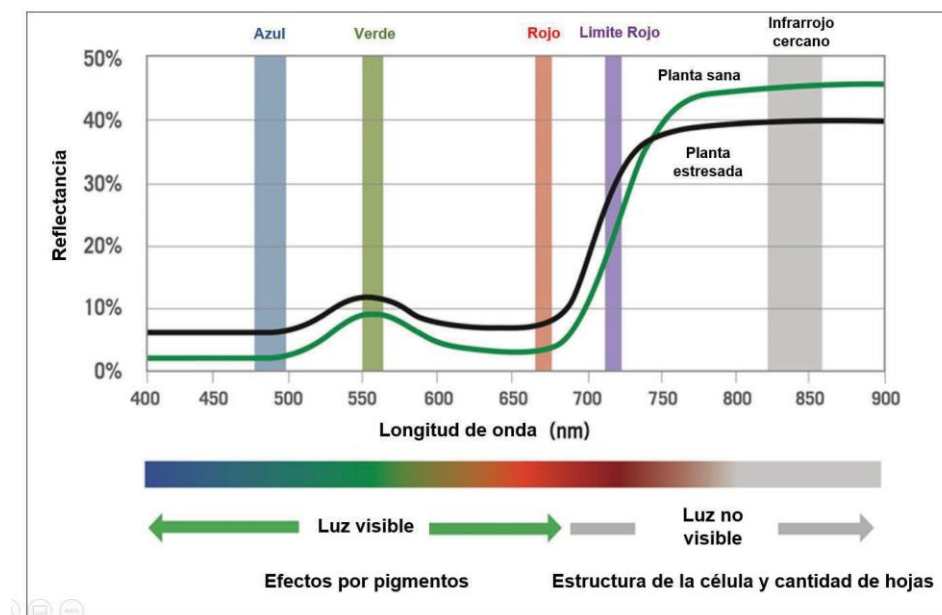


Figura 1. Curva espectral de la vegetación saludable y estresada.

Por lo anterior se explica que los valores de absorbancia y reflectividad cambien cuando se aproxima la caída de las hojas, ya que la hoja senescente tiende a disminuir la actividad fotosintética y la clorofila ejerce menor influencia (Fig. 2), explicando su mayor reflectividad en la banda roja y por ende menor vigor (Gates, 2003, Gini *et al.*, 2014; De Luca *et al.*, 2019).

En este sentido, Gini *et al.* (2014); Chianucci *et al.* (2016); Baena *et al.* (2017); Dash *et al.* (2017); Komárek *et al.* (2018); De Luca *et al.* (2019); Khokthong *et al.* (2019); Maimaitijiang *et al.* (2019) y muchos otros, han aprovechado la reflectividad de las plantas para evaluar elementos como la cobertura, biomasa, composición específica, sanidad vegetal, distribución de las especies, entre otros. Lo anterior, mediante la estimación de IV, gracias a los cuales se obtiene información acerca de las características físicas o estado de salud forestal (Jackson, 1983; Bannari *et al.*, 1995).

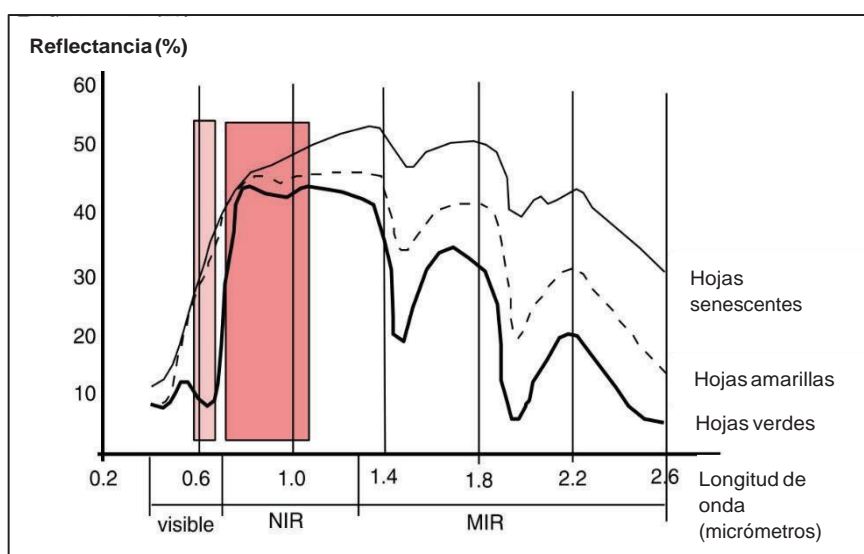


Figura 2. Respuesta espectral del comportamiento de la vegetación en tres etapas de desarrollo foliar (Fuente, Yengoh *et al.*, 2015).

A la fecha, se han desarrollado una gran cantidad de IV con el objeto de identificar aquel que represente las condiciones de la vegetación de una manera más contundente minimizado así la influencia de las perturbaciones externas (Gutman, 1991; Bannari *et al.*, 1995; Gilabert *et al.*, 1997), esto en consecuencia de que factores como el brillo, color del suelo, condiciones atmosféricas y relieve, pueden afectar la respuesta de los índices (Jackson, 1983; Elvidge y Lyon, 1985).

A través de la percepción remota aérea los IV han sido ampliamente usados como una forma indirecta para estimar el particular comportamiento espectral de la vegetación, el cual, está en función del estado fenológico, el contenido de humedad y la densidad foliar que forma el

dosel (Guyot *et al.*, 1989; Manzo-Delgado y Meave, 2003; Paz *et al.*, 2014). Generalmente, los índices que han sido propuestos utilizan combinaciones de las bandas visibles roja, verde y azul (RGB) y además, la banda infrarrojo cercano (NIR), esto por la capacidad de respuesta de los pigmentos foliares a esta banda en particular (Rouse *et al.*, 1974; Kaufman y Tanré, 1992; Bannari *et al.*, 1995; Rondeaux *et al.*, 1996; Rodríguez-Moreno *et al.*, 2013; Saberioon *et al.*, 2014; Berrío *et al.*, 2015; Kyratzis *et al.*, 2017; Brovkina *et al.*, 2018; Maimaitijiang *et al.*, 2019).

A la fecha existen más de 100 IV basados tanto en la parte visible de la luz como en el infrarrojo cercano (Ahmad y Reid, 1996; Silleos *et al.*, 2006; Xue y Su, 2017). Esto se debe a que los diferentes IV fueron formulados para el monitoreo de la cobertura vegetal en ecosistemas naturales (Tucker, 1979; Silleos *et al.*, 2006) o para el monitoreo de la salud vegetal en agroecosistemas (Mulla, 2013; Edwin, 2019). No obstante, en casos específicos, los IV son variaciones a los cuales se les agregan constantes que se determinan dependiendo el tipo de vegetación presente, sin embargo, algunos autores sugieren valores específicos cuando estos no pueden ser calculados por el usuario final (Bannari *et al.*, 1995; IDB, 2020).

El índice mayormente conocido y utilizado para evaluar a la vegetación es el Índice de Vegetación de Diferencia Normalizada (NDVI), el cual responde al infrarrojo cercano y por ende es el que comúnmente se relaciona con un indicador de salud forestal (Rouse *et al.*, 1974; Bannari *et al.*, 1995; Matese *et al.*, 2015; Yengoh *et al.*, 2015), no obstante, existen muchos otros índices que también emplean el infrarrojo cercano (NIR) y han sido ampliamente utilizados en diferentes estudios a escala global de forma precisa (Kaufman y Tanre, 1992; Rodríguez-Moreno *et al.*, 2013; Lisein *et al.*, 2015; Michez *et al.*, 2016).

Actualmente se ha incursionado en gran medida en la evaluación de los índices que responden a las bandas del espectro de luz visible (RGB) para el monitoreo vegetal, incluso, muchos autores los describen como eficaces y suficientes para caracterizar a la vegetación (Ahmad y Reid, 1996; Gitelson *et al.*, 2002; Guijarro *et al.*, 2011; Chianucci *et al.*, 2016; Jiménez L. y Mulero-Pázmány, 2019; Maimaitijiang *et al.*, 2019).

Los primeros estudios en donde se evaluaron índices de vegetación para conocer la dinámica vegetal fueron utilizando percepción remota satelital (Chuvieco, 1995, 2002; Gilabert *et al.*, 1997; Reuter, 2009), actualmente estos son empleados en estudios globales y regionales dada su exactitud ya que la resolución espacial limitada provoca que los estudios a escala local no sean tan precisos como los estudios realizados con imágenes de alta resolución (Gutman, 1991; Dymond *et al.*, 2002; Joy *et al.*, 2003; Feeley *et al.*, 2005; Lloret *et al.*, 2007; Meneses-Tovar, 2012; Prieto *et al.*, 2013).

En consecuencia, a partir de las últimas dos décadas, numerosas investigaciones han explorado el potencial de evaluar índices de vegetación mediante percepción remota aérea como un método eficiente para el monitoreo local de la vegetación, esto derivado de que el empleo de un VANT, como plataforma de teledetección, genera imágenes con una elevada resolución espacial (Morgan *et al.*, 2010; Jiménez L. y Mulero-Pázmány, 2019; Nowak *et al.*, 2019) y bajo la premisa de que cada especie tiene una firma espectral que la identifica de otras gracias a la cantidad de radiación reflejada (Tucker, 1979).

Si bien se ha demostrado que los VANT son eficientes en obtener información significativa para conocer a más detalle sobre la ecología de la vegetación, aún resulta un desafío la caracterización o cuantificación de las especies mediante interpretación visual, por ende, diversos autores han documentado la precisión de la clasificación de especies vegetales empleando imágenes multiespectrales de alta resolución, con el fin de poder discriminar mediante la estimación de IV, diferentes tipos de vegetación e incluso conocer la composición específica de una comunidad arbórea (Gini *et al.*, 2014; Cruzan *et al.*, 2016; Michez *et al.*, 2016; Dash *et al.*, 2017; Lu y He, 2017; Tay *et al.*, 2018; De Luca *et al.*, 2019; Rominger y Meyer, 2019).

Para esta aproximación, comúnmente se emplea la clasificación supervisada mediante metodología en la que se asignan clases o entradas conocidas a una imagen, basado en información espectral como un entrenamiento de la información, logrando entonces una caracterización precisa de las especies (Jensen, 1996). Una vez realizada la clasificación, el método mayormente utilizado para la valoración de la clasificación es mediante el uso de

matrices de confusión o las matrices de error, tabulación cruzada que indica la proporción de datos correctamente clasificados (Morgan *et al.*, 2010).

Michez *et al.* (2016) propone una metodología empleando clasificación supervisada con imágenes de alta resolución obtenidas a partir de un VANT en una aproximación multitemporal para diferenciar especies riparias y sus condiciones de salud. Para su análisis compararon el desempeño de diferentes IV basados en las bandas RGB y GRN con el algoritmo de clasificación Random Forest o árboles aleatorios. Sus resultados mostraron que el mejor periodo para la descripción de las especies fue durante la fase vegetativa tardía, previo a la senescencia, con una precisión del 79% y 84% para cada sitio muestreado con índices basados en el espectro visible. También determinaron que los índices sensibles al NIR tienen mayor contraste cuando se presentan especies fotosintéticamente activas e inactivas, debido al cambio que se genera por la reflectancia de las hojas.

Baena *et al.* (2017), demostraron que la estimación de índices sensibles a la banda verde, azul, y a la banda entre el rojo y el infrarrojo cercano a través de imágenes adquiridas con un VANT, son una alternativa viable para obtener resultados precisos para el monitoreo de la vegetación mediante clasificación supervisada, esto además de ser un método efectivo para identificar y cuantificar especies arbóreas en una cuenca semi-árida gracias a las características deciduas de la vegetación objeto de estudio.

Pese a la precisión que genera la clasificación supervisada, Komárek *et al.* (2018) infiere que la confianza durante la clasificación puede ser afectada tanto por las propiedades y calidad de la información espectral como del modelo de elevación del dosel (MED). Durante su estudio concluyeron que utilizar el MED y aumentar la resolución espectral, conduce a un rendimiento significativamente mejor de los modelos que una resolución espacial más alta.

Otro factor que, de acuerdo con Gini *et al.* (2014), Rominger y Meyer, (2019), Huang *et al.*, (2019), juega un papel importante en la identificación a nivel específico de la vegetación, es el desarrollo fenológico de las especies tal como, el crecimiento foliar, la floración y/o senescencia. Como ejemplo de lo anterior, durante su investigación en un bosque deciduo a lo largo de las 4 estaciones del año, Dymond *et al.* (2002) probaron mediante imágenes

satelitales, que los cambios fenológicos durante la caída de las hojas de los árboles, mejoran significativamente la precisión al clasificar a la vegetación.

Por otro lado, Lisein *et al.* (2015) realizaron un estudio con el objeto de determinar el estado fenológico en el que se discriminan mejor a especies caducifolias; para lo anterior emplearon imágenes multitemporales de alta resolución y dos sensores multiespectrales RGB y NIR. Como resultados obtuvieron que la mejor época para realizar la identificación de las especies es en primavera y verano, cuando terminan de crecer los renuevos de hojas con el sensor sensible al espectro visible, sin embargo, al combinar bandas RGB y NIR obtuvieron un mejor desempeño. Esto lo asocian a que en verano el follaje vigoroso maximizó la variación espectral de las especies gracias a su firma espectral, ya que la variabilidad fenológica intraespecífica durante la senescencia no permitió identificar a las especies en este periodo pese a sus cambios visuales.

En el caso de Sierra La Laguna, en el estado de Baja California Sur, León de la Luz y Domínguez-Cadena (2010) realizaron un muestreo *in-situ* apoyándose de imágenes LANDSAT con las cuales, delimitaron y clasificaron mediante el método de distancia entre sitios, la estructura forestal y dominancia por especie, así como el grado sucesional y de perturbación del bosque de pino-encino, bosque de roble y bosque de encino.

Otro aspecto relevante por considerar para la categorización de la vegetación utilizando imágenes multiespectrales de alta resolución, es la determinación de la estructura vertical del dosel, la cual se considera de gran importancia ya que es un reflejo de la biomasa, estructura de la población arbórea, estado de salud, entre otros (Panagiotidis *et al.*, 2017).

En este caso, la percepción remota aérea se apoya de los modelos digitales originados a partir del procesamiento de las fotografías obtenidas, como el modelo digital de terreno (MDT) que representa la superficie terrestre o suelo desnudo, el modelo digital de superficie (MDS), que representa las elevaciones sobre el nivel del mar como lo es la vegetación, edificios entre otros y el modelo de elevación del dosel (MED) o Canopy Height Model (CHM), que es la altura residual entre el suelo y la parte superior de árboles u objetos, brindando la altura real

de las características topográficas en el suelo, este se obtiene al sustraer el MDT del MDS (Remmel y Perera, 2017).

Numerosas investigaciones han evaluado la estructura vertical del dosel mediante el sistema LIDAR, cuyos resultados han sido precisos ya que a diferencia de los VANT el sistema LIDAR utiliza un láser que le permite penetrar las copas de los árboles a través de pequeños espacios entre las hojas y de esta manera detectar diferentes puntos del suelo, mientras que los VANT, capturan la estructura del dosel sin penetrarlo (Remmel y Perera, 2017; Zhang *et al.*, 2019). No obstante, de manera reciente se ha optado por el uso de los drones para estimar la altura forestal, tecnología accesible económicamente, basada también en la percepción remota y fotogrametría y cuyos resultados han sido confiables (Chen *et al.*, 2017).

Algunos investigadores han estudiado el efecto de la cobertura foliar para estimar la altura en diferentes especies arbóreas con drones (Lin *et al.*, 2015; Giannetti *et al.*, 2018; Huang *et al.*, 2019), Huang *et al.* (2019) determinaron mediante una investigación realizada en 6 especies arbóreas diferenciadas por la temporalidad en el crecimiento foliar, que es posible estimar la altura de los árboles con mayor precisión cuando su follaje es denso, lo anterior, ya que se pueden construir nubes de puntos fotogramétricas más densas a partir de imágenes obtenidas con un VANT, sin embargo cuando la cobertura foliar es densa, el modelo digital de elevación (MDT) puede ser inexacto ya que no es posible detectar todos los puntos en suelo.

Casalegno (1999) realizó un estudio en Sierra la Laguna con imágenes de alta resolución para identificar y cuantificar la distribución espacial del ecotono entre el bosque tropical caducifolio y el bosque de roble en Sierra de la Laguna, basado en datos obtenidos *in-situ* y en imágenes de alta resolución. Sus resultados mostraron que la firma radiométrica del ecotono se puede identificar en febrero, cuando el contraste entre la fenología de las hojas de los sistemas forestales estudiados es el más pronunciado, sin embargo, por sus resultados concluye la necesidad de apoyar la clasificación con datos de campo para obtener una caracterización confiable.

Por lo antes descrito, globalmente la obtención de información mediante percepción remota aérea empleando VANTs ha resultado confiable para realizar censos de vegetación en diferentes tipos de vegetación e incluso en sitios protegidos y de difícil o acceso limitado (Rominger y Meyer, 2019).

3. JUSTIFICACIÓN

El impacto antrópico de la vegetación en Sierra La Laguna se ha reducido de forma notoria a partir del decreto que la convirtió en un Área Natural Protegida (ANP), bajo la categoría de Reserva de la Biósfera (Breceda *et al.*, 2015). Este hecho resulta de gran relevancia, ya que al interior de la reserva se desarrolla de forma discontinua, el Bosque de encino o *Quercus*. Este tipo de vegetación sobresale en la región debido a, su restringido rango de distribución en el estado, por contribuir significativamente en la recarga de los mantos acuíferos de la región (Sánchez Brito *et al.*, 2013) y por formar una zona de transición (Arriaga y Ortega, 1988) con la Selva Baja Caducifolia (SBC) de acuerdo con INEGI (2016) o Bosque Tropical Caducifolio (BTC) de acuerdo con Rzedowski (2006) y también con el Bosque de Pino en las zonas más altas.

En este contexto, desde la declaratoria como ANP, muchas investigaciones han mostrado gran interés en el estudio de diferentes grupos taxonómicos en la región (Arriaga y Ortega, 1988; Ortega *et al.*, 1989; Arriaga, 1994; León de la Luz *et al.*, 1994, 2000; León de la Luz y Domínguez-Cadena, 2010; Ortega-Rubio *et al.*, 2013; Breceda *et al.*, 2014, 2015). No obstante, pocos esfuerzos se han dedicado al estudio de los encinos; a la fecha, se desconocen aspectos de abundancia, requerimientos ecológicos, o el estado poblacional de los mismos, es decir, si actualmente existen poblaciones fragmentadas o si sus poblaciones son estables posterior a los impactos producidos en el sitio.

Ante la ausencia de estudios a nivel local sobre el género y con el fin de reducir esfuerzos y costos durante los monitoreos, la presente investigación tiene el propósito de generar un método práctico, preciso y económico que ayude a identificar especies del género *Quercus* y a estimar su cobertura mediante el uso de percepción remota aérea. Asimismo, se pretende que la metodología propuesta pueda ser replicada en otros sitios de la sierra, permitiendo así mejorar el conocimiento actual del género para conocer el estado poblacional en Sierra La Laguna y en caso necesario, establecer programas de conservación y restauración gracias a modelos de identificación y cobertura basados en imágenes obtenidas con un VANT.

Pregunta de investigación

¿Son los índices de vegetación basados en el infrarrojo cercano (NIR) mejores que aquellos basados en el espectro visible de la luz (RGB) para discernir especies en un Bosque de encinos?

¿Es aplicable el método de clasificación supervisada en imágenes aéreas de alta resolución, para identificar y cuantificar especies de encinos?

¿Es el MED una herramienta que contribuye a mejorar la clasificación de las especies de encinos?

¿Es el MED eficiente para estimar la altura de los encinos?

4. HIPÓTESIS

Dado que la respuesta espectral generalizada de la vegetación sana presenta una alta reflectancia en el infrarrojo cercano (NIR), se espera que los IV basados en las bandas sensibles al GRN tengan mejor desempeño en identificar a la vegetación que los IV basados en la parte visible de la luz (RGB).

Si la identificación de las especies vegetales mediante la estimación de IV ha resultado precisa gracias a la diferencia en la señal radiométrica durante sus distintas fases fenológicas, entonces, el uso de los IV estimados a partir de imágenes multitemporales de alta resolución en un Bosque de *Quercus*, permitirá identificar a las especies de encinos y con ello conocer su estructura horizontal.

Dado que los modelos necesarios para el proceso fotogramétrico generados mediante percepción remota aérea resultan altamente precisos cuando la cobertura foliar de la vegetación es densa, se espera que el modelo de elevación del dosel generado a partir de imágenes aéreas obtenidas con un VANT en los meses de mayor cobertura foliar, contribuya a mejorar la identificación de encinos y además sea útil para estimar su estructura vertical.

5. OBJETIVOS

5.1 Objetivo general

Implementar un modelo de clasificación supervisada a partir de imágenes aéreas de alta resolución obtenidas con un VANT para identificar y estimar la estructura horizontal y vertical de un Bosque de encinos.

5.2 Objetivos particulares

- Determinar mediante el desempeño de diferentes IV sensibles al espectro de luz visible y al infrarrojo cercano, aquel que por sí solo identifique a los encinos durante la temporada seca y de lluvias.
- Evaluar el desempeño de los índices de vegetación en los modelos de clasificación al integrar el modelo de elevación del dosel.
- Estimar la cobertura de encinos mediante un modelo de clasificación supervisada.
- Evaluar la eficiencia del modelo de elevación del dosel para estimar la altura de encinos.

6. MATERIALES Y MÉTODOS

6.1 Área de estudio

El estudio se llevó a cabo en una localidad de la Sierra la Laguna, centrada en las coordenadas Lat. 23.68° N y Long. 109.94° O, a una altitud promedio de 775 m. Específicamente, el área se encuentra en el kilómetro 17 de la terracería que ingresa hacia San Antonio de la Sierra en el límite noreste de la zona de amortiguamiento de la Reserva de la Biosfera Sierra La Laguna (Fig. 3; CONANP, 2003).

El sitio forma parte de San Antonio de la Sierra, el cual tiene influencia acentuada por la vertiente del golfo, en este caso seca y calurosa gracias a su protección por el macizo continental, a diferencia de la vertiente Pacífico, húmeda y fría debido a la entrada de vientos cargados de humedad provenientes del océano Pacífico (Coria, 1988; González *et al.*, 2010; Troyo-Diéguez *et al.*, 2013), lo cual le confiere características propias de temperatura y humedad.

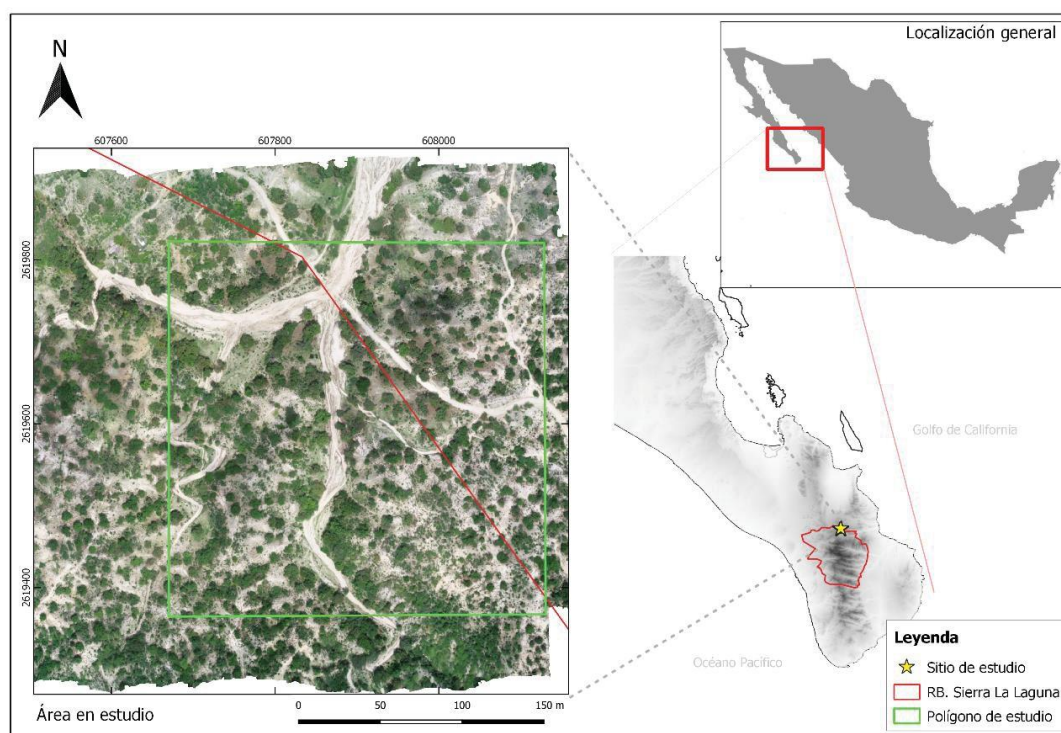


Figura 3. Área de estudio en San Antonio de la Sierra. Elaboración propia.

De acuerdo con la clasificación climática de Köppen, modificada por García (2004), en Sierra La Laguna se han reconocido diferentes subtipos climáticos diferenciados por el efecto altitudinal y ubicación con respecto al mar (Coria, 1988). Particularmente por su altitud, entre 700 y 800 msnm, San Antonio de la Sierra, se caracteriza por tener un clima semi seco BS₁hw(e), con una temperatura media anual entre 18 y 20°C (Arriaga, 1994), con lluvias intensas en los meses de julio a septiembre con un total anual de 200 a 400mm de acuerdo con la estación más cercana, Agua de San Antonio (Fig. 4) y un porcentaje de lluvia invernal entre 5 y 10% (Arriaga, 1994; SMN, 2020).




Figura 4. Climograma de la temperatura y precipitación media anual registrada en el periodo 1998-2017 por la estación Agua de San Antonio. Fuente SMN.

Los suelos de la Sierra de la Laguna se originan de rocas graníticas, por lo que es característica su textura gruesa (Arriaga, 1994). En San Antonio de la Sierra dominan los litosoles asociados a regosoles eútricos, suelos delgados y poco desarrollados que están limitados por roca; con consistencia suelta, con cero adhesividad y plasticidad (Maya, 1988; 2012). El sitio presenta un cambio de pendiente de 0 a 71 ° de acuerdo con las partes más altas, lo que indica el ángulo de inclinación del terreno con respecto a la horizontal.

Con relación a la vegetación, el sitio de estudio en San Antonio de la Sierra, tiene una ubicación privilegiada ya que, se presenta en un ecotono entre selva baja caducifolia y bosque de encinos o *Quercus* marcando la transición entre la vegetación tropical y la boreal de Sierra La Laguna (Breceda *et al.*, 2015; INEGI, 2016).

Entre las especies características de SBC que se encuentran en el sitio de estudio, están: lomboy (*Jatropha cinérea*, *Jatropha cuneata*), papelillo o copal (*Bursera microphylla*), mauto (*Lysiloma divaricata*), mezquite (*Prosopis articulata*), palo verde (*Parkinsonia aculeata*), cacachila (*Karwinskia humboldtiana*), entre otros (Morelos, 1988; León De La Luz y Coria, 1992; Rzedowski, 2006). Con respecto al Bosque de encino, San Antonio de la Sierra se caracteriza por presentar las siguientes especies (Fig. 5):

- ***Quercus tuberculata*** Liebm. Es la especie de encino más abundante y mayormente distribuida a lo largo de la Sierra La Laguna, conocida como “encino roble”. Es un árbol deciduo de hasta 12 m de altura con hojas ovaladas o lanceoladas, gruesas y coriáceas de hasta 15 cm de longitud con bordes variables. Crece en suelos ligeramente ácidos con escasa materia orgánica. La pérdida de sus hojas se da entre primavera y verano (León De La Luz y Coria, 1992; Breceda *et al.*, 2015, Gallagher, 2018 b) que corresponde a la temporada seca y coincide con el periodo de mayores temperaturas y de menor cantidad de agua (González-Medrano, 2012). Esta especie no se encuentra enlistada bajo alguna categoría de riesgo por la Legislación Mexicana o Internacional (NOM-059-SEMARNAT-2010; Gallagher, 2018 b).
- ***Quercus albocincta*** Trel. Nativo a México (CONABIO, 2020). Localmente llamado “encino laurel”, con un reducido número de registros en la península y mejor representada en las sierras de Sonora y Chihuahua, en donde se desarrolla en las partes más bajas de las vertientes de la Sierra Madre Occidental desde los 340 hasta los 1400 msnm (González-Elizondo *et al.*, 2012; Flora del Noroeste de México, 2020). Es un árbol deciduo que puede crecer hasta 15 m. Generalmente crece en suelos con pocos nutrientes y cercano a arroyos. Tiene hojas aristadas coriáceas de hasta 16 cm de largo con 3-6

pares de agujas en punta a lo largo de los bordes. Florece de febrero a mayo con fructificación anual inconsistente (Flora del Noroeste de México, 2020).

La pérdida de hojas se da previo al verano (Gallagher, 2018 a). Esta especie no se encuentra enlistada bajo alguna categoría de riesgo por la Legislación Mexicana o Internacional (NOM-059-SEMARNAT-2010; Gallagher, 2018 a).

- ***Quercus devia*** Goldman. Conocido como “encino negro”, especie endémica de Baja California Sur y única en las zonas más altas de la sierra, conformando un bosque mixto con el pino piñonero (*Pinus lagunae*) (Carter, 1955; Rzedowski, 2006). Es un árbol perennifolio con hojas alternas y dientes aristados pequeños a lo largo de cada margen (León De La Luz y Coria, 1992). De acuerdo con la Lista roja de la IUCN, esta especie se encuentra en categoría de amenazada (Jerome, 2020).



Figura 5. Aspecto de las hojas de los encinos en la temporada seca (columna izquierda) y la temporada de lluvias (columna derecha). a) *Q. tuberculata*, b) *Q. albocincta* y c) *Q. devia*. Fuente: Trabajo en campo.




Figura 6. Apariencia de las tres especies de encinos en la temporada seca (a y c) y temporada de lluvias (b y d). Imágenes panorámicas con dos individuos de *Q. tuberculata* en la parte central (a y b). Imágenes con *Q. albocincta* a la izquierda y *Q. devia* a la derecha (c y d). Nótese la senescencia en *Q. albocincta* en la época seca. Fuente: *Trabajo en campo*.

6.2 Geoposicionamiento de encinos

Una superficie de 20.9 hectáreas fue delimitada, con la finalidad de geo-posicionar los encinos en el área. La geolocalización se registró mediante un receptor REACH RS+ de la empresa EMLID®, sistema global de navegación satelital en tiempo real (RTK/GNSS). Durante el geoposicionamiento se identificó la especie de cada individuo, registrándose un total de 372 encinos, de los cuales 246 (66%) correspondieron a *Q. tuberculata*, 82 (22%) a *Q. albocincta* y 44 (12%) a *Q. devia* (Fig. 7).

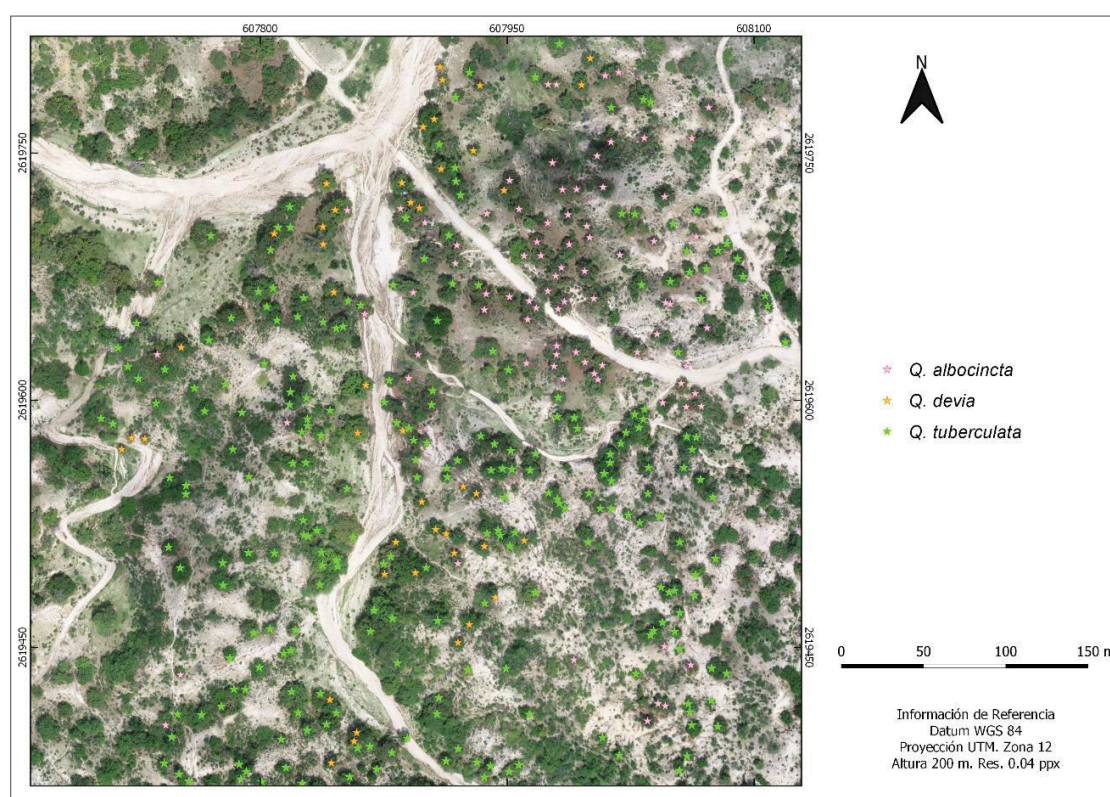


Figura 7. Geoposicionamiento de las 3 especies de encinos en el polígono de estudio. Elaboración propia.

6.3 Imágenes aéreas

Para la obtención de fotografías aéreas, se empleó un vehículo aéreo no tripulado modelo DJI Phantom 4 Pro, cuya cámara registra la reflectancia en el espectro visible de la luz en las bandas rojo, verde y azul (RGB). De forma simultánea, el dron se equipó con una segunda cámara de la empresa MAPIR modelo Survey 3, que registra la reflectancia en verde, rojo e infrarrojo cercano (GRN). Ambas cámaras poseen un sistema de posicionamiento global (GPS) integrado para proporcionar un geo-etiquetado a cada imagen capturada con una precisión de ± 3 metros.

Para la toma de fotografías con ambas cámaras, se diseñó una línea o ruta de vuelo personalizada mediante el software Ground Station Pro de DJI®. La ruta se compuso de líneas paralelas entre sí. GSP además permite capturar imágenes de forma automática para la generación de ortomosaicos. Para este trabajo se ajustó el traslape de las imágenes en un 85% en la parte frontal y 70% en la parte lateral, una velocidad máxima de 10 m/s y una altura de 200 m, de forma que se capturaron 75 fotografías por cada vuelo realizado. La hora de vuelo fue a medio día para minimizar el factor sombra causado por la trayectoria del sol. En cuanto a la cámara MAPIR, ésta no puede ser controlada con el software GSP, por lo tanto, se ajustó el intervalo de captura a 5 segundos entre cada toma para lograr un traslape similar a la de la cámara DJI.

Las fotografías aéreas fueron tomadas una vez al mes, durante 9 meses consecutivos a partir de abril del 2019. Sin embargo, con el fin de diferenciar a los encinos por sus características caducifolias, las cuales fueron identificadas *in situ*, se decidió emplear el mosaico del mes de abril para la temporada seca, en el cual la precipitación es nula (Fig. 8 y Fig. 9) y el de septiembre para la temporada de lluvias, mes que registra la mayor precipitación (Fig. 10). Ambos meses fueron elegidos debido al contraste en la coloración y en la cantidad de follaje de las especies arbóreas, ya que en el mes de abril los encinos se encontraban en fase senescente, aún con gran cantidad de follaje y los árboles característicos de SBC habían perdido sus hojas, característica que permitió caracterizar únicamente a los encinos. Por otro

lado, en el mes de septiembre, el follaje de los encinos era abundante, verde y vigoroso a diferencia de los meses secos.

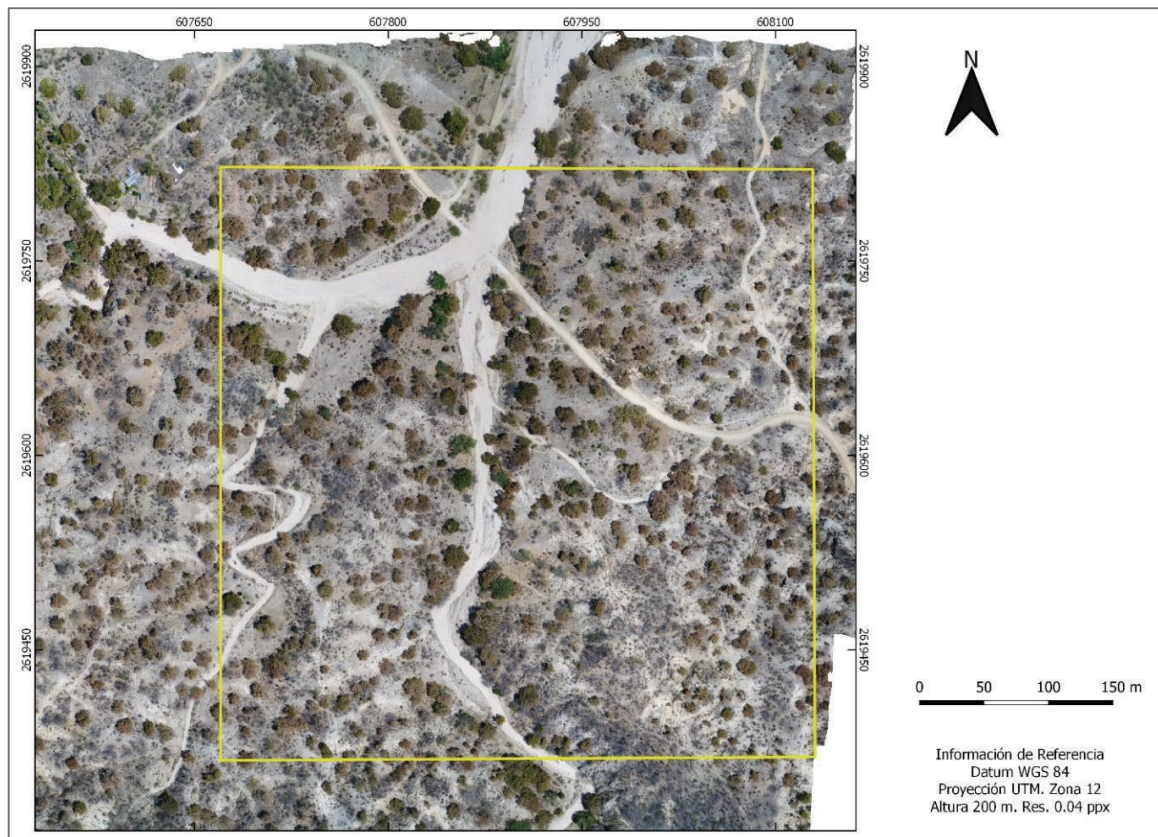


Figura 8. Ortomosaico RGB generado con imágenes obtenidas en la temporada seca (abril). El recuadro amarillo corresponde al polígono de 20.9 hectáreas en donde se geoposicionaron los encinos.




Figura 9. Ortomosaico generado con imágenes obtenidas en la temporada seca (abril) con el sensor GRN.

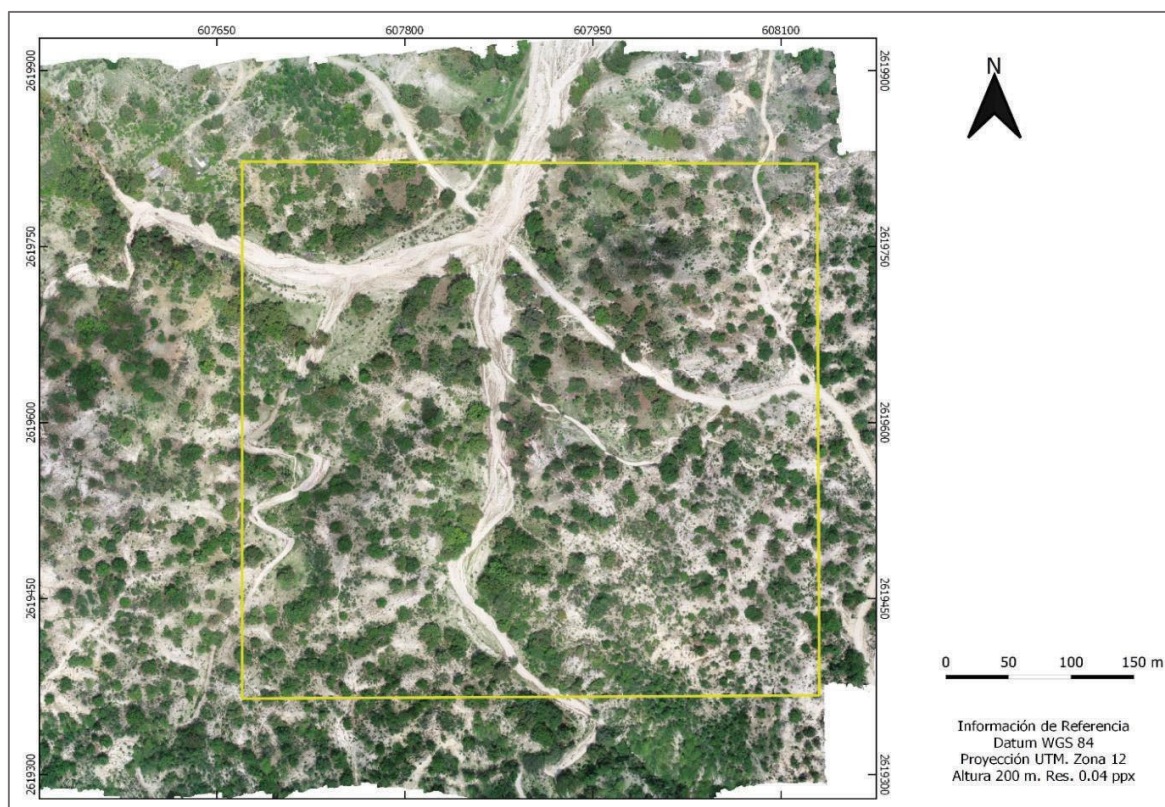


Figura 10. Ortomosaico generado con imágenes obtenidas en la temporada de lluvias (septiembre).

6.4 Procesamiento de imágenes y obtención de ortomosaicos

Mediante el software especializado en fotogrametría *Agisoft Metashape*®, se procesaron las imágenes obtenidas con el VANT. En correspondencia con el método propuesto por Feurer y Vinatier (2018), las imágenes obtenidas en las 2 temporadas se alinearon al mismo tiempo. Inicialmente se agregaron los 17 Puntos de Control (PC) georreferenciados *in situ* mediante el receptor REACH RS+, de esta manera el software reconoció la posición y orientación de los puntos geolocalizados en las imágenes de ambos meses y realizó la alineación de forma precisa, como resultado se creó una nube de puntos dispersa.

Posteriormente, se construyó una nube de puntos densa, con base en el cálculo de la profundidad de los metadatos en las fotografías, para así formar una malla con múltiples puntos que se interpolaron constituyendo todos los objetos en el sitio por encima del suelo.

Una vez obtenida la nube de puntos densa, con imágenes de los meses con mayor follaje (septiembre, octubre, noviembre y diciembre) se generó el modelo digital de superficie (MDS) y el modelo digital de terreno (MDT) (Agisoft., 2019). El MDS incluyó tanto la elevación del terreno como la de los objetos sobre este, mientras que el MDT incluyó la elevación del terreno con respecto al nivel medio del mar. Al sustraer el MDT al MDS, se obtuvo el modelo de elevación del dosel (MED), el cual representa la altura de todos los objetos por encima del terreno.

Finalmente, utilizando las fotografías obtenidas en cada uno de los vuelos, el software generó los ortomosaicos del sitio de estudio. En total se generaron tres ortomosaicos (Tabla I): dos correspondientes al mes de abril (RGB y GRN) y uno al mes de septiembre (RGB). El mosaico GRN no pudo ser generado para el mes de septiembre debido a una falla en el GPS del sensor infrarrojo, por lo tanto, las fotografías no pudieron ser procesadas. La resolución de los mosaicos se igualó a 20 cm por píxel debido a que ésta fue la resolución con la que se generó el MED.

Tabla I. Características de los mosaicos creados a partir de los diferentes sensores empleados.

Sensor	Fecha (2019)	Resolución espacial (cm/px)
RGB	Abril	5
GRN	Abril	10
RGB	Septiembre	5
MED	Septiembre/Octubre/ Noviembre/Diciembre	20

6.5 Estimación de índices de vegetación

A partir de los ortomosaicos creados en los meses de abril y septiembre, se calcularon 21 índices de vegetación basados en la parte visible de la luz (RGB) de acuerdo con Maimaitijiang *et al.* (2019) (Tabla II) y 10 índices basados en las bandas GRN (Xue y Su, 2017) (Tabla III).

Tabla II. Índices de vegetación calculados basados en el espectro visible (RGB).

ÍNDICES DE VEGETACIÓN	FORMULA
Rojo normalizado	$rn = \frac{RED}{RED + GREEN + BLUE}$
Verde normalizado	$gn = \frac{GREEN}{(RED + GREEN + BLUE)}$
Azul normalizado	$bn = \frac{BLUE}{(RED + GREEN + BLUE)}$
Índice de proporción verde rojo	$GRRR = \frac{GREEN}{RED}$
Índice de proporción verde azul	$GBRI = \frac{GREEN}{BLUE}$
Índice de proporción rojo azul	$RBRI = \frac{RED}{BLUE}$
Índice de intensidad de color	$INT = \frac{(RED + GREEN + BLUE)}{3}$
Índice de vegetación verde-rojo	$GRVI = \frac{(GREEN - RED)}{(GREEN + RED)}$
Índice de diferencia normalizada	$NDI = \frac{(rn - gn)}{(rn + gn + 0.01)}$
Índice Woebbecke	$WI = \frac{(GREEN - BLUE)}{(RED + BLUE)}$
Índice de kawashima	$IKAW = \frac{(RED - BLUE)}{(RED + BLUE)}$
Índice verde foliar	$GLI = \frac{(2 * GREEN - RED - BLUE)}{(2 * GREEN + RED + BLUE)}$
Índice de resistencia atmosférica visible	$VARI = \frac{(GREEN-RED)}{(GREEN+RED-BLUE)}$
IV exceso de rojo	$ExR = (1.4 * rn - gn)$
IV exceso de verde	$ExG = (2 * gn - rn - bn)$
IV exceso de azul	$ExB = (1.4 * bn - gn)$
IV exceso de verde menos exceso de rojo	$ExGR = (ExG - ExR)$
Índice vegetativo	$VEG = \frac{GREEN}{(RED * BLUE (1 - a))}$, $a = 0.667$
Índice de análisis de componentes principales	$IPCA = 0.994 * RED - BLUE + 0.961 * GREEN - BLUE + 0.914 * GREEN - RED $
Índice de color de la vegetación	$CIVE = 0.441 * RED - 0.881 * GREEN + 0.385 * BLUE + 18.78745$
Combinado	$COM = 0.25 * EXG + 0.3 * ExGR + 0.33 * CIVE + 0.12 * VEG$

Tabla III. Índices de vegetación basados en las bandas GRN.

ÍNDICE DE VEGETACIÓN	FORMULA
Índice de vegetación de diferencia normalizada	$NDVI = \frac{NIR - RED}{NIR + RED}$
Índice de vegetación de diferencia normalizada verde	$GNDVI = \frac{NIR - GREEN}{NIR + GREEN}$
Índice de vegetación ajustado al suelo	$SAVI = \frac{NIR - RED}{(NIR + RED + 0.5)} * (1 + 0.5)$
Índice de vegetación de proporción	$RVI = \frac{NIR}{RED}$
Índice de vegetación de proporción verde	$GVI = \frac{NIR}{GREEN}$
Índice de vegetación de diferencia normalizada rojo-verde	$GRNDVI = \frac{NIR - (GREEN + RED)}{NIR + (GREEN + RED)}$
Índice de vegetación diferenciada	$DVI = NIR - RED$
Índice de vegetación mejorado	$EVI = 2.5 * \frac{NIR - RED}{NIR + (2.4 * RED) + 1}$
Índice de vegetación no lineal	$NLI = \frac{NIR^2 - RED}{NIR^2 + RED}$
Índice de vegetación modificado ajustado al suelo	$MSAVI = 0.5 * (2 NIR + 1) - (\sqrt{(2NIR + 1)^2 - 8(NIR - RED)})$

* NIR. Infrarrojo cercano.

Para estimar los índices de vegetación de cada uno de los mosaicos se empleó el paquete *raster* (Hijmans, 2019) del software de acceso libre R (R Core Team, 2020) versión 3.5.3.

6.6 Clasificación Supervisada

Para evaluar cuál es el índice de vegetación que discierne de mejor manera elementos del área de estudio, se crearon 9 clases diferentes: 1) arbusto, 2) hojarasca, 3) otros árboles, 4) palmeras, 5) *Q. albocincta*, 6) *Q. devia*, 7) *Q. tuberculata*, 8) sombra y 9) suelo. Estas clases fueron geoposicionadas directamente en campo, clases: 1, 3-7, o a partir de los ortomosaicos, clases: 2, 8 y 9, con el software QGIS 3.4.3-Madeira.

Como primer paso de la evaluación del desempeño de estos índices, se crearon dos macro clases: 1) Vegetación (comprendió: arbusto, otros árboles, palmeras, *Q. albocincta*, *Q. devia*, *Q. tuberculata*) y 2) No vegetación (comprendió hojarasca, suelo y sombra). De manera tal, que se identificó al índice de vegetación que separa de una manera más adecuada la vegetación presente en el área de estudio y posteriormente se evaluaron la clasificación aplicada a las 9 clases creadas.

Para aumentar el número de datos y tener una mejor representación de la variabilidad de los valores de los píxeles de cada una de las clases, se aplicó un buffer de 40 cm a las posiciones geográficas. Cabe recalcar que, para mejorar el desempeño de la clasificación, se tomaron en cuenta únicamente los árboles con un diámetro de tronco mayor a 25 cm ya que el escaso dosel en los individuos con menor diámetro era imperceptible en las imágenes aéreas.

Con base en lo anterior descrito y utilizando el método de Bosques aleatorios o Random Forest (Breiman, 2001) se procedió a evaluar el desempeño de los índices de vegetación, basados en el espectro visible y en el infrarrojo cercano en los siguientes algoritmos:

Clasificación supervisada – Índice de Vegetación:

- a) Índice que por sí solo identificó mejor a las macro clases
- b) Índice que por sí solo identificó mejor a las 9 clases.

Clasificación supervisada – Índice de vegetación + MED:

- c) Índice asociado al MED que identificó mejor a las macro clases
- d) Índice asociado al MED que identificó mejor a las 9 clases.

Clasificación supervisada – Modelo de precisión general:

- e) Todos los Índices de vegetación asociados al MED para identificar a las 9 clases.

Random Forest es un método ampliamente usado por su capacidad de clasificar una gran cantidad de información con gran precisión (Pino-Mejías *et al.*, 2010; Medina M. y Ñique C., 2017; De Luca *et al.*, 2019; Puliti *et al.*, 2019). Este método selecciona variables al azar y construye árboles independientes, de modo que, la precisión de cada árbol depende de la fuerza de clasificación de los árboles individuales y una baja correlación entre ellos, es decir

aunque estos se consideren “ruidosos” el análisis genera una interacción entre ellos para posteriormente realizar la clasificación (Breiman, 2001). Este método se aplicó con el paquete *RandomForest* (Liaw y Wiener, 2002) del software R (R Core Team, 2020).

6.7 Evaluación de la Clasificación supervisada

Con los modelos de clasificación resultantes generados a partir de los algoritmos de clasificación, se obtuvieron con la paquetería *Caret* (Kuhn, 2019) las “matrices de confusión”. Método binario que representa numéricamente el desempeño del análisis y determina si las observaciones fueron clasificadas de forma correcta o no (Ting, 2017). La matriz de confusión emplea dos clases, una designada como la clase observada y otra como la clase predicha (Landis y Koch, 1977). A partir de la matriz de confusión se calculó la proporción de aciertos y errores generados por el algoritmo de clasificación. En este contexto la matriz se establece de la manera siguiente:

		Observación	
		Positivo	Negativo
Predicción	Positivo	VP	FP
	Negativo	FN	VN

De manera diagonal se mantienen los píxeles que han sido clasificados de forma correcta en cada categoría (verdadero positivo, VP y verdadero negativo, VN), mientras que los márgenes de la matriz determinan aquellos píxeles de cada categoría que han sido erróneamente clasificados, es decir, asignados a otra categoría y por ende llamados falsos positivos (FP) y falsos negativos (FN).

La misma paquetería se empleó para calcular los indicadores de precisión y kappa (Tabla IV) con los que se evaluó el desempeño de los modelos de clasificación sobre las especies objeto de estudio (Landis y Koch, 1977).

Tabla IV. Indicadores para evaluar el desempeño de clasificación.

Indicador		
Kappa de Cohen	$K = \frac{Pr(a) - Pr(e)}{N - Pr(e)}$	Es una proporción en un rango de 0 a 1, que indica la confiabilidad del modelo para clasificar todos los eventos observados. <i>Donde</i> , Pr(a): probabilidad de una estimación correcta, Pr(e): es la probabilidad de una correcta estimación en relación a lo que se esperaría por casualidad, N: total de observaciones (Cohen, 1960).
Precisión	$P = \frac{TP + TN}{VP + FP + FN + VN}$	Proporción de casos verdaderos positivos y verdaderos negativos que el modelo asignó de forma correcta.

Posteriormente, como producto final de los modelos de clasificación se generaron con la paquetería *raster* (Hijmans, 2019) del software R (R Core Team, 2020) los mapas temáticos o de predicción de cobertura de los modelos con mejor desempeño.

Una vez generados los mapas de predicción, estos estuvieron corrompidos por el ruido impulsivo generado por el reemplazo de valores atípicos de la clasificación, fenómeno que se conoce como efecto “sal y pimienta” y puede afectar significativamente la calidad de una imagen, además de implicar dificultades para el posterior análisis como lo es la clasificación y estimación de los elementos en las mismas (Gómez-Moreno *et al.*, 2014; Ma y Nie, 2018).

Para remover el efecto “sal y pimienta” del mapa temático con el mejor desempeño, se empleó la paquetería *rasterkernelEstimates* (Lisic, 2016) usando una ventana móvil de 9 x 9, la cual calcula la densidad de cada categoría con mayor probabilidad de ocurrencia de acuerdo a un radio de búsqueda tomando en cuenta los pixeles vecinos (Gómez-Moreno *et al.*, 2014; Ma y Nie, 2018).

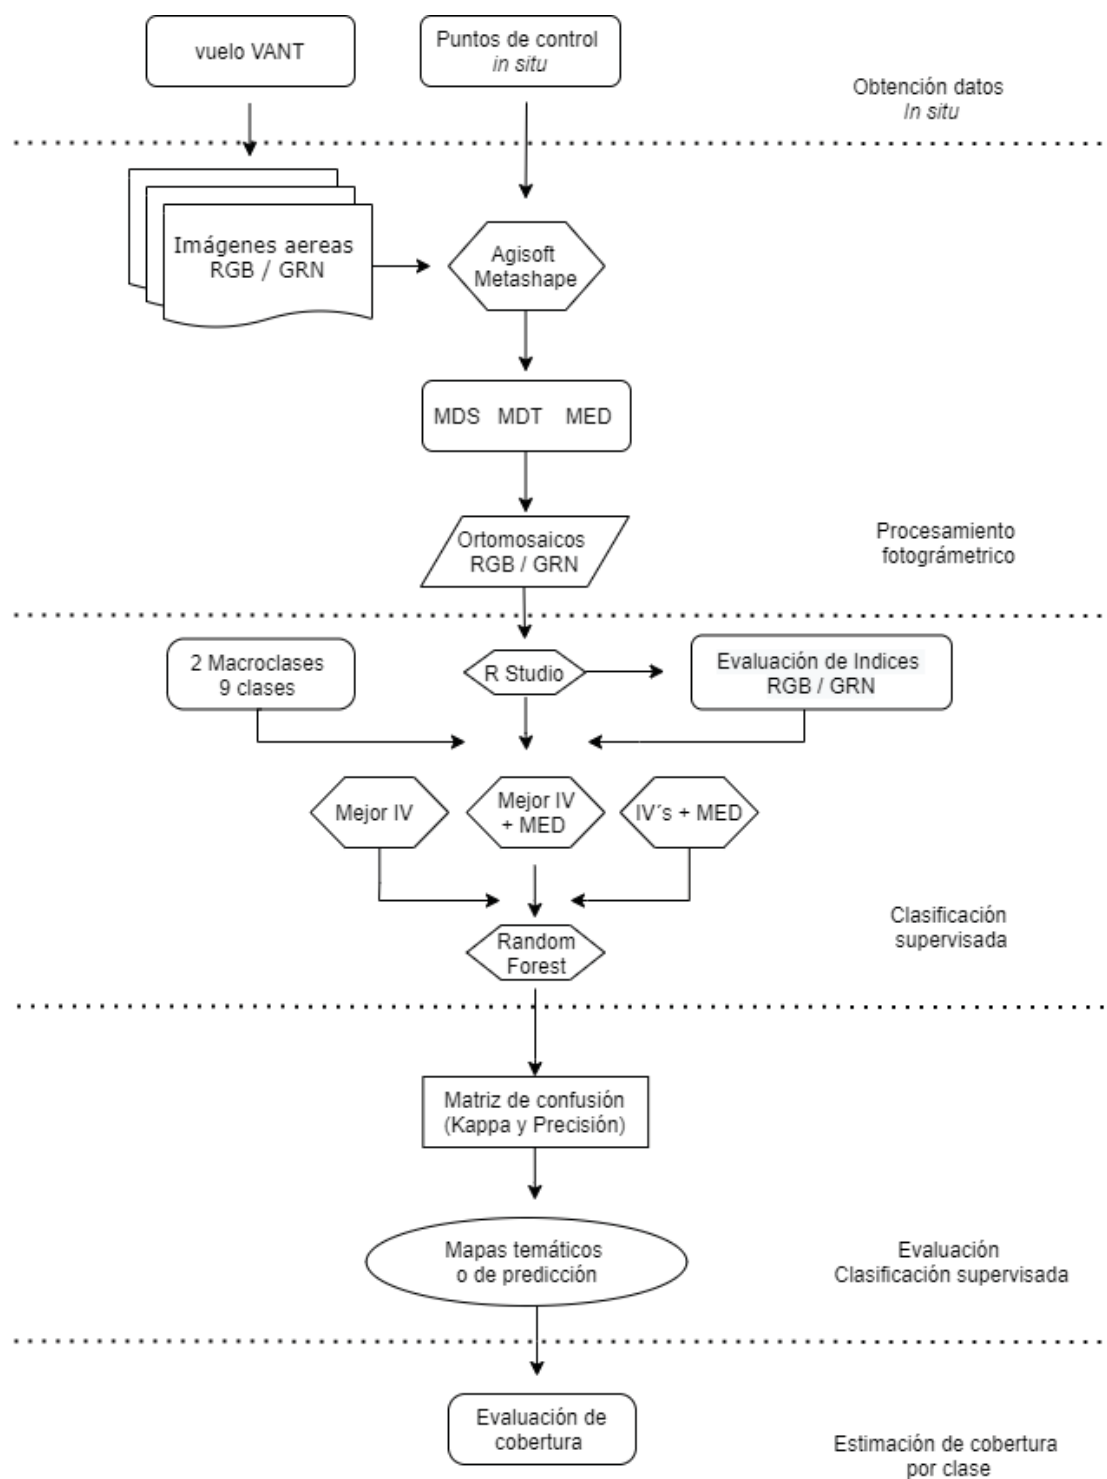


Figura 11. Diagrama de flujo de la metodología empleada. Elaboración propia.

6.8 Estimación de la cobertura de encinos

Con el modelo de clasificación supervisada con mejor desempeño, se estimó la cobertura por hectárea y porcentaje de todos los elementos en el área de estudio, esto mediante el software R (R Core Team, 2020) versión 3.5.3.

6.9 Desempeño del Modelo de elevación del dosel (MED)

Para evaluar el desempeño del MED, generado a partir de las fotografías aéreas y determinar si su uso permite reconocer características de la estructura vertical de un Bosque de encino, se compararon los valores con mediciones *in situ* de la altura de 117 encinos de las 3 especies presentes en el área de estudio. Las mediciones *in situ* se realizaron en los meses húmedos con un hipsómetro Nikon Forestry y con un estadal métrico se compararon las mediciones entre sí, resultando en una precisión del hipsómetro de ± 1 m. Los árboles medidos fueron geoposicionados previamente con el receptor RTK. La comparación de la altura *in situ* y la estimada por el modelo se realizó mediante una regresión lineal, misma que permite establecer el grado de relación que existe entre dos variables continuas.

7. RESULTADOS

7.1 Reflectancia de los píxeles en bandas RGB y GRN

Una vez definidas las clases en el estudio, se evaluó el comportamiento espectral de los píxeles en porcentaje de reflectancia para el mosaico RGB e infrarrojo cercano.

En el mosaico RGB (aprox. 400 –700 nm) de la temporada seca, la reflectancia del suelo superó el 80% en todas las bandas al tener un color muy claro. En cuanto a la banda roja, las clases *Q. tuberculata*, *Q. albocincta* y hojarasca tuvieron mayor reflectividad que en las bandas azul y verde, siendo la reflectividad de *Q. tuberculata*, *Q. albocincta* muy semejantes; mientras que en *Q. devia* y palmeras, la reflectividad tuvo mayor porcentaje en la banda verde, lo cual se debe a que sus hojas permanecen verdes todo el año a diferencia de los encinos (Fig. 12).

En la Figura 13 se muestra el comportamiento de reflectancia de los píxeles con el mosaico GRN para la temporada seca. En la banda del infrarrojo cercano, la clase palmera y hojarasca tuvieron mayor reflectancia (>10%) comparado con las medianas de las otras clases, en las cuales se observaron valores menores reflectancia, resultado esperado ya que la mayor cantidad de especies se encontraban en senescencia o habían perdido sus hojas disminuyendo la reflectancia del NIR, el cual es sensible a la vegetación vigorosa. En la Figura 12 y Figura 13, es notoria la semejanza en el comportamiento de los valores de los píxeles correspondientes a *Q. tuberculata* y *Q. albocincta*.

En la temporada de lluvias, con el mosaico RGB, la banda verde fue la que tuvo mayor reflectancia en comparación con la roja y la azul en las clases correspondientes a flora, esto de acuerdo con la teoría del comportamiento espectral de la vegetación, al presentarse todas las especies vegetales con follaje abundante y vigoroso (Fig. 14).




Figura 12. Valor de reflectancia obtenida por clase con el sensor RGB en temporada seca.




Figura 13. Valor de reflectancia por clase con el sensor GRN en temporada seca.




Figura 14. Valor de reflectancia obtenida por clase con el sensor RGB en temporada húmeda.

7.2 Clasificación supervisada – Desempeño de un Índice de vegetación

En total se estimaron 31 índices de vegetación, 21 basados en el espectro de luz visible y 10 en el infrarrojo cercano. Cada uno de los modelos generados evaluó 5839 píxeles. En general los índices basados en el espectro visible tuvieron un mejor desempeño que los basados en el infrarrojo cercano al clasificar las categorías definidas en el sitio de estudio. De forma general los modelos que fueron aplicados a las 2 macro clases tuvieron un mejor desempeño en comparación con los modelos que integraron a las 9 clases.

Para el análisis de la temporada seca, el IV basado en el RGB que por sí solo separó mejor a la clase “vegetación” de la clase “no vegetación”, fue el índice de Intensidad de color (INT). Por su parte, el mejor índice de vegetación basado en el GRN fue el índice de vegetación diferenciada (DVI). Sin embargo, el algoritmo la clasificación de la vegetación en la temporada de lluvias resultó mejor que durante la temporada seca, siendo el mejor índice basado en la parte visible de la luz el combinado (COM) (Tabla V).

Tabla V. Desempeño de los diferentes índices de vegetación en la clasificación vegetación y no vegetación para la temporada de lluvias (septiembre) y seca (abril).

IV RGB	SECA		LLUVIAS		IV GRN	SECA	
	Precisión (%)	Kappa	Precisión (%)	Kappa		Precisión (%)	Kappa
RN	91	0.35	93	0.46	NDVI	88	0.18
GN	89	0.24	99	0.88	GNDVI	90	0.32
BN	92	0.47	94	0.50	SAVI	92	0.37
GRR1	87	0.14	97	0.78	RATIO	92	0.41
GBRI	92	0.46	98	0.84	GVI	90	0.32
RBRI	95	0.42	88	0.01	GRNVI	91	0.34
GRVI	87	0.14	97	0.78	DVI	93	0.43
INT	96	0.72	96	0.63	EVI	91	0.38
NDI	88	0.17	97	0.78	NDVI.SQ	91	0.32
WI	93	0.50	98	0.86	MSAVI	91	0.40
IKAW	92	0.42	88	0.01			
GLI	89	0.24	99	0.88			
VARI	89	0.23	98	0.80			
EXR	88	0.18	97	0.76			
EXG	89	0.25	99	0.88			
EXB	92	0.47	94	0.50			
ExGR	87	0.08	98	0.84			
VEG	94	0.58	92	0.38			
IPCA	89	0.26	93	0.46			
CIVE	86	0.06	99	0.90			
COM	89	0.22	99	0.94			

La proporción de los píxeles que fueron correctamente clasificados se resume en la matriz de confusión tanto para la temporada seca como para la de lluvias (Tabla VI). En la clasificación, el índice COM basado en el espectro de luz visible en temporada húmeda resultó más precisa al clasificar correctamente el 99.6% de píxeles de “vegetación”, a diferencia de la temporada seca en donde el porcentaje de los píxeles correctamente clasificados como “vegetación” fue del 98% con el índice INT. En Anexo A se integra el mapa de predicción basado en el índice COM que tuvo mejor desempeño sobre los otros dos modelos.

Asimismo, en la clasificación basada en el infrarrojo cercano, el índice que por sí solo tuvo mejor desempeño (DVI), resultó con una clasificación correcta de los píxeles correspondientes a vegetación del 98.8%, no obstante, únicamente 34.5% de los píxeles fueron clasificados correctamente como elementos que no eran vegetación (suelo, hojarasca y sombra), incrementándose la proporción de falsos negativos (65.4%) de manera que el desempeño general del modelo fue del 93%, referido en el indicador de precisión (Tabla V).

Tabla VI. Matriz de confusión correspondiente a los 3 modelos aplicados a las 2 macro clases.

Temporada seca			
RGB		Vegetación (%)	No vegetación (%)
INT	Vegetación	98	2
	No vegetación	27.7	72.2
GRN		Vegetación (%)	No vegetación (%)
DVI	Vegetación	98.8	0.12
	No vegetación	65.4	34.5
Temporada de lluvias			
RGB		Vegetación (%)	No vegetación (%)
COM	Vegetación	99.6	0.4
	No vegetación	5.6	94.4

En los algoritmos de clasificación supervisada aplicados a las nueve clases establecidas sin el MED, se observó un descenso considerable en el desempeño de los índices de vegetación comparados con los modelos resultantes en donde únicamente se evaluaron las dos macro clases (vegetación/ no vegetación).

El modelo con mayor precisión que responde a las bandas del RGB fue el que empleó el índice RN en la temporada seca, con una precisión del 50% y 0.25 de kappa. En relación con el modelo en donde se evaluaron los índices que responden al NIR, el índice DVI fue el que tuvo un mejor desempeño con 53% de precisión y 0.15 valor de kappa. En cuanto al modelo evaluando índices sensibles al RGB para la temporada húmeda, el mejor índice fue el ExGR con un 47% de precisión y 0.18 de kappa (Tabla VII).

Tabla VII. Desempeño de los diferentes índices de vegetación en la clasificación de 9 clases, en la temporada de lluvias (septiembre) y seca (abril).

IV RGB	SECA		LLUVIAS		IV GRN	SECA	
	Precisión (%)	Kappa	Precisión (%)	Kappa		Precisión (%)	Kappa
RN	50	0.25	42	0.10	NDVI	40	0.10
GN	39	0.09	44	0.13	GNDVI	39	0.09
BN	47	0.22	40	0.09	SAVI	42	0.11
GRI	47	0.21	46	0.16	RATIO	41	0.10
GBRI	44	0.17	45	0.15	GVI	40	0.09
RBRI	47	0.20	37	0.03	GRNVI	39	0.08
GRVI	47	0.21	46	0.16	DVI	53	0.15
INT	47	0.16	41	0.10	EVI	41	0.12
NDI	47	0.21	44	0.14	NDVLSQ	42	0.12
WI	46	0.20	44	0.14	MSAVI	41	0.12
IKAW	47	0.21	37	0.03			
GLI	39	0.09	44	0.13			
VARI	49	0.24	45	0.15			
EXR	47	0.22	45	0.15			
EXG	39	0.09	44	0.13			
EXB	47	0.22	40	0.09			
ExGR	41	0.12	47	0.18			
VEG	39	0.08	40	0.08			
IPCA	46	0.19	41	0.10			
CIVE	40	0.11	44	0.14			
COM	39	0.10	44	0.14			

En la Figura 15 se muestran de manera gráfica las matrices de confusión de los modelos con el mejor desempeño para: 1) temporada seca utilizando el índice RN (Fig. 15a); 2) la misma temporada pero utilizando el índice basado en el infrarrojo DVI (Fig. 15b) y 3) temporada de lluvias utilizando el índice ExGR (Fig. 15c).

En estos gráficos cada clase está representada por un color, en donde los nodos o conexiones entre clases representan el porcentaje de error en los modelos, mientras que una correcta clasificación mantiene a las clases formando elipses perfectas sin interconexión entre ellas.

En la temporada seca, al utilizar el índice RN, un porcentaje de píxeles de todas las clases fueron clasificadas de manera incorrecta ya que todos los grupos se están sobreestimando con otros (Fig. 15a, Anexo B inciso a). Al emplear el índice DVI basado en el infrarrojo cercano en la misma temporada, la clase suelo fue la mejor clasificada, sin embargo, los píxeles incrementan a la clase *Q. tuberculata*, impidiendo así la clasificación correcta de las clases debido a la sobreestimación mencionada (Fig. 15b, Anexo B, inciso b). Finalmente, en la clasificación durante la época húmeda cuando se utiliza el índice ExGR, se aprecia un patrón similar al anteriormente descrito (Fig. 15c, Anexo B inciso c).

En el mapa temático creado a partir del mejor modelo de clasificación, se puede evidenciar que los componentes del sitio de estudio no se logran discernir unos de otros debido a la baja precisión de clasificación (Anexo B).

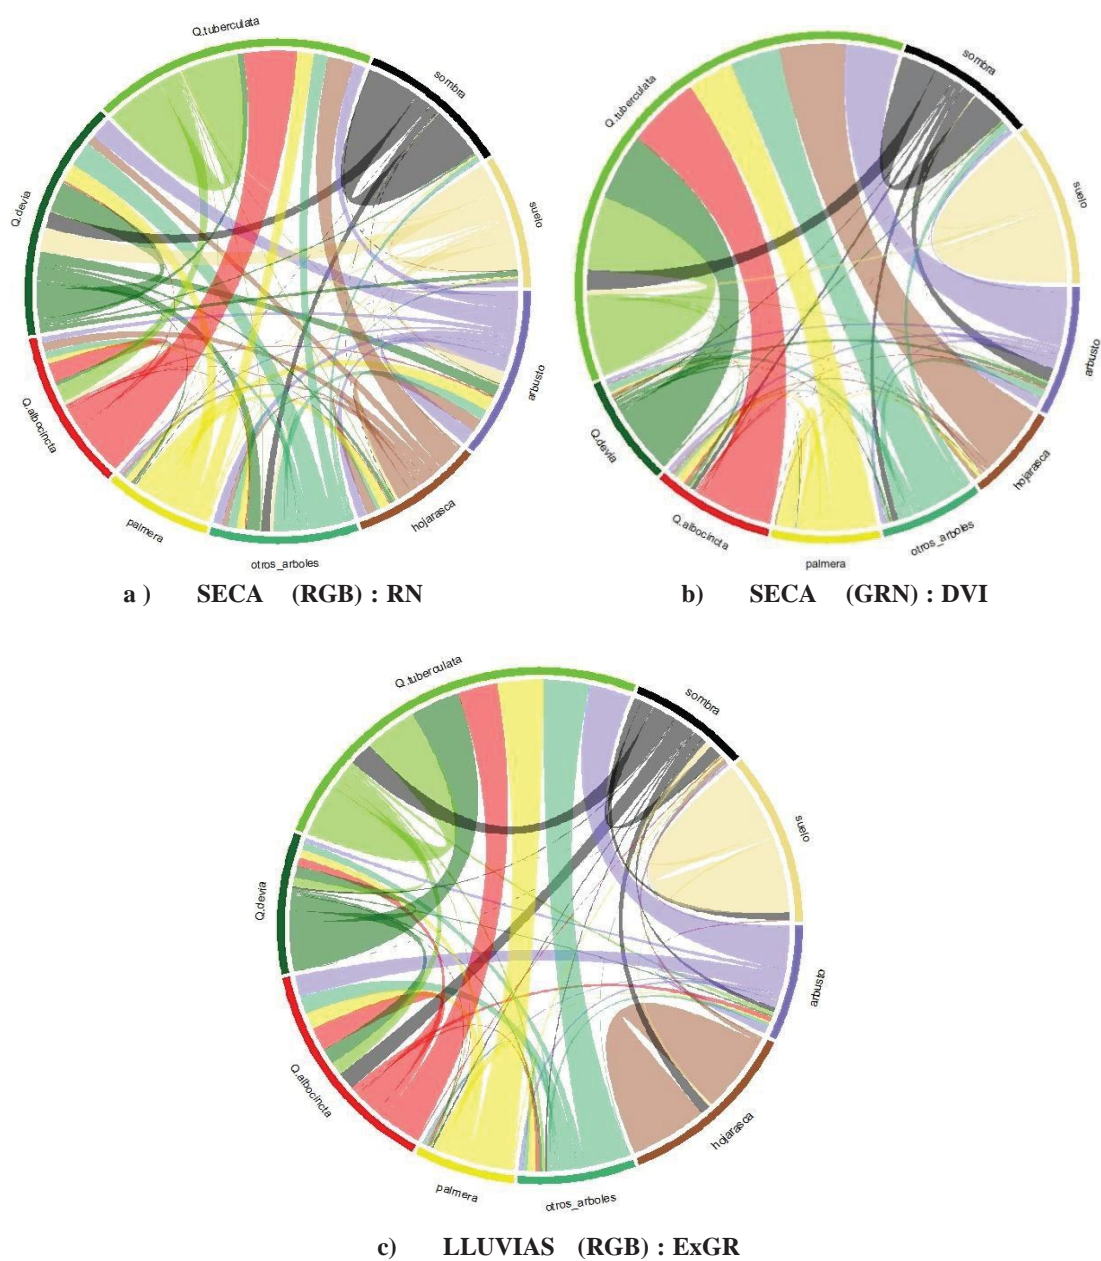


Figura 15. Diagramas circulares que muestran el comportamiento de clasificación de los píxeles basado en los modelos RGB y GRN al emplear el mejor índice de vegetación aplicado a las 9 clases. Cada clase es representada por un color. En Anexo B se encuentran las matrices de confusión numéricas que generaron los diagramas.

7.3 Clasificación supervisada – Desempeño de Índice de vegetación + MED

Al asociar el modelo de elevación del dosel al algoritmo de clasificación supervisada, con el fin de conocer el índice que integrado a la variable altura identificase mejor a las 2 macro clases, se obtuvo un aumento en la precisión de los modelos.

La comparación de ambas temporadas señaló que el modelo generado con mayor precisión correspondió al de la temporada húmeda, en el cual el mejor índice para clasificar fue el índice COM y cuyo desempeño reflejó una precisión del 99.81% y valor Kappa de 0.98, esto contra la temporada seca al usar el índice con mejor desempeño (INT), cuya precisión fue del 99.5% y valor de Kappa de 0.97.

En comparación con los dos modelos anteriores, el algoritmo que empleó el índice de vegetación de proporción verde (GVI), índice sensible al infrarrojo cercano, fue el de menor precisión con 96.8% y con un valor de Kappa de 0.803. No obstante, el GVI fue el índice que mejor clasificó a la vegetación a diferencia de los otros índices sensibles al GRN (Tabla VIII).

Tabla VIII. Desempeño de los diferentes índices de vegetación en la clasificación de vegetación y no vegetación integrando el MED, en la temporada húmeda (septiembre) y seca (abril).

IV RGB	SECA		LLUVIAS		IV GRN	SECA	
	Precisión (%)	Kappa	Precisión (%)	Kappa		Precisión (%)	Kappa
RN	97.9	0.87	98.85	0.902	NDVI	96.7	0.786
GN	97.5	0.82	99.1	0.925	GNDVI	96.7	0.798
BN	98.6	0.91	97.89	0.829	SAVI	96.5	0.769
GRR1	97.3	0.82	98.87	0.905	RATIO	96.4	0.765
GBRI	98.7	0.91	99.12	0.927	GVI	96.8	0.803
RBRI	98.2	0.88	97.89	0.823	GRNVI	96.8	0.799
GRVI	97.3	0.82	98.9	0.908	DVI	96.6	0.780
INT	99.5	0.97	98.2	0.846	EVI	96.3	0.759
NDI	97.3	0.82	98.85	0.903	NDVI.SQ	96.4	0.754
WI	98.8	0.92	99.27	0.940	MSAVI	96.4	0.760
IKAW	98.2	0.88	97.98	0.831			
GLI	97.6	0.83	99.15	0.929			
VARI	97.6	0.84	98.76	0.896			
EXR	97.5	0.83	98.89	0.907			
EXG	97.5	0.82	99.15	0.929			
EXB	98.6	0.91	97.81	0.824			
ExGR	96.8	0.78	99.04	0.921			
VEG	98.9	0.93	98.27	0.866			
IPCA	97.0	0.81	98.9	0.915			
CIVE	96.9	0.80	99.79	0.983			
COM	97.6	0.83	99.81	0.984			

En la matriz de confusión resultante (Tabla IX), se observa que en la temporada seca, al emplear el índice INT del espectro visible, el porcentaje de píxeles correctamente clasificados como vegetación y como no vegetación fue 99.7% y 98.5%, respectivamente, valores que en conjunto representan el 99.5% de exactitud del modelo (valor en Tabla VIII).

De forma semejante, en el modelo creado para la temporada húmeda, basándose en el espectro visible, el porcentaje de píxeles correctamente clasificados como vegetación (VP) fue del 99.9% y como no vegetación (verdaderos negativos) del 97.9%, lo que significó un 99.8% de precisión en la clasificación. En Anexo C se integra el mapa de predicción que corresponde al modelo basado en el índice COM, cuyo desempeño destacó sobre los otros.

Finalmente, el modelo creado para la temporada seca basado en el índice GVI (GRN) tuvo una precisión del 96.8% (Tabla VIII), en este caso, como resultado de que los píxeles clasificados correctamente como no vegetación (verdaderos negativos) resultaron en un 91.2% únicamente (Tabla IX), provocando la disminución en el desempeño general del modelo.

Al igual que el método en donde no se integra el MED, los índices que responden a las bandas del espectro visible tuvieron un mejor desempeño para identificar a todo aquello categorizado como vegetación comparándolos con los índices que responden al infrarrojo cercano. Por lo que, una vez que el MED es asociado al modelo, la separación de las dos clases mejora.

Tabla IX. Matriz de confusión resultante de las 3 predicciones de clasificación al incorporar el MED para identificar a la vegetación

Temporada seca			
RGB			
		Vegetación (%)	No vegetación (%)
INT	Vegetación	99.7	0.3
	No vegetación	1.5	98.5
GRN			
		Vegetación (%)	No vegetación (%)
GVI	Vegetación	97.2	2.8
	No vegetación	8.8	91.2
Temporada de lluvias			
RGB			
		Vegetación (%)	No vegetación (%)
COM	Vegetación	99.9	0.1
	No vegetación	2.1	97.9

Al integrar el MED a los modelos de clasificación supervisada aplicados a las 9 clases establecidas, se observó un incremento en el desempeño de los índices de vegetación en comparación con el modelo en donde se evaluaron 9 clases y no se integra el MED (Anexo D).

El modelo con mayor precisión en la temporada seca (que responde a las bandas del espectro visible) fue el que empleó el índice VARI, con una precisión del 72.7%. En relación al modelo que evaluó los índices que responden al infrarrojo cercano, el índice GVI fue el que tuvo un mejor desempeño con 62.4% de precisión, el cual estuvo por debajo del desempeño del índice RN (RGB) evaluado para la temporada húmeda con un 66.3% de precisión (Tabla X). Por lo anterior descrito, la clasificación empleando datos de la temporada seca, es la más adecuada.

Tabla X. Desempeño de los diferentes índices de vegetación en la clasificación de 9 clases, integrando el MED, en la temporada húmeda (septiembre) y seca (abril).

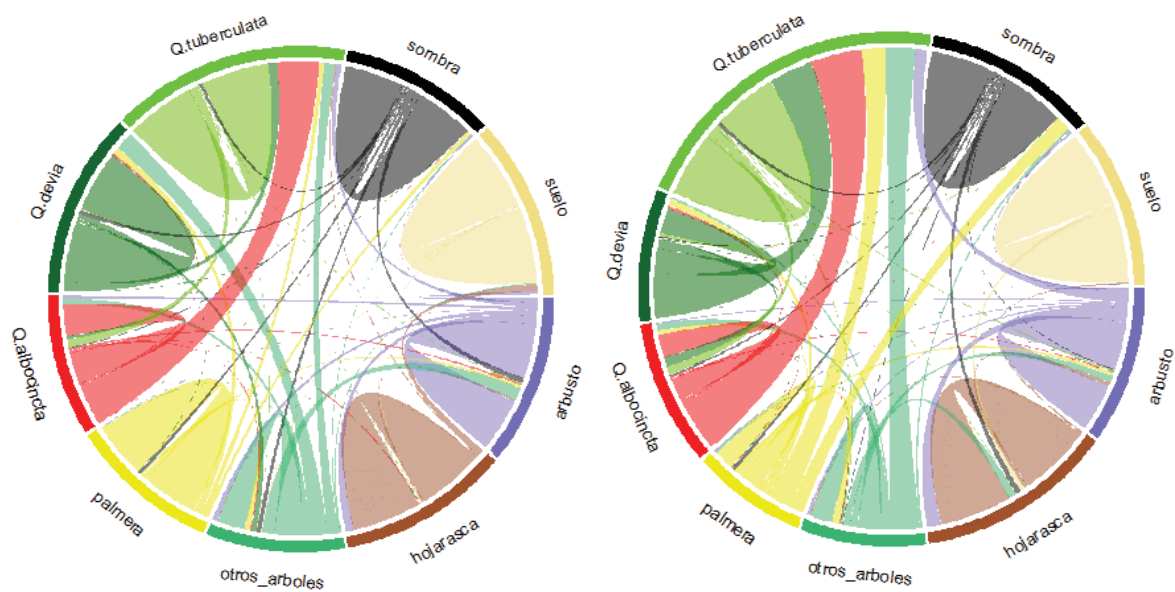
IV RGB	SECA		LLUVIAS		IV GRN	SECA	
	Precisión (%)	Kappa	Precisión (%)	Kappa		Precisión (%)	Kappa
RN	71.2	0.55	66.3	0.442	NDVI	60.7	0.3807
GN	64.1	0.44	63	0.389	GNDVI	62.4	0.4089
BN	68.3	0.50	62.5	0.376	SAVI	59.8	0.3590
GRR1	72.3	0.58	65.3	0.427	RATIO	59.3	0.3485
GBRI	66.1	0.47	63.3	0.395	GVI	62.4	0.4094
RBRI	68.7	0.51	63.3	0.393	GRNVI	60.8	0.3825
GRVI	72.3	0.58	65.4	0.428	DVI	61.6	0.3923
INT	61.1	0.39	61.3	0.347	EVI	60.0	0.3619
NDI	72.2	0.58	65.7	0.434	NDVI.SQ	60.6	0.3769
WI	68.3	0.51	63.1	0.391	MSAVI	59.0	0.3422
IKAW	68.6	0.51	63.1	0.39			
GLI	64.3	0.45	63.4	0.397			
VARI	72.7	0.59	64.9	0.418			
EXR	72.5	0.58	65.4	0.43			
EXG	64.3	0.44	63.2	0.393			
EXB	68.4	0.50	62.3	0.372			
ExGR	66.2	0.48	64.7	0.416			
VEG	61.2	0.38	60.1	0.335			
IPCA	67	0.49	65.6	0.436			
CIVE	65.8	0.47	65.3	0.428			
COM	64.5	0.45	65.6	0.435			

En la Figura 16 se muestran de manera gráfica las matrices de confusión de los modelos con el mejor desempeño para: 1) la temporada seca utilizando VARI + MED (Fig.16a); la misma temporada con un índice RGN: GVI + MED (Fig.16b) y 3) la temporada de lluvias utilizando RN + MED (Fig. 16c) (Anexo D, inciso a, b y c, respectivamente).

Como se aprecia en la Figura 16a, en la temporada seca al utilizar el índice VARI + MED, gran proporción de los pixeles correspondientes a *Q. albocincta* son clasificados como *Q. tuberculata*, mientras que una pequeña proporción de los valores de otros árboles son clasificados como *Q. devia*. Las otras categorías presentan una proporción baja de mala clasificación, lo que se aprecia en el mapa temático creado a partir de estos modelos (Anexo D), en donde *Q. tuberculata* está siendo sobrestimado en el área de estudio, debido principalmente a que una gran cantidad de pixeles que pertenecen a *Q. albocincta* y en menor proporción a otros árboles y arbustos, fueron clasificados como *Q. tuberculata*.


Con respecto a la clasificación de la temporada seca con un índice basado en el NIR, utilizando el algoritmo GVI + MED, la sobreestimación de *Q. tuberculata* es mayor debido a la alta presencia pixeles de *Q. devia*, *Q. albocincta*, palmeras, otros árboles y arbustos que incrementan la categoría *Q. tuberculata* (Fig. 16b). En el gráfico que muestra la matriz de confusión del modelo, se visualiza que la especie *Q. tuberculata* se sobreestima en mayor medida en comparación con el modelo clasificado con un índice RGB en la época seca.

Finalmente, en la clasificación en temporada de lluvias, cuando se utiliza el algoritmo RN + MED (Fig.16c), se aprecia un patrón similar al anteriormente descrito y de forma peculiar, en esta temporada, la clase sombra incrementó la categoría arbustos y suelo. Lo anterior se atribuye a que en este periodo los pixeles correspondientes a la sombra se confundieron con el suelo húmedo y el denso follaje de la vegetación, el cual generó un aumento en la respuesta espectral de la banda verde, la cual es característica de vegetación vigorosa.



a) SECA (RGB) : VARI + MED

b) SECA (GRN) : GVI + MED



c) LLUVIAS (RGB) : RN + MED

Figura 16. Diagramas circulares que muestran el comportamiento de la clasificación de los píxeles basado en los modelos RGB y GRN con el mejor desempeño al emplear el mejor índice de vegetación + MED aplicado a las 9 clases. En Anexo D se encuentran las matrices de confusión numéricas que generaron cada diagrama.

7.4 Clasificación supervisada – Modelo de precisión general

Una vez que el algoritmo de clasificación fue alimentado con todos los índices de vegetación (RGB y GRN) más el modelo de elevación del dosel, la clasificación mejoró en comparación con la clasificación de los modelos donde se evaluó cada índice por separado. En este caso, el modelo más confiable para clasificar a todos los elementos resultó ser el que incluye índices basados en la parte visible de la luz (RGB) en la temporada seca, con un desempeño general del 81 % y un valor de Kappa de 0.71 (Tabla XI).

Tabla XI. Comparación de los resultados del índice Kappa y de desempeño general (Precisión) de los modelos de clasificación integrando los IV y MED para evaluar a las 9 clases.

	SECA (RGB)			LLUVIAS (RGB)			SECA (GRN)		
	Mejor índice	Precisión	Kappa	Mejor índice	Precisión	Kappa	Mejor índice	Precisión	Kappa
IV	RN	50%	0.25	ExGR	47%	0.18	DVI	53%	0.15
IV + MED	VARI	72.7%	0.58	RN	66.3%	0.44	GVI	62.4%	0.40
IV's + MED	Todos	81%	0.71	Todos	74%	0.54	Todos	71%	0.55

En la matriz de confusión de este modelo (Anexo E, inciso a) se muestra la clasificación perfecta de la clase sombra con el 100% de píxeles correctamente clasificados y con un porcentaje mayor al 98%, la clase hojarasca y suelo. En referencia a la vegetación, los píxeles de los arbustos y palmeras correctamente clasificados tuvieron un valor igual o mayor al 90%, *Q. tuberculata* fue la especie de encino mejor clasificada con un 91% de verdaderos positivos, *Q. devia* con 84 % y *Q. albocincta*, fue el encino en el que se observó menor precisión de clasificación al obtener 41% píxeles bien identificados.

En el mapa de la predicción creado a partir del modelo de precisión general, adjunto en el Anexo E, se muestra una clara discriminación del encino negro (*Q. devia*). Por otro lado, se observa la sobreestimación del encino roble (*Q. tuberculata*) debido a que gran cantidad de píxeles fueron clasificados como éste a pesar de que corresponden al encino laurel (*Q. albocincta*).

En cuanto al modelo que empleó los índices que miden la reflectancia en el infrarrojo cercano (GRN) en la temporada seca, este obtuvo un desempeño del 71% con valor de Kappa de 0.55, valores que disminuyeron comparados con los obtenidos en el modelo basado en los índices del espectro visible (Tabla XI).

Al visualizar numéricamente en la matriz de confusión el desempeño de la clasificación supervisada del modelo GRN (Anexo E, inciso b), se puede observar que el porcentaje de verdaderos positivos correspondientes a la sombra, suelo y hojarasca fue mayor al 96%, considerándose una buena clasificación. No obstante, en relación con las especies de encinos, *Q. tuberculata* fue la especie que mejor se clasificó con un 87% de verdaderos positivos, *Q. devia* con un 56%; *Q. albocincta* con un 25% demostró ser la especie peor clasificada por el modelo. A causa de que *Q. devia* y *Q. albocincta* tuvieron una tendencia de ser clasificados como *Q. tuberculata*, este último se sobreestimó en la clasificación.

El desempeño de la clasificación con modelo generado en temporada de lluvias integrando el MED, fue similar al modelo generado con los índices que responden al infrarrojo cercano, con un Kappa de 0.54 y una precisión del 74% (Tabla XI). La matriz de confusión de este modelo (Anexo E, inciso c), señaló que *Q. tuberculata* resalta por ser la especie que mejor se clasificó con un 90% de píxeles bien identificados, seguido por *Q. albocincta* con 49%; *Q. devia* fue la especie que se clasificó con mayor inexactitud con solo el 30% de píxeles correctamente clasificados. Nuevamente los píxeles de *Q. devia* y *Q. albocincta* fueron clasificadas de manera equívoca como *Q. tuberculata*.

En la Figura 17, representación gráfica de las matrices de confusión generadas a partir de los modelos basados en todos los índices RGB/GRN + MED, respectivamente, se puede apreciar que en el modelo general de la temporada seca con el mosaico RGB, se discriminan mejor los elementos del sitio de estudio, ya que las clases representadas por elipses, muestran un mínimo de interconexiones entre ellas, es decir, menor porcentaje de error en la clasificación.

En específico, la clase sombra muestra una perfecta clasificación, de modo que la elipse que la forma no tiene ningún nodo dirigiéndose hacia otra clase. No obstante, pese a la información con la que se creó este modelo, *Q. albocincta* continúa clasificándose como *Q. tuberculata*. En la Figura 17a es evidente esta mala clasificación por el nodo o conexión que se dirige desde *Q. albocincta* hacia *Q. tuberculata*.

Con la aplicación de los índices de vegetación basados en el mosaico GRN (Fig.17b), se obtuvo que, *Q. albocincta*, *Q. devia*, palmeras y otros árboles son clasificados como *Q. tuberculata* al conectarse con esta clase.

Finalmente, en la clasificación aplicada para la temporada húmeda con índices basados en el RGB+MED, se muestra un patrón similar al descrito anteriormente en donde *Q. tuberculata* es sobreestimado por otras clases vegetales (Fig.17c).

Estos resultados sugieren que en el área de estudio tanto en la temporada seca como en la de lluvias, la presencia de *Q. tuberculata* es sobreestimada principalmente por *Q. albocincta*. Esto se confirma en el mapa temático al eliminar el efecto “sal y pimienta” presentado en la Figura 18.

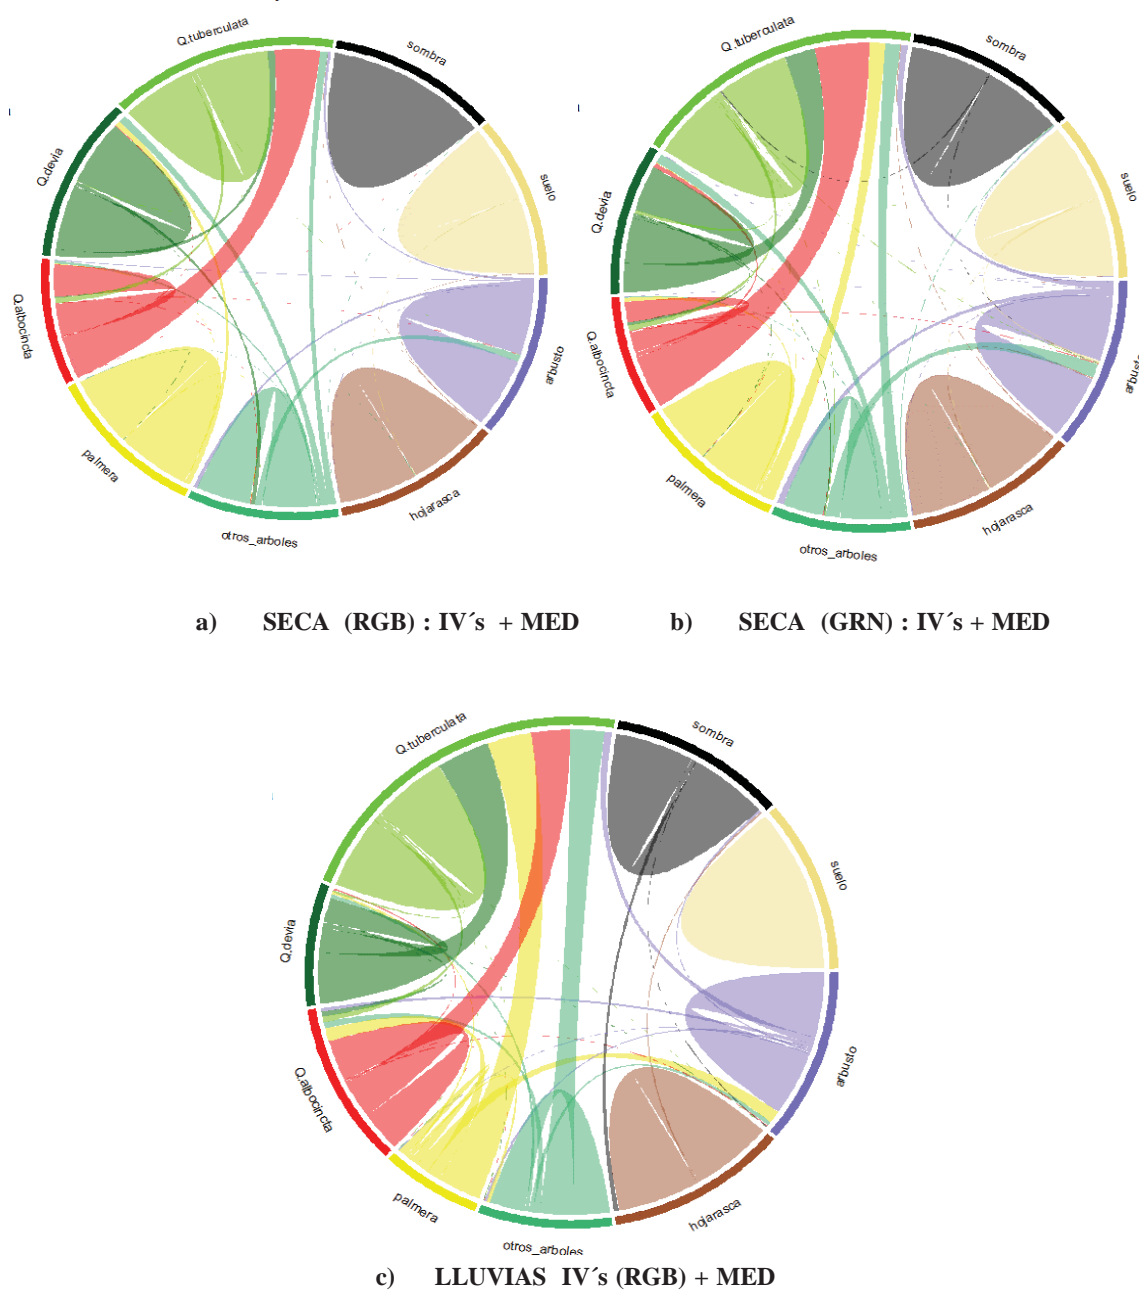


Figura 17. Diagramas circulares que muestran el comportamiento de la clasificación de los píxeles basados en los modelos que evaluaron todos los índices de vegetación + MED.

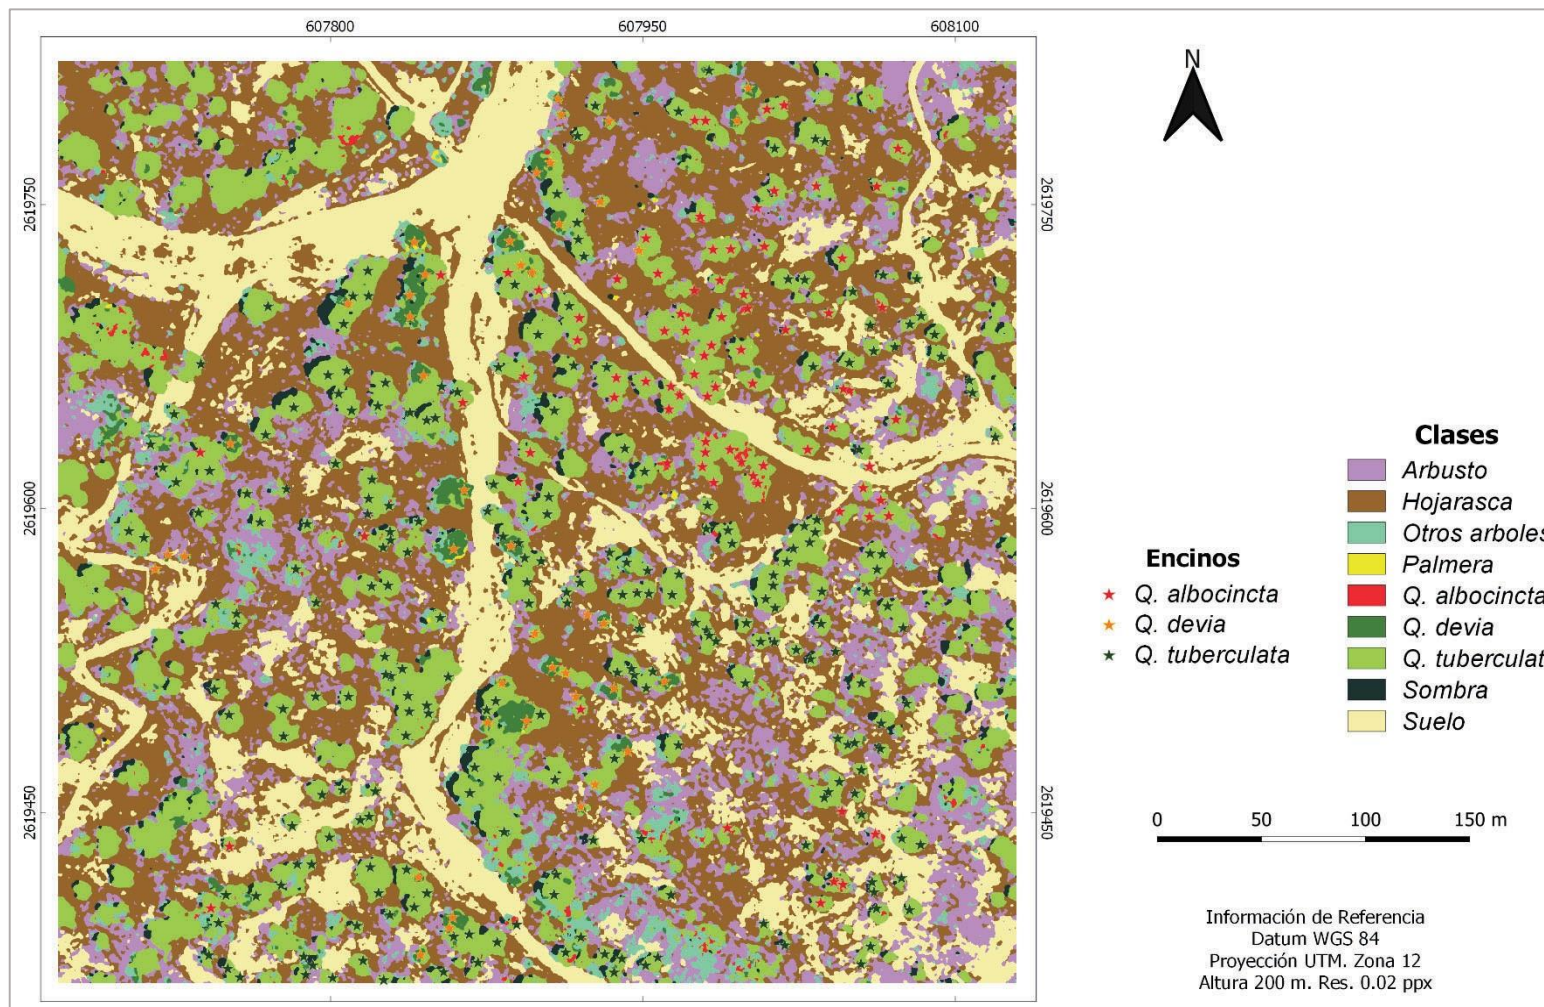


Figura 18. Mapa de predicción generado al remover el efecto “sal y pimienta”, a partir del mejor modelo de clasificación supervisada en la temporada seca al integrar los IV sensibles al espectro visible y el MED. Notese que en el cuadrante superior derecho(región noreste) donde se desarrolla *Q. albocincta*, el modelo no identifica a la especie (elaboración propia).

7.5 Cobertura de encinos

Una vez obtenido el modelo de clasificación que demostró mayor precisión (temporada seca), se cuantificó la cobertura de los elementos presentes en el polígono de estudio. La clase hojarasca es la que tuvo mayor cobertura en el polígono de estudio, seguida de la clase suelo.

En términos de cobertura, *Quercus tuberculata* fue la especie con mayor superficie cubierta (4.16 ha), que corresponde al 19.9 % de la superficie de estudio (20.9 ha), mientras que *Q. devia* solo cubre una superficie de 0.3 ha. Debido a que, en el modelo resultante para la temporada seca, los pixeles correspondientes a *Q. albocincta* presentaron un error de asignación de categoría en la clasificación supervisada, la superficie ocupada por esta especie únicamente resultó de 0.06 hectáreas (Tabla XII).

Respecto a la densidad encinos, *Q. albocincta* es la segunda especie más dominante con 4 ind ha⁻¹, después de *Q. tuberculata* con 12 ind ha⁻¹, mientras que la densidad de *Q. devia* fue estimada en 2 ind ha⁻¹ (Tabla XIII). En el mapa booleano, generado a partir del mejor modelo de clasificación obtenido, se puede evidenciar la presencia de encinos de la especie *Q. tuberculata* y *Q. devia*, ya que estos fueron identificados con un alto porcentaje de clasificación en el modelo de clasificación (IV's RGB+MED), sin embargo *Q. albocincta* no se logra apreciar debido al error de asignación en la clasificación del modelo (Fig. 19).

Tabla XII. Cobertura por categorías resultado del mejor modelo de clasificación supervisada en la temporada seca.

Clase	Hectáreas (ha)	%
arbusto	3.18	15.2
hojarasca	7.48	35.79
otros árboles	0.71	3.40
palmera	0.01	0.05
<i>Q. albocincta</i>	0.06	0.29
<i>Q. devia</i>	0.3	1.44
<i>Q. tuberculata</i>	4.16	19.90
sombra	0.38	1.82
suelo	4.62	22.11
Total	20.9 ha	100

En relación con las especies del SBC, las cuales se integraron en la clase “otros árboles”, su cobertura fue subestimada debido a que el modelo con mayor precisión fue generado en la temporada seca cuando estos árboles ya no presentaban hojas, y por consiguiente la cobertura resultante fue menor que la de los encinos.

Tabla XIII. Número de encinos por hectárea (ind ha⁻¹) presentes en el sitio de estudio.

Especie	ind ha ⁻¹
<i>Q. albocincta</i>	4
<i>Q. devia</i>	2
<i>Q. tuberculata</i>	12
Total	18

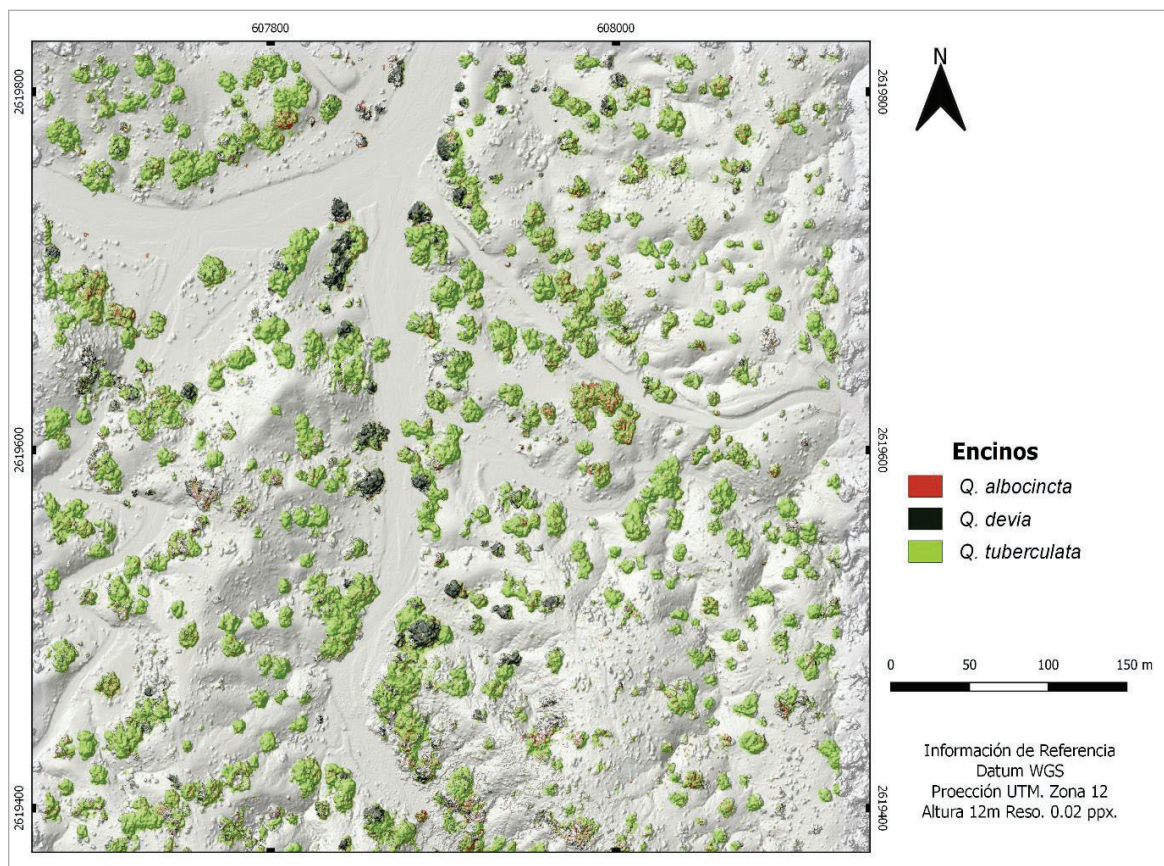


Figura 19. Mapa booleano de las especies de encinos en el área de estudio creado a partir del modelo de clasificación supervisada con mejor desempeño. Elaboración propia.

7.6 Estimación de la altura de encinos mediante el Modelo de Elevación del dosel

El análisis de regresión lineal sugiere que la altura de los árboles estimados a partir del MED de la vegetación presenta diferencias significativas con respecto a las mediciones en campo, debido a que la relación lineal entre ambas variables resultó de $r^2 = 0.29$, $p = 1.844 \times 10^{-10} < 0.05$, por lo que estadísticamente no hay correlación en los modelos, haciendo del MED un mal predictor. Como se aprecia en las Figura 20 y 21, el MED subestimó la altura de árboles con alturas menores a 5 m y sobreestimó la altura de los árboles de más de 10 m.




Figura 20. Gráfico de cajas y bigotes de la altura observada y altura estimada de los encinos.




Figura 21. Gráfico del modelo de regresión lineal de la altura registrada in situ y la altura estimada por el MED.

7.6.1 Estimación de la altura de encinos por especie

En el análisis de regresión individual se evaluaron 3 especies de encinos para determinar si el modelo era mejor predictor con cada una de ellas. Con base en lo anterior, el coeficiente de determinación para *Q. tuberculata* fue de $r^2 = 0.29$, $p = 5.36 \cdot 10^{-5} < 0.05$ (Fig. 22); para *Q. devia* de $r^2 = 0.31$, $p = 0.001284 < 0.05$ (Fig. 23) y para *Q. albocincta* de $r^2 = 0.46$, $p = 3.948 \cdot 10^{-6} < 0.05$ (Fig. 24). Estadísticamente se confirma que *Q. albocincta* es la especie mejor representada en el modelo de altura, aunque en las 3 especies se presentan diferencias significativas.




Figura 22. Gráfico del modelo de regresión lineal de la altura de *Q. tuberculata* registrada *in situ* y la altura estimada por el MED.




Figura 23. Gráfico del modelo de regresión lineal de la altura de *Q. devia* registrada *in situ* y la altura estimada por el MED.




Figura 24. Gráfico del modelo de regresión lineal de la altura de *Q. albocincta* registrada *in situ* y la altura estimada por el MED.

8. DISCUSIÓN

Este estudio describe la aplicación de la fotogrametría aérea a partir de imágenes obtenidas con un VANT para diferenciar especies de encinos en un área de Sierra La Laguna, BCS; especies arbóreas que son consideradas un elemento de importancia ecológica para la región por situarse entre las más áridas existentes en el país (León De La Luz y Coria, 1992) y por evolucionar de forma particular debido al aislamiento geográfico (Padilla *et al.*, 1988; Ortega *et al.*, 1989; CONANP, 2003), lo que convierte a la sierra La Laguna en una isla de vegetación rodeada por matorral xerófilo (McLaughlin, 1995; Breceda *et al.*, 2015).

Pese a su importancia ecosistémica, el reducido número de estudios a nivel específico que aporten información para la conservación del género *Quercus* en el BCS, encaminaron a este estudio a evaluar por medio de fotogrametría aérea a los encinos en la REBISOLA.

En el ecotono de SBC – Bosque de encino, comunidad vegetal en el que se situó el sitio de estudio, las temperaturas y porcentaje de humedad relativa favorecen los cambios fenológicos en las especies (Arriaga, 1994; Rzedowski, 2006), la vegetación es exuberante durante la temporada húmeda y contrasta con la fisonomía presente en temporada seca en la que los árboles pierden por completo sus hojas (Breceda *et al.*, 2014).

Para la temporada húmeda, empleando el mosaico del mes de septiembre, periodo en el que el follaje de todas las especies se encontraba vigoroso y denso, el comportamiento espectral de la vegetación con el sensor sensible a las bandas RGB mostró un porcentaje de reflectancia similar en las 3 bandas de todas las clases vegetales, sin embargo, en la banda azul y roja la reflectancia fue menor a diferencia de la banda verde en donde se generó mayor reflectancia, lo cual concuerda con la respuesta espectral generalizada de la vegetación sana y vigorosa (Chuvienco, 1995, 2002; Yengoh *et al.*, 2015). Lo anterior por ser el periodo con un follaje abundante gracias a la humedad dada por las precipitaciones (León de la Luz *et al.*, 2000; Rzedowski, 2006).

De forma contraria, en la temporada seca con el mosaico RGB, el rojo fue la banda que obtuvo mayor reflectancia en las diferentes especies vegetales, esto como resultado de que en estado senescente, el tejido vegetal pierde su capacidad fotosintética y la clorofila no ejerce la misma influencia en la absorbancia de la luz que con una hoja sana y vigorosa, dejando a la banda rojo reflejar un mayor porcentaje de luz; asimismo, el tejido esponjoso colapsa y el NIR refleja un menor porcentaje de luz (Boyer *et al.*, 1988; Pandey y Makkar, 1991; Mahajan y Raj Bundel, 2016).

En relación a los valores en el infrarrojo cercano en temporada seca, se registraron valores bajos en el NIR en la mayoría de las especies vegetales excepto en los pixeles de las palmeras, especies perennes que mantienen su vigor durante todo el año, por lo que es en esta banda, sensible a la vegetación vigorosa, en la que las especies senescentes tienen baja reflectancia, lo que concuerda con la teoría del comportamiento espectral, que afirma que en tejidos con bajo vigor el NIR disminuye su reflectancia (Rouse *et al.*, 1974; Yengoh *et al.*, 2015).

8.1 Modelos de clasificación supervisada con el mejor índice RGB o NIR

Evaluando únicamente dos macro clases “vegetación” y “no vegetación”, la precisión de los modelos fue mayor en comparación con aquellos en donde se evalúan una mayor cantidad de categorías. De acuerdo con Komárek *et al.* (2018) si la estructura o identificación a nivel especie de la vegetación no es requerida, es suficiente aplicar el método cuya información es mínima debido al contraste de reflectancia entre la vegetación y el suelo como únicas clases.

El índice con el mejor desempeño para reconocer a la vegetación durante la época de lluvia fue el COM, como su nombre lo dice, éste IV emplea la combinación de los índices: ExG, ExGR, CIVE y VEG. De acuerdo con Guijarro *et al.* (2011), el COM permite evitar la variabilidad de la cantidad de luz dispersada, al sumar los pixeles en donde la reflectancia del verde es mayor que la del rojo y azul (vegetación), más las regiones en donde el rojo y azul predominan (suelo). Esto explica el desempeño del COM, al separar pixeles que corresponden a vegetación de pixeles que corresponden a suelo, ya que en la temporada de

lluvias todas las especies vegetales, presentan un follaje vigoroso y conspicuo contrastándose en gran medida del suelo. Además, es en esta temporada cuando la presencia de individuos en estado senescente es menor.

En la temporada seca, en la clasificación de macro clases, los IV basados en el RGB presentaron mejor desempeño que aquellos basados en el NIR. Si bien los valores de precisión son similares entre varios IV basados en el RGB, el índice que tuvo el valor más alto de Kappa entre los 21 índices fue el INT. Al respecto, Ahmad y Reid (1996), quienes propusieron como índice aplicable el INT para detectar cambios en la intensidad de las tres bandas visibles, determinaron que al emplear este índice en hojas senescentes, se tiende a incrementar el rojo y este a su vez incrementa el verde y azul debido a una relación linear positiva entre las bandas en esta fase, sin embargo, visualmente se destaca el rojo debido a la ausencia de clorofila, por tanto, se asume que este índice fue mejor en detectar los árboles en la temporada seca debido a la cantidad de píxeles con coloración marrón correspondientes al follaje en estado senescente de *Q. tuberculata* y *Q. albocincta*, así como de muchas otras especies presentes en el sitio.

Para las nueve categorías, el desempeño de los modelos de clasificación con un solo IV no alcanzó el 55% de precisión en alguna temporada. Demostrando que, para el reconocimiento de especies, el uso de un solo IV en un algoritmo de clasificación como única información, es insuficiente para generar un modelo confiable de clasificación supervisada, lo cual puede deberse a la confusión espectral, la cual causa un porcentaje de error en la clasificación como resultado de variables como son, la resolución de la imagen, la variabilidad de las coberturas de terreno y el número de clases determinadas (Prieto y Luna, 1994). Asimismo, Komárek *et al.* (2018) determinaron que empleando como única información la resolución espectral, la identificación a nivel especie resulta poco precisa.

El índice RN o rojo normalizado demostró ser el índice que mejor desempeño tuvo cuando se aplicó en la temporada seca. Géé *et al.* (2008) indican que, al obtener el espectro normalizado de las bandas rojo, verde o azul, la intensidad de luz en cada banda se sensibiliza, esto explica que el índice RN resultase mejor en la temporada seca, ya que es en esta en la que color rojo se incrementa por el efecto de senescencia de las especies presentes.

Pese a que el desempeño del RN sin integrar los valores de altura del dosel o MED (precisión 50%) fue el mejor entre los 21 índices RGB evaluados, cuando se aplican 9 clases al algoritmo en la temporada seca, los índices son incapaces de diferenciar la hojarasca de las hojas que se mantienen aún en los árboles lo que podría deberse a que la hojarasca y las hojas senescentes de *Q. tuberculata* y *Q. albocincta* tienen un valor de reflectancia alto en la banda roja.

Aunado a lo anterior, el suelo también tuvo problemas al clasificarse debido a los altos valores de reflectancia producidos por el brillo característico de suelos secos y desprovistos de vegetación, tal como lo confirma Jackson (1983) al comparar la reflectancia del suelo seco y un suelo húmedo. Asimismo, Rondeaux *et al.* (1996) afirman que la reflectancia del suelo está dada por la combinación de las tres bandas: rojo, verde y azul, resaltando así su intensidad o brillo en los análisis de reflectancia.

El bajo desempeño de los IV basados en el NIR al clasificar nueve clases en temporada seca, podría estar relacionado con el hecho de que en zonas áridas o con baja cobertura vegetal, los valores de las bandas espectrales están dominados por el suelo seco, en consecuencia, los índices generan resultados inexactos al enmascarar el verdor de la vegetación a causa del brillo del suelo (Jackson, 1983; Huete *et al.*, 1985).

En el modelo GRN sin incluir el MED, el DVI fue el índice con mejor desempeño, según Elvidge y Lyon (1985) y Silleos *et al.* (2006) este índice, el cual se incluye en los IV que cancelan el efecto del brillo del suelo en zonas con escasa vegetación, le da peso al NIR al sustraer los valores de la banda roja; por lo que valores en cero indican suelo y positivos vegetación vigorosa.

Lo anterior podría explicar que la precisión empleando el DVI basado en las bandas GRN superara la precisión del modelo basado en el RGB por un 3%, sin embargo, debido a que en la temporada seca, el follaje que puede ser vigoroso o resaltar el NIR, corresponde únicamente al de las palmeras y a *Q. devia*, especies de menor abundancia en el área de estudio, la reflectancia en el NIR de estas especies no fue relevante sobre las especies senescentes, causando que, el modelo en su mayoría estuviese influenciado por el brillo del

suelo desprovisto de vegetación característico de zonas semi áridas, resultando en un valor de kappa de 0.15, por debajo del índice RGB en temporada seca (kappa = 0.25).

El modelo generado en la temporada de lluvias sin el MED, evaluado con el índice ExGR, índice con mejor desempeño entre 21 índices RGB, resultó con menor precisión al compararse con el modelo de la temporada seca. Se infiere que a pesar de que el índice ExGR identifica el verdor de la vegetación, éste tiene como supuesto que las plantas muestren un verde brillante con el suelo como único elemento de fondo, porque factores como las condiciones ambientales, el momento de captura, el estado de salud de las plantas, el porcentaje de humedad, etc., afectan la respuesta espectral de la vegetación (Yang *et al.*, 2015), por lo que, la presencia de diferentes elementos en el sitio de estudio, como hojarasca, suelo húmedo, pasto, herbáceas y cielo nublado pudieron ocasionar una baja precisión en el modelo.

Finalmente es importante mencionar para la presente investigación que, los valores de uno de los índices mayormente empleados para el monitoreo vegetal (NDVI) no se cumplen cuando este es estimado a partir de imágenes tomadas desde un VANT. De forma teórica, el uso del NDVI es práctico ya que toma valores positivos en presencia de vegetación vigorosa (Rouse *et al.*, 1974; Gilabert *et al.*, 1997), sin embargo, en esta investigación el comportamiento espectral de los píxeles mostró tanto valores positivos como negativos en presencia de vegetación.

Al respecto, los resultados sugieren que cuando los IV son evaluados de forma individual, el uso de los IV basados en la parte visible de la luz (RGB) en temporada seca, son los más adecuados para la separación de los elementos que cubren el sitio de estudio y su desempeño es mayor en la época de lluvia, cuando el algoritmo de clasificación es aplicado con solo dos macro clases.

8.2 Modelo de clasificación supervisada integrando el mejor índice + MED

Al incluir al algoritmo de clasificación los valores de altura de los encinos, inferidos a partir del MED, el modelo de clasificación incrementa los valores del índice Kappa de manera significativa. No obstante, este efecto fue mayor al aplicarse a las macro clases para el índice INT (RGB) en la temporada seca, el cual incrementó su valor de Kappa de 0.72 a 0.97 en presencia de los datos del MED; lo que implica que tanto los pixeles correspondientes a vegetación como los correspondientes a no vegetación fueron correctamente clasificados en casi el 100% de los casos.

Con base en lo anterior, los resultados de precisión de los modelos al evaluar 2 macro clases, concuerdan con Komárek *et al.* (2018), autores que comparan modelos de clasificación integrando por separado a: a) 2 macro clases o 24 clases que representan todos los elementos en el sitio de estudio, b) el MED y 3) la información espectral con las bandas RGB, NIR y LWIR (Long Wavelength Infrared); con sus resultados concluyen que la altura es un elemento significativo, que al integrarse a los modelos de clasificación, se logra una precisión elevada para detectar diferentes formas en la vegetación. Asimismo, concluyen que al reducir la información de las clases y usar sólo 2 macro clases e integrar el MED, el modelo de clasificación incrementa su precisión.

Una vez integrado el MED al algoritmo de clasificación aplicado a las 9 clases, la precisión de los modelos RGB y GRN evaluados con el mejor IV, respectivamente, se incrementó significativamente, reiterando que los valores de altura mejoran la clasificación. En este orden de ideas, el mejor modelo de clasificación fue el RGB con el índice VARI.

Gitelson *et al.* (2002) afirman que este índice fue creado inicialmente para imágenes satelitales y ayuda a mitigar los efectos de la atmósfera y diferencias en la iluminación, permitiendo entonces enfatizar la cobertura vegetal en la parte del espectro visible, por lo tanto, para las imágenes RGB de alta resolución, resulta idóneo ya que los efectos de la atmósfera generan una menor influencia sobre la reflectancia de la vegetación. Asimismo, de acuerdo con Lin *et al.*, (2015) con un VANT, el índice VARI puede organizar los espectros azul, verde y rojo de manera más eficiente y por ello puede retener espectros heterogéneos de las bandas RGB, lo que contribuye a un mejor desempeño en los modelos.

En el modelo VARI + MED en temporada seca, la reflectancia de la hojarasca en el suelo y de las hojas que aún permanecían en los encinos senescentes, generó una respuesta espectral elevada en la banda rojo, esto en virtud de que las hojas en esta temporada han perdido su capacidad fotosintética y su estructura foliar, originando la oxidación de taninos y carotenoides, aumentando la reflectancia en la banda rojo la cual enmascara al NIR y verde (Boyer *et al.*, 1988; Pandey y Makkar, 1991). En consecuencia, visualmente todas las hojas tenían una coloración rojiza o marrón, de manera que el modelo sin datos de altura no logró identificar diferencias entre las hojas en el suelo de las que permanecían en los árboles, no obstante, agregando el valor estimado de la altura arbórea (MED), el modelo logró identificar que hojarasca, sombra y suelo se encuentran a 0 m y los árboles, en este caso los encinos, superan los 2m.

Por lo mencionado arriba, uniendo los datos de altura (MED) con la reflectividad de la vegetación dada por el estado fenológico, se mejora la precisión del modelo y así la discriminación de especies en esta temporada. Lo anterior indica que la estimación de la altura provista por el MED se considera de gran importancia para identificar especies arbóreas, tal como lo demostró Sothe *et al.* (2019) al identificar árboles en un bosque tropical con una precisión del 74% integrando el MED a su modelo que contenía diferentes variables como IV RGB / NIR y la nube de puntos densa.

Es de enfatizar que, aunque los IV basados en el NIR han sido ampliamente usados por ser efectivos en el monitoreo vegetal gracias a la elevada respuesta espectral que tiene la vegetación saludable en el infrarrojo (Rouse *et al.*, 1974; Gilabert *et al.*, 1997; Yengoh *et al.*, 2015; Mahajan y Raj Bundel, 2016), utilizando un VANT, no fueron mejores que aquellos basados en el RGB, resultados que coinciden con Chianucci *et al.* (2016).

Investigadores han señalado diversos factores que afectan a los índices basados en el NIR (Colwell, 1974; Philpot, 2014), de acuerdo con ellos en esta investigación, las condiciones semiáridas, el estrés al que están sometidas las hojas en la temporada seca por el déficit de agua y la amplia cobertura descubierta del suelo, produjeron valores elevados de reflectancia, provocando la baja sensibilidad del NIR, afectando de esta manera a los índices basados en el GRN. No obstante, es de enfatizar que al incluir los valores del MED, la

precisión se incrementó del 53% al 62.4%, especificando que la información que aporta la estructura vertical del modelo es de significancia para la discriminación de la vegetación (Sankey *et al.*, 2017; Sothe *et al.*, 2019).

8.3 Evaluación del modelo de precisión general

Al reforzar el algoritmo de clasificación con todos los índices de vegetación más la altura del dosel, la precisión de los modelos para identificar diferentes clases incrementó hasta el 81%, porcentaje superior que el mostrado en los modelos que integran la información de forma aislada. Al respecto, estudios realizados sobre diferentes tipos de vegetación, han demostrado que la precisión de los algoritmos de clasificación se incrementa al integrar a los modelos información como, bandas multiespectrales (Sankey *et al.*, 2017; Ishida *et al.*, 2018; Komárek *et al.*, 2018; Tuominen *et al.*, 2018), diferentes índices de vegetación (Lisein *et al.*, 2015; Michez *et al.*, 2016; Baena *et al.*, 2017) y adicionalmente información de la estructura vertical de la vegetación, la cual está determinada por el MED (Giannetti *et al.*, 2018; Huang *et al.*, 2019; Sothe *et al.*, 2019).

Para el procesamiento de los modelos de clasificación, se ha reportado que el método de Bosques Aleatorios (Random Forest) es un método idóneo para la clasificación ya que es capaz de procesar una gran cantidad de variables explicativas de manera precisa con una tasa de error baja (Breiman, 2001; Pino-Mejías *et al.*, 2010; Lisein *et al.*, 2015; Michez *et al.*, 2016; Medina M. y Ñique C, 2017; Komárek *et al.*, 2018). Por lo que, en este trabajo, aunado al uso del método de Random Forest y la integración de 21 índices sensibles al RGB o 10 índices sensibles al NIR y el MED, se obtuvieron mejores resultados en la clasificación de las especies, que en el algoritmo que incluye un solo índice o un índice más el MED para la clasificación.

De manera específica se observó que el mejor modelo de clasificación fue aquel que considera los datos de altura y todos los IV basados en el RGB durante la temporada seca. Al respecto, Tay *et al.* (2018), después de comparar imágenes RGB y NIR, determinaron que las imágenes sensibles al espectro visible son la mejor opción para la clasificación de especies, pues son estas bandas las que enfatizan los cambios fenológicos de las mismas,

esto se debe a que durante las diferentes fases fenológicas, las especies modifican su reflectancia facilitando así su diferenciación (Gini *et al.*, 2014; Lisein *et al.*, 2015; Baena *et al.*, 2017; Rominger y Meyer, 2019; Huang *et al.*, 2019). Por su parte también Chianucci *et al.* (2016) concluyen que empleando un sensor RGB, se obtienen resultados confiables con un algoritmo de clasificación supervisada para estimar la cobertura del dosel.

En este sentido, el mejor periodo para reconocer a los encinos en un ecotono de SBC-bosque de encino, con imágenes de alta resolución, es la temporada seca previo a la pérdida de las hojas de los encinos, que de acuerdo a lo observado en campo correspondió al mes de abril, a mediados de primavera, fase en que las especies características de Selva Baja Caducifolia, han perdido por completo su follaje previniendo la época de mayor radiación solar (Rzedowski, 2006; León de la Luz *et al.*, 2012), de forma que el dosel en estas especies fue nulo durante el estudio, permitiendo así la evaluación exclusiva de los encinos cuyas hojas en abril aún se mantienen en los árboles.

En relación a los índices de vegetación basados en el NIR, se ha documentado para la percepción remota satelital, que estos presentan una serie de limitaciones para diferenciar especies de flora tales como, la cantidad de luz, el porcentaje de cobertura vegetal, el cielo nublado o el área foliar (Colwell, 1974). A partir de imágenes aéreas, estos índices han sido ampliamente utilizados para el monitoreo vegetal (García-Ruiz *et al.*, 2013; Mahajan y Raj Bundel, 2016; Kyratzis *et al.*, 2017), principalmente el NDVI, que emplea el NIR y el rojo, pues su teoría recae en factor de que el tejido esponjoso de las hojas sanas refleja mucha luz en el NIR, sin embargo, cuando la planta esta deshidratada o estresada, este tejido colapsa y la cantidad de luz reflejada disminuye incrementando la reflectancia en el rojo (Mahajan y Raj Bundel, 2016).

No obstante, se ha probado en diferentes tipos de vegetación que, los índices basados sólo en la banda NIR y roja, han resultado menos precisos en comparación con aquellos que además del NIR emplean de forma combinada a las bandas verde y azul, con esta combinación se mejora la sensibilidad para la descripción de la vegetación densa y vigorosa (Lisein *et al.*, 2013; Torres-Sánchez *et al.*, 2013; Michez *et al.*, 2016; Xue y Su, 2017).

Para el sitio de estudio, a pesar del empleo de índices que integran las bandas infrarrojo, verde y rojo (GRN), el modelo tuvo un desempeño menor al modelo que empleó todos los IV basados en el RGB, por lo que se infiere que el porcentaje de suelo desnudo, elemento característico de las zonas semiáridas (González-Medrano, 2012), y la cobertura vegetal en estado senescente que tiene baja reflectancia en la banda verde y azul, fueron factores que pudieron afectar los valores de reflectancia impidiendo un desempeño confiable de los modelos basados en el GRN, inferencia que podría evaluarse de tener los valores de un modelo GRN en temporada de lluvias.

De acuerdo con Jackson y Pinter, (1986), otro elemento que afecta la respuesta espectral de la vegetación en las bandas GRN, es el arreglo vertical del dosel en la temporada seca, debido a que el estado senescente de los árboles mantiene el follaje en una orientación inclinada, con bajo vigor, por lo que de esta manera se absorbe una menor cantidad de radiación incrementando la reflectancia y en consecuencia se generan datos inexactos. Si bien, pese a que las imágenes GRN en temporada de lluvias no pudieron ser analizadas, con este estudio se confirma que, el uso de un sensor RGB para discriminar especies de encinos en un ecotono de SBC-Bosque de encino, resulta ser un método confiable y más rentable ya que, este sensor es asequible en comparación con un sensor NIR o uno multiespectral (Chianucci *et al.*, 2016).

En cuanto a los cambios fenológicos de *Q. tuberculata* y *Q. albocincta*, en el presente trabajo, se evidenció mediante las gráficas del comportamiento espectral de los píxeles, que en estas especies la fase de senescencia esta sincronizada en los meses de marzo a junio, por lo que en el mes de abril, se observó una respuesta espectral semejante en las dos especies. Por esa semejanza, los cambios en su follaje son casi imperceptibles con las imágenes de alta resolución basadas en los IV del espectro visible y en consecuencia la sobreestimación de *Q. albocincta* por *Q. tuberculata*.

Asimismo, factores como el número de individuos muestreado de *Q. albocincta*, su filotaxia, la forma, tamaño o el ángulo de sus hojas, (Valladares y Brites, 2004) y/o la geometría de la copa (Guyot *et al.*, 1989), pudieron afectar el algoritmo de clasificación, el cual priorizó a *Q. tuberculata* sobre *Q. albocincta*. En cuanto a *Q. devia*, al ser una especie perennifolia, su follaje se mantiene siempre verde y se va sustituyendo de manera paulatina por lo que esta especie fue fácilmente discriminada por los índices RGB en la temporada seca.

Con base en lo anterior, las variaciones interanuales de las hojas modifican la absorbancia de la luz debido a su morfología y contenido de clorofila y nitrógeno, lo que se relaciona con sus cambios fenológicos. Al respecto diversos autores mencionan que a medida que el follaje de las especies crece, se aumenta en gran medida la absorbancia de la luz gracias a la disposición foliar y a los pigmentos fotosintéticos presentes, lo contrario sucede durante la senescencia (Noda *et al.*, 2015). Estas características causaron que, para la temporada húmeda la confusión espectral del follaje vigoroso y de gran cobertura, tanto de los encinos como de las especies de SBC, dificultara la descripción de las especies objeto de estudio al emplear IV sensibles al RGB.

8.4 Análisis de cobertura por especie

Empleando el modelo con el que se obtuvo una mayor precisión y mayor valor de kappa, se aseguró tener la mejor estimación para evaluar de manera precisa la cobertura por hectárea de cada especie. Al ser el mejor modelo el obtenido en la temporada seca, los árboles mejor representados fueron los encinos, ya que las especies o la mayoría características de SBC ya habían perdido sus hojas (León de la Luz *et al.*, 1994; Rzedowski, 2006), en consecuencia, la cobertura de estos árboles no pudo ser detectada por el modelo con tal precisión, datos que coinciden con Brubaker *et al.* (2014) quienes estimaron la cobertura de un bosque deciduo en dos fases fenológicas y determinaron que la mejor temporada para estimar la cobertura vegetal en un bosque tropical, es en la temporada cuando los árboles se mantienen con un follaje denso, no obstante, este escenario facilitó la discriminación de los encinos, nuestro género de interés.

De los encinos, *Q. tuberculata* fue la especie que ocupó mayor cobertura con un 19.9% de superficie cubierta en un total de 20.9 hectáreas, seguido de *Q. devia* con 1.44% y con menor superficie de ocupación, *Q. albocincta* con un 0.29%; al respecto León De La Luz y Coria, (1992); León de la Luz *et al.* (1994) y Breceda *et al.* (2014, 2015) describen que *Q. tuberculata* es el encino más frecuente en la Sierra La Laguna y este puede coexistir con especies de SBC en las partes bajas de la sierra, por lo que, encontrarlo en mayor porcentaje de cobertura en comparación con *Q. albocincta* y *Q. devia*, corresponde con lo observado por los autores mencionados.

En su estudio, León de la Luz y Domínguez-Cadena (2010), identificaron como “Bosque de Roble” a la comunidad que se desarrolla desde los 820 hasta los 1830 m, con *Q. tuberculata* como especie dominante y en menor proporción de encino negro y encino laurel, *Q. devia* y *Q. albocincta*, respectivamente. No obstante, en el Bosque de Roble descrito, también registraron en baja densidad especies de pino piñonero y madroño, árboles que se desarrollan por encima de los 1300 m (Rzedowski, 2006). Por lo que, debido al gradiente altitudinal y a las especies descritas en el presente trabajo, se considera que la comunidad vegetal no corresponde al “Bosque de Roble”, sino al que le antecede, el ecotono de SBC- Bosque de encino, distribuido a una altitud aproximada a los 800 m, por ende, la abundancia no corresponde a la misma presentada en el Bosque de Roble.

Por su parte, *Q. albocincta*, es descrita como una especie de distribución restringida en la Sierra (Arriaga *et al.*, 1992) considerándose un relicto en BCS (León de la Luz *et al.*, 1994). De acuerdo con el HCIB (2019), esta especie únicamente se ha registrado en San Antonio de la Sierra. Esto concuerda con la baja abundancia en el presente trabajo (4 ind ha⁻¹) en comparación con *Q. tuberculata* (12 ind ha⁻¹), no obstante, es de recalcar que factores como: la forma, tamaño o el ángulo de las hojas, la filotaxia (Valladares y Brites, 2004) y la geometría de la copa (Guyot *et al.*, 1989) de *Q. albocincta*, pudieron afectar el algoritmo de clasificación para identificar la superficie ocupada por esta especie, por lo que de acuerdo con el modelo ésta fue subestimada.

Con respecto a la especie *Q. devia*, ésta es comúnmente relacionada con el pino piñonero (*Pinus lagunae*) en el bosque de pino-encino en las partes más altas de la sierra, en donde claramente su abundancia es mayor que *Q. tuberculata*, (Arriaga *et al.*, 1992; León de la Luz *et al.*, 1994; León de la Luz y Domínguez-Cadena, 2010). En este estudio, *Q. devia* se evidenció de forma atípica en el ecotono de SBC-Bosque de encino (2 ind. ha⁻¹), con las especies *Q. tuberculata* y *Q. albocincta*; y como se esperaba de acuerdo con lo descrito por León de la Luz y Domínguez-Cadena (2010), en una abundancia mucho menor que la registrada en el bosque de pino-encino y en este caso en particular, se registró asociado a las orillas del arroyo intermitente, por lo que se infiere que al ser una especie que generalmente se encuentra en una zona templada, este requiere de condiciones de mayor humedad y menor temperatura.

Carter (1955), describe la presencia de *Q. devia* y *Q. tuberculata* al oeste de la localidad de Santiago a unos 850 msnm, altitud semejante a la de este estudio, y en cuyo gradiente altitudinal también predomina la SBC, la cual se extiende desde los 400 hasta los 1000 msnm (Arriaga, 1994). No obstante, Carter (1955) no describe la abundancia relativa de las especies de encinos, por lo que el presente estudio, generó información nueva de la abundancia y cobertura de los encinos en una localidad entre los 700 y 850 msnm en la sierra.

Por otra parte Arriaga *et al.* (1992), indican que a 700 msnm *Q. tuberculata* prevalece en una densidad de 250 ind. ha⁻¹ subsistiendo con elementos tropicales como *Lysiloma divaricata*, *Jatropha cinerea* y *Randia megacarpa*, especies observadas también en San Antonio de la Sierra. No obstante, dicho estudio no menciona al encino negro o encino laurel coexistiendo con el encino roble, por lo que la asociación de las tres especies de encino en conjunto con la vegetación de SBC, convierte a San Antonio de la Sierra en un sitio con características específicas y distintivas de la REBIOSLA y por ende este estudio da un preámbulo de la abundancia y cobertura de *Q. tuberculata*, *Q. albocincta* y *Q. devia*, en una localidad de BCS en la que coexisten, así como también del empleo de tecnologías novedosas sobre estas especies.

8.5 Evaluación del desempeño del MED para estimar alturas

Al evaluar a las 3 especies de encinos de manera asociada para estimar la altura mediante el MED, el coeficiente de determinación del modelo de regresión indicó una baja relación entre la altura observada en campo y la altura estimada por el modelo de elevación del dosel.

Panagiotidis *et al.* (2017), emplearon imágenes de alta resolución obtenidas con un VANT para estimar la altura de los árboles en dos parcelas ubicadas en un bosque de coníferas utilizando el modelo de elevación del dosel (MED) con una resolución de 0.05 m pp. Como resultados obtuvieron modelos de regresión lineal con $r^2 = 0.75$ y 0.63 , con lo que concluyen que la alta resolución fue óptima pero la forma discontinua del dosel generó errores en la estimación, sin embargo, los puntos de control que integraron al modelo y el factor del terreno plano ayudaron a que los valores de r^2 fuesen aceptables. En este contexto, en la presente investigación, factores como una resolución de 0.2 mpp y un relieve con pendientes mayores a 45° pudieron generar un ajuste por debajo del $r^2 = 0.5$.

Zarco-Tejada *et al.* (2014) emplearon un VANT en una plantación de olivos para comparar la eficiencia de modelos de elevación del dosel a diferente resolución (desde 0.045 mpp hasta 0.5 mpp) sobrevolando a 200 m, ellos obtuvieron un ajuste de $r^2 = 0.86$ a 0.045 mpp y de $r^2 = 0.5$ a 0.5 mpp. Lo que indica en nuestro estudio, que a una mayor resolución (>0.2 mpp), los resultados generados con los valores estimados del modelo de elevación del dosel pudieron tener un mejor desempeño, sin embargo, una desventaja es que la duración de los vuelos aumentaría debido a que la cantidad de fotografías a obtener incrementaría, así como el traslape de las imágenes, por ende, la cantidad de información y tiempo de procesamiento sería mayor y esto requeriría de una mayor capacidad del procesador empleado.

Para determinar si la baja determinación fue causa de considerar a las 3 especies en conjunto, estas se evaluaron de manera individual y con ello determinar si existía una mejor correlación por especie, la cual mejoró en *Q. albocincta* con $r^2 = 0.46$, seguida de *Q. devia* $r^2 = 0.31$ y la más baja en *Q. tuberculata* con $r^2 = 0.29$. Dadas las bajas correlaciones aun en cada especie, en este trabajo, la forma de la copa, la resolución y el relieve (Panagiotidis *et al.*, 2017; Giannetti *et al.*, 2018; Tuominen *et al.*, 2018) parecen haber sido los factores determinantes

en nuestro estudio para la correlación de la altura ya que incluso a nivel especie no mejoró el ajuste en gran medida .

Por otra parte, la densidad del follaje y el estado fenológico de las especies son factores determinantes para precisar la altura de las especies arbóreas (Huang *et al.*, 2019). Estos autores demuestran que la estimación del componente “altura” mediante el MED generado con un VANT, resulta más precisa en árboles con una mayor cantidad de hojas en el dosel, que en árboles cuyo follaje está ausente, esto se refiere a la etapa fenológica posterior a la senescencia y previo a la etapa vegetativa, cuando el crecimiento foliar apenas empieza.

No obstante, Giannetti *et al.* (2018) y Huang *et al.* (2019) mencionan que a pesar de que el follaje genera una predicción confiable de la altura arbórea, la diferencia de pendientes en el terreno afectan la precisión de los modelos de superficie (MDS), de terreno (MDT) y consecuentemente el de elevación del dosel (MED), ya que el espesor del follaje evita adquirir datos precisos del suelo con las imágenes obtenidas con un dron a diferencia de como lo haría un sistema LIDAR.

Con base en lo anterior, se infiere que la pendiente y la densidad de las copas presentes en los meses de la temporada húmeda, cuando el follaje era denso, empleados para generar el MDT, MDS y a partir de ellos el MED, fueron elementos que evitaron un mayor ajuste en el modelo de regresión lineal ya que el follaje impidió tomar los puntos del terreno cuya pendiente era irregular.

Esta aseveración también coincide con Chen *et al.* (2017) quienes demostraron que estimar la altura con un VANT produce resultados confiables en lugares donde la vegetación tiene una baja densidad, y en sitios con elevada cobertura, la altura de los modelos tiende a sobreestimarse.

9. CONCLUSIONES

En la temporada seca, los índices de vegetación basados en el espectro visible son mejores que aquellos basados en el infrarrojo cercano para identificar encinos mediante clasificación supervisada, lo que sugiere que un sensor sensible al RGB es suficiente para implementar la metodología propuesta y monitorear sitios con el mismo tipo de vegetación.

El estado fenológico de *Quercus tuberculata* y *Quercus devia* permitió su identificación con un valor alto de precisión en la temporada seca.

Los individuos de *Quercus albocincta* fueron subestimados con los de *Q. tuberculata*, debido a la semejanza en su respuesta espectral, por ende, el modelo implementado se considera impreciso para clasificar a *Q. albocincta*.

El modelo de elevación del dosel es una herramienta que mejora el desempeño de los modelos de clasificación y con él se lograron identificar a los elementos del sitio de estudio con un 81% de precisión.

La especie dominante en términos de cobertura y abundancia en San Antonio de la Sierra es *Q. tuberculata*, seguida en términos de abundancia de *Q. albocincta* y al final *Q. devia*.

El modelo de elevación del dosel generado a partir de fotogrametría no generó resultados precisos para conocer la altura de los encinos en San Antonio de la Sierra debido al relieve heterogéneo, el denso follaje en temporada húmeda, la resolución espacial y la geometría de las copas de las 3 especies de encinos.

Se generó un modelo de clasificación supervisada para identificar las especies de encinos presentes en el ecotono de SBC-Bosque de encinos en San Antonio de la Sierra y se concluye que la mejor temporada para identificar y cuantificar a estas especies, empleando el método Random Forest, es en la temporada seca, cuando los encinos están en senescencia.

Con la presente investigación se desarrolló una metodología práctica, precisa y económica que puede ser replicada en otras áreas de San Antonio de la Sierra e incluso en otros sitios

de la sierra con la cual se espera generar más información relacionada con el género *Quercus*, de forma que puedan establecerse prioridades sobre su manejo y conservación.

RECOMENDACIONES

Si bien, gran parte de la serranía forma parte del ANP REBIOSLA, San Antonio de la Sierra se localiza en la parte limítrofe de dicha zona protegida, zonificada como “zona de amortiguamiento”, en la que de acuerdo con el Plan de Manejo de la Reserva se permiten diversas actividades productivas para los pobladores de la sierra, tal como: ganadería, agricultura, aprovechamiento forestal, actividades turísticas, entre otras; que aunadas a la cercanía con asentamientos humanos puede ser la razón de que San Antonio de la Sierra presente un parche de erosión según lo documentado con imágenes satelitales por Maya (2013).

Por lo anterior, se recomienda aplicar el modelo en diferentes sitios de la sierra, ya sea, afectados por cambio de uso de suelo o sitios mayormente conservados y de esa manera comparar la distribución, abundancia y composición específica del género *Quercus* en la región de manera práctica y económica. Con lo cual, se puede definir el grado de conservación en el que se encuentran estas especies y de acuerdo con ello recomendar si se requiere la rehabilitación de sitios, entre ellos San Antonio de la Sierra.

Asimismo, dada la ausencia de información de *Q. albocincta* en el estado y a que fue la especie con mayor imprecisión de clasificación en el modelo, se recomienda emplear el algoritmo generado, modificando algunas de sus características para lograr la clasificación precisa de la especie a partir de imágenes aéreas de alta resolución y con ello identificar otros sitios de la sierra donde se pueda distribuir este encino además del área de estudio, ya que no se descarta su presencia en otros sitios de la sierra; datos con los que se ampliaría el conocimiento de esta especie considerada relicto y con ello generar planes de manejo específicos a esta especie.

10 LITERATURA CITADA

- Agisoft. 2019. Agisoft Metashape User Manual. 139.
- Ahmad, I.S. y J.F. Reid. 1996. Evaluation of colour representations for maize images. *Journal of Agricultural and Engineering Research*. 63(3):185–195.
- Alonso, C., V. Moreno, y E. Rodríguez. 1999. Determinación experimental de la firma espectral de la vegetación. Una sencilla práctica de introducción a la teledetección. 429–432p.
- Araque, L. y A. Jiménez. 2009. Caracterización de firma espectral a partir de sensores remotos para el manejo de sanidad vegetal en el cultivo de palma de aceite. *Revista Palmas*. 30(3):63–79.
- Arriaga, L. 1994. Estrategia para la conservación de la Sierra de la Laguna. Centro de Investigaciones Biológicas del Noroeste en colaboración con WWF, Baja California Sur, México.
- Arriaga, L., S. Diaz, y C. Mercado. 1992. The Oak and Oak-Pine Forests of Baja California Sur: Present State and Management perspectives. En: Ffolliott P. et al. (eds.) *Rocky Mountain Research Station Publications*. Arizona, EU. 41–48p.
- Arriaga, L. y A. Ortega. 1988. La Sierra de la Laguna de Baja California Sur. Centro de Investigaciones Biológicas del Noroeste S.C., Baja California Sur, México.
- Austin, R. 2010. *Unmanned Aircraft Systems. UAVs design, development and deployment*. Wiley, United Kingdom.
- Baena, S., J. Moat, O. Whaley, y D.S. Boyd 2017. Identifying species from the air: UAVs and the very high resolution challenge for plant conservation. *PLoS ONE*. 12:1–21.
- Bannari, A., D. Morin, F. Bonn, y A.R. Huete. 1995. A review of vegetation indices. *Remote Sensing Reviews*. 13(1–2):95–120.
- Berrío, V.A., J. Mosquera, y D.F. Alzate. 2015. Uso de drones para el análisis de imágenes multiespectrales en agricultura de precisión. *@limentech, Ciencia y Tecnología Alimentaria*. 13(1):28–40.

- Bonneval, H. 1972. *Photogrammetrie generale. I: enregistrement photographique des gerbes perspectives*. Eyrolles. Paris.
- Boyer, M., J. Miller, M. Belanger, E. Hare, y J. Wu. 1988. Senescence and spectral reflectance in leaves of northern pin oak (*Quercus palustris* Muenchh.). *Remote Sensing of Environment*. 25(1):71–87.
- Breceda, A., J. Sosa Ramírez, C. Leonor Jiménez Sierra, y A. Ortega Rubio. 2014. Conservación en la Reserva de la Biósfera Sierra la Laguna, Baja California Sur: logros y retos. *Investigación y Ciencia: de la Universidad Autónoma de Aguascalientes*. 60:78–84.
- Breceda, A., J. Sosa, C. Jimenez-Sierra, A. Ortega, y I.C. Espitia-Moreno. 2015. La Sierra La Laguna en Baja California Sur: importancia de su conservación. En: Ortega A. et al. (eds.) *Las Áreas Naturales Protegidas y la Investigación Científica en México*. Centro de Investigaciones Biológicas de Baja California Sur S.C., México. 473–492p.
- Breiman, L. 2001. Random forests. *Machine Learning*. 45:5–32.
- Brovkina, O., E. Cienciala, P. Surový, y P. Janata. 2018. Unmanned aerial vehicles (UAV) for assessment of qualitative classification of Norway spruce in temperate forest stands. *Geospatial Information Science*. 21(1):12–20.
- Brubaker, K.M., S.E. Johnson, J. Brinks, y L.P. Leites. 2014. Estimating Canopy Height of Deciduous Forests at a Regional Scale with Leaf-Off, Low Point Density LiDAR. *Canadian Journal of Remote Sensing*. 40(2):123–134.
- Camara, A.O. 2005. *Metodo Contextual Para Fusion De Datos*. Tesis de Maestría. Universidad Nacional Autónoma de México, Mexico.
- Carter, A. 1955. Observaciones sobre los encinos de Baja California. *Botanical Sciences*. (18):39.
- Casagleno S. 2000. Utilisation de données de télédétection pour la caractérisation d'un écotone en région tropicale de montagne: Exemple dans la Sierra de la Laguna, Basse Californie Sud Mexiqu. *Bulletin Societe. Francaise de Photogrametrie et Teledetection*. 160: 3-12.

- Chapin, F.S.I., P.A. Matson, y P.M. Vitousek. 2011. *Principles of Terrestrial Ecosystem Ecology*. USA.
- Chen, S., G.J. McDermid, G. Castilla, y J. Linke. 2017. Measuring vegetation height in linear disturbances in the boreal forest with UAV photogrammetry. *Remote Sensing*. 9(12):.
- Chianucci, F., L. Disperati, D. Guzzi, D. Bianchini, V. Nardino, C. Lastrì, A. Rindinella, y P. Corona. 2016. Estimation of canopy attributes in beech forests using true colour digital images from a small fixed-wing UAV. *International Journal of Applied Earth Observation and Geoinformation*. 47:60–68.
- Chuvieco, E. 1995. *Fundamentos de Teledetección espacial*. Unigraf S.A, España.
- Chuvieco, E. 2002. *Teledetección Ambiental. La observación de la tierra desde el espacio*. Ariel, España.
- Cohen, J. 1960. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*. 20(1):37–46.
- Colwell, J.E. 1974. Vegetation canopy reflectance. *Remote Sensing of Environment*. 3(3):175–183.
- CONANP. 2003. Programa de Manejo Reserva de la Biosfera Sierra La Laguna. D.F. Mexico.
- Coria R. 1988. Climatología. En Arriaga L. y A. Ortega (Eds). *La Sierra la Laguna de Baja California Sur*. Centro de Investigaciones biológicas de Baja California Sur. A.C., La Paz, Baja California Sur, México. 45-52 p.
- Cruzan, M.B., B.G. Weinstein, M.R. Grasty, B.F. Kohn, E.C. Hendrickson, T.M. Arredondo, y P.G. Thompson. 2016. Small Unmanned Aerial Vehicles (Micro-Uavs, Drones) in Plant Ecology. *Applications in Plant Sciences*. 4(9):11.
- Dash, J.P., M.S. Watt, G.D. Pearse, M. Heaphy, y H.S. Dungey. 2017. Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. *ISPRS Journal of Photogrammetry and Remote Sensing*. 131:1–14.
- Dymond, C.C., D.J. Mladenoff, y V.C. Radeloff. 2002. Phenological differences in Tasseled

- Cap indices improve deciduous forest classification. *Remote Sensing of Environment*. 80(3):460–472.
- Edwin., P. V. 2019. Drones a tool for efficient agriculture: A high-tech future. *Idesia*. 37(1):75–84.
- Elvidge, C.D. y R.J.P. Lyon. 1985. Influence of rock-soil spectral variation on the assessment of green biomass. *Remote Sensing of Environment*. 17(3):265–279.
- Feeley, K.J., T.W. Gillespie, y J.W. Terborgh. 2005. The Utility of Spectral Indices from Landsat ETM+ for Measuring the Structure and Composition of Tropical Dry Forests 1. *Special Section Biotropical*. 37(4):508–519.
- Feurer, D. y F. Vinatier. 2018. Joining multi-epoch archival aerial images in a single SfM block allows 3-D change detection with almost exclusively image information. *ISPRS Journal of Photogrammetry and Remote Sensing*. 146:495–506.
- Garcia-Ruiz, F., S. Sankaran, J.M. Maja, W.S. Lee, J. Rasmussen, y R. Ehsani. 2013. Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*. 91:106–115.
- García, E. 2004. Modificacones al sistema de clasificación climática de Köppen. Instituto de Geografía. Universidad Nacional Autónoma de México, México.
- Gates, D. M. 2003. *Biophysical Ecology*. Dover Publications. USA.
- Gée, C., J. Bossu, G. Jones, y F. Truchetet. 2008. Crop/weed discrimination in perspective agronomic images. *Computers and Electronics in Agriculture*. 60(1):49–59.
- Giannetti, F., G. Chirici, T. Gobakken, E. Næsset, D. Travaglini, y S. Puliti. 2018. A new approach with DTM-independent metrics for forest growing stock prediction using UAV photogrammetric data. *Remote Sensing of Environment*. 213(May):195–205.
- Gilabert, M.A., J. González-Piqueras, y J. García-Haro. 1997. Acerca de los índices de vegetación. *Revista de Teledetección*. 8:1–10.
- Gini, R., D. Passoni, L. Pinto, y G. Sona. 2014. Use of unmanned aerial systems for multispectral survey and tree classification: A test in a park area of northern Italy. *European*

Journal of Remote Sensing. 47(1):251–269.

Gitelson, A.A., Y.J. Kaufman, R. Stark, y D. Rundquist. 2002. Novel algorithms for remote estimation of vegetation fraction. 80:76–87.

Gómez-Moreno, H., P. Gil-Jiménez, S. Lafuente-Arroyo, R. López-Sastre, y S. Maldonado-Bascón 2014. A “salt and pepper” noise reduction scheme for digital images based on support vector machines classification and regression. Scientific World Journal. 15.

Gonzaga, C. 2014. Aplicación de índices de vegetación derivados de imágenes satelitales Landsat 7 ETM+ y ASTER para la caracterización de la cobertura vegetal en la zona centro de la provincia de Loja, Ecuador. Tesis de Maestría. Facultad de Ingeniería y Facultad de Ciencias Astronómicas y Geofísicas de la Universidad Nacional de La Plata. Ecuador., Ecuador.

González-Elizondo, M.S., M. González-Elizondo, J.A. Tena-Flores, L. Ruacho-González, y I.L. López-Enríquez. 2012. Vegetation of Sierra Madre Occidental, Mexico: A synthesis work. Acta Botanica Mexicana. 100:351–403.

González-Medrano, F. 2012. Las zonas áridas y semiáridas de México y su vegetación. Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT), Mexico.

González, A., E. Charlotte, P. Garcillan, y E. Ezcurra. 2010. Ecorregiones de la península de Baja California: Una síntesis. Boletín Sociedad Botánica de México. 87:69–82.

Grenzdörffer, G.J., A. Engel, y B. Teichert. 2008. The photogrammetric potential of low-cost UAVs in forestry and agriculture. International Society for Photogrammetry and Remote Sensing. 3:1207–1214.

Guijarro, M., G. Pajares, I. Riomoros, P.J. Herrera, X.P. Burgos-artizzu, y A. Ribeiro. 2011. Automatic segmentation of relevant textures in agricultural images. Computers and Electronics in Agriculture. 75(1):75–83.

Gutman, G.G. 1991. Vegetation indices from AVHRR: An update and future prospects. Remote Sensing of Environment. 35(2–3):121–136.

Guyot, G., D. Guyon, y J. Riom. 1989. Factors affecting the spectral response of forest

- canopies: A review. *Geocarto International*. 4(3):3–18.
- Halffter, G. 2011. Reservas de la Biosfera: Problemas y Oportunidades en México. *Acta Zoológica Mexicana*. 27(1):177–189.
- Harriman, L. y J. Muhlhausen. 2013. A new eye in the sky: eco-drones. *UNEP Global Environmental Alert Service (GEAS)*, 1–13p.
- HCIB, Herbario. 2020. Base de datos de la colección del Herbario, V.2019. Consultada en Junio 2020. La Paz, BCS.
- Huang, H., S. He, y C. Chen. 2019. Leaf abundance affects tree height estimation derived from UAV images. *Forests*. 10(10):931.
- Huete, A.R., R.D. Jackson, y D.F. Post. 1985. Spectral response of a plant canopy with different soil backgrounds. *Remote Sensing of Environment*. 17(1):37–53.
- INEGI. 2016. Uso de Suelo y Vegetación. Escala 1:250 000. Serie VI (Capa Union), escala: 1:250 000. Edición 1. Instituto Nacional de Estadística y Geografía., Mexico.
- Ishida, T., J. Kurihara, F.A. Viray, S.B. Namuco, E.C. Paringit, G.J. Perez, Y. Takahashi, y J.J. Marciano. 2018. A novel approach for vegetation classification using UAV-based hyperspectral imaging. *Computers and Electronics in Agriculture*. 144:80–85.
- Ivošević, B., Y.G. Han, Y. Cho, y O. Kwon. 2015. The use of conservation drones in ecology and wildlife research. *Journal of Ecology and Environment*. 38(1):113–118.
- Jackson, R.D. 1983. Spectral indices in N-Space. *Remote Sensing of Environment*. 13(5):409–421.
- Jackson, R.D. y P.J. Pinter 1986. Spectral response of architecturally different wheat canopies. *Remote Sensing of Environment*. 20(1):43–56.
- Jensen, J. R., (1986), *Introductory Digital Image Processing: A Remote Sensing Perspective*, Prentice-Hall, New Jersey.
- Jiménez L., J. y M. Mulero-Pázmány. 2019. Drones for Conservation in Protected Areas: Present and Future. *Drones*. 3(1):10.

- Joy, S.M., R.M. Reich, y R.T. Reynolds. 2003. A non-parametric, supervised classification of vegetation types on the Kaibab National Forest using decision trees. *International Journal of Remote Sensing*. 24(9):1835–1852.
- Kaufman, Y. y D. Tanre. 1992. Atmospherically resistant vegetation index. *IEEE Transactions on Geoscience and Remote Sensing*. 30(2):260–271.
- Kharuf-Gutierrez, S., L. Hernández-Santana, R. Orozco-Morales, O. de la Aday Díaz, y I. Delgado Mora. 2018. Análisis de imágenes multispectrales adquiridas con vehículos aéreos no tripulados. *Ingeniería Electrónica, Automática y Comunicaciones*. 39(2):79–91.
- Khokthong, W., D.C. Zemp, B. Irawan, L. Sundawati, H. Kreft, y D. Hölscher. 2019. Drone-Based Assessment of Canopy Cover for Analyzing Tree Mortality in an Oil Palm Agroforest. *Frontiers in Forests and Global Change*. 2:.
- Komárek, J., T. Klouček, y J. Prošek. 2018. The potential of Unmanned Aerial Systems: A tool towards precision classification of hard-to-distinguish vegetation types? *International Journal of Applied Earth Observation and Geoinformation*. 71:9–19.
- Kyratzis, A.C., D.P. Skarlatos, G.C. Menexes, V.F. Vamvakousis, y A. Katsiotis. 2017. Assessment of Vegetation Indices Derived by UAV Imagery for Durum Wheat Phenotyping under a Water Limited and Heat Stressed Mediterranean Environment. *Frontiers in Plant Science*. 8:1114.
- Landis, J.R. y G.G. Koch 1977. The Measurement of Observer Agreement for Categorical Data. *Biometrics*. 33(1):159.
- León de la Luz, J., M. Domínguez, L., y R. Coria., B. 1994. Flora of the Woodlands of the Sierra de La Laguna, Baja California Sur, México. USDA Forest Service, Tucson Arizona.
- León de la Luz, J.L., J.J. Navarro, y A. Breceda. 2000. A Transitional Xerophytic Tropical Plant Community of the Cape Region , Baja California. *Journal of Vegetation Science*. 11(4):555–564.
- León de la Luz, J.L., R. Domínguez-Cadena, y A. Medel-Narváez. 2012. Florística de la Selva Baja Caducifolia de la Península de Baja California, México. *Botanical Sciences*. 90(2):143.

- León De La Luz, J.L. y R. Coria. 1992. Flora Iconografica De Baja California Sur. Centro de Investigaciones Biológicas del Noroeste A.C., Mexico.
- León de la Luz, J.L. y R. Domínguez-Cadena. 2010. Analysis of forest types and estimates of biomass in the Sierra de La Laguna Reserve, Baja California Sur, Mexico. *Canadian Journal of Forest Research*. 40(10):2059–2068.
- Liaw, A. y M. Wiener 2002. Classification and Regression by randomForest. *R News*. 2(3):18–22.
- Lin, C., S.C. Popescu, G. Thomson, K. Tsogt, y C.I. Chang. 2015. Classification of tree species in overstorey canopy of subtropical forest using QuickBird images. *PLoS ONE*. 10(5):1–23.
- Lisein, J., M. Pierrot-Deseilligny, S. Bonnet, y P. Lejeune. 2013. A photogrammetric workflow for the creation of a forest canopy height model from small unmanned aerial system imagery. *Forests*. 4(4):922–944.
- Lisein, J., A. Michez, H. Claessens, y P. Lejeune. 2015. Discrimination of Deciduous Tree Species from Time Series of Unmanned Aerial System Imagery. 1–20.
- Lloret, F., A. Lobo, H. Estevan, P. Maisongrande, J. Vayreda, y A.J. Terradas. 2007. Woody plant richness and NDVI response to drought events in Catalonia (Northeastern Spain) *Forests. Ecology*. 88(9):2270–2279.
- Lu, B. y Y. He. 2017. Species classification using Unmanned Aerial Vehicle (UAV)-acquired high spatial resolution imagery in a heterogeneous grassland. *ISPRS Journal of Photogrammetry and Remote Sensing*. 128:73–85.
- De Luca, G., J.M.N. Silva, S. Cerasoli, J. Araújo, J. Campos, S. Di Fazio, y G. Modica. 2019. Object-based land cover classification of cork oak woodlands using UAV imagery and Orfeo Toolbox. *Remote Sensing*. 11(10):1238.
- Ma, H. y Y. Nie 2018. A two-stage filter for removing salt-andpepper noise using noise detector based on characteristic difference parameter and adaptive directional mean filter. *PLoS ONE*. 13(10):1–24.

Mahajan, U. y B. Raj Bundel 2016. Drones for Normalized Difference Vegetation Index (NDVI), to Estimate Crop Health for Precision Agriculture: A Cheaper Alternative for Spatial Satellite Sensors. *International Conference on Innovative Research in Agriculture, Food Science, Forestry, Horticulture, Aquaculture, Animal Sciences, Biodiversity, Ecological Sciences and Climate Change*, 38–41p.

Maimaitijiang, M., V. Sagan, P. Sidike, M. Maimaitiyiming, S. Hartling, K.T. Peterson, M.J.W. Maw, N. Shakoor, T. Mockler, y F.B. Fritschi 2019. Vegetation Index Weighted Canopy Volume Model (CVM VI) for soybean biomass estimation from Unmanned Aerial System-based RGB imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*. 151:27–41.

Manzo-Delgado, L. y J.A. Meave. 2003. La vegetación vista desde el espacio: La fenología foliar a través de la percepción remota. *Ciencia*, 18–28p.

Matese, A., P. Toscano, S.F. Di Gennaro, L. Genesio, F.P. Vaccari, J. Primicerio, C. Belli, A. Zaldei, R. Bianconi, y B. Gioli 2015. Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing*. 7(3):2971–2990.

Maya-Delgado, Y. 1988. Edafología. En: La Sierra La Laguna de Baja California Sur. Arriaga y Ortega (Eds.). La Sierra la Laguna de Baja California Sur. Centro de Investigaciones biológicas de Baja California Sur A.C., La Paz, Baja California Sur, México. 53-65p.

Maya-Delgado, Y. 2012. Suelo y erosión. En: A. Ortega-Rubio., M. Lagunas- Vázquez y L. F. Beltrán-Morales (Eds). *Evaluación de la Reserva de la Biosfera Sierra La Laguna, Baja California Sur: Avances y Retos.* (pp. 295-302). Centro de Investigaciones Biológicas del Noroeste S.C. 422 pp.

McLaughlin, S.P. 1995. An Overview of the Flora of the Sky Islands, Southeastern Arizona: Diversity, Affinities, and Insularity. En: LeBano F.L. et al. (eds.) *Biodiversity and Management of the Madrean Archipelago: The Sky Islands of Southwestern United States and Northwestern Mexico.* USDA forest Service, Tucson Arizona. 60–70p.

- Medina M., R.F. y C.I. Ñique C. 2017. Bosques aleatorios como extensión de los árboles de clasificación con los programas R y Python. *Interfases*. (10):165–189.
- Meneses-Tovar, C.L. 2012. El índice normalizado diferencial de la vegetación como indicador de la degradación del bosque. *Unasyuva: revista internacional de silvicultura e industrias forestales*. 62(238):39–46.
- Michez, A., H. Piégay, J. Lisein, H. Claessens, y P. Lejeune. 2016. Classification of riparian forest species and health condition using multi-temporal and hyperspatial imagery from unmanned aerial system. *Environmental Monitoring and Assessment*. 188(3):1–19.
- Mohan, M., C.A. Silva, C. Klauberg, P. Jat, G. Catts, A. Cardil, A.T. Hudak, y M. Dia. 2017. Individual tree detection from unmanned aerial vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. *Forests*. 8(9):1–17.
- Morelos, S. 1988. La vegetación: una aproximación a través de la fotointerpretación. En Arriaga, L. y A. Ortega (Eds). *La Sierra la Laguna de Baja California Sur*. Centro de Investigaciones biológicas de Baja California Sur A.C., La Paz, Baja California Sur, México. 69-82 p.
- Morgan, J.L., S.E. Gergel, y N.C. Coops. 2010. Aerial Photography: A Rapidly Evolving Tool for Ecological Management. *BioScience*. 60(1):47–59.
- Mulla, D.J. 2013. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*. 114(4):358–371.
- Nex, F. y F. Remondino. 2014. UAV for 3D mapping applications: A review. *Applied Geomatics*, 6, 1–15p.
- Noda, H.M., H. Muraoka, K.N. Nasahara, N. Saigusa, S. Murayama, y H. Koizumi 2015. Phenology of leaf morphological, photosynthetic, and nitrogen use characteristics of canopy trees in a cool-temperate deciduous broadleaf forest at Takayama, central Japan. *Ecological Research*. 30(2):247–266.
- Nowak, M.M., K. Dziób, y P. Bogawski. 2019. Unmanned Aerial Vehicles (UAVs) in environmental biology: A review. *European Journal of Ecology*. 4(2):56–74.

- Ojeda-Bustamante, W., A. González-Sánchez, A. Mauricio-Pérez, y J. Flores-Velázquez 2017. Aplicaciones de los vehículos aéreos no tripulados en la ingeniería hidroagrícola. *Tecnología y Ciencias del Agua*. 8(4):157–166.
- Ortega-Rubio, A., M. Lagunas-Vázquez, y L.F. Beltrán-Morales. 2013. Evaluación biológica y Ecológica de la Reserva de la Biósfera Sierra La Laguna, Baja California Sur: Avances y Retos. Centro de Investigaciones Biológicas del Noroeste S.C., Mexico.
- Ortega, A., L. Arriaga, S. León de la Luz, Jose Luis Alvarez, P. Gallina, R. Rodriguez, R. Coria, G. Arnaud, y G. Halffer. 1989. Como conservar la diversidad en Baja California. *Información científica y Tecnológica, CONACYT*. 11(153):34–40.
- Padilla A., G.; S., Pedrin A. y E. Díaz R. 1988. Historia geológica y paleoecología. En Arriaga, L. y Ortega, A. (eds.), *La Sierra de La Laguna en Baja California Sur*. Centro de Investigaciones Biológicas de Baja California Sur A.C., La Paz, Baja California Sur, México. 27-36 p.
- Panagiotidis, D., A. Abdollahnejad, P. Surovyy, y V. Chiteculo. 2017. Determining tree height and crown diameter from high-resolution UAV imagery. *International Journal of Remote Sensing*. 38(8–10):2392–2410.
- Pandey, R.K. y H.P.S. Makkar 1991. Variation of Tannins in Oak Leaves. *Biochemie und Physiologie der Pflanzen*. 187(5):392–394.
- Paz, F., M. Enrique Romero Sánchez, E. Palacios Vélez, M. Bolaños González, J. René Valdez Lazalde, y A. Aldrete. 2014. Alcances y limitaciones de los índices espectrales de la vegetación: Marco Teórico. *Terra Latinoamericana*. 32(3):177–194.
- Philpot, W. 2014. Spectral reflectance of drying, sandy soils. *IGARSS*. 131–18.
- Pino-Mejías, R., M.D. Cubiles-de-la-Vega, M. Anaya-Romero, A. Pascual-Acosta, A. Jordán-López, y N. Bellinfante-Crocci. 2010. Predicting the potential habitat of oaks with data mining models and the R system. *Environmental Modelling and Software*. 25(7):826–836.
- Prieto, J.L.P. y L. Luna 1994. Clasificación espectral automática vs. clasificación visual. *Un*

ejemplo al sur de la ciudad de México. *Investigaciones geográficas*. 25–40.

Prieto, R., G. Montoya, L. Granado, I. Pino, E. Méndez, I. Carpintero, J. Vales, F. Giménez de Azcárate, F. Cáceres, y M. JM 2013. Discriminación entre especies arbóreas del género *Quercus* y *Pinus* a partir de imágenes Landsat y Spot para caracterización de la capa de vegetación forestal del Siose-Andalucía. *REDIAM*. 22–25p.

Puliti, S., S. Solberg, y A. Granhus 2019. Use of UAV photogrammetric data for estimation of biophysical properties in forest stands under regeneration. *Remote Sensing*. 11(3):.

Quirós R, E. 2014. *Introducción a la Fotogrametría y Cartografía aplicadas a la Ingeniería Civil*. universidad de Extremadura, España.

Ramírez Chavez, E.J., A. Cruz García, A.G. Lagunas Pérez, y O.E. Reyes Carreño. 2013. Uso de vehículos aéreos no tripulados para la caracterización del paisaje sumergido; Bahía Estacahuite. *Ciencias del Mar*. (51):35–40.

Rommel, T.K. y A.H. Perera. 2017. *Mapping forest landscape patterns*. Toronto, ON, Canada.

Reuter, F. 2009. *Principios de Teledetección*. Santiago, Chile.

Riggins, J.J., J.M. Defibaugh Y Chávez, J.A. Tullis, y F.M. Stephen 2011. Spectral identification of previsual Northern Red Oak (*Quercus rubra* L.) foliar symptoms related to oak decline and Red Oak Borer (Coleoptera: Cerambycidae) attack. *Southern Journal of Applied Forestry*. 35(1):18–25.

Rodríguez-Moreno, M. Víctor, y S.H. Bullock 2013. Comparison of vegetation indexes in the Sonoran desert incorporating soil and moisture indicators and application to estimates of LAI. *Revista Mexicana de Ciencias Agrícolas*. 4(4):611–623.

Rominger, K. y S.E. Meyer 2019. Application of UAV-Based methodology for census of an endangered plant species in a fragile habitat. *Remote Sensing*. 11(6):1–16.

Rondeaux, G., M. Steven, y F. Baret 1996. Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*. 55(2):95–107.

Rouse, R.W.H., J.A.W. Haas, y D.W. Deering 1974. Monitoring vegetation systems in the

Great Plains with ERTS. En: Freden S.C. et al. (eds.) Third Earth Resources Technology Satellite-1 Symposium. NASA, Washington, D.C. 309–317p.

Roy, P.S. 1989. Spectral reflectance characteristics of vegetation and their use in estimating productive potential. *Proceedings: Plant Sciences*. 99(1):59–81.

Rzedowski, J. 2006. *Vegetación de México*. 1a Edición Digital. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad, Mexico.

Saberioon, M.M., M.S.M. Amin, A.R. Anuar, A. Gholizadeh, A. Wayayok, y S. Khairunniza-Bejo. 2014. Assessment of rice leaf chlorophyll content using visible bands at different growth stages at both the leaf and canopy scale. *International Journal of Applied Earth Observation and Geoinformation*. 32:35–45.

Sánchez Brito, I., M.A. Almendarez Herández, y C.A. Morales Zarate, María Verónica Salinas Zavala. 2013. Valor de existencia del servicio ecosistémico hidrológico en la Reserva de la Biosfera Existence Value of Hydrological Ecosystem Service in the Biosphere Reserve Sierra La Laguna, Baja California Sur, Mexico. *Frontera Norte*. 25(50):97–129.

Sankey, T., J. Donager, J. McVay, y J.B. Sankey. 2017. UAV lidar and hyperspectral fusion for forest monitoring in the southwestern USA. *Remote Sensing of Environment*. 195:30–43.

Silleos, N.G., T.K. Alexandridis, I.Z. Gitas, y K. Perakis. 2006. Vegetation indices: Advances made in biomass estimation and vegetation monitoring in the last 30 years. *Geocarto International*. 21(4):21–28.

Soria, J. y R. Granados 2005. Relación entre los índices de vegetación obtenidos de los sensores AVHRR del satélite NOAA y TM del Landsat. *Ciencia Ergo Sum*. 12(2):167–174.

Sothe, C., M. Dalponte, C.M. Almeida, M.B. Schimanski, C.L. Lima, V. Liesenberg, G. Takahashi M., y A.M. Tommaselli 2019. Tree Species Classification in a Highly Diverse Subtropical Forest Integrating UAV-Based Photogrammetric Point Cloud and Hyperspectral Data. *Remote Sensing*. 11:2–24.

Tay, J.Y.L., A. Erfmeier, y J.M. Kalwij. 2018. Reaching new heights: can drones replace current methods to study plant population dynamics? *Plant Ecology*. 219(10):1139–1150.

- Ting, K. 2017. Confusion Matrix. En: Shultz T.R. y Fahlman S.E. (eds.) *Encyclopedia of Machine Learning and Data Mining*. 260–261p.
- Torres-Sánchez, J., F. López-Granados, A.I. De Castro, y J.M. Peña-Barragán. 2013. Configuration and Specifications of an Unmanned Aerial Vehicle (UAV) for Early Site Specific Weed Management. *PLoS ONE*. 8(3):15.
- Troyo-Diéguez, E., G. Solís-Garza, A. Cruz-Falcón, C. Peña-Limón, J.O., Navarro-Lozano, A., Nieto-Garibay, M.S., De la Toba y J.L., Meza-Trejo. 2013. Recursos Hídricos. En Ortega-Rubio, A., M. Lagunas-Vázquez, y L.F. Beltrán-Morales (Eds). *Evaluación biológica y Ecológica de la Reserva de la Biósfera Sierra La Laguna, Baja California Sur: Avances y Retos*. Centro de Investigaciones Biológicas del Noroeste S.C., Mexico. 269-294 p.
- Tucker, C.J. 1979. Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. *Remote Sensing of Environment*. 8:127–150.
- Tuominen, S., R. Näsi, E. Honkavaara, A. Balazs, T. Hakala, N. Viljanen, I. Pölönen, H. Saari, y H. Ojanen. 2018. Assessment of classifiers and remote sensing features of hyperspectral imagery and stereo-photogrammetric point clouds for recognition of tree species in a forest area of high species diversity. *Remote Sensing*. 10(5):1–28.
- Valladares, F. y D. Brites 2004. Leaf phyllotaxis: Does it really affect light capture? *Plant Ecology*. 174(1):11–17.
- Wahab, I., O. Hall, y M. Jirstrom 2018. Remote Sensing of Yields: Application of UAV Imagery-Derived NDVI for Estimating Maize Vigor and Yields in Complex Farming Systems in Sub-Saharan Africa. *Drones*. 2(3):28.
- Van Der Wal, T., B. Abma, A. Viguria, E. Prévinaire, P.J. Zarco-Tejada, P. Serruys, E. Van Valkengoed, y P. Van Der Voet 2013. Fieldcopter: Unmanned aerial systems for crop monitoring services. *Precision Agriculture 13´ - Papers Presented at the 9th European Conference on Precision Agriculture, ECPA 2013*, 169–175p.
- Xue, J. y B. Su 2017. Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*. 1–17.

Yang, W., S. Wang, X. Zhao, J. Zhang, y J. Feng 2015. Greenness identification based on HSV decision tree. *Information Processing in Agriculture*. 2(3–4):149–160.

Yengoh, G.T., D. Dent, L. Olsson, A.E. Tengberg, y C. Tucker III. 2015. Use of the Normalized Difference Vegetation Index (NDVI) to Assess Land Degradation at Multiple Scales. Current Status, Future Trends, and Practical considerations. Springer International Publishing, New York.

Zarco-Tejada, P.J., R. Diaz-Varela, V. Angileri, y P. Loudjani. 2014. Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. *European Journal of Agronomy*. 55:89–99.

Zhang, D., J. Liu, W. Ni, G. Sun, Z. Zhang, Q. Liu, y Q. Wang 2019. Estimation of Forest Leaf Area Index Using Height and Canopy Cover Information Extracted From Unmanned Aerial Vehicle Stereo Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 12(2):471–481.

Referencias electrónicas

Flora del Noroeste de México. 2020. URL. <http://herbanwmex.net/portal/taxa/index.php?taxon=Quercus+albocincta&forms-submit=Search+Terms>. Consultado 24 de marzo 2020.

Gallagher, G. 2018 a. *Quercus albocincta*. The IUCN Red List of Threatened Species 2018: e.T32759A81100455. URL. <https://dx.doi.org/10.2305/IUCN.UK.2018-2.RLTS.T32759A81100455.en>. Consultado el 07 de junio 2020.

Gallagher, G. 2018 b. *Quercus tuberculata*. The IUCN Red List of Threatened Species 2018:e.T78978451A78978454. URL. <https://dx.doi.org/10.2305/IUCN.UK.2018-2.RLTS.T78978451A78978454.en>. Consultado el 07 de junio 2020.

Hijmans, R. J. 2019. raster: Geographic Data Analysis and Modeling. R package version 2.9-5. URL. <https://CRAN.R-project.org/package=raster> Consultado el 24 febrero 2020.

Harriman, L. y J. Muhlhausen 2013. A new eye in the sky: eco-drones. UNEP Global Environmental Alert Service (GEAS). URL. www.unep.org/geasp. IDB. 2011. Consultado el 15 de febrero de 2020

Index Database (IDB). 2020. A database for remote sensing indices. URL. <https://www.indexdatabase.de/db/i-single.php?id=242> Consultado el 15 de febrero de 2020.

Jerome, D. 2020. *Quercus devia*. The IUCN Red List of Threatened Species 2020: e.T30730A2795552. URL. <https://www.iucnredlist.org/species/30730/2795552>. Consultado el 13 julio 2020.

Kuhn, M., J. Wing, S. Weston, A. Williams, C. Keefer, A. Engelhardt, T. Cooper, Z. Mayer, B. Kenkel, the R Core Team, M. Benesty, R. Lescarbeau, A. Ziem, L. Scrucca, Y. Tang, C. Candan y T. Hunt. 2019. caret: Classification and Regression Training. R package versión 6.0-84. <https://CRAN.R-project.org/package=caret> Consultado 25 marzo 2020.

Lisic, J. 2016. rasterKernelEstimates: Kernel Based Estimates on in-Memory Raster Images. R package version 1.0.1. URL. <https://CRAN.R-project.org/package=rasterKernelEstimates> Consultado 25 abril 2020.

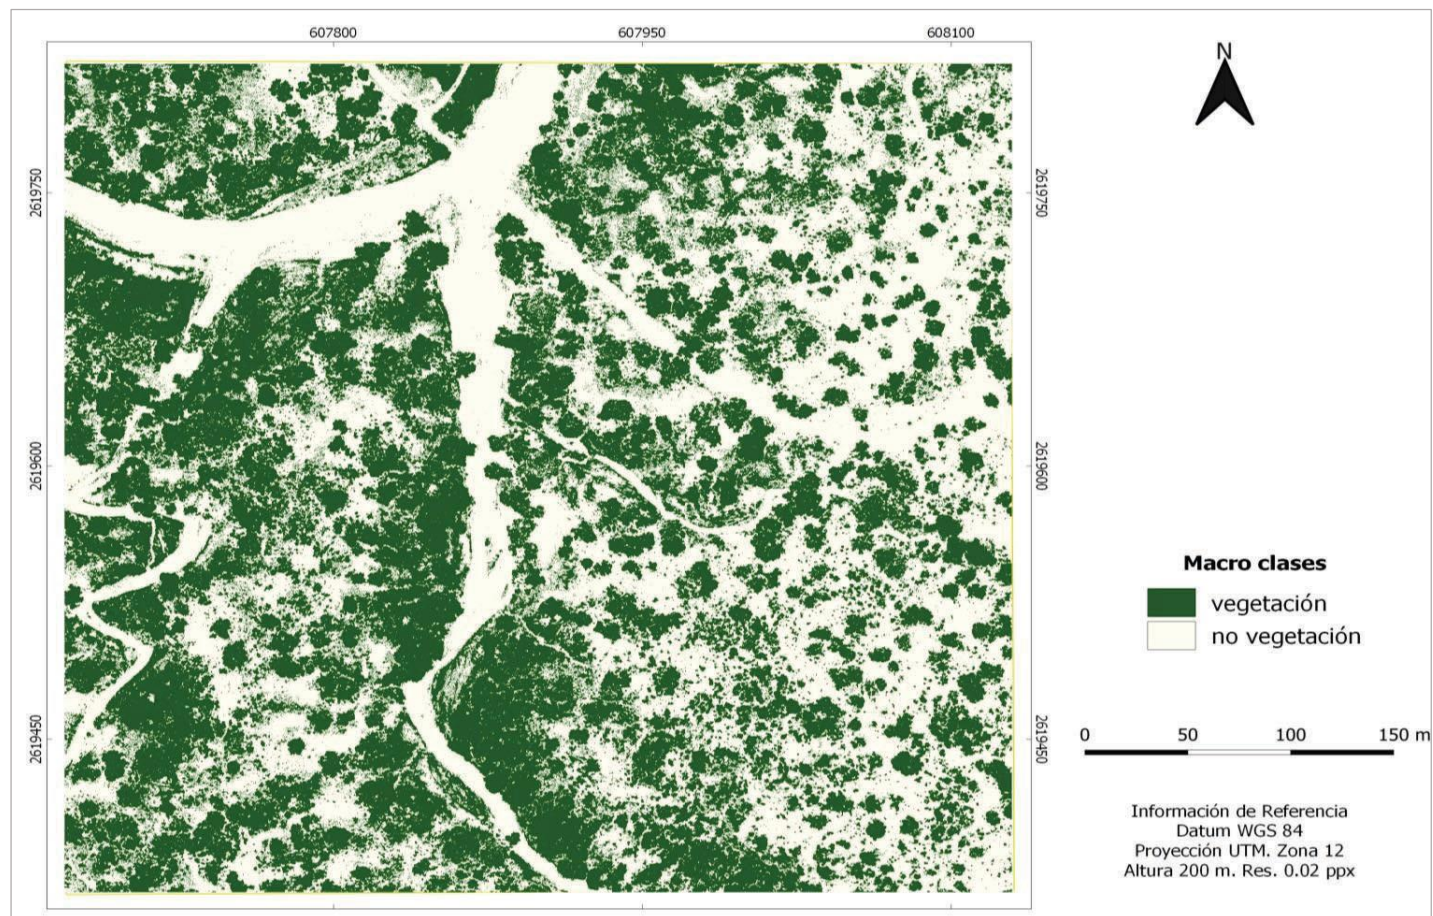
NORMA Oficial Mexicana NOM-059-SEMARNAT-2010. 2010. Protección ambiental-Especies nativas de México de flora y fauna silvestres-Categorías de riesgo y especificaciones para su inclusión, exclusión o cambio-Lista de especies en riesgo. URL. https://dof.gob.mx/nota_detalle_popup.php?codigo=5173091. Consultado 13 julio 2020.

R Core Team. 2020. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>. Consultado 10 diciembre 2020

Sistema Meteorológico Nacional (SMN). 2020. Información Estadística climatológica. Estación Agua de San Antonio. Comisión Nacional del Agua. URL. <https://smn.conagua.gob.mx/tools/RESOURCES/Diarios/3186.txt> Consultado 28 julio 2020.

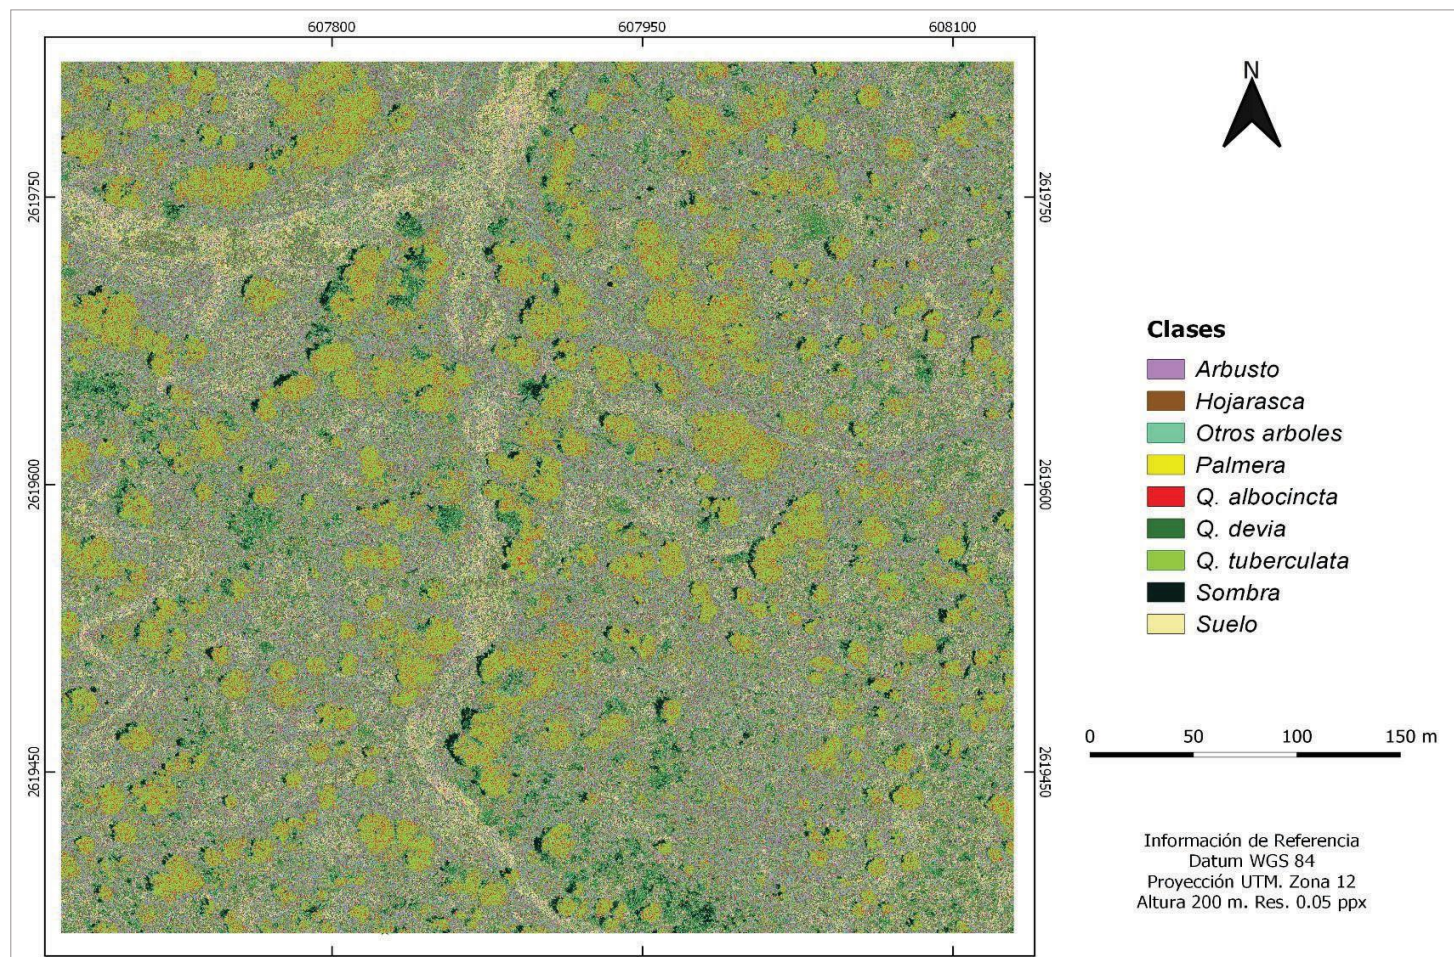
11 ANEXOS

Anexo A



Mapa temático de la cobertura vegetal obtenido a partir del mejor modelo de clasificación para temporada de lluvias utilizando el índice COM (elaboración propia). [Regreso a documento](#)

Anexo B



Mapa temático de la cobertura vegetal obtenido a partir del mejor modelo de clasificación aplicando a 9 clases para la temporada seca utilizando el índice RN (elaboración propia). [Regreso a documento](#)

a) **Matriz de confusión resultado del modelo de clasificación supervisada en la temporada seca con el IV RN**

%	arbusto	hojarasca	otros árboles	palmera	<i>Q. albocincta</i>	<i>Q. devia</i>	<i>Q. tuberculata</i>	sombra	suelo
arbusto	18.5	11	11.3	3.9	6.6	26.5	15.2	1.2	5.7
hojarasca	16.9	12.6	6.8	4.7	11.6	11.6	32.1	0.5	2.6
otros árboles	13.5	5.5	10.9	3.3	9.1	31.6	17.5	5.8	2.5
palmera	16.7	11.8	9.8	7.8	5.9	22.6	20.6	2	2
<i>Q. albocincta</i>	2.3	1.5	2.1	1.2	24.3	2.5	65.6	0	0.3
<i>Q. devia</i>	14.4	4.8	17	3.7	5	37.5	7.8	3	6.8
<i>Q. tuberculata</i>	1.7	1.9	1.7	0.8	21.4	1.5	70.9	0	0.1
sombra	1.3	0.7	10.6	0.7	0	20	0	65.2	1.3
suelo	15.8	4.7	4.7	0.8	3.9	30	2.4	0.8	36.3

b) **Matriz de confusión resultado del modelo de clasificación supervisada en la temporada seca con el IV DVI**

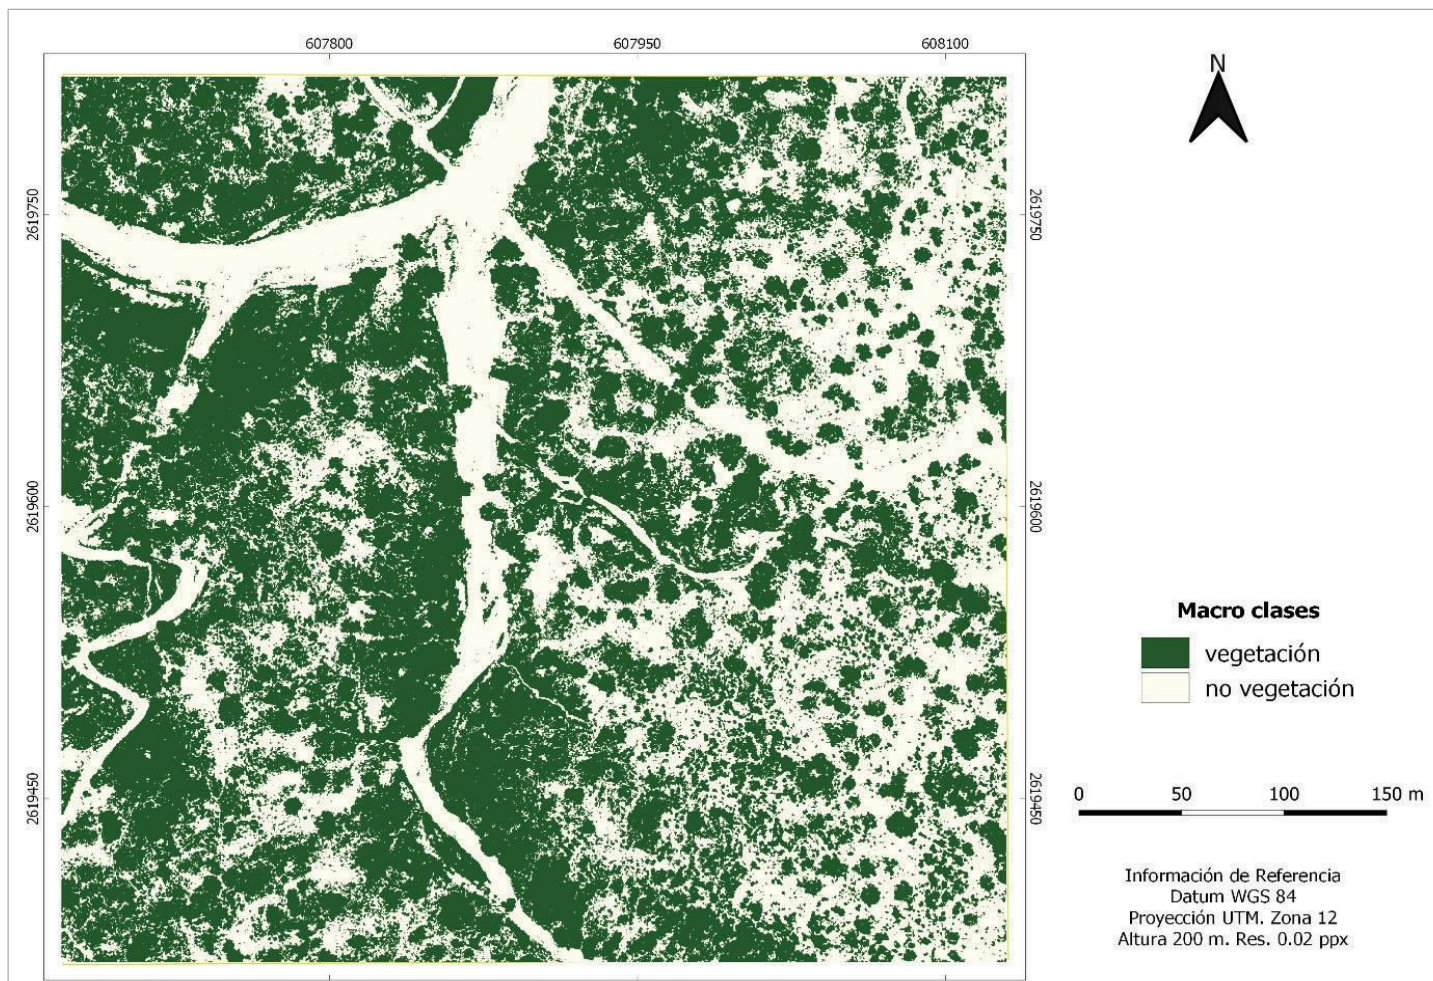
%	arbusto	hojarasca	otros árboles	palmera	<i>Q. albocincta</i>	<i>Q. devia</i>	<i>Q. tuberculata</i>	sombra	suelo
Arbusto	11.9	0	6	0	5.4	4.8	65.5	6.3	0
Hojarasca	1.6	5.3	0.5	2.1	4.3	2.1	82.9	0.5	0
otros árboles	11	0.4	3.5	0	4.3	9.4	61.6	9.4	0
palmera	0	4.8	0	23.9	11.5	2.9	56.3	0	0
<i>Q. albocincta</i>	2.1	0.6	0.5	0.6	3.9	2.5	89.3	0.5	0
<i>Q. devia</i>	5.9	0.2	2.3	0.5	4.3	2.1	82.1	2.3	0
<i>Q. tuberculata</i>	2	0.4	0.7	0.8	2.3	1.9	90.6	1.2	0
sombra	16.8	0	7.8	0	5.2	1.9	24.6	43.3	0
suelo	0	0	0	0	0.8	0.8	5.6	1.6	91.2

c) **Matriz de confusión resultado del modelo de clasificación supervisada en temporada de lluvias con el IV ExGR**

%	arbusto	hojarasca	otros árboles	palmera	<i>Q. albocincta</i>	<i>Q. devia</i>	<i>Q. tuberculata</i>	sombra	suelo
arbusto	9.1	0	5.2	2	25.8	5.2	49.6	2.8	0
hojarasca	0	92.4	0	0	0	0	0	5.8	1.8
otros árboles	4.6	0	5.4	4.2	20.8	9.5	54	1.2	0
palmera	2	0	9.9	0	19.8	9.9	55.4	2	0
<i>Q. albocincta</i>	5.8	0	4.1	2.4	28.2	10.4	47.3	1.8	0
<i>Q. devia</i>	2.3	0	3.4	1.8	18.8	14.1	59	0.4	0
<i>Q. tuberculata</i>	4.1	0	3.7	1.9	15.8	11.2	62.7	0.7	0
sombra	5.5	12.1	2.2	2.2	22	2.2	28.6	15.4	8.8
suelo	0	3.5	0	0	0	0	0	8	88.4

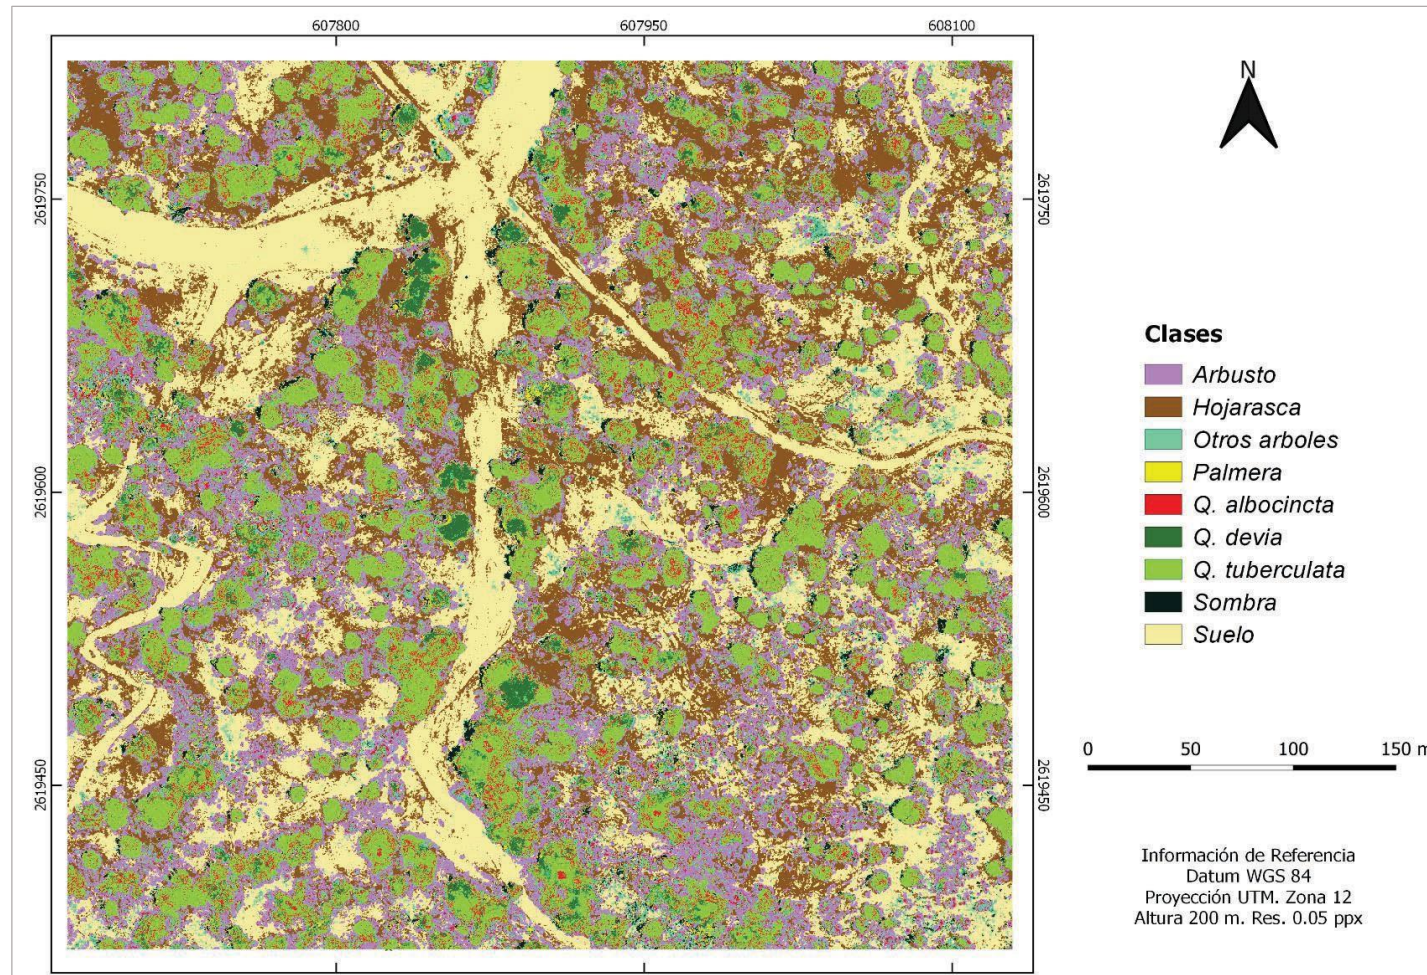
[Regreso a Diagramas circulares](#)

Anexo C



Mapa temático de cobertura vegetal obtenido a partir del mejor modelo de clasificación para temporada de lluvias utilizando el índice COM y el Modelo de elevación del dosel (elaboración propia). [Regreso a documento](#)

Anexo D



Mapa temático de la cobertura vegetal obtenido a partir del mejor modelo de clasificación aplicado a 9 clases para la temporada seca utilizando el índice VARI y el Modelo de elevación del dosel (elaboración propia). [Regreso a documento](#)

a) **Matriz de confusión resultado del modelo de clasificación supervisada en la temporada seca con el índice VARI y el MED.**

%	arbusto	hojarasca	otros árboles	palmera	<i>Q. albocincta</i>	<i>Q. devia</i>	<i>Q. tuberculata</i>	sombra	suelo
arbusto	67.4		10.4	0.6	3.9	0	6	1.2	4.2
hojarasca	2.1	87.2		0	0	0	1.6	0	8.5
otros árboles	15.7	0.7	34.6	1.1	7.3	22.9	13.8	1.8	1.8
palmera	3	0	6.9	70.1	0	8.9	5.9	4.9	0
<i>Q. albocincta</i>	2.4	1.3	1.7	0	39.2	2.4	52.7	0.2	0
<i>Q. devia</i>	0	0	6.7	0.9	3.5	76.9			11.
<i>Q. tuberculata</i>	0.9	0.5	0.5	0.1	10.8	1.7			85.
sombra	6.7	0	5.3	4	1.3	4.7	4		73.9
suelo	0	1.6	0.8	0	0	0	0	0	97.6

b) **Matriz de confusión resultado del modelo de clasificación supervisada en la temporada seca con el índice GVI y el MED.**

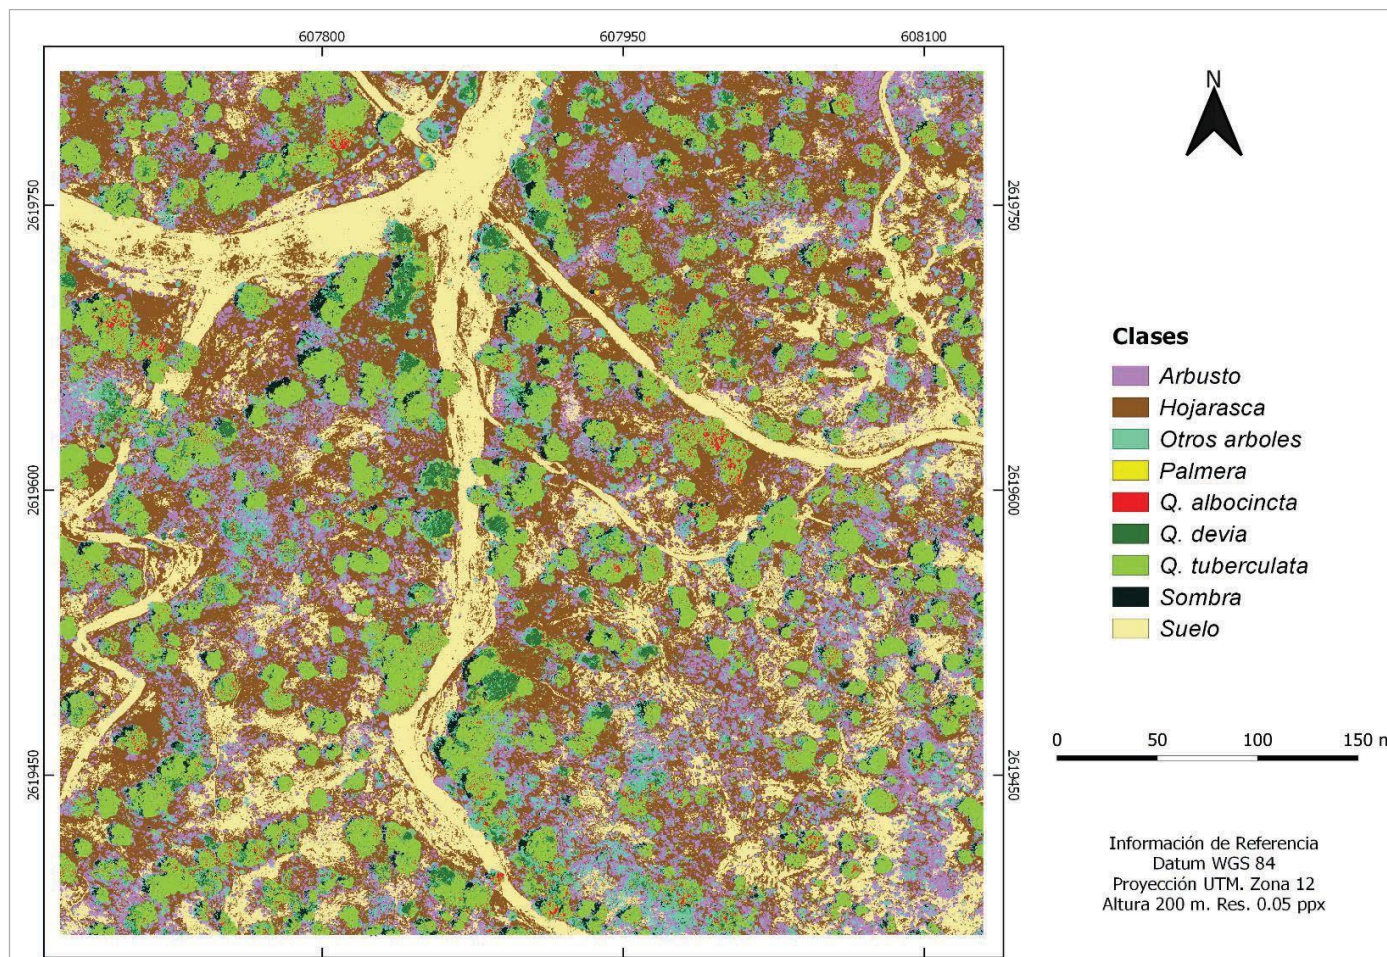
%	arbusto	hojarasca	otros árboles	palmera	<i>Q. albocincta</i>	<i>Q. devia</i>	<i>Q. tuberculata</i>	sombra	suelo
arbusto	58.7	17.3	3.3	1.8	1.5	0	14.3	2.7	0.3
hojarasca	4.8	91.4	1.6	0	0	0	0	0.5	1.6
otros árboles	8.6	9.4	27.1	2.4	8.6	2.7	37.7	3.1	0
palmera	3.8	0	9.5	24.8	4.8	8.6	29.6	18.1	0
<i>Q. albocincta</i>	1.3	0	1.2	0.6	28.3	3.9	64.5	0.1	0
<i>Q. devia</i>	0.4	0	1.1	0.4	12	30.6	55.3	0.2	0
<i>Q. tuberculata</i>	1.8	0.5	1.5	0.6	10.5	4.4	79.7	0.9	0
sombra	1.3	6.5	1.3	3.9	2.6	1.3	4.5	78.5	0
suelo	0	5.6	0	0	0	0	0	0	94.4

c) **Matriz de confusión resultado del modelo de clasificación supervisada en la temporada de lluvias con el índice RN y el MED.**

%	arbusto	hojarasca	otros árboles	palmera	<i>Q. albocincta</i>	<i>Q. devia</i>	<i>Q. tuberculata</i>	sombra	suelo
arbusto	69.2	2.8	5.2	0.8	6.8	1.2	8.4	1.6	4.0
hojarasca	2.3	87.7	0.6	0	0.6	0	1.2	0	7.6
otros árboles	8.7	7.5	30.7	2.1	10.8	2.9	37	0	0
palmera	10.9	3	5.0	15.9	12.6	1	50.6	0	0
<i>Q. albocincta</i>	3.3	0.6	2.1	0.4	40.6	4.1	48.9	0	0
<i>Q. devia</i>	0.5	0	1.1	0.4	9.3	23.1	65.5	0	0
<i>Q. tuberculata</i>	0.5	0	1.4	0.5	10.2	4.8	82.6	0.1	0
sombra	3.3	0	0	0	0	0	0	75.4	21.1
suelo	0	0.9	0	0	0	0	0	0	99.1

[Regreso a diagramas circulares](#)

Anexo E



Mapa temático de la cobertura vegetal obtenido a partir del mejor modelo de clasificación aplicado a 9 clases para la temporada seca utilizando todos los índices RGB y el modelo de elevación del dosel (elaboración propia). [Regreso a documento](#)

a) **Matriz de confusión resultado del modelo de clasificación supervisada en la temporada seca al integrar los IV del espectro visible y MED.**

%	arbusto	hojarasca	otros árboles	palmera	<i>Q. albocincta</i>	<i>Q. devia</i>	<i>Q. tuberculata</i>	sombra	suelo
arbusto	90.4	0.3	4.8	0	1.2	0	3.3	0	0
hojarasca	0	98.4	0	0	0	0	0.5	0	1.1
otros árboles	8.8	0.4	66.8	0.7	3.6	9.9	9.5	0.4	0
palmera	0	0	1	91.1	1	6.9	0	0	0
<i>Q. albocincta</i>	0.3	0	0.8	0	41.9	1.1	55.9	0.1	0
<i>Q. devia</i>	0	0	5.2	0.4	1.1	84.5	8.9	0	0
<i>Q. tuberculata</i>	0.1	0	0.1	0	7	0.8	91.9	0	0
sombra	0	0	0	0	0	0	0	100	0
suelo	0	0.8	0	0	0	0	0	0	99.2

b) **Matriz de confusión resultado del modelo de clasificación supervisada en la temporada de seca al integrar índices de vegetación sensibles al NIR y el MED**

%	arbusto	hojarasca	otros árboles	palmera	<i>Q. albocincta</i>	<i>Q. devia</i>	<i>Q. tuberculata</i>	sombra	suelo
arbusto	82.6	0	7.5	0	0	0.3	9.5	0	0
hojarasca	0	99.5	0	0	0	0	0	0	0.5
otros árboles	16.5	0	50.7	0	1.6	12.2	18.9	0	0
palmera	0	0	0	72.9	7.7	0	19.2	0	0
<i>Q. albocincta</i>	1	0	0.7	0.6	24.2	5.8	67.8	0	0
<i>Q. devia</i>	0	0	1.8	0.4	4.3	55.9	37.6	0	0
<i>Q. tuberculata</i>	1	0	0.6	0.4	6.2	4.3	87.5	0	0
sombra	0	0	0	0	0	0	0	100	0
suelo	0	1.6	0	0	0	0	0	0	98.4

c) **Matriz de confusión resultado del modelo de clasificación supervisada en temporada húmeda al integrar índices de vegetación del espectro visible y MED.**

%	arbusto	hojarasca	otros árboles	palmera	<i>Q. albocincta</i>	<i>Q. devia</i>	<i>Q. tuberculata</i>	sombra	suelo
arbusto	79.6	0	3.2	1.2	4.4	0	8.8	2.8	0
hojarasca	0	97.6	0	0	0	0	0	2.3	0
otros árboles	5.4	0	41.1	0.4	7.9	4.6	40.3	0	0
palmera	14.9	0	4	9.9	15.9	3	51.5	0	0
<i>Q. albocincta</i>	1.4	0	0.5	0.2	49.9	2.4	45.7	0	0
<i>Q. devia</i>	0.2	0	0.4	0	6.1	30.6	62.6	0	0
<i>Q. tuberculata</i>	0.3	0	0.3	0.2	6.7	2.4	90.1	0	0
sombra	1.1	5.6	0	0	0	0	0	93.3	0
suelo	0	0	0	0	0	0	0	0	100

[Regreso a Diagramas circulares](#)