



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

**CARTOGRAFÍA Y MONITOREO DE COBERTURA BENTÓNICA ARRECIFAL
MEDIANTE SENSORES REMOTOS EMERGENTES**

TESIS
QUE PARA OPTAR POR EL GRADO DE:
MAESTRA EN CIENCIAS
PRESENTA:

NANCY DANIELA NÚÑEZ MORALES

TUTOR PRINCIPAL:

DR. JOAQUÍN RODRIGO GARZA PÉREZ
FACULTAD DE CIENCIAS, UMDI-SISAL, UNAM.

COMITÉ TUTOR:

DR. RODOLFO RIOJA NIETO
FACULTAD DE CIENCIAS, UMDI-SISAL, UNAM.
DR. FRANCISCO JAVIER FLORES DE SANTIAGO
INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA, CDMX, UNAM.
DR. SERGIO CERDEIRA ESTRADA
CONABIO, CDMX.
DR. LORENZO ÁLVAREZ FILIP
INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA, PUERTO MORELOS, UNAM

SISAL, YUCATÁN, MX., MARZO, 2021.



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

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

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



CARTOGRAFÍA Y MONITOREO DE COBERTURA BENTÓNICA ARRECIFAL MEDIANTE SENSORES REMOTOS EMERGENTES

TESIS

QUE PARA OBTENER EL GRADO ACADÉMICO DE:

MAESTRA EN CIENCIAS

(BIOLOGÍA MARINA)

PRESENTA:

NANCY DANIELA NÚÑEZ MORALES

TUTOR PRINCIPAL:

DR. JOAQUÍN RODRIGO GARZA PÉREZ
FACULTAD DE CIENCIAS, UMDI-SISAL, UNAM.

COMITÉ TUTOR:

DR. RODOLFO RIOJA NIETO
FACULTAD DE CIENCIAS, UMDI-SISAL, UNAM.
DR. FRANCISCO JAVIER FLORES DE SANTIAGO
INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA, CDMX, UNAM.
DR. SERGIO CERDEIRA ESTRADA
CONABIO, CDMX.
DR. LORENZO ÁLVAREZ FILIP
INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA, PUERTO MORELOS, UNAM

SISAL, YUCATÁN, MX., MARZO, 2021.

AGRADECIMIENTOS

A la Universidad Nacional Autónoma de México, por permitirme una vez más formar parte de ella, al Posgrado de Ciencias del Mar y Limnología por abrirme sus puertas y brindarme las herramientas para continuar creciendo académica y profesionalmente.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por la beca de manutención otorgada (CVU: 933652).

Al proyecto PAPIIT-DGAPA clave IN114119 “Ortomosaicos multispectrales submarinos como herramientas de caracterización, evaluación y monitoreo de arrecifales coralinos.” Por el apoyo para salidas a campo.

A mi tutor, el Dr. Joaquín Rodrigo Garza, por aceptar guiarme en este proceso, por adentrarme al mundo de la percepción remota y de los arrecifes de coral. Por siempre estar al pendiente de mi crecimiento académico y siempre ser solidario y motivarme a lo largo de este camino.

A los miembros de Comité Tutor: al Dr. Rodolfo Rioja, por el enriquecimiento al proyecto con sus conocimientos y sugerencias, además del apoyo con equipo en campo. A el Dr. Francisco Flores de Santiago, el Dr. Lorenzo Álvarez Filip y el Dr. Sergio Cerdeira, por estar comprometidos durante todo el proceso, por compartir sus conocimientos y consejos para mejorar la tesis y mi aprendizaje.

A la UMDI-Facultad de Ciencias Sisal y en especial al Programa de Investigación Espacial en Ambientes Costeros y Marinos (PIESACOM), porque dentro de ellos pude desarrollar mi proyecto de investigación y enriquecerme profesionalmente. Además, me permitió conocer a personas maravillosas.

Al Laboratorio de Análisis Espacial de Zonas Costeras (COSTALAB), principalmente a él Mtro. Carlos Cruz y al Biól. Héctor Ricardo Sánchez por su apoyo en campo con los vuelos de dron y videobarridos. Al Mtro. Eric Barrera, por su apoyo en la resolución de dudas y asesoramiento a lo largo del proyecto.

Al Planet's Education and Research Program por el acceso a las imágenes PlanetScope. A Iván Penié del Centro Ecológico Akumal (CEA) y Gerardo Orozco del Akumal Dive Center, por el apoyo logístico en las campañas de trabajo.

Y finalmente como una tesis no se escribe sola, sino también se escribe por las personas que te dicen que puedes lograrlo, te apoyan y motivan, infinitas gracias: Eduardo Ramade, Rodrigo Rodríguez, Heber Joctan, Alejandrina Espinoza, Daniela Santana, Frida Coronel, Raquel Rodríguez, Maryjo García, Sara Vianney y Alejandra Gutiérrez.

DEDICATORIA

A mis padres: Aurelio Núñez y Ana Raquel Morales

mis hermanas: Andrea y Karen Núñez

Contenido

1. INTRODUCCIÓN	16
2. MARCO TEÓRICO	19
2.1. Percepción Remota.....	19
2.1.1. Uso de Percepción Remota en el estudio de arrecifes coralinos.....	20
2.2. Preprocesamiento de las imágenes	21
2.2.1. Corrección atmosférica.....	21
2.2.2. Corrección del brillo de olas	22
2.2.3. Corrección de la columna de agua	22
2.3. PlanetScope Analytic Ortho Scene	24
2.4. WorldView-3.....	26
2.5. Cámara multispectral RedEdge-M	27
2.6. Uso de clasificación supervisada	28
2.7. Exactitud en la cartografía temática	28
3. ANTECEDENTES	30
4. PREGUNTA DE INVESTIGACIÓN	35
5. JUSTIFICACIÓN	36
6. OBJETIVOS	38
6.1. Objetivo general	38
6.2. Objetivos específicos	38
7. ÁREA DE ESTUDIO.....	39
8. MATERIALES Y MÉTODOS	41
8.1. Obtención de datos y caracterización de los hábitats arrecifales.....	41
8.2. Obtención de imágenes de baja altitud y generación de ortomosaicos multispectrales.....	43

8.3.	Preprocesamiento de imágenes de satélite y ortomosaicos multiespectrales	44
8.3.1.	Corrección atmosférica	45
8.3.2.	Corrección del brillo de olas	45
8.3.3.	Corrección de la columna de agua/Calibración de profundidad	46
8.4.	Clasificación supervisada	46
8.5.	Evaluación de la exactitud de cartografía de imágenes satelitales y ortomosaico multiespectral	47
8.5.1.	Prueba de diferencias significativas e intervalos de confianza	49
9.	RESULTADOS	50
9.1.	Comparación entre imágenes satelitales WorldView-3 y PlanetScope	50
9.2.	Caracterización de comunidades bentónicas, 2019	55
9.2.1.	Laguna arrecifal	55
9.2.2.	Esquema de clasificación de la cobertura de la laguna arrecifal, 2019	55
9.1.	Elaboración de ortomosaicos multiespectrales	58
9.1.1.	Preprocesamiento de ortomosaico multiespectral	58
9.2.	Preprocesamiento de imagen satelital PlanetScope Analytic Ortho Scene, 2019.	59
9.3.	Clasificaciones supervisadas de insumos de 2019	61
9.3.1.	Ortomosaico multiespectral	62
9.3.2.	Imagen satelital PlanetScope Analytic Ortho Scene, 2019	66
10.	DISCUSIÓN	70
10.1.	Evaluación de exactitud	70
10.2.	Diferencias entre PlanetScope Analytic Ortho Scene y WorldView-3, 2016	71

10.3. Caracterización del área de estudio, 2019.....	73
10.4. Diferencias entre ortomosaico multiespectral e imagen satelital PlanetScope Analytic Ortho Scene, 2019.....	74
11. CONCLUSIONES	80
12. RECOMENDACIONES	83
13. REFERENCIAS.....	85

Lista de tablas

Tabla 1. Características de la constelación PlanetScope.....	24
Tabla 2. Características de las imágenes PlanetScope Analytic Ortho Scene.	25
Tabla 3. Características del satélite WorldView-3.	26
Tabla 4. Características de las imágenes multiespectrales WorldView-3.	26
Tabla 5. Grupos Funcionales para identificación de organismos arrecifales bentónicos y sustratos inertes.	42
Tabla 6. Esquema de clasificación de los hábitats bentónicos arrecifales de Akumal, Q. Roo, 2016.	50
Tabla 7. Evaluación de exactitud de clasificadores para las imágenes satelitales PlanetScope y WorldView-3 (2016) en Akumal, Q. Roo, 2016.....	51
Tabla 8. Esquema de clasificación de hábitats en la laguna de Akumal, Q. Roo, 2019....	56
Tabla 9. Porcentaje de cobertura de GGF en la laguna arrecifal de Akumal, Q. Roo, 2019.	56
Tabla 10. Rangos de cobertura.....	56
<i>Tabla 11. Evaluación de exactitud de clasificadores para el ortomosaico multiespectral, en la laguna arrecifal de Akumal, Q. Roo, 2019.....</i>	<i>62</i>
Tabla 12. Matriz de contingencia por porcentaje. Clasificación supervisada (Support Vector Machine) del ortomosaico multiespectral de la laguna arrecifal. Clase 1: Praderas de pastos marinos; clase 2: Cobertura alta de sedimento con cobertura media de algas filamentosas; clase 3: Dominado por sedimento con cobertura baja de macroalgas; clase 4: Cobertura alta de sedimento con cobertura baja de pastos marinos; clase 5: Cobertura media de sedimento y de macroalgas; clase 6: Arena y sedimento; clase 7: Parches de coral con cobertura media de sedimento y cobertura baja de macroalgas y algas filamentosas; clase 8: Sargazo.	64
Tabla 13. Evaluación de exactitud de clasificadores para la imagen satelital PlanetScope Analytic Ortho Scene (2019), en la laguna arrecifal de Akumal, Q. Roo, 2019.....	66
Tabla 14. Matriz de contingencia por porcentaje. Clasificación supervisada (Maximum Likelihood) de imagen satelital PlanetScope Ortho Scene 2016, zona de la laguna arrecifal. Clase 1: Praderas de pastos marinos; clase 2: Cobertura alta de sedimento con cobertura media de algas filamentosas; clase 3: Dominado por sedimento con cobertura baja de macroalgas; clase 4: Cobertura alta de sedimento con cobertura baja de pastos marinos; clase 5: Cobertura media de sedimento y de macroalgas; clase 6: Arena y sedimento; clase	

7: Parches de coral con cobertura media de sedimento y cobertura baja de macroalgas y algas filamentosas; clase 8: Sargazo en degradación.....	68
<i>Tabla 15. Tabla comparativa entre insumos de percepción remota: imágenes satelitales WorldView-3 vs PlanetScope (2016) y ortomosaicos multiespectrales (2019).</i>	79

Lista de figuras

Figura 1. Ubicación de la localidad de Akumal, Q. Roo.....	40
Figura 2. Diseño de muestreo del arrecife de Akumal, Q. Roo; a) Imagen de satélite WorldView-3 (2016), b) Clasificación no supervisada con 10 clases de cobertura bentónica. Estaciones de muestreo, sitios de entrenamiento y polígonos de vuelos del dron.	42
Figura 3. Comparación de exactitud general (Po), Kappa (K) y Tau (Te) para imagen satelital PlanetScope, 2016, a través de diferentes clasificadores. MD: Mahalanobis Distance; MinD: Minimum Distance; ML: Maximum Likelihood; NN: Neural Network; SVM: Support Vector Machine.	52
Figura 4. Comparación de exactitud general (Po), Kappa (K) y Tau (Te) para imagen satelital WorldView-3, 2016, a través de diferentes clasificadores. MD: Mahalanobis Distance; MinD: Minimum Distance; ML: Maximum Likelihood; NN: Neural Network.	52
Figura 5. Comparación de imágenes clasificadas (clasificación supervisada) con diferentes algoritmos. A partir de imágenes satelitales PlanetScope (2016) y WorldView-3 (2016), representando las diferentes clases de cobertura bentónica en el arrecife de Akumal, Q. Roo.....	53
Figura 6. Comparación de imágenes clasificadas (clasificación supervisada), mediante el algoritmo Maximum Likelihood: a) Imagen satelital PlanetScope, 2016 (exactitud general de 92.36%); b) Imagen satelital WorldView-3, 2016 (exactitud general de 82.21%). Representando la distribución espacial de las diferentes clases de cobertura bentónica del arrecife de Akumal, Q. Roo.....	54
Figura 7. Porcentaje de los componentes bentónicos en la laguna arrecifal de Akumal, Q. Roo, junio 2019.....	55
Figura 8. Dendrograma de clúster jerárquico de la Laguna arrecifal de Akumal, Q. Roo., 2019.	57
Figura 9. Vista previa en el software Agisoft Metashape de un ortomosaico de la laguna arrecifal de Akumal, Q. Roo, del mes de agosto de 2019, no resuelto por completo, generado a través de imágenes de la cámara multiespectral del dron.	58

Figura 10. Ortomosaico multiespectral preprocesado de la laguna arrecifal de Akumal, Q. Roo (junio de 2019). a) Ortomosaico multiespectral generado a través de las imágenes de la cámara multiespectral en el dron (visualizado en RGB); b) Recorte del área de interés, ortomosaico multiespectral después de aplicarle la corrección de la columna de agua. ..	59
Figura 11. Imagen satelital PlanetScope Analytic Ortho Scene (2019), preprocesada. a) Recorte del área de interés de la imagen satelital original (visualizada en RGB), b) Recorte de la imagen satelital después de aplicarle la corrección del brillo de olas y de la columna de agua. c) Detalle del área de interés de la laguna arrecifal de Akumal, Q. Roo.	60
Figura 12. Comparación de imágenes clasificadas (clasificación supervisada) con diferentes algoritmos. A partir de ortomosaico multiespectral (obtenido con la cámara multiespectral RedEdge-M, instalada en el dron Matrice 100), e imagen satelital PlanetScope Analytic Ortho Scene (2019), representando las diferentes clases de cobertura bentónica de la laguna arrecifal de Akumal, Q. Roo.	61
Figura 13. Comparación de exactitud general (Po), Kappa (K) y Tau (Te) para ortomosaico multiespectral de la laguna, a través de diferentes clasificadores. MD: Mahalanobis Distance; MinD: Minimum Distance; ML; Maximum Likelihood; NN: Neural Network; SVM: Support Vector Machine.	63
Figura 14. Clasificación supervisada de ortomosaico multiespectral (obtenido con la cámara multiespectral RedEdge-M, instalada en el dron Matrice 100) de cobertura bentónica en la laguna arrecifal de Akumal, Q. Roo, 2019, mediante el clasificador Support Vector Machine.	65
Figura 15. Comparación de exactitud general (Po), Kappa (K) y Tau (Te) para imagen satelital PlanetScope, 2019, a través de diferentes clasificadores. MD: Mahalanobis Distance; MinD: Minimum Distance; ML: Maximum Likelihood; NN: Neural Network; SVM: Support Vector Machine.	67
Figura 16. Clasificación supervisada de imagen satelital PlanetScope Analytic Ortho Scene, de cobertura bentónica en la laguna arrecifal de Akumal, Q. Roo, 2019, mediante el clasificador Maximum Likelihood.....	69

RESUMEN

Debido al declive severo en el que se encuentran los arrecifes de coral en todo el mundo y dada su gran importancia al brindar múltiples servicios ecosistémicos, es necesaria la búsqueda de herramientas innovadoras y con buena exactitud para su monitoreo, y así generar información que permita establecer estrategias para el manejo y conservación de estos importantes ecosistemas. La percepción remota y la cartografía temática de los hábitats bentónicos arrecifales constituyen las herramientas de monitoreo de mayor uso y éxito en las últimas décadas, gracias a su amplia cobertura y sus resoluciones espacial y temporal, principalmente. En el presente estudio se evaluaron dos insumos de percepción remota que han surgido en los últimos años y que apenas comienzan a aplicarse en el mapeo de arrecifes de coral: 1) imágenes satelitales PlanetScope de los años 2016 y 2019 (resolución espacial de 3 m), y 2) ortomosaicos multiespectrales (2019) elaborados a partir de una cámara multiespectral aerotransportada, (resolución espacial de 8 cm), que a su vez fueron comparados con una imagen satelital WorldView-3, del año 2016 (resolución espacial 1.2 m); esta última plataforma ha sido utilizada exitosamente para este fin, por lo que se utilizó como parámetro en el desempeño de la cartografía bentónica arrecifal. Para la caracterización del arrecife y obtención de datos de entrenamiento, se hicieron videos de barrido submarino de la cobertura bentónica del arrecife de Akumal Q. Roo durante el verano de 2019. Los insumos de imagen multiespectral obtenidos no permitieron la generación de ortomosaicos de las zonas de frente y pendiente del arrecife (software Agisoft Metashape) y solo se generó el ortomosaico (y la cartografía correspondiente) de la laguna arrecifal hasta una profundidad máxima de entre 4 y 5 m. El mapeo de los tipos de fondo se realizó mediante clasificaciones supervisadas, a través de los siguientes clasificadores: Maximum Likelihood, Support Vector Machine, Minimum Distance, Mahalanobis Distance y Neural Network. La exactitud de las clasificaciones se estableció a través de matrices de contingencia, de donde se obtuvieron la exactitud general (P_o) y el coeficiente Kappa (K), y adicionalmente se calculó el coeficiente Tau (T_e). Los productos con mejor representación de la cobertura bentónica obtuvieron las siguientes exactitudes; imagen satelital WorldView-3 (2016): $P_o=82.21\%$, $K=0.69$, $T_e=0.79$; PlanetScope (2016): $P_o=92.37\%$, $K=0.85$, $T_e=0.91$; PlanetScope, (2019): $P_o=80.11\%$, $K=0.74$, $T_e=0.77$, y el ortomosaico multiespectral (2019): $P_o=85.35\%$, $K=0.70$, $T_e=0.83$. Siendo en las imágenes satelitales el clasificador de Maximum Likelihood el que mejor desempeño presentó, y Support Vector Machine en el caso del ortomosaico multiespectral. Para todos los insumos se obtuvieron exactitudes elevadas. Sin embargo, debido a que solo se logró resolver el

ortomosaico multiespectral de la laguna arrecifal, consideramos que esta aproximación aún no puede competir con la amplia cobertura y profundidades a las que alcanza a penetrar una imagen satelital; no obstante, los insumos de drones pueden ser utilizados de manera complementaria al mapeo de estos ecosistemas, con resultados de resolución espacial muy finos (cm) y con exactitudes muy elevadas. Por otro lado, nuestros resultados sugieren que las imágenes satelitales PlanetScope son la mejor opción para el mapeo del bentos arrecifal, ya que brindan gran exactitud, tienen una alta resolución espacial, abarcan grandes coberturas y es sencillo aplicarles las correcciones de pretratamiento y clasificaciones supervisadas.

ABSTRACT

Due to severe decline in coral reefs worldwide and given their ecological importance in providing multiple ecosystem services, it is necessary to develop innovative tools with high accuracy to support both monitoring of these ecosystems, and management and conservation decisions of these important ecosystems. In the last decades, remote sensing and thematic mapping of reef benthic habits have been one of the most successfully applied and widely used monitoring tools, associated to their wide coverage and spatial-temporal resolution. In this study, we assess two remote sensing products that have emerged in recent years and are just beginning to be applied in coral reef mapping: 1) PlanetScope satellite imagery from the years 2016 and 2019 (spatial resolution of 3 m), and 2) multispectral orthomosaics (2019), generated using an airborne multispectral camera (spatial resolution of 8 cm). The products obtained, were compared with those from a WorldView-3 satellite imagery from 2016 (spatial resolution 1.2 m); this last platform have been used successfully for this characterization and monitoring purpose, for this reason, we used it as a parameter in the performance of mapping reef benthic coverage. During the summer of 2019, benthic video sweeps along the reef in Akumal were carried out for reef characterization and generation of training data. The obtained multispectral imagery data were not useful for the generation of orthomosaics (software Agisoft Metashape) for the reef front and reef slope zones of the reef, and they were only able to resolve the orthomosaic of the reef lagoon up to a maximum depth between 4 and 5 m, thus image classification was only applied to this area. Bottom types classification was carried out applying different supervised classifications algorithms: Maximum Likelihood, Support Vector Machine, Minimum Distance, Mahalanobis Distance and Neural Network. Accuracy assessment procedures were implemented using an independent subset of field stations and obtaining error matrices from where overall accuracy (P_o) and Kappa coefficient (K) were calculated, additionally Tau coefficient (T_e) was also estimated. All multispectral datasets were classified with high accuracies; the best cartographic products representing the bottom types obtained the following accuracies: WorldView-3 (2016) image: $P_o=82.21\%$, $K=0.69$, $T_e=0.79$; PlanetScope (2016) image: $P_o=92.37\%$, $K=0.85$, $T_e=0.91$; PlanetScope, (2019) image: $P_o=80.11\%$, $K=0.74$, $T_e=0.77$; and multispectral orthomosaic (2019): $P_o=85.35\%$, $K=0.70$, $T_e=0.83$. Maximum Likelihood was the supervised classification algorithm with overall better performance for our satellite imagery datasets, as Support Vector Machine algorithm was for the multispectral orthomosaic. Our results suggest that PlanetScope imagery is the best option, of these two, for mapping reef benthic habitats, since they provide

high accuracy, they also have high spatial resolution, they cover wide areas and they are easy to apply pre-processing and supervised classifications to. Since drone multispectral datasets only resolved the reef lagoon area, we consider this approach not competitive with satellite imagery regarding area coverage and deep bottom resolutions. Nevertheless, the multispectral drone datasets, as those used in this study, can be used in a complementary way to map these ecosystems, with very high resolutions (cm) and accuracies.

1. INTRODUCCIÓN

Los arrecifes de coral tropicales son estructuras tridimensionales de aguas poco profundas formadas de carbonato de calcio (CaCO_3), el cual es secretado por los corales (Bellwood *et al.*, 2004; Phelan, 2012). Se desarrollan principalmente en aguas cálidas, superficiales, claras y con buena incidencia solar. Estos ecosistemas están contruidos en su mayoría por corales hermatípicos comúnmente llamados duros, los cuales están formados por pólipos, que secretan un exoesqueleto de carbonato de calcio que provee soporte y protección al cuerpo de cada uno de los mismos (Phelan, 2012). Los arrecifes de coral brindan múltiples servicios ecosistémicos: protección contra huracanes, una amplia biodiversidad, actividades turísticas, materiales de construcción, entre otros (Mumby y Edwards, 2002).

En los últimos años alrededor del mundo la condición de los arrecifes ha sufrido un declive severo debido principalmente a la sobreexplotación, contaminación, enfermedades y al cambio climático (Gardener *et al.*, 2003; Hughes *et al.*, 2003; Wilkinson, 2008). Esto ha generado una degradación significativa de la cobertura de coral y un cambio en la dominancia de especies (Álvarez-Filip *et al.*, 2009).

En el caso específico de los arrecifes coralinos del Mar Caribe, se ha registrado una pérdida masiva de cobertura de coral desde los 1980s, relacionada principalmente al efecto de actividades antrópicas como: crecimiento de la población, sobrepesca especialmente eliminando los depredadores tope (tiburones, meros, barracudas, etc.) y peces herbívoros (p.ej. pez loro), además de la introducción de contaminantes de varios tipos y especies invasoras. Estas presiones aunadas al cambio climático global han generado el colapso de poblaciones de coral, blanqueamiento, enfermedades e incremento en la cobertura de macroalgas, así como una disminución en la capacidad de resiliencia de estos sistemas. Se estima que desde los 1970s hasta el 2012 la cobertura coralina en el Caribe ha declinado más de un 80%, a diferencia de la cobertura de macroalgas, las cuales han ido en aumento. El comportamiento de la cobertura de macroalgas y corales representa un persistente cambio en la dominancia de las comunidades de macroalgas respecto a los corales en los últimos 30 años (Jackson, *et al.*, 2014).

La degradación de los arrecifes de coral ha sido tal, que muchas ONG (Organización No Gubernamental) han abandonado la causa hacia su conservación (Jackson, *et al.*, 2014).

Sin embargo, en el medio científico, el declive de estos ecosistemas ha generado un impulso alrededor del mundo para realizar investigaciones acerca del estado de los arrecifes de coral.

El monitoreo de características de los recursos y condición de los ecosistemas es esencial tanto para entender su comportamiento bajo el efecto de estrés climático o antropogénico, como en su caso, para dar seguimiento a la recuperación (Hedley *et al.*, 2016). En general, los métodos tradicionales *in situ* para determinar la estructura y distribución de la comunidad bentónica en los arrecifes de coral se pueden clasificar en: cuadrantes, transectos y manta-tows. Estas metodologías se ven limitadas ya sea por la pequeña porción del área total de los arrecifes que cubren o por la limitada exactitud que ofrecen. Por lo tanto, proporcionan el estado del arrecife de los sitios mejor medidos, pero el resto de las áreas extensas del arrecife permanecen sin explorar (Hochberg, 2011).

Incluso cuando el área de interés se limita a solo un arrecife, las consideraciones logísticas dificultan la aplicación de enfoques estadísticos de muestreo. Las observaciones se realizan en ubicaciones discretas en el arrecife por lo que grandes áreas del arrecife permanecen sin ser observadas. Tal muestreo proporciona estimaciones como la media y la varianza de los parámetros observados. Sin embargo, estos métodos generan un problema de parcheo y los muestreos intensivos pueden no capturar adecuadamente las distribuciones de la comunidad (Hochberg, 2011). Al ampliar los muestreos a más de un arrecife, los métodos intensivos *in situ* se vuelven poco viables.

Lo anterior hace considerar el uso de la teledetección en el estudio de los arrecifes coralinos, cuyo valor radica en la capacidad de realizar observaciones de áreas grandes y remotas y con una periodicidad sumamente corta. En los últimos años, la incorporación de la percepción remota en la evaluación de estos ecosistemas ha permitido reflejar el drástico daño ocasionado por el hombre o por el estrés natural que han sufrido estas comunidades (Andréfouët *et al.*, 2003).

La percepción remota permite observar y monitorear la situación de los corales alrededor del mundo, con lo que se puede determinar las diferencias de estructuras coralinas, mapear la diversidad y la zonificación del hábitat (Andréfouët *et al.*, 2003; Garza-Pérez *et al.*, 2004; Hochberg y Atkinson, 2003; Mumby y Edwards, 2002; Roelfsema *et al.*, 2018; Shihavuddin *et al.*, 2013) evaluar la batimetría, el avance de fenómenos de blanqueamiento, entre muchos otros aspectos (Witze, 2016).

El uso de imágenes satelitales de alta resolución (se denominan así ya que ofrecen una resolución espacial mayor a 10 m) ha revolucionado y mejorado el estudio de los arrecifes de coral (Andréfouët *et al.*, 2003; Collin, 2012; Cruz-Vázquez *et al.*, 2019; Garza-Pérez *et al.*, 2004; Ortiz *et al.*, 2020; Purkis *et al.*, 2019) puesto que muchas investigaciones se veían limitadas por las imágenes de baja resolución e imágenes aéreas en su mayoría pancromáticas (Andréfouët *et al.*, 2002; Mumby *et al.*, 1999; Palandro *et al.*, 2003).

Actualmente, existen varias fuentes de imágenes satelitales, todas ellas ofrecen diferentes grados de exactitud, resolución y características espectrales. Una de ellas, son las imágenes satelitales PlanetScope, las cuales con su alta resolución espacial y temporalidad diaria (que las distingue de otras imágenes satelitales), son ideales para el mapeo y monitoreo de las dinámicas de hábitats bentónicos arrecifales (Wicaksono & Lazuardi, 2018).

Por otro lado, el reciente desarrollo de plataformas aéreas de baja altitud, tales como los drones (vehículos aéreos no tripulados, VANTs), permiten obtener imágenes de baja altitud que pueden ser utilizadas para monitoreo ambiental, a un bajo costo en comparación a aeronaves tripuladas (Casella *et al.*, 2014, 2016; Bryson *et al.*, 2016; Duffy y Anderson, 2016).

Además, los estudios de alta resolución con drones pueden ser repetidos constantemente, por lo que cambios en la cobertura y la incidencia de blanqueamiento en el coral pueden ser detectados y así darles un seguimiento a los daños ocasionados en los arrecifes de coral. Respecto a las restricciones de este método, son las condiciones climáticas atmosféricas y marinas las que representan la principal limitación de este método (Casella, 2017). Sin embargo, entre más y mejor sea planeado el vuelo, los datos obtenidos tendrán mayor exactitud.

En este contexto, en el presente trabajo se pretende evaluar a través de la comparación de su exactitud que aproximación de percepción remota es más recomendable para el mapeo de fondos bentónicos arrecifales: imágenes satelitales PlanetScope Analytic Ortho Scene u ortomosaicos multiespectrales generados con ayuda de un dron.

2. MARCO TEÓRICO

2.1. Percepción Remota

La teledetección o percepción remota es un proceso mediante el cual se obtiene información de las propiedades físicas de objetos o áreas, a través de la medición de la radiación reflejada y emitida a una distancia desde el área objetivo y sin entrar en contacto directo con éstos (Goodman *et al.*, 2013). Mediante sensores especiales se recopilan imágenes de la superficie terrestre, las cuales proporcionan información de objetos sobre la Tierra. Las herramientas más conocidas de percepción remota son: sensores en satélites y aviones, y los sistemas de sonar en los barcos utilizados para crear imágenes del fondo oceánico (USGS, 2019).

La percepción remota se divide en pasiva y activa, la primera de éstas registra la energía ambiental (comúnmente la del sol) reflejada en la superficie, por ejemplo, los generadores de imágenes multi e hiperespectrales. En cambio, en la detección remota activa, se emite una señal en una longitud de onda en particular y el sensor registra la retrodispersión, un ejemplo son los dispositivos LIDAR (Light Detection And Ranging) (Goodman *et al.*, 2013; Hochberg, 2011) y los SAR (Synthetic Aperture Radar).

Algunas de las aplicaciones en las que puede ser utilizada la teledetección son: evaluaciones de impactos por desastres naturales, toma de decisiones para la protección de recursos naturales, rastreo de nubes para predecir el clima, registrar el crecimiento de urbes, cambio de uso de suelo a través del tiempo, monitoreo de cambios en la línea costera, rastreo del transporte de sedimentos, mapeo del fondo oceánico, entre muchas otras (NOAA, 2018; USGS, 2019).

En el caso particular de sistemas arrecifales, la percepción remota tiene la capacidad de proporcionar información de la geomorfología y distribución de las comunidades arrecifales a gran escala (Mumby *et al.*, 2001). Además, se ha demostrado que esta tecnología es el medio más rentable para adquirir datos relativos a su geomorfología (Mumby *et al.*, 1999), y es la única herramienta disponible que puede adquirir datos globalmente uniformes de este tipo de ecosistemas (Hochberg, 2011).

2.1.1. Uso de Percepción Remota en el estudio de arrecifes coralinos

El estudio de los arrecifes coralinos mediante percepción remota se realiza gracias a un esfuerzo interdisciplinario entre la ciencia de los arrecifes, la óptica ambiental y la ingeniería. Generalmente a través de las imágenes satelitales se busca caracterizar algún aspecto de la estructura o función del arrecife, por lo que es necesario tener conocimientos de geología y biogeoquímica de estos ecosistemas, a pesar de que se hacen inferencias indirectas de la información en las imágenes. Para poder interpretar las señales ópticas reflejadas por el arrecife es necesario contar con el conocimiento de la manera en que la luz interactúa con los componentes del arrecife y como se transmite la luz a través de la atmosfera y el ambiente acuático (Hochberg, 2011).

El empleo de teledetección en el estudio de los arrecifes de coral comenzó a partir del lanzamiento del satélite Landsat 1 en los 1970s y fue enfocada a observar la geomorfología de estos ecosistemas (Smith *et al.*, 1975). Las primeras investigaciones (en los 1970s – 1980s) realizadas con percepción remota, se llevaron a cabo utilizando insumos de los satélites Landsat y SPOT (*Satellite Pour l'Observation de la Terre*). Estas primeras imágenes satelitales eran multiespectrales (con dos o tres bandas en el espectro visible), de un ancho de banda de 60 a 100 nm y con una resolución espacial moderada (píxel de 20 a 80 m). Estas características de bajo número de bandas y resolución espacial moderada limitaron muchos estudios en arrecifes (Hochberg, 2011).

Fue hasta los 1990s que surgieron las imágenes hiperespectrales de sensores aerotransportados. Estas imágenes tenían una resolución espacial más alta (0.5-20 m). Además, estos sensores hiperespectrales poseían decenas o centenas de bandas de rangos espectrales cortos (5-10 nm). Las resoluciones espaciales y espectrales mejoradas revelaron el potencial para la identificación directa y el mapeo de las comunidades de arrecifes (por ejemplo, Hochberg y Atkinson 2000). A pesar de que las imágenes ya tenían una mejor resolución aún no existían las herramientas para la corrección ambiental de éstas (atmosfera, columna de agua, brillo de la superficie de mar, etc.) (Maritorena *et al.*, 1994; Lee *et al.*, 1999).

A finales del siglo XX y principios del siglo XXI, las imágenes satelitales multiespectrales IKONOS y Quickbird se hicieron disponibles al público, con bandas de rango espectral amplio y con una resolución espacial de 2.4 a 4 m para imágenes a color y de 0.6 a 1 m para imágenes pancromáticas. Estas imágenes satelitales ya pueden distinguir de cinco a

nueve clases bentónicas con una exactitud general entre 50 y 80%. Estas clases se definían subjetivamente caso por caso y a menudo no se alineaban con tipos de comunidad fundamentales. Sin embargo, por primera vez, las observaciones satelitales proporcionan vistas detalladas de los arrecifes de coral (Hochberg, 2011).

Desde los inicios de la percepción remota, ésta ha sido una herramienta prometedora, por lo que cada vez tiene más presencia en el estudio de los arrecifes coralinos. Además, de que día a día la percepción remota se encuentra avanzando tecnológicamente por lo que a la par se irán encontrando más aplicaciones de ésta en el ámbito científico. En la actualidad, hay más opciones de insumos de percepción remota de alta calidad para la comunidad científica, por lo que la investigación y gestión de los arrecifes con teledetección es cada vez más común (Hochberg, 2011). No obstante, su elevado costo limita el uso y potencial de estos insumos; si bien existen insumos que están disponibles de manera gratuita, gran parte no lo está. Y desafortunadamente, la mayoría de los investigadores carecen de recursos financieros para adquirir grandes cantidades de datos de percepción remota, así como softwares especializados para su procesamiento y análisis (Pettorelli *et al.*, 2014).

2.2. Preprocesamiento de las imágenes

Las imágenes satelitales e imágenes aéreas proporcionan información útil de la composición bentónica en aguas someras (Lyzenga, 1978). Sin embargo, las imágenes multiespectrales son muy sensibles a los parámetros ambientales (Lyzenga, 1985). La utilización de percepción remota para el estudio de fondos bentónicos debe considerar diversos factores ambientales como la profundidad y las propiedades ópticas del agua. Otro factor que puede influir es la reflexión de la luz en la superficie del agua, por lo que es importante aplicar distintas correcciones a los insumos de percepción remota para mejorar su utilidad (Green *et al.*, 2000; Lyzenga, 1978; Lyzenga, 1981).

2.2.1. Corrección atmosférica

La radiación electromagnética (EMR) al momento de ser registrada por un sensor ya ha sido influenciada por los procesos de absorción y dispersión, el primero reduce la intensidad de la radiación y el otro modifica su dirección. Ambos fenómenos ocurren cuando la energía interactúa con gases como el vapor de agua, el dióxido de carbono, el ozono y partículas en suspensión en el aire (Goodman *et al.*, 2013). Además, la dispersión crea un “efecto de píxel adyacente”, en el cual la radiancia registrada para un píxel incorpora parcialmente la

radiancia dispersada de los píxeles vecinos. A la radiación que es registrada por el sensor pero que fue dispersada y no estuvo en contacto con la superficie de la Tierra, se le conoce como “path radiance” (Green *et al.*, 2000).

Debido a todos estos efectos que interfieren en la energía registrada por un sensor, es importante aplicar una corrección atmosférica para que se tenga un registro más exacto de la reflectancia de la superficie de la Tierra. Por lo que se aplican técnicas para eliminar el efecto de dispersión (path radiance). Normalmente en las imágenes con arrecifes coralinos, los píxeles de las áreas oceánicas más profundas son los que se utilizan para realizar la corrección atmosférica (Goodman *et al.*, 2013).

Existen diferentes métodos que pueden ser utilizados para la corrección atmosférica como la substracción del píxel más oscuro, el método de sombra de nube, los modelos de transferencia radiativa (como Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes “FLAASH”) y el método de calibración vicaria (Goodman *et al.*, 2013).

2.2.2. Corrección del brillo de olas

La reflexión de la luz solar en la superficie del agua también es un problema, principalmente en aguas poco profundas, con cielos despejados y cuando la superficie del agua no es plana (oleaje), ya que se crea un reflejo especular sobre la superficie que crea destellos de color blanco brillante, los cuales obstruyen la visibilidad del fondo bentónico. Estas manchas ocultan las características del fondo marino (Hedley *et al.*, 2005). Desafortunadamente, en las zonas someras como lo son los arrecifes de coral este efecto se ve muy a menudo, y las clasificaciones del fondo se ven fuertemente influenciadas por estos destellos. La corrección del brillo solar sobre la superficie del agua aumenta considerablemente la exactitud por clase en la clasificación de fondos bentónicos (Hochberg *et al.*, 2003). Por lo que es importante corregir los efectos del brillo solar y conservar únicamente la reflectancia del componente bentónico y los procesos de transferencia radiativa en la columna de agua.

2.2.3. Corrección de la columna de agua

La profundidad del agua afecta considerablemente el mapeo de los hábitats bentónico-marinos ya que a medida que va aumentando la profundidad, la intensidad de luz que penetra en el agua decrece exponencialmente. Este proceso es conocido como atenuación de la luz, y varía dependiendo de la longitud de onda de la EMR. El fenómeno de atenuación

se da a cabo por los procesos de absorción y dispersión, la absorción se refiere a la conversión de la energía electromagnética en otras formas de energía como calor o energía química, mientras que la dispersión se lleva a cabo cuando la energía electromagnética interactúa con las partículas suspendidas en la columna de agua y cambia de dirección (Green *et al.*, 2000).

A lo largo de los años en el estudio de las comunidades bentónicas acuáticas mediante sensores remotos, se han desarrollado diferentes métodos para identificar de manera automática las características bentónicas y la profundidad del agua a través de distintos algoritmos. Tales como las técnicas de Polcyn *et al.*, (1970) y Wezernak & Lyzenga (1975), cuyas técnicas se basaban en un modelo simple de reflectancia del agua, sin embargo, estas técnicas no consideraban los efectos de la dispersión en el agua, ni la reflexión interna en la superficie del agua. Además, ambas técnicas están restringidas a dos bandas de longitud de onda, por lo que no se aprovechaba la información registrada por el resto de las bandas, lo que las hace poco aplicables y poco útiles (Lyzenga, 1978).

Lyzenga en 1978 realizó una modificación del modelo de radiancia simple e incluyó los efectos de la dispersión en el agua y la reflexión interna en la superficie del agua. Algunas de las ventajas que se generaron a partir de esta técnica fueron: una mejor discriminación de los tipos de fondo con espectros de reflectancia similar y mejor rendimiento mediante el uso de más de dos bandas. Como desventajas se encontró que los parámetros de entrada para este algoritmo son más difíciles de determinar.

2.3. PlanetScope Analytic Ortho Scene

La constelación de satelitales PlanetScope, perteneciente a la compañía Planet Labs, Inc., constituyen aproximadamente 130 satélites individuales. Estos satélites generan tres productos multispectrales: 1) PlanetScope Basic Scene, 2) PlanetScope Ortho Scene y 3) PlanetScope Ortho Tile. Las imágenes PlanetScope Basic Scene, están corregidas radiométricamente, pero no están ortorectificadas ni en ninguna proyección cartográfica. Las imágenes PlanetScope Ortho Tile son varias escenas ortorectificadas que han sido unidas en una sola tira, están corregidas radiométricamente y proyectadas a UTM (Planet Labs Inc., 2018).

Las imágenes PlanetScope Ortho Scene están disponibles como productos visuales (R, G, B) y analíticos (R, G, B, NIR). Para este proyecto, se utilizó una imagen PlanetScope Analytic Ortho Scene, las cuales están corregidas radiométricamente, ortorectificadas y proyectadas en UTM, con la opción de obtenerlas con corrección atmosférica (Planet Labs Inc., 2018). Las características de estos insumos están descritas en las tablas 1 y 2.

Tabla 1. Características de la constelación PlanetScope.

<i>Atributos</i>	
<i>Bandas espectrales</i>	Blue: 455 – 515 nm Green: 500 – 590 nm Red: 590 – 670 nm NIR: 780 – 860 nm
<i>Capacidad de captura de imagen</i>	340 millones km ² /día
<i>Resolución temporal:</i>	24 h.

Tabla 2. Características de las imágenes PlanetScope Analytic Ortho Scene.

<i>Atributos</i>	
<i>Resolución espacial</i>	3 m
<i>Bandas</i>	4-bandas multiespectrales (blue, green, red, near-infrared).
<i>Bit Depth</i>	16 – bit
<i>Tamaño de escena</i>	24 por 7 km aproximadamente (varía con la altitud).
<i>Datum</i>	WGS84
<i>Proyección de mapa</i>	UTM
<i>Resampling Kernel</i>	Cubic Convolution
<i>Ground Sample Distance</i>	3.7 m (promedio de referencia a una altitud de 475 km)
<i>Exactitud posicional</i>	Menos de 10 m RMSE
<i>Correcciones radiométricas</i>	<ul style="list-style-type: none"> • Conversión a valores radiométricos absolutos basado en coeficientes de calibración. • Valores radiométricos escalados a 100 para reducir el error de cuantización.
<i>Correcciones geométricas</i>	<ul style="list-style-type: none"> • Los efectos relacionados con el sensor son corregidos utilizando un sensor de telemetría y un sensor modelo. • Para la ortorectificación usa GCPs (Ground Control Points) y DEMs (Digital Elevation Models).
<i>Correcciones atmosféricas</i>	<ul style="list-style-type: none"> • Conversión a valores de reflectancia de la parte superior de la atmósfera (TOA) utilizando la radiancia en el sensor y los coeficientes suministrados. • Conversión a valores de reflectancia de superficie utilizando el código de transferencia radiativa 6SV2.1 y los datos MODIS NRT. • Valores de reflectancia escalados en 10,000 para reducir el error de cuantificación.

2.4. WorldView-3

El satélite WorldView-3 forma parte de la constelación de satélites de Digital Globe Inc., junto con QuickBird, WorldView-1 y WorldView-2. Las imágenes de WorldView-3, se dividen en cuatro productos: las imágenes pancromáticas, las multiespectrales, las de infrarrojo de onda corta (SWIR, por sus siglas en inglés), y CAVIS (Clouds, Aerosols, Vapors, Ice, y Snow) (European Space Agency, 2014). La resolución espacial de las imágenes WorldView-3 es de 31 cm para las pancromática, 1.24 m para las multiespectrales, 3.7 m para infrarrojo de onda corta (SWIR), y 30 m para CAVIS (Digital Globe, 2014). Las características de las imágenes WV-3, que fue una de las imágenes utilizadas en este proyecto se encuentran descritas en las tablas 3 y 4.

Tabla 3. Características del satélite WorldView-3.

<i>Atributos</i>	
<i>Resolución espectral</i>	Coastal Blue: 400 – 450 nm Blue: 450 – 510 nm Green: 510 – 580 nm Yellow: 585 – 625 nm Red: 630 – 690 nm Red edge: 705 – 745 nm NIR1: 770 – 895 nm NIR2: 860 – 1040 nm
<i>Capacidad de captura de imagen</i>	1.2 millones km ² /día
<i>Resolución temporal:</i>	< 1 día

Tabla 4. Características de las imágenes multiespectrales WorldView-3.

<i>Atributos</i>	
<i>Resolución Espacial</i>	1.24 m
<i>Bandas</i>	8 bandas multiespectrales (Coastal Blue, Blue, Green, Yellow, Red, Red Edge, NIR, NIR2) 8 bandas infrarrojos y 12-bandas CAVIS.
<i>Resolución</i>	16-bit GeoTIFF
<i>Radiométrica</i>	8-bit NITF
<i>Exactitud posicional</i>	3.5 m
<i>Niveles de procesamiento</i>	Basic Standard Ortorectified

2.5. Cámara multispectral RedEdge-M

La cámara multispectral RedEdge-M de MicaSense, es una cámara con cinco bandas espectrales: Blue, Green, Red, NIR, Red Edge (Tabla 5). Cuenta con un panel de calibración de reflectancia, un GPS, y está equipada con un sensor de luz (Downwelling Light Sensor, DLS), que mide y registra la luz en el ambiente durante los vuelos para cada una de las cinco bandas. Esta información puede ser utilizada para corregir los cambios en la iluminación durante el vuelo, los cuales pueden ocurrir por nubes que cubren el sol (MicaSense, Inc., 2017). Otras características de la cámara y de las imágenes obtenidas por esta herramienta se encuentran descritas en las tablas 6 y 7.

Tabla 5. Bandas espectrales de la cámara multispectral RedEdge-M.

Número de banda	Banda	Centro de longitud de onda (nm)	Ancho de banda FWHM (nm)
1	Blue	475	20
2	Green	560	20
3	Red	668	10
4	NIR	840	40
5	Red Edge	717	10

Tabla 6. Características de la cámara multispectral RedEdge-M.

Atributos

<i>Peso</i>	170 g (Incluyendo DLS y GPS).
<i>Dimensiones</i>	9.4 cm x 6.3 cm x 4.3 cm
<i>Bandas espectrales</i>	Blue, Green, Red, Red Edge, NIR.
<i>Ground Sample Distance</i>	8.2 cm/píxel a 120 m AGL
<i>Máxima velocidad de captura</i>	1 captura por segundo

Tabla 7. Características de imágenes multispectrales de la cámara RedEdge-M.

Atributos

<i>Tamaño de la imagen</i>	12-bit DNG 16-bit TIFF
<i>Resolución espacial</i>	8 cm a 120 m
<i>Resolución</i>	1280 x 960 píxeles

2.6. Uso de clasificación supervisada

La clasificación es un análisis de fotointerpretación que se realiza a imágenes y puede ser supervisada o no. En la clasificación no supervisada se asignan clases dependiendo de las similitudes estadísticas entre píxeles, es decir los píxeles similares se asignan a una misma clase. El resultado es un conjunto de clases que se basan en el agrupamiento natural dentro del conjunto de datos. Las clases resultantes no corresponden necesariamente a clases ecológicamente significativas (Hochberg, 2011).

A diferencia de la clasificación no supervisada, la clasificación supervisada utiliza píxeles o espectros (datos de entrenamiento) en los que ya se conoce sus propiedades o la clase a la que pertenece, para guiar la clasificación del resto de los píxeles. Después las reglas de clasificación asignan el resto de los píxeles a alguna de las clases predefinidas en función de la organización estadística de los datos de entrenamiento. Entonces son los datos de entrenamiento los que definen el conjunto de clases *a priori*, si éstos son clases ecológicas, la clasificación resultante muestra la distribución de estas clases (Hochberg, 2011).

2.7. Exactitud en la cartografía temática

La exactitud se define como la relación entre el valor asignado y la condición verdadera del área (Khatami *et al.*, 2016). En las imágenes generadas por clasificación supervisada, la exactitud se refiere a la extensión de la imagen que coincide con los datos de referencia (ground truth data). Generalmente, esta exactitud se mide a través de una matriz de datos, comúnmente conocida como matriz de error o matriz de contingencia, construida a partir de los datos de clasificación y los datos de referencia (Ma & Redmond, 1995). A partir de estas matrices de error se obtiene una exactitud general (overall accuracy) de la clasificación, la cual se calcula sumando el número de píxeles clasificados correctamente entre el número de píxeles totales del set de datos de referencia. Al utilizar solo los elementos de la diagonal y no considerar la proporción de acuerdo entre los conjuntos de datos que se debe solo al azar, tiende a sobreestimar la exactitud de la clasificación (Congalton & Mead, 1983; Congalton *et al.*, 1983; Rosenfield & Fitzpatrick-Lins, 1986).

Otra medida de exactitud que se puede calcular a partir de una matriz de error es el coeficiente Kappa (Cohen, 1960), el cual mide la concordancia entre la clasificación y los valores verdaderos. Kappa expresa la reducción proporcional en el error generado por un proceso de clasificación comparado con el error de una clasificación completamente

aleatoria (Congalton, 1991). A diferencia de exactitud total, el coeficiente Kappa, considera la concordancia aleatoria "Random agreement" incorporando las distribuciones marginales en la matriz (Cohen, 1960). Un valor Kappa de 1 representa una perfecta coincidencia, mientras que un valor de 0 representa que no hay ninguna coincidencia. De acuerdo con Foody (1992), Kappa tiende a sobrestimar la concordancia aleatoria, por lo que la exactitud total de la clasificación es subestimada.

En 1995, Ma & Redmond presentaron el coeficiente Tau como un nuevo método para medir la exactitud de una clasificación. Tau se puede definir como el radio entre el número de píxeles clasificados correctamente y el número de píxeles que no fueron clasificados correctamente por asignación aleatoria. El coeficiente Tau, así como el Kappa utilizan las distribuciones marginales de los datos de referencia, la diferencia entre ambos radica en que el coeficiente Tau está basado en las probabilidades *a priori* de pertenencia al grupo, mientras que el Kappa usa las probabilidades *a posteriori* (Ma & Redmond, 1995).

La mejora de la exactitud y una mejor resolución en los mapas, son indispensables para la optimización de tiempo y recursos económicos invertidos en investigación (Garza-Pérez *et al.*, 2004). Es por eso, por lo que es importante continuar en la búsqueda e implementación de nuevas técnicas de monitoreo que proporcionen información valiosa y exacta para la gestión y toma de decisiones y acciones que favorezcan la conservación y recuperación de los arrecifes de coral a escala regional y/o global.

3. ANTECEDENTES

Distintas investigaciones en arrecifes de coral se han hecho con la ayuda de percepción remota. Una de las primeras investigaciones realizadas con teledetección en arrecifes de coral, fue la de Bour y colaboradores en 1986; mediante imágenes de alta resolución SPOT realizaron mapas temáticos de los principales tipos de hábitats arrecifales, esto con el fin de identificar los sitios de posible explotación de *Trochus niloocus* un bivalvo de gran importancia comercial en el Indo-Pacífico. Una década más tarde, en 1999, Holden y Ledrew realizaron una identificación hiperespectral de las características del arrecife de coral en Fiji, Indonesia. Ellos encontraron que la ubicación geográfica no influye en la reflectancia espectral, mientras que la morfología de los arrecifes sí lo hace y que el coral con blanqueamiento y el coral sano tienen diferencias en la reflectancia espectral.

Ya en el siglo XXI, en 2003, Hochberg y Atkinson, evaluaron la capacidad de distintos sensores remotos multi e hiperespectrales para clasificar coral, algas y sedimentos; encontrando que los sensores hiper y multiespectrales de banda estrecha tienen la capacidad de discriminar entre el coral y las algas en muchos niveles de mezcla, mientras que los sensores multiespectrales de banda ancha no lo hacen. Mumby y Edwards (2002), en un estudio en el que compararon los resultados de la clasificación de imágenes IKONOS de áreas costeras del Caribe, concluyeron que las imágenes de alta resolución son valiosas para evaluar los cambios cualitativos en hábitats marinos, e identificaron de entre 5 a 9 clases de hábitats con una exactitud general de 64 a 74%. Sin embargo, las imágenes IKONOS tienen sus limitantes, ya que en lugares en los que existe dominancia de algas, una exactitud alta en las imágenes no es posible, ya que la cobertura de las algas es subestimada y la de los corales es sobrestimada (Hochberg y Atkinson, 2003). Andréfouët *et al.*, (2003), evaluaron el potencial de las imágenes satelitales IKONOS para el mapeo de hábitats de arrecifes de coral en diferentes partes del mundo. En este estudio se observó que, a mayor complejidad del hábitat, la exactitud del mapeo mediante imágenes satelitales de alta resolución tiende a decrecer.

Teja y colaboradores (2013), en las Islas Andamán, India, evaluaron distintas técnicas de clasificación supervisada de imágenes satelitales Landsat-7 para la identificación de arrecifes de coral, encontrando que la clasificación mediante Maximum Likelihood y Support Vector Machine son buenos algoritmos para la clasificación de imágenes satelitales, gracias a sus resultados estadísticos y de clasificación por lo que son una buena herramienta para

la detección y monitoreo de arrecifes de coral. Un año después (2015), en la isla Morotai, Wahidin y colaboradores compararon la exactitud de distintos algoritmos para determinar hábitats de arrecifes coralinos, mediante técnicas de Análisis de Imágenes Basadas en Objetos (OBIA, por sus siglas en inglés) tales como: Support Vector Machine (SVM), Random Tree, Decision Tree (DT), Bayesian y k-Nearest Neighbour (KNN). Encontrando también que los valores más altos de exactitud eran obtenidos por el algoritmo SVM. Además, demostraron que los métodos basados en OBIA producían mejor exactitud que la técnica de clasificación basada en píxeles.

Por su parte, Roelfsema *et al.*, (2018), realizaron un mapeo ecológico del hábitat coralino de los arrecifes del Capricorn Bunker Group de la Gran Barrera Arrecifal (GBR), mediante un modelo empírico (OBIA) para mapear la zonación geomorfológica, tipo de cobertura bentónica dominante y el tipo de coral dominante. Los conjuntos de datos ambientales utilizados fueron: la reflectividad de fondo (obtenida de una imagen satelital Landsat 8 OLI), profundidad, pendiente, datos de impacto de arrecifes y la exposición de onda modelada. El estudio demostró que mediante la combinación de reglas y modelos geomorfológicos y ecológicos con imágenes de detección remota se pueden obtener resultados de mapeo robustos (~2500km²), esta área fue mucho más grande que la mayoría de los proyectos de cartografía con percepción remota de arrecifes de coral realizados hasta entonces. Demostraron que el método empleado puede ser utilizado para la zonación geomorfológica y cobertura bentónica de los grandes arrecifes de coral. Basado en el método de Roelfsema *et al.*, (2018), la compañía Vulcan, Inc. ha lanzado la iniciativa Allen Coral Atlas, en la cual a través de un trabajo en conjunto con Planet, Arizona State University's Center for Global Discovery and Conservation Science, University of Queensland y National Geographic Society, se ha comenzado un mapeo regional de los arrecifes alrededor del mundo. A través de técnicas de Machine Learning (Random Forest) y OBIA, utilizando imágenes satelitales PlanetScope Dove, datos de profundidad y ondas modeladas y sustitutos de textura y pendiente, se ha cartografiado arrecifes de coral con profundidades menores a 20 m, obteniendo las zonas geomórficas y zonas bentónicas.

Purkis *et al.*, (2019), publican parte del trabajo realizado por la fundación Khaled bin Sultan Living Oceans, quienes durante 10 años (2006-2015) realizaron un muestreo de diferentes arrecifes alrededor del mundo en la expedición Global Reef Expedition (KSLOF-GRE). Uno de los resultados generados en esta investigación y que abordan Purkis y colaboradores es el mapeo de 2 m de resolución del hábitat y batimetría generados a partir de imágenes de

satélite WorldView-2 y datos de campo. La cartografía total cubre 65,000 km² de arrecifes de coral de aguas someras, en los océanos Pacífico, Índico y Atlántico, teniendo exactitudes sustancialmente elevadas. El software eCognition, fue utilizado para realizar la clasificación de los hábitats, a través de la técnica de clasificación OBIA, en la que se segmenta la imagen en “objetos” los cuales están rodeados por píxeles con atributos similares. Estos objetos posteriormente son asignados en una de las clases del mapa (datos de entramiento), basado en sus firmas espectrales/texturales, forma y relaciones con las clases alrededor. Cada objeto se clasificó de acuerdo con su cobertura bentónica, zona y estructura geomorfológica. Este trabajo refleja el aumento de la resolución y exactitud en los mapas elaborados de arrecifes de coral a nivel regional.

En México, desde 2010 y durante ocho años, la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO), con la finalidad de obtener la distribución y estimación de los hábitats bentónicos, y utilizando imágenes satelitales WorldView-2 y 674 estaciones en campo, comenzó con el mapeo del arrecife caribeño que pertenece al Sistema Arrecifal Mesoamericano (SAM) y se encuentra en la costa del estado de Quintana Roo. Como resultado se generaron mapas de 4 m de resolución espacial y hasta 18 m de profundidad de: batimetría, relieve o tipos de fondos, hábitat bentónico y cobertura del fondo marino o bentónica, abarcando un área total de 1001 km².

En términos de la evaluación y aplicaciones de mapeo de fondos asociados a arrecifes y sus aplicaciones. En los últimos 30 años en el Mar Caribe diversos trabajos se han realizado del mapeo de los componentes bentónicos y zonas geomorfológicas, principalmente mediante imágenes satelitales y/o fotografía aérea (Contreras-Silva *et al.*, 2012; Cuevas-Jiménez & Ardisson, 2002; Jordan-Dahlgren, 1993; Rioja-Nieto & Sheppard, 2008). Por ejemplo, Cruz-Vázquez *et al.*, (2019) evaluaron los efectos en el espacio-tiempo del manejo en el Área Marina Protegida (AMP) Parque Nacional de Arrecifes de Cozumel (PNAC). Con imágenes satelitales IKONOS (2004) y SPOT 7 (2015), realizaron estimaciones cuantitativas del porcentaje de cobertura de los sustratos bentónicos y la ubicación de los arrecifes de coral e hicieron la comparación de las variaciones de métricas de paisaje entre 2004 y 2015, comparando dos áreas adyacentes (una dentro del área de protección y otra fuera de ella). Concluyendo que la capacidad de la AMP para contrarrestar el cambio a escala marina es limitada. Ortiz y colaboradores (2020) también en el PNAC, identificaron sitios prioritarios para su conservación, a través de un análisis de superposición ponderada en cual integraron: tipo de hábitat (SPOT 7, 2017), métricas del paisaje (β -diversidad,

complejidad estructural y conectividad), variación espacio-temporal de la cobertura bentónica (IKONOS, 2004 y SPOT 7, 2017) y la frecuencia de uso de los arrecifes para actividades de buceo. Finalmente se identificaron cinco áreas donde las estrategias de manejo necesitan ser fortalecidas y de las cuales dos se ubicaron en el área de alto uso intensivo (HIMZ).

Recientemente, se han utilizado los drones como herramienta de percepción remota, ganando popularidad principalmente por su muy alta resolución (VHR: Very High Resolution) espacial y temporal. En estos se colocan cámaras que capturan la superficie de la Tierra, principalmente en ecosistemas terrestres y teniendo un uso amplio en estudios de agricultura, en los que se han mapeado distintos cultivos a partir de imágenes multiespectrales y térmicas tomadas desde UAVs (Raeva *et al.*, 2018), obteniendo resultados más amplios y exactos al complementar la información con imágenes satelitales de alta resolución (Johansen *et al.*, 2020; Murugan *et al.*, 2016), o integrando variables de textura y modelos digitales de superficie (MDS) obtenidos a partir del ortomosaico original (Liu *et al.*, 2018). También se han utilizado las imágenes de los VANT para generar datos de entrenamiento (ground truth) (Hegarty-Craver *et al.*, 2020).

En ecosistemas costeros y marinos se han utilizado con menor frecuencia, tal es el caso del estudio realizado por Casella y colaboradores en 2016, quienes en el litoral de Borghetto Santo Spirito, Italia, a través de un dron obtuvieron modelos digitales de elevación y ortofotos de la playa, mediante los cuales evaluaron los cambios en la topografía de la playa en términos de ganancia/perdida de sedimentos y desplazamiento del límite húmedo seco que define la costa. Demostrando en su investigación que los drones pueden ser empleados para el monitoreo de playas y que pueden proporcionar información sobre los procesos de los cambios topográficos en las playas. Un año después (2017), Casella y colaboradores elaboraron datos multiespectrales y batimétricos de alta resolución espacial de una laguna arrecifal a través de un dron hasta una profundidad de 1.5 m, concluyendo que con técnicas de fotogrametría aplicadas a imágenes generadas por drones es posible mapear aspectos de ecología, geomorfología, generar datos multiespectrales y de batimetría de arrecifes de coral de poca profundidad, de manera rápida y a un bajo costo.

Las técnicas de Structure from Motion (SfM) y fotogrametría resultan prometedoras en el estudio de hábitats marinos, no obstante, Bryson y colaboradores (2017) mencionan que hay que considerar la manera en que se genera la información y la interpretación de ésta. En un estudio en el que ellos utilizaron fotogrametría para medir la complejidad estructural

de hábitats marinos (arrecifes naturales y artificiales), identificaron los errores de medición con base en la precisión y exactitud. La cuantificación de los errores de medición fue en función de la cobertura, la rugosidad y la composición de la comunidad morfológica. Los resultados mostraron que las medidas de complejidad estructural pueden estar sesgadas hasta un 7.5%, pero que este error puede disminuir al aumentar el número de imágenes de cobertura.

Existen pocos estudios de mapeo de fondos arrecifales a través de drones; Collin *et al.*, (2018), combinaron datos LiDAR con una imagen multiespectral capturada desde un dron, con el fin de mapear el estado ecológico de la laguna arrecifal de la Isla Moorea, perteneciente a la Polinesia Francesa. La imagen multiespectral abarcó un área de 0.01 km² de la laguna arrecifal con una profundidad máxima de 2 m, donde de manera visual se interpretó el estado ecológico en cinco clases y se utilizó como variable de respuesta. Obteniendo una exactitud general de 75%, el estudio demostró que se pueden obtener datos del estado de la laguna del arrecife de imágenes capturadas por cámaras multiespectrales en drones y que los datos de superficie e intensidad de LiDAR son buenos predictores del estado del arrecife de coral a escala de colonia.

Kabiri *et al.*, (2020), a través del dron Phantom 4 Pro de DJI, mapearon diferentes tipos de corales y sustratos de aguas someras del Golfo Pérsico. El vuelo fue realizado a 50 m de altura y abarcaron un área de ~6 ha, generando un ortomosaico de 2 cm de resolución espacial, del cual se vectorizó a través de digitalización los diferentes tipos de coral (*Acropora*, *Porites*, *Porites* muertos y coral con blanqueamiento) y sustratos (roca) por interpretación visual. Concluyendo que a través de la metodología planteada es posible diferenciar entre tipos de corales y sustratos mayores a 20 cm, e incluso aquellos que presentan blanqueamiento, a un costo menor que observaciones en campo y con mayor exactitud que aquellos realizados con imágenes satelitales.

Siendo relativamente nuevo su uso y teniendo éxito en ambientes terrestres, en el presente estudio se plantea evaluar la utilidad de sensores remotos emergentes en la cartografía de coberturas de arrecifes de coral mediante: 1) imágenes satelitales PlanetScope Analytic Ortho Scene y 2) ortomosaicos multiespectrales obtenidos mediante drones (VANTs); ambos compartiendo la característica de tener una alta resolución temporal (un día, u horas para los VANT). Por lo que se planea encontrar una metodología con alta exactitud para poder realizar un monitoreo robusto que pueda ser aplicado a generar estrategias de conservación de los ecosistemas arrecifales.

4. PREGUNTA DE INVESTIGACIÓN

En el marco del cambio en las comunidades bentónicas arrecifales, por causas naturales (variabilidad temporal) y asociado a presiones antropogénicas, en el presente trabajo se pretendió encontrar las herramientas de percepción remota más recomendables, mediante la evaluación de la exactitud de cada fuente de datos, abordando las siguientes preguntas:

- ¿Qué plataforma de sensores remotos emergentes de alta resolución espacial y temporal es la más adecuada para la cartografía continua (monitoreo) de componentes bentónicos arrecifales?
- ¿La información geográfica generada a través de estas plataformas es comparable, o es complementaria?
- ¿Qué algoritmo de clasificación supervisada resulta ser más exacto para la elaboración de mapas continuos de arrecifes coralinos?

5. JUSTIFICACIÓN

De acuerdo con el Reporte del Arrecife Mesoamericano (2020), en México, durante 2018, el 17% de los arrecifes de coral se encontraba en estado crítico, con un Índice de Salud Arrecifal (ISA) de entre 1.9 y 2.6 (los valores del ISA van de 1.0 igual a crítico, y 5.0 igual a muy bueno), siendo el arrecife de Akumal, Q. Roo uno de estos sitios (Healthy Reefs, 2020). En los últimos años, en la localidad de Akumal ha existido una disminución de la estructura bentónica arrecifal y de peces arrecifales, lo que ha provocado la condición crítica de este arrecife (López, 2014; Molina-Hernández *et al.*, 2018). Cabe mencionar que el Reporte del Arrecife Mesoamericano se basó en muestreos realizados antes del brote del síndrome blanco por lo que muy probablemente el ISA en la actualidad sea mucho menor (Healthy Reefs, 2020).

En pro de la recuperación de esta zona se han impulsado distintas medidas de conservación. En 2015, se implementó una Zona de Refugio Pesquero parcial temporal de seis años, como medida de manejo para la conservación y aprovechamiento sustentable de las especies de interés pesquero. De acuerdo con la Ley General de Pesca y Acuicultura, una Zona de Refugio Costero busca conservar y contribuir, natural o artificialmente, al desarrollo de los recursos pesqueros para su reproducción, crecimiento o reclutamiento, así como preservar y proteger el ambiente que los rodea (DOF, 2015). Un año después (2016) se estableció un Acuerdo para el Programa de Protección del Área de Refugio para la Protección de Especies Marinas, nombrado “Bahía de Akumal”, el cual busca la protección de diferentes especies de tortugas marinas que se encuentran en peligro de extinción, corales duros, octocorales, mangle y pastos marinos (DOF, 2017).

Dado el estado de condición en el que se encuentra el arrecife de Akumal y a las medidas de conservación que se han llevado a cabo, es necesario implementar un programa de monitoreo, que ayude a registrar la distribución espacial de los hábitats bentónicos arrecifales y su condición a lo largo de una serie de tiempo. Una manera de monitoreo es través del mapeo del ecosistema mediante el cual se pueden monitorear grandes áreas, por lo que a través de éste se podrían registrar los cambios en la cobertura del arrecife bajo la influencia de presiones antropogénicas y a lo largo de las medidas de conservación implementadas.

Mediante esta investigación proponemos dos insumos de percepción remota innovadores en el mapeo de arrecifes: 1) imágenes satelitales multiespectrales PlanetScope Analytic

Ortho Scene, las cuales tienen un alta resolución espacial (3 m) y temporal de (1 día), cuentan ya con correcciones radiométricas y en su servidor (*Planet Imagery and Archive*) se puede elegir la imagen del día que se desee por lo que hay más probabilidades de obtener una buena imagen satelital; 2) ortomosaicos multispectrales generados desde un dron, los cuales proveen una resolución espacial de centímetros y se pueden realizar múltiples vuelos en diferentes días y a diferentes horas. La facilidad y la opción de generar o elegir los insumos para su análisis, puede hacer más idóneo el uso de estas fuentes para el monitoreo de ecosistemas, que las herramientas de percepción remota tradicionales. Tanto las imágenes satelitales PlanetScope Analytic Ortho Scene, como las imágenes generadas a partir de la cámara RedEdge-M, comparten cuatro bandas espectrales y longitudes de onda similares, exceptuando por la banda Red Edge presente en la cámara RedEdge-M y ausente en las imágenes PlanetScope (-apartados 2.3 y 2.5-). Estas características espectrales hacen viable la comparación de la información generada a través de estos insumos.

A través de los resultados generados por el presente estudio se espera proveer con herramientas innovadoras para un monitoreo de alta resolución espacial y temporal y así facilitar la toma de decisiones de gestión del arrecife de coral en Akumal u otros arrecifes del Caribe; todo esto con el fin de preservar el arrecife y las especies que lo conforman, ya que los arrecifes prestan una amplia gama de servicios ambientales al ser ecosistemas productivos, con una gran riqueza biológica, y una gran importancia ecológica (participan en ciclos biogeoquímicos, proveen zonas de crianza, suministran alimento, dan protección contra tormentas tropicales, tienen atractivo turístico, etc.) (López, 2014).

6. OBJETIVOS

6.1. Objetivo general

Evaluar y comparar la exactitud de los productos geográficos generados mediante imágenes satelitales de alta resolución PlanetScope Analytic Ortho Scene e imágenes de baja altitud generadas por drones para el monitoreo de arrecifes coralinos.

6.2. Objetivos específicos

- Caracterizar la comunidad bentónica arrecifal de Akumal, Q. Roo.
- Generar ortomosaicos multiespectrales de baja altitud del arrecife mediante un dron (VANT).
- Generar mapas temáticos de fondos arrecifales a partir de ortomosaicos multiespectrales, de imágenes satelitales PlanetScope Analytic Ortho Scene y WorldView-3.
- Analizar y comparar la exactitud de la información generada por el dron y las imágenes satelitales de alta resolución PlanetScope Analytic Ortho Scene con WorldView-3.

7. ÁREA DE ESTUDIO

El arrecife de Akumal está situado en el municipio de Tulum, estado de Quintana Roo, México, en la parte este de la Península de Yucatán (Figura 1) y forma parte del Sistema Arrecifal Mesoamericano (SAM) (García-Salgado *et al.*, 2006). Es un arrecife con diversos hábitats, los cuales incluyen parches de coral, lechos de algas marinas y praderas de algas. Las estructuras del arrecife presentes en esta área tienen una geomorfología relativamente homogénea (Garza-Pérez *et al.*, 2004). Es un arrecife que cuenta con lagunas arrecifales rodeadas por el arrecife bordante y praderas de pastos marinos. Desde 2015, este arrecife forma parte de una Zona de Refugio Pesquero (Fish Refuges) temporal de seis años y una extensión de 988 ha (DOF, 2015). Además, en 2016 se inició el Programa de Protección del Área de Refugio para la Protección de Especies Marinas denominado “Bahía de Akumal” y con un área de 1653.433 ha, para la protección de tortuga verde (*Chelonia mydas*), tortuga caguama (*Caretta caretta*), tortuga carey (*Eretmochelys imbricata*), los corales cuerno de alce (*Acropora palmata*) y cuerno de ciervo (*Acropora cervicornis*), abanicos de mar (*Plexaura homomalla* y *Plexaura dichotoma*), mangle blanco (*Laguncularia racemosa*), mangle botoncillo (*Conocarpus erectus*) y mangle rojo (*Rhizophora mangle*) y los pastos marinos *Thalassia testudinum*, *Halodule wrightii* y *Syringodium filiforme* (DOF, 2017).

En la localidad de Akumal, Q. Roo, el principal ingreso económico es el turismo, el cual se ve atraído principalmente por sus playas y arrecifes de coral, donde se puede realizar snorkel y buceo, así como la observación de avistamiento de tortugas marinas. Estas mismas actividades son las que más han afectado a las comunidades coralinas, y que pueden verse comprometidas a medida que se va perdiendo cobertura coralina (Gil *et al.*, 2015; Mata-Lara *et al.*, 2018).



Figura 1. Ubicación de la localidad de Akumal, Q. Roo.

8. MATERIALES Y MÉTODOS

8.1. Obtención de datos y caracterización de los hábitats arrecifales

Se generó un muestro aleatorio estratificado al azar para asegurar que se cubrieran todos los hábitats del arrecife. Para esto se hizo una clasificación no supervisada en ERDAS IMAGINE de una imagen satelital WorldView-3 (2016) (Figura 2 a) considerando 10 clases de acuerdo con estudios pasados en el arrecife de Akumal, Q. Roo (Garza-Pérez *et al.*, 2004). Al suponer que cada estrato representa diferentes tipos de fondo, se distribuyeron aleatoriamente 80 puntos en el área de interés, distribuidos proporcionalmente al área ocupada por cada estrato, estos puntos se utilizaron como referencia para realizar los videobarridos. Sin embargo, en campo fue complicado realizar algunas de las estaciones, principalmente por las profundidades de los sitios (>15 m) o porque estaban muy cerca de la cresta arrecifal, por lo que algunas de las estaciones fueron cambiadas. El muestreo fue realizado durante los días 25 y 26 de junio de 2019, y en total fueron realizados 96 videobarridos del arrecife: laguna (66) frente y pendiente (30) (Figura 2).

Para ampliar la representación de las clases en la laguna, se agregaron estaciones de entrenamiento adicionales (dummies) de diferentes tipos de fondo (arena, parches de coral, pavimento calcáreo, pastos marinos y sargazo flotante), esto se pudo realizar gracias a la alta resolución espacial del ortomosaico multispectral obtenido y al conocimiento previo del área de estudio (Figura 2).

Para realizar los videobarridos del frente y pendiente, desde una lancha se sumergió la cámara acuática SeaViewer 6000 y se filmó por un tiempo de 15 segundos a una distancia promedio de 1 m del sustrato (Hamyilton *et al.*, 2013; 2016; Ortiz *et al.*, 2020). En el caso de la laguna arrecifal los videobarridos se hicieron nadando con la ayuda de visor y snorkel y filmando con la cámara Garmin Virb Ultra 30 a una distancia de 50 cm del sustrato aproximadamente. En el caso de ambas zonas se registraron las posiciones geográficas de inicio y final de cada barrido a través de un GPS (Garmin Etrex 10).

Para la caracterización del área de estudio, en cada videobarrido se analizaron tres cuadros contiguos (pausas) (Ortiz *et al.*, 2020), en los que se estimó el porcentaje de cobertura de grandes grupos funcionales (GGF) y tipos de sustrato (Tabla 5), considerando cada pausa como una unidad muestral, se obtuvo un total de 288 unidades muestrales.

Tabla 5. Grupos Funcionales para identificación de organismos arrecifales bentónicos y sustratos inertes.

Grupo Funcional	
Macroalgas	Algas pardas, algas verdes, algas rojas, algas calcáreas rojas, algas calcáreas articuladas.
Algas filamentosas	Algas filamentosas y algas coralinas incrustantes.
Sedimento	Arena y sedimento.
Coral Duro	Ramoso, digitiforme, domo, incrustante, cerebro, folioso, carnoso, plato, copa, pilar.
Octocoral	Digitiforme, ramoso, pluma, abanico, incrustante.
Pastos marinos	<i>Thalassia testudinum</i> , <i>Syringodium filiforme</i> .
Eponjas	Incrustantes, columna, tubo, vaso, semiesférica.
Pedacería	Cascajo coralino sin tejido vivo.

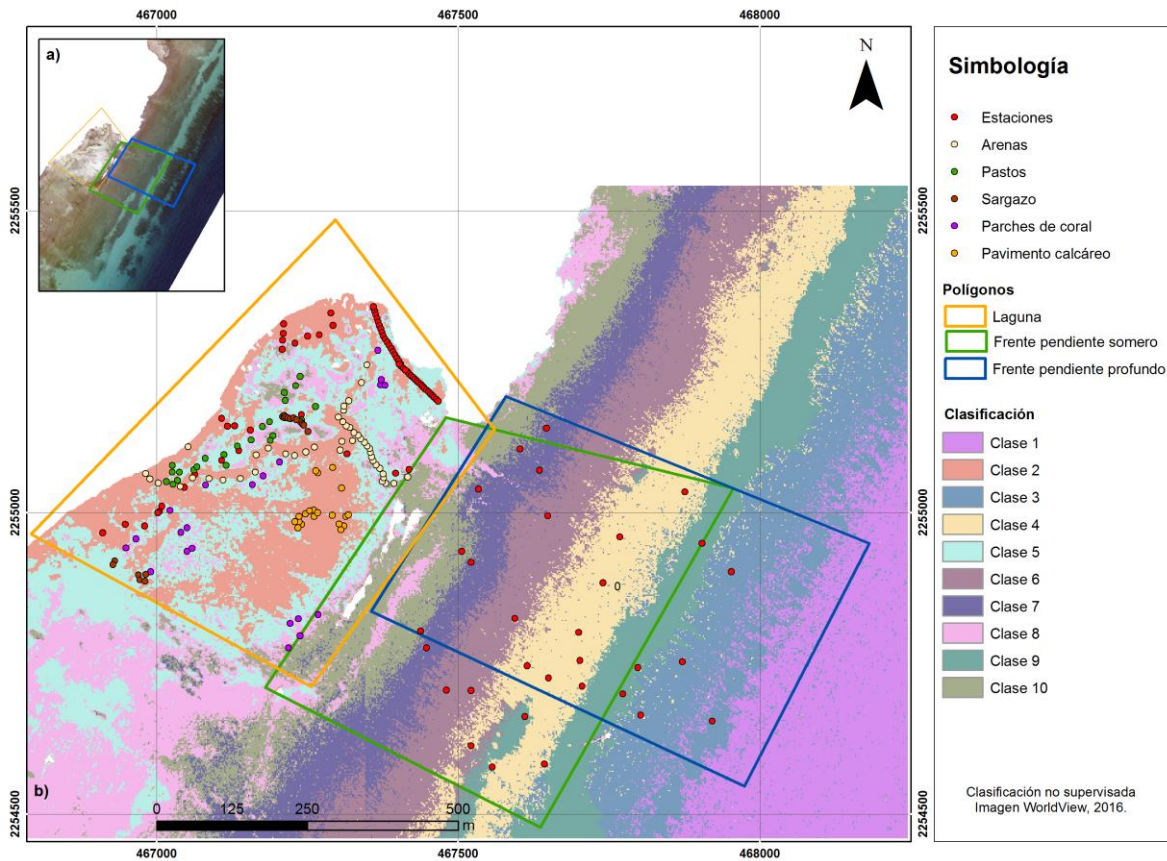


Figura 2. Diseño de muestreo del arrecife de Akumal, Q. Roo; a) Imagen de satélite WorldView-3 (2016), b) Clasificación no supervisada con 10 clases de cobertura bentónica. Estaciones de muestreo, sitios de entrenamiento y polígonos de vuelos del dron.

Para determinar las clases de cobertura bentónica de la laguna, el frente y pendiente del arrecife, se aplicó una prueba de disimilitud de Bray-Curtis a los datos de porcentaje de coberturas de cada unidad muestral, y posteriormente se realizó un análisis de clúster jerárquico (group average linkage) en PRIMER 6.0. Para obtener las clases estadísticamente distintas entre unas y otras se aplicó la prueba de hipótesis SIMPROF ($p=0.05$) (Clarke *et al.*, 2008). Estas clases fueron utilizadas para el análisis de clasificación supervisada.

8.2. Obtención de imágenes de baja altitud y generación de ortomosaicos multiespectrales

Para la generación de ortomosaicos multiespectrales de baja altitud del arrecife, se diseñaron previamente tres polígonos ($\sim 0.23\text{km}^2/23\text{ ha c/u}$) sobre la imagen de satélite WV-3: 1) laguna, 2) frente y pendiente somero y 3) frente y pendiente profundo (Figura 2 b). La obtención de imágenes fue realizada mediante una cámara multiespectral RedEdge-M de MicaSense instalada en un dron modelo Matrice 100 de la marca DJI con una sobreposición de 80%. Se realizaron dos vuelos por cada polígono en el mes de junio (2019) y tres vuelos por polígono en agosto (2019), realizando un total de 15 vuelos. Los vuelos de junio se realizaron a una altura de 100 m al nadir, mientras que en agosto el dron se voló a 120 m. De acuerdo con la NOM-107-SCT3-2019, en México la altura máxima de vuelo permitida para este tipo de drones (pequeños) es de 122 m (DOF, 2019).

Los vuelos se hicieron durante la mañana (0800 h aprox.) y antes del atardecer (1600 h aprox.), en cuanto a las condiciones atmosféricas durante los vuelos de ambos meses, el cielo estuvo despejado y con poco viento, sin nubosidad durante los vuelos del mes de junio y poca nubosidad durante agosto. Respecto a las condiciones marinas, había poco oleaje. Sin embargo, durante buceos realizados durante esos días se pudo percibir turbidez en la columna de agua, turbulencia y corriente.

Las imágenes obtenidas fueron procesadas en el software Agisoft Metashape, para generar los ortomosaicos multiespectrales a través de cuatro pasos.

1. Alineación: En este paso el software alinea las imágenes utilizando el algoritmo Structure from Motion (SfM), el cual busca puntos en común en las imágenes y las empareja, y a su vez ajusta los parámetros de calibración de la cámara. Finalmente genera una nube de puntos dispersos y un conjunto de posiciones de cámara.

- 1.1. Para el caso de los ortomosaicos del frente y pendiente, fue necesario optimizar la alineación de imágenes, colocando marcadores con aproximaciones manuales para especificar ubicaciones en las imágenes tomadas por la cámara multiespectral, debido a que el software por sí mismo no pudo hacer la alineación de las imágenes.
2. Nube de puntos densos: A partir del conjunto de posiciones de cámara se genera una nube de puntos densos.
3. Generar una superficie: A partir de la nube de puntos densos, se construye un MDE (Modelo Digital de Elevación) con una proyección geográfica, en este caso WGS84.
4. Generación del ortomosaico: el cual se proyecta sobre una superficie, en este caso el MDE.

8.3. Preprocesamiento de imágenes de satélite y ortomosaicos multiespectrales

A las imágenes satelitales del año 2016: PlanetScope (20161022_140829, 30, 31 y 32_0c65_3B_AnalyticMS) (con fecha del 22 de octubre de 2016) y WorldView-3 (16MAY29164014-M2AS-055333332010_01_P001 y _P002) (con fecha del 16 de mayo de 2016), se les aplicaron las técnicas de preprocesamiento de corrección atmosférica, del brillo de olas y de la columna de agua, en el software ENVI 5.3.

La imagen satelital de alta resolución PlanetScope Analytic Ortho Scene (Nivel 3B) del área de estudio y con fecha de 16 de mayo de 2019 (20190516_155847, 48_1032_3B_AnalyticMS_DN), fue obtenida a través de *Planet Imagery and Archive*, ya ortorectificada, con corrección radiométrica, sensorial y atmosférica y en un sistema de coordenadas WGS84. Por lo que, esta imagen únicamente se le aplicó la corrección del brillo de olas y corrección de la columna de agua, en el software ENVI 5.3. Esta imagen fue la mejor de las imágenes más cercanas a la fecha del muestreo.

En el caso del ortomosaico multiespectral de la laguna solo se le aplicó la corrección de la columna de agua. Además, se realizó un re-escalamiento espacial de éste, disminuyendo la escala de 8 a 32 cm a través del método de Pixel Aggregate, el cual es el método recomendado cuando los factores “x” y “y”, son menores a 1. Este método promedia el porcentaje de contribución de cada uno de los 16 píxeles que contribuyeron al píxel de salida (Harris Geospatial Solutions, Inc., 2020).

8.3.1. Corrección atmosférica

Para eliminar el efecto de la dispersión de la energía electromagnética se hizo una corrección atmosférica a la imagen WorldView-3 (2016) y PlanetScope (2016), a través del Método Simple de Sustracción de Objetos Oscuros (Dark Pixel Subtraction) (Chavez, 1988). El método consiste en restar los valores de los píxeles oscuros a todos los demás píxeles, esto de acuerdo con la suposición de que en algún lugar de la imagen se encuentra un píxel con cero reflectancia, lo que se interpretaría como que el valor registrado únicamente proviene de la dispersión atmosférica (path radiance). Se optó por este método ya que ENVI 5.3 no cuenta con las especificaciones de formato para procesar imágenes PlanetScope con algoritmos más avanzados como el FLAASH o el QUAC (Quick Atmospheric Correction).

8.3.2. Corrección del brillo de olas

Varios algoritmos para eliminar la reflexión del brillo solar en la superficie del agua han sido propuestos, todos basados en la suposición de que la variación espacial en la banda del infrarrojo cercano (NIR) se debe únicamente al brillo. El método propuesto por Hochberg *et al.*, (2003), también se basa en que el brillo solar en las bandas visibles está linealmente relacionado con el brillo en la banda NIR.

La corrección del brillo en las olas o *sun-glint correction*, se realizó por el método descrito por Hochberg *et al.*, (2003) y redefinido por Hedley *et al.*, (2005). Además, se omitió la resta del valor mínimo de NIR de la ecuación original, ya que los valores de los píxeles oscuros fueron eliminados durante la corrección atmosférica. Por lo que la ecuación para eliminar el brillo de olas quedo de la siguiente manera:

$$R'_i = R_i - b_i (R_{NIR})$$

Donde:

R_i = es la radiancia de la banda i .

b_i = es la pendiente de la regresión lineal para la banda i (axis y) con la banda NIR (axis x).

R_{NIR} = es la radiancia de la banda NIR.

8.3.3. Corrección de la columna de agua/Calibración de profundidad

Para eliminar los efectos de la profundidad en las imágenes satelitales y el ortomosaico multiespectral se les aplicó una corrección a los insumos de acuerdo con el método de Lyzenga (1985).

Procedimiento:

1. Crear un subconjunto espacial del área más profunda de la imagen corregida atmosféricamente y del brillo de las olas.
2. Determinar el valor mínimo espectral para cada banda.
3. Restar el valor anterior y sacar el logaritmo natural de esta cifra para la totalidad de cada banda.

$$R_{Linear} = Ln (R_i - R_{imin})$$

Donde:

R_i = es la radiancia de la banda i

R_{imin} = es la radiancia mínima de la banda i

8.4. Clasificación supervisada

A manera de referencia, se realizó la clasificación supervisada de una imagen satelital WorldView-3 (2016) con datos de archivo *-no publicados-* de coberturas de GGF del área de estudio en octubre de 2016 (76 estaciones; videotransectos de 50 x 0.6 m) del Programa de Investigación Espacial en Ambientes Costeros y Marinos (PIESACOM). Para tener un parámetro de comparación entre las imágenes satelitales PlanetScope y el ortomosaico multiespectral, ya que las imágenes multiespectrales de los satélites de la serie WorldView han sido utilizadas ampliamente para el mapeo de ambientes costeros marinos con éxito (Cerdeira-Estrada *et al.*, 2012; CONABIO, 2010; Guoqiang *et al.*, 2016; Purkis *et al.*, 2019).

A su vez, también se realizaron las clasificaciones supervisadas de las imágenes satelitales PlanetScope (2016) (con los datos del muestreo de 2016), PlanetScope Analytic Ortho Scene (2019) y del ortomosaico multiespectral previamente preprocesado. Utilizando el 70% de las unidades muestrales como datos de entrenamiento, para aplicar distintos algoritmos de clasificación: Máximum Likelihood, Minimum Distance, Mahalanobis

Distance, Support Vector Machine y Neural Network. Todas las clasificaciones supervisadas se realizaron en el software ENVI 5.3.

8.5. Evaluación de la exactitud de cartografía de imágenes satelitales y ortomosaico multiespectral

Para evaluar la exactitud de la clasificación de los insumos, se utilizó un set de datos independiente (un subconjunto del 30% de los datos colectados en campo, separados del conjunto de datos utilizados para la generación de la cartografía). Al realizar las clasificaciones se generó una matriz de error (Story & Congalton, 1986), la cual compara las clases que fueron identificadas contra los datos de entrenamiento. A partir de esta matriz de error, se midió la exactitud a través de tres métodos distintos: 1) exactitud general (overall accuracy), 2) coeficiente Kappa (Congalton, 1991) y 3) coeficiente Tau con sus intervalos de confianza con un nivel de significancia del 95% (Ma & Redmond, 1995).

La exactitud general, se calculó a través de la suma de los píxeles clasificados correctamente entre el número total de los píxeles utilizados como referencia. Es decir, en los píxeles ubicados en la diagonal de la matriz. El reporte de exactitud de una clasificación cuantifica que porcentaje de los datos de entrenamiento (que ya están asignados dentro de una clase) está contenido dentro de las clases resultantes.

El coeficiente Kappa determina la exactitud de la clasificación, un valor Kappa de 1 representa una coincidencia perfecta, mientras que un valor de 0 indica que las clases determinadas no coinciden con la realidad. Para evaluar el rendimiento de las clasificaciones a través de Kappa, se establecieron las siguientes categorías: pobre (≤ 0), escaso (0.01-0.20), justo (0.21-0.40), moderado (0.41-0.60), substancial (0.61-0.80) y excelente (≥ 0.81) (Sim & Wright, 2005; Ventura *et al.*, 2018).

El coeficiente Kappa, se calculó mediante la siguiente formula:

$$K = \frac{P_o - P_c}{1 - P_c}$$

donde:

$$P_o = \sum_{i=1}^M P_{ii}$$

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

y

$$Pc = \sum_{i=1}^M P_{i+} P_{+i}$$

$$= \frac{1}{N^2} \sum_{i=1}^M n_{ii}$$

Po: Overall accuracy/Percentage agreement.

Pc: Chance agreement.

N: Número total de píxeles.

M: Número de clases.

P_{ii} : el número de observaciones en filas i y columnas i

P_{i+} y P_{+i} : los totales marginales de filas i y columnas i .

Adicionalmente, se calculó el coeficiente Tau, el cual se obtiene de dos maneras distintas: una cuando las probabilidades *a priori* de pertenecer a una clase son iguales y la otra cuando estas probabilidades son desiguales. En este estudio para todas las clasificaciones, se calculó el coeficiente Tau para probabilidades iguales, porque en la clasificación supervisada no se utilizó información *a priori* de probabilidad de clase (Purkis *et al.*, 2019). Para clasificaciones basadas en la misma probabilidad, la concordancia aleatoria (Pr) es el recíproco del número de grupos (Ma & Redmond, 1995).

Para Tau con probabilidades iguales:

$$Te = \frac{Po - \frac{1}{M}}{1 - \frac{1}{M}}$$

$$= T_e$$

tal que

$$\begin{aligned}
 Pr &= \frac{1}{N^2} \sum_{i=1}^M n_{i+} x_i \\
 &= \frac{1}{N^2} \sum_{i=1}^M n_{i+} \frac{N}{M} \\
 &= \frac{1}{M}
 \end{aligned}$$

Po: Overall accuracy/Percentage agreement.

Pr: Random agreement.

N: Número total de píxeles.

M: Número de clases.

$P_{i+}(n_{i+}/N)$: La distribución marginal de los datos de referencia.

$P_i(x_i/N)$: Las probabilidades *a priori* de pertenencia de grupo.

8.5.1. Prueba de diferencias significativas e intervalos de confianza

Cuando los coeficientes de exactitud son significativamente mayores a cero, indican que la clasificación es significativamente mejor que una asignación aleatoria. Sin embargo, para evaluar estadísticamente cuál de los insumos tiene mejor desempeño en el mapeo de la cobertura bentónica arrecifal, se aplicó una prueba de diferencias significativas y se calcularon los intervalos de confianza con un nivel de significancia del 95%.

$$\text{Intervalo de confianza} = \text{Coeficiente de exactitud} \pm 1.96\sigma$$

Para la prueba de significancia entre dos coeficientes de exactitud, para dos clasificaciones independientes:

$$Z = \frac{T_{e1} - T_{e2}}{\sqrt{\sigma_1^2 + \sigma_2^2}}$$

T_e = valor de coeficiente Tau para probabilidades iguales.

σ^2 = varianza de Tau.

9. RESULTADOS

9.1. Comparación entre imágenes satelitales WorldView-3 y PlanetScope

De los datos de cobertura bentónica de 2016, se definieron 7 clases (Tabla 6). Basado en el esquema de clasificación y con el 70% de los datos colectados en campo se procedió a realizar las clasificaciones supervisadas a las imágenes satelitales del año 2016 previamente preprocesados: WorldView-3 (mayo) y PlanetScope (octubre), con los diferentes algoritmos de clasificación (Maximum Likelihood, Support Vector Machine, Neural Network, Mahalanobis Distance y Minimum Distance) (Figura 5).

Tabla 6. Esquema de clasificación de los hábitats bentónicos arrecifales de Akumal, Q. Roo, 2016.

<i>Clase</i>	
1	Parches en Laguna con baja cobertura coralina.
2	Parches en Laguna con algas filamentosas y octocorales.
3	Parches en Laguna dominados por algas filamentosas.
4	Frente arrecifal, dominado por coral pétreo y macroalgas.
5	Pendiente del arrecife dominado por algas pardas.
6	Frente arrecifal, dominado por algas filamentosas.
7	Arenas en su totalidad: zona de laguna, canal de arena y zona profunda.

Para la imagen satelital de PlanetScope (2016), el algoritmo que presentó mayor exactitud de acuerdo con la medición de exactitud general (P_o) fue SVM, seguido de Maximum Likelihood, con 95.70 y 92.37%, respectivamente. En el caso de la imagen WorldView-3, los clasificadores con exactitud general más alta fueron Neural Network y Minimum Distance, con 96.53 y 87.74%, respectivamente (Tabla 7 y Figuras 3 y 4). Sin embargo, para la comparación de los resultados de la clasificación de ambas imágenes se decidió utilizar el algoritmo de Maximum Likelihood y reportar su eficiencia para la clasificación de fondos bentónicos arrecifales, teniendo una exactitud general de 92.37% para PlanetScope (2016) y 82.21% para WV-3 (2016) (Figura 6).

Adicionalmente se calculó el coeficiente Tau de probabilidades equitativas (T_e), para todos los algoritmos de clasificación (Tabla 7). Con el cual, el algoritmo de Maximum Likelihood, en la clasificación de la imagen PlanetScope (2016), obtuvo un $T_e=0.9108$, lo que indica que 91% más píxeles se clasificaron correctamente de lo que se esperaría por asignación

aleatoria (Figura 6a). Mientras que para la imagen WV-3 (2016), 79% más píxeles se clasificaron correctamente de lo que se esperaría por asignación aleatoria (Figura 6b).

Tabla 7. Evaluación de exactitud de clasificadores para las imágenes satelitales PlanetScope y WorldView-3 (2016) en Akumal, Q. Roo, 2016.

Clasificador	PlanetScope, 2016			WorldView-3, 2016		
	Exactitud general	Kappa	Tau e intervalo de confianza (95%)	Exactitud general	Kappa	Tau e intervalo de confianza (95%)
Maximum Likelihood	92.37%	0.8567	0.9108 (0.8963, 0.9253)	82.21%	0.6945	0.7924 (0.7861, 0.7987)
Support Vector Machine	95.70%	0.9156	0.9458 (0.9313, 0.9603)	-	-	
Neural Network	19.97%	0.1653	0.0615 (0.0470, 0.0760)	96.53%	0.9315	0.9594 (0.9531, 0.9657)
Mahalanobis Distance	83.88%	0.6719	0.8118 (0.7973, 0.8263)	79.64%	0.6429	0.7623 (0.7560, 0.7683)
Minimum Distance	88.41%	0.7785	0.8647 (0.8502, 0.8792)	87.74%	0.7706	0.8568 (0.8505, 0.8631)

En el análisis estadístico para determinar si existen diferencias significativas entre la exactitud de ambas clasificaciones con Maximum Likelihood (WorldView-3 y PlanetScope, 2016), se obtuvo un valor de 14.64 ($\alpha=0.05$). Lo que indica que el valor de Tau de ambas clasificaciones es significativamente diferente con un nivel de significancia del 95%. Esto indica, que efectivamente con los datos utilizados para esta clasificación la imagen satelital PlanetScope (2016), tuvo un mejor desempeño que la imagen WorldView-3.




Figura 3. Comparación de exactitud general (Po), Kappa (K) y Tau (Te) para imagen satelital PlanetScope, 2016, a través de diferentes clasificadores. MD: Mahalanobis Distance; MinD: Minimum Distance; ML: Maximum Likelihood; NN: Neural Network; SVM: Support Vector Machine.


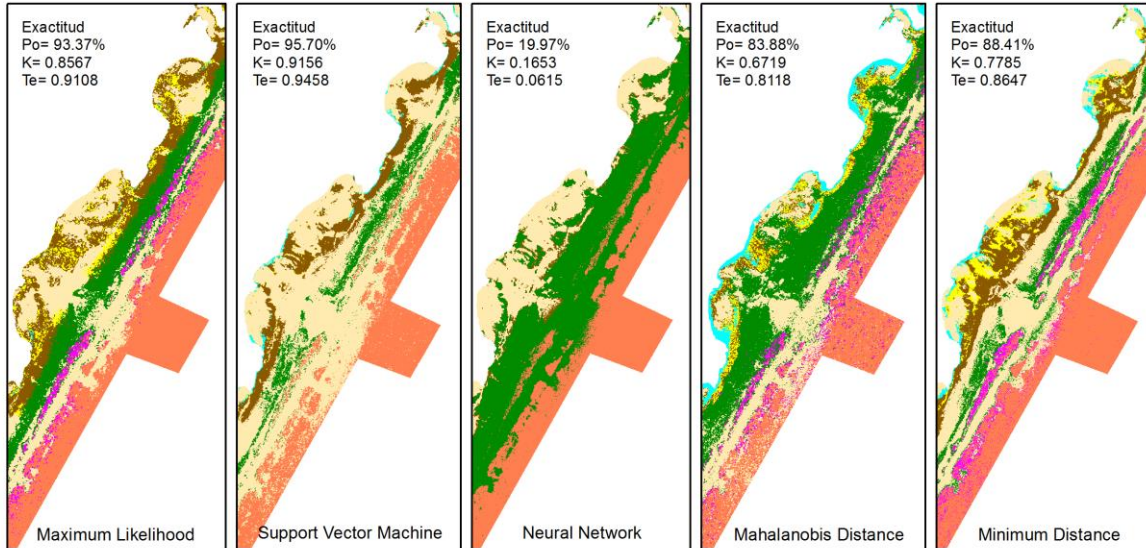
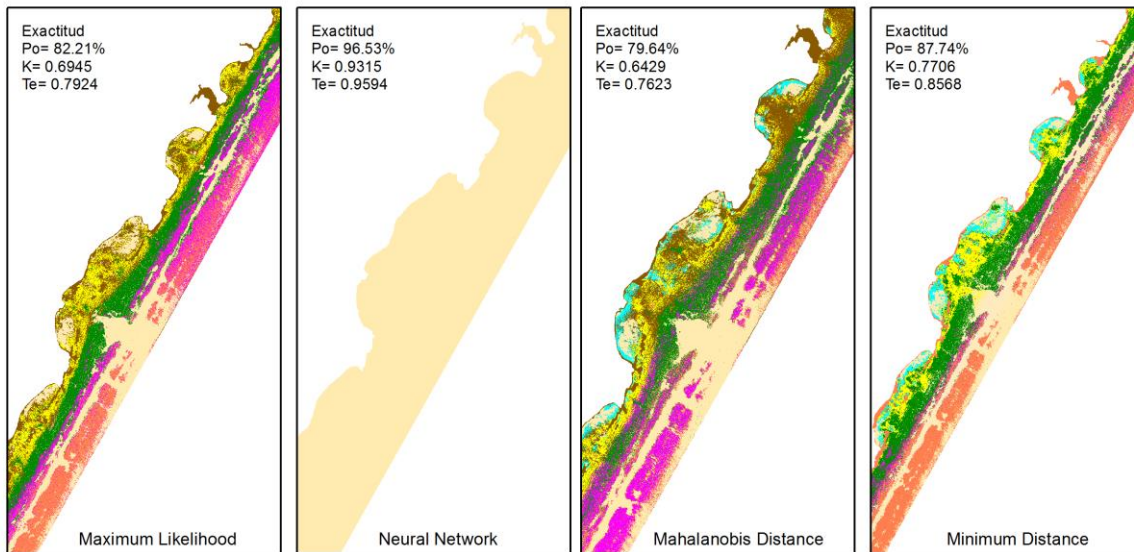


Figura 4. Comparación de exactitud general (Po), Kappa (K) y Tau (Te) para imagen satelital WorldView-3, 2016, a través de diferentes clasificadores. MD: Mahalanobis Distance; MinD: Minimum Distance; ML: Maximum Likelihood; NN: Neural Network.

PlanetScope, 2016



WorldView-3, 2016



Simbología

- Clase 1. Parches en Laguna con baja cobertura coralina.
- Clase 2. Parches en Laguna con algas filamentosas y octocorales.
- Clase 3. Parches en Laguna dominados por algas filamentosas.
- Clase 4. Frente arrecifal, dominado por coral pétreo y macroalgas.
- Clase 5. Pendiente del arrecife dominado por algas pardas.
- Clase 6. Frente arrecifal, dominado por algas filamentosas.
- Clase 7. Arenas: zona de laguna, canal de arena y zona profunda.

Figura 5. Comparación de imágenes clasificadas (clasificación supervisada) con diferentes algoritmos. A partir de imágenes satelitales PlanetScope (2016) y WorldView-3 (2016), representando las diferentes clases de cobertura bentónica en el arrecife de Akumal, Q. Roo.

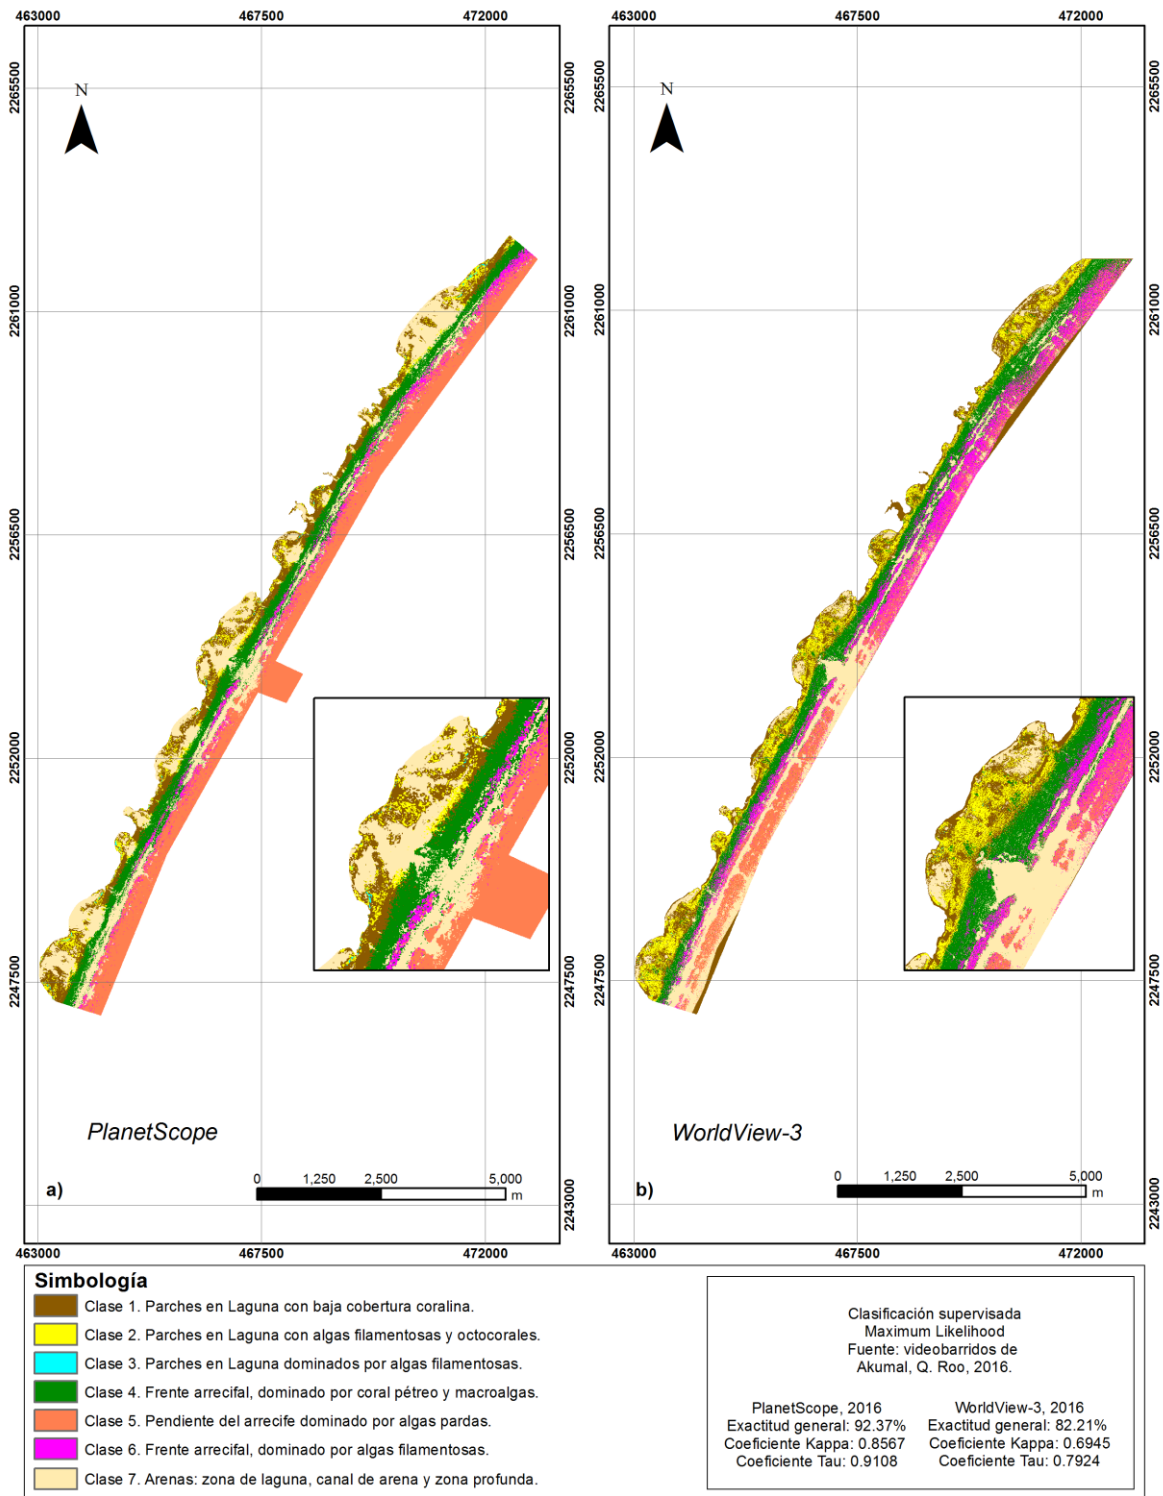


Figura 6. Comparación de imágenes clasificadas (clasificación supervisada), mediante el algoritmo Maximum Likelihood: a) Imagen satelital PlanetScope, 2016 (exactitud general de 92.36%); b) Imagen satelital WorldView-3, 2016 (exactitud general de 82.21%). Representando la distribución espacial de las diferentes clases de cobertura bentónica del arrecife de Akumal, Q. Roo.

9.2. Caracterización de comunidades bentónicas, 2019

9.2.1. Laguna arrecifal

De acuerdo con los videotranssectos realizados en la laguna arrecifal durante el muestro en campo de junio de 2019, los GGF que dominaron fueron las arenas y sedimentos en casi un 60%, seguido de pastos marinos (26.30%) y algas filamentosas (10.14%), y con menos de 5% de cobertura se encuentran las macroalgas (algas pardas, algas verdes, algas rojas, algas calcáreas rojas), coral duro, octocoral, esponjas y pedacería (Figura 7).

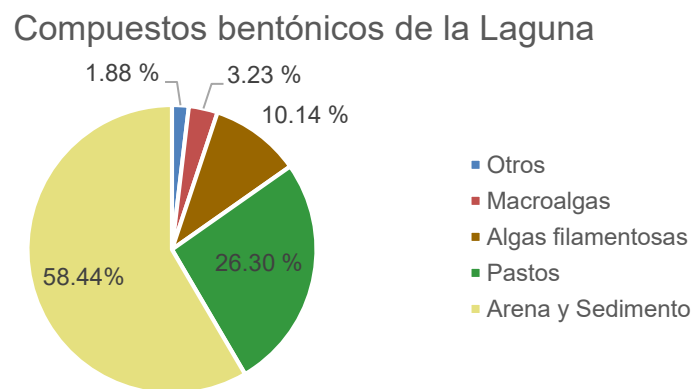


Figura 7. Porcentaje de los componentes bentónicos en la laguna arrecifal de Akumal, Q. Roo, junio 2019.

9.2.2. Esquema de clasificación de la cobertura de la laguna arrecifal, 2019

Después de realizar el análisis de clúster jerárquico de los porcentajes de cobertura de las estaciones de la laguna (Figura 8), se definieron 6 clases de cobertura bentónica (primeras seis clases de la tabla 8).

Con el fin de representar adecuadamente todas las características tanto de la laguna como de la superficie del agua, se decidió añadir estaciones de entrenamiento adicionales (dummies) de pastos marinos, arena y sedimento, pavimento calcáreo, parches de coral y sargazo flotante. De las estaciones de entrenamiento de parches de coral y de sargazo flotante se decidió hacer una clase para representar cada uno de esos componentes, añadiendo las clases 7 (Parches de coral) y 8 (Sargazo flotante). En el caso de las estaciones adicionales de pastos marinos y arenas y sedimento, se incluyeron dentro de las clases 1 y 6, respectivamente. Las estaciones de pavimento calcáreo se incluyeron

dentro de la clase 2 (Cobertura alta de sedimento con cobertura media de algas filamentosas), esto último después de realizar un análisis de separabilidad (Tabla 8).

Tabla 8. Esquema de clasificación de hábitats en la laguna de Akumal, Q. Roo, 2019.

<i>Clase</i>	
1	Praderas de pastos marinos.
2	Cobertura alta de sedimento con cobertura media de algas filamentosas.
3	Dominado por sedimento con cobertura baja de macroalgas.
4	Cobertura alta de sedimento con cobertura baja de pastos marinos.
5	Cobertura media de sedimento y de macroalgas.
6	Arena y sedimento.
7	Parches de coral con cobertura media de sedimento y cobertura baja de macroalgas y algas filamentosas.
8	Sargazo flotante.

La descripción de cada clase se hizo respecto al porcentaje de cobertura de cada grupo funcional y tipo de sustrato (Tabla 9), tomando los rangos de la tabla 10 como referencia (Ortiz, 2019).

Tabla 9. Porcentaje de cobertura de GGF en la laguna arrecifal de Akumal, Q. Roo, 2019.

<i>Clase</i>	<i>Coral duro</i>	<i>Octocoral</i>	<i>Macroalgas</i>	<i>Algas filamentosas</i>	<i>Esponjas</i>	<i>Pastos</i>	<i>Arena y sedimento</i>	<i>Pedacería</i>	<i>Sargazo</i>
1	0.00	0.00	0.08	0.00	0.00	93.81	6.11	0.00	0.00
2	0.20	0.30	1.20	35.30	0.10	0.00	62.70	0.20	0.00
3	0.00	0.00	13.60	3.60	0.00	0.00	82.80	0.00	0.00
4	0.00	0.00	1.33	0.00	0.00	24.67	74.00	0.00	0.00
5	0.67	0.00	34.67	4.00	0.00	2.67	56.00	2.00	0.00
6	0.12	0.06	0.49	0.86	0.06	0.18	98.03	0.18	0.00
7	2.50	4.70	15.80	15.65	0.60	0.10	60.53	0.12	0.00
8	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	100.00

Tabla 10. Rangos de cobertura.

<i>Cobertura</i>	<i>Rangos</i>
Presencia	<10%
Cobertura Baja	≥ 10 < 30%
Cobertura Media	≥ 30 < 60%
Cobertura Alta	≥ 60 < 80%
Dominado	≥ 80

Cobertura Laguna Group average

Resemblance: S17 Bray Curtis similarity




Figura 8. Dendrograma de clúster jerárquico de la Laguna arrecifal de Akumal, Q. Roo., 2019.

9.1. Elaboración de ortomosaicos multiespectrales

En el software Agisoft Metashape se realizó de manera automática un ortomosaico multiespectral de la laguna del mes de junio. No obstante, no se logró alinear las imágenes de los vuelos de la laguna del mes de agosto (Figura 9) ni del frente y pendiente de ninguno de los dos meses. Por lo que, para optimizar la alineación de las imágenes del frente y pendiente, se procedió a colocar marcadores de ubicación de manera manual. A pesar de lo anterior, el software tampoco consiguió alinear estas imágenes.




Figura 9. Vista previa en el software Agisoft Metashape de un ortomosaico de la laguna arrecifal de Akumal, Q. Roo, del mes de agosto de 2019, no resuelto por completo, generado a través de imágenes de la cámara multiespectral del dron.

9.1.1. Preprocesamiento de ortomosaico multiespectral

Debido a la baja altitud a la que se realizan los vuelos y a la ausencia de brillo en la superficie del agua en el ortomosaico multiespectral de la laguna, a este solo se le aplicó la corrección de la columna de agua (Figura 10). Además, debido a que se identificó en los ortomosaicos multiespectrales una alta variabilidad de los valores espectrales (efecto sal y pimienta), se decidió aplicarles un re-escalamiento espacial, disminuyendo la resolución espacial de 8 a 32 cm, por el método de Pixel Aggregate en ENVI 5.3.




Figura 10. Ortomosaico multispectral preprocesado de la laguna arrecifal de Akumal, Q. Roo (junio de 2019). a) Ortomosaico multispectral generado a través de las imágenes de la cámara multispectral en el dron (visualizado en RGB); b) Recorte del área de interés, ortomosaico multispectral después de aplicarle la corrección de la columna de agua.

9.2. Preprocesamiento de imagen satelital PlanetScope Analytic Ortho Scene, 2019.

A la imagen satelital PlanetScope Analytic Ortho Scene del mes de mayo del 2019, se le aplicaron las correcciones del brillo de olas y de la columna de agua (Figura 11). Este imagen ya preprocesada es la que fue utilizada posteriormente para la clasificación supervisada.

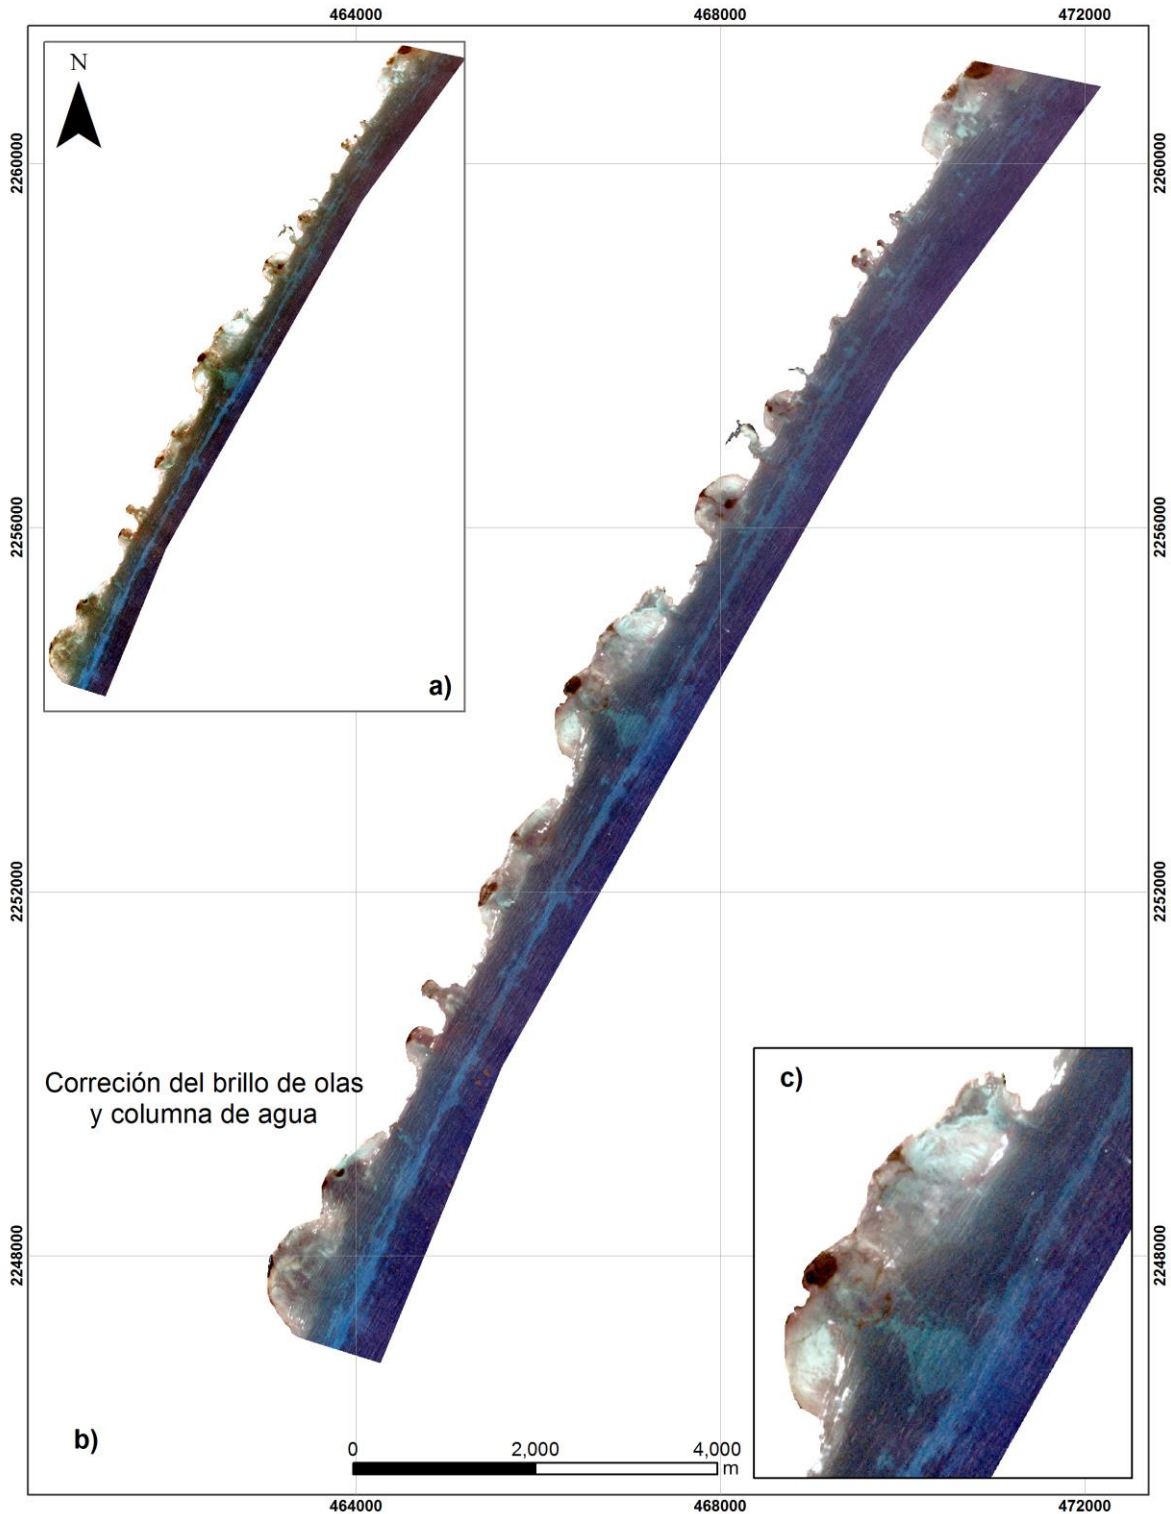
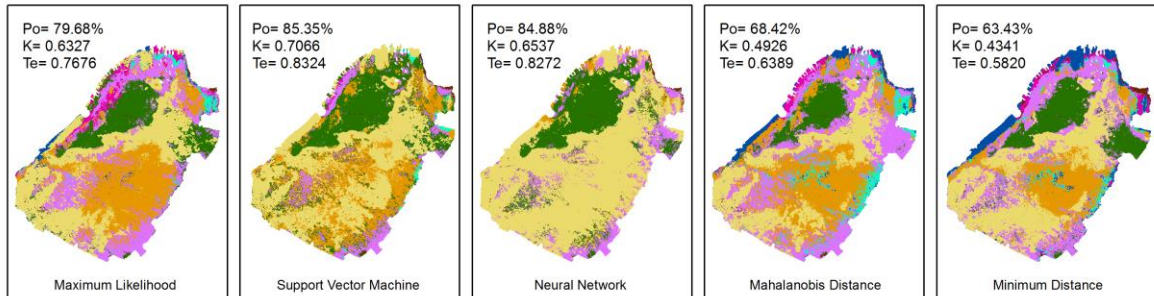


Figura 11. Imagen satelital PlanetScope Analytic Ortho Scene (2019), preprocesada. a) Recorte del área de interés de la imagen satelital original (visualizada en RGB), b) Recorte de la imagen satelital después de aplicarle la corrección del brillo de olas y de la columna de agua. c) Detalle del área de interés de la laguna arrecifal de Akumal, Q. Roo.

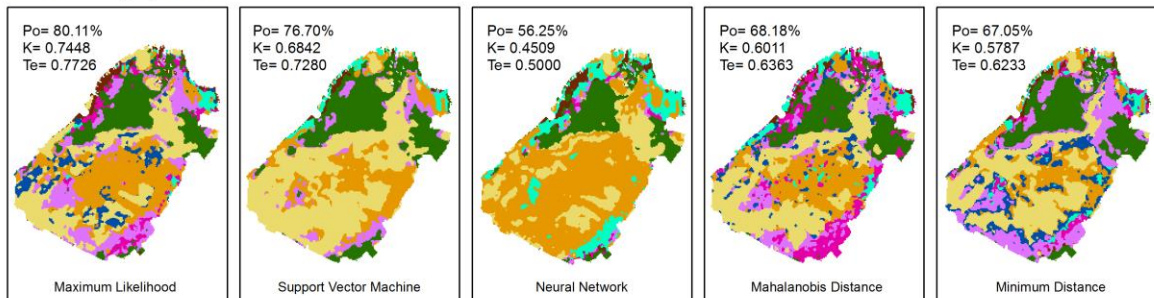
9.3. Clasificaciones supervisadas de insumos de 2019

Para ambas fuentes de datos (ortomosaico multispectral e imagen satelital PlanetScope Analytic Ortho Scene, 2019) se aplicaron los mismos algoritmos de clasificación: Maximum Likelihood, Support Vector Machine, Neural Network, Mahalanobis Distance y Minimum Distance, en el software ENVI 5.3 (Figura 12).

Ortomosaico multispectral, 2019



PlanetScope, 2019



Simbología	
	Clase 1. Praderas de pastos marinos.
	Clase 2. Cobertura alta de sedimento con cobertura media de algas filamentosas.
	Clase 3. Dominado por sedimento con cobertura baja de macroalgas.
	Clase 4. Cobertura alta de sedimento con cobertura baja de pastos marinos.
	Clase 5. Cobertura media de sedimento y de macroalgas.
	Clase 6. Arena y sedimento.
	Clase 7. Parches de coral con cobertura media de sedimento y cobertura baja de macroalgas y algas filamentosas.
	Clase 8. Sargazo flotante/Sargazo en degradación.

Figura 12. Comparación de imágenes clasificadas (clasificación supervisada) con diferentes algoritmos. A partir de ortomosaico multispectral (obtenido con la cámara multispectral RedEdge-M, instalada en el dron Matrice 100), e imagen satelital PlanetScope Analytic Ortho Scene (2019), representando las diferentes clases de cobertura bentónica de la laguna arrecifal de Akumal, Q. Roo.

9.3.1. Ortomosaico multiespectral

Se obtuvieron distintas exactitudes para cada uno de los algoritmos en las clasificaciones supervisadas en el ortomosaico multiespectral (Tabla 11). Siendo el algoritmo de Support Vector Machine el que apporto mayor exactitud a la clasificación, con una exactitud general de 85.35% y un coeficiente kappa de 0.7066. La exactitud medida por el coeficiente Tau fue de 0.8324, lo que indica que 83.24% más de píxeles se clasificaron correctamente de lo que se esperaría por asignación aleatoria (Figuras 13 y 14).

El algoritmo de Neural Network fue el siguiente en cuanto a nivel de exactitud ($P_o = 84.88\%$, $K = 0.6537$, $T_e = 0.8272$), no obstante, en este insumo se sobreestimó el porcentaje de arenas y sedimentos (Figura 12), al igual que en las clasificaciones de las imágenes satelitales del 2016 (Figura 5).

Tabla 11. Evaluación de exactitud de clasificadores para el ortomosaico multiespectral, en la laguna arrecifal de Akumal, Q. Roo, 2019.

Clasificador	Exactitud general	Kappa	Tau e intervalos de confianza (95%)
Maximum Likelihood	79.68%	0.6327	0.7676 (0.7545, 0.7807)
Support Vector Machine	85.35%	0.7066	0.8324 (0.8193, 0.8455)
Neural Network	84.88%	0.6537	0.8272 (0.8141, 0.8403)
Mahalanobis Distance	68.42%	0.4926	0.6389 (0.6258, 0.6520)
Minimum Distance	63.43%	0.4341	0.5820 (0.5689, 0.5951)

En este insumo, no se obtuvieron exactitudes de producción y de usuario prometedoras, teniendo exactitudes de producción y de usuario de 0 a 48% para la mitad de las clases. Y para la otra mitad de 82 a 100% (Tabla 12).

De acuerdo con este análisis, la clase que se clasificó con mayor exactitud fue la clase 8 (Sargazo flotante) ya que el 95% (producir accuracy) de los píxeles de referencia de esta clase fueron asignados correctamente. Las clases 1, 6 y 7 también tuvieron una buena exactitud, con más del 80% de sus puntos de control clasificados correctamente. Mientras que las clases 3, 4 y 5 tuvieron una clasificación deficiente (Tabla 12).




Figura 13. Comparación de exactitud general (Po), Kappa (K) y Tau (Te) para ortomosaico multiespectral de la laguna, a través de diferentes clasificadores. MD: Mahalanobis Distance; MinD: Minimum Distance; ML; Maximum Likelihood; NN: Neural Network; SVM: Support Vector Machine.

Las clases 3 y 5 (Dominado por sedimento con cobertura baja de macroalgas y Cobertura media de sedimento y de macroalgas, respectivamente) fueron las que presentaron mayor complicación ya que ninguno de los datos de entrenamiento de esa clase, fueron clasificados como tal, y hay nula probabilidad de que los píxeles clasificados como esas dos clases sean realmente clase 3 o 5. En el caso de la clase 3 (Dominado por sedimento con cobertura baja de macroalgas), ésta en su mayoría fue clasificada como clase 2 y clase 6 (Cobertura alta de sedimento con cobertura media de algas filamentosas y Arena y sedimento, respectivamente), lo que podría considerarse como un error, o no, si consideramos que los sedimentos es lo que domina en la clase 3. Lo mismo para la clase 5, que en su mayoría fue clasificada como clase 2 (Tabla 12).

Tabla 12. Matriz de contingencia por porcentaje. Clasificación supervisada (Support Vector Machine) del ortomosaico multiespectral de la laguna arrecifal. Clase 1: Praderas de pastos marinos; clase 2: Cobertura alta de sedimento con cobertura media de algas filamentosas; clase 3: Dominado por sedimento con cobertura baja de macroalgas; clase 4: Cobertura alta de sedimento con cobertura baja de pastos marinos; clase 5: Cobertura media de sedimento y de macroalgas; clase 6: Arena y sedimento; clase 7: Parches de coral con cobertura media de sedimento y cobertura baja de macroalgas y algas filamentosas; clase 8: Sargazo.

PORCENTAJE %								
	Clase 1	Clase 2	Clase 3	Clase 4	Clase 5	Clase 6	Clase 7	Clase 8
Clase 1	82.72	11.2	0	13.89	0	0.12	9.38	5
Clase 2	0.41	47.62	68.18	41.67	92.31	4.32	0	0
Clase 3	0	9.24	0	0	0	1.39	0	0
Clase 4	0	0	0	5.56	0	0	0	0
Clase 5	0	0	0	0	0	0	0	0
Clase 6	0	25.49	31.82	16.67	7.69	94.18	0	0
Clase 7	16.46	6.44	0	22.22	0	0	90.63	0
Clase 8	0.41	0	0	0	0	0	0	95
Total	100	100	100	100	100	100	100	100
Producer accuracy	82.72	47.67	0	5.56	0	94.18	90.63	95
User accuracy	86.82	48.57	0	100	0	95.46	43.93	97.43

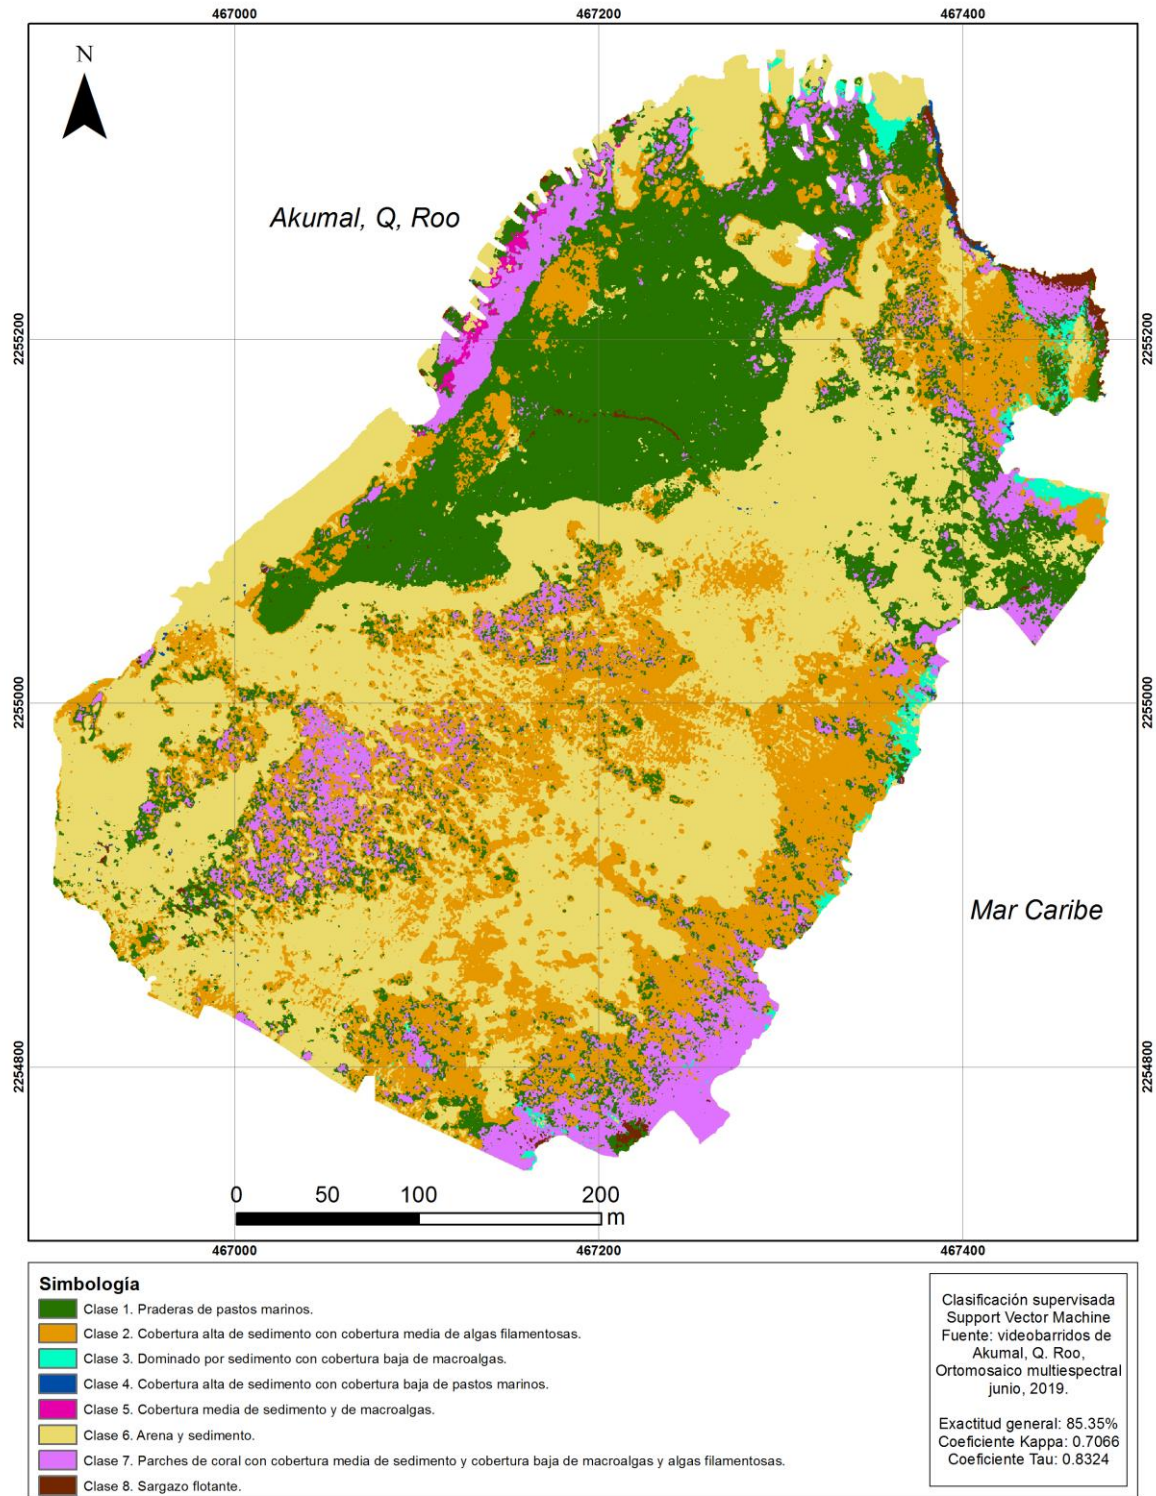


Figura 14. Clasificación supervisada de ortomosaico multiespectral (obtenido con la cámara multiespectral RedEdge-M, instalada en el dron Matrice 100) de cobertura bentónica en la laguna arrecifal de Akumal, Q. Roo, 2019, mediante el clasificador Support Vector Machine.

9.3.2. Imagen satelital PlanetScope Analytic Ortho Scene, 2019

De las clasificaciones supervisadas aplicadas a la imagen satelital PlanetScope Analytic Ortho Scene (2019), se obtuvieron exactitudes generales por arriba de 56%, coeficientes kappa de 0.45 y Tau de 0.5 (Tabla 13, Figura 15). Siendo el clasificador de Maximum Likelihood, con una exactitud general de 80.11% y un coeficiente kappa de 0.7448, el que presento mejor exactitud de clasificación en la laguna (Figura 16). De acuerdo con el coeficiente Tau 77.26% más píxeles fueron clasificados correctamente de lo que se esperaría por asignación aleatoria.

Cabe mencionar que para la clasificación de esta imagen se cambió la clase 8 definida previamente como “Sargazo flotante”, a clase 8 “Sargazo en degradación”. Por lo que, para esta nueva clase, se agregaron distintos sitios de entrenamiento a los anteriores.

Tabla 13. Evaluación de exactitud de clasificadores para la imagen satelital PlanetScope Analytic Ortho Scene (2019), en la laguna arrecifal de Akumal, Q. Roo, 2019.

<i>Clasificador</i>	<i>Exactitud general</i>	<i>Kappa</i>	<i>Tau e intervalos de confianza 95%</i>
<i>Maximum Likelihood</i>	80.11%	0.7448	0.7726 (0.7052, 0.8400)
<i>Support Vector Machine</i>	76.70%	0.6842	0.728 (0.6606, 0.7954)
<i>Neural Network</i>	56.25%	0.4509	0.5 (0.4326, 0.5674)
<i>Mahalanobis Distance</i>	68.18%	0.6011	0.6363 (0.5689, 0.7037)
<i>Minimum Distance</i>	67.05%	0.5787	0.6233 (0.5559, 0.6907)

Con este insumo la clase que mayor problema tuvo fue la clase 4 (Cobertura alta de sedimento con cobertura baja de pastos marinos), donde solo el 16.67% de esta clase fue correctamente clasificado, con 11% de probabilidad de que los píxeles clasificados como esta clase, sean realmente clase 4. La mayoría de los píxeles de la clase 4, fueron clasificados como clase 3 (Dominado por sedimento con cobertura baja de macroalgas), lo que técnicamente sería un error de la clasificación, sin embargo, como en ambas clases, son las arenas y sedimentos los que dominan, podría no considerarse un error como tal, debido a la similitud entre clases. Lo mismo para la clase 5 (Cobertura media de sedimento y de macroalgas), que también se clasifica como clase 3, estando ambas compuestas por sedimento en su mayoría y menor cantidad de macroalgas (Tabla 14).




Figura 15. Comparación de exactitud general (Po), Kappa (K) y Tau (Te) para imagen satelital PlanetScope, 2019, a través de diferentes clasificadores. MD: Mahalanobis Distance; MinD: Minimum Distance; ML: Maximum Likelihood; NN: Neural Network; SVM: Support Vector Machine.

Si bien, la exactitud general y coeficiente Tau fueron más altos en para el ortomosaico multiespectral, en la imagen satelital se obtuvieron mayores exactitudes de producción y usuario para la mayoría de las clases, teniendo porcentajes de exactitud de producción por arriba de 50%, exceptuando a la clase 4. La exactitud de usuario también fue de $\geq 78\%$ para las clases: 1, 2, 6, 7 y 8 y de 11 a 42% para las clases: 3, 4, y 5 (Tabla 14).

De acuerdo con la prueba de significancia entre los coeficientes Tau de las clasificaciones del ortomosaico multiespectral y la imagen PlanetScope 2019 con el algoritmo que obtuvieron un valor más alto (SVM y Maximum Likelihood, respectivamente), no existe diferencia significativa entre las exactitudes de estas dos clasificaciones: $z = 1.70$ ($\alpha=0.05$), es decir, son estadísticamente iguales.

Tabla 14. Matriz de contingencia por porcentaje. Clasificación supervisada (Maximum Likelihood) de imagen satelital PlanetScope Ortho Scene 2016, zona de la laguna arrecifal. Clase 1: Praderas de pastos marinos; clase 2: Cobertura alta de sedimento con cobertura media de algas filamentosas; clase 3: Dominado por sedimento con cobertura baja de macroalgas; clase 4: Cobertura alta de sedimento con cobertura baja de pastos marinos; clase 5: Cobertura media de sedimento y de macroalgas; clase 6: Arena y sedimento; clase 7: Parches de coral con cobertura media de sedimento y cobertura baja de macroalgas y algas filamentosas; clase 8: Sargazo en degradación.

PORCENTAJE %								
	Clase 1	Clase 2	Clase 3	Clase 4	Clase 5	Clase 6	Clase 7	Clase 8
Clase 1	90	0	0	0	0	1.35	0	0
Clase 2	3.33	78.13	0	16.67	0	6.76	0	0
Clase 3	3.33	21.88	100	66.67	50	0	0	0
Clase 4	3.33	0	0	16.67	0	9.46	0	0
Clase 5	0	0	0	0	50	0	33.33	0
Clase 6	0	0	0	0	0	82.43	0	0
Clase 7	0	0	0	0	0	0	66.67	0
Clase 8	0	0	0	0	0	0	0	100
Total	100	100	100	100	100	100	100	100
<i>Producer accuracy</i>	90	78.13	100	16.67	50	82.43	66.67	100
<i>User accuracy</i>	96.43	78.13	37.5	11.11	42.86	100	100	100

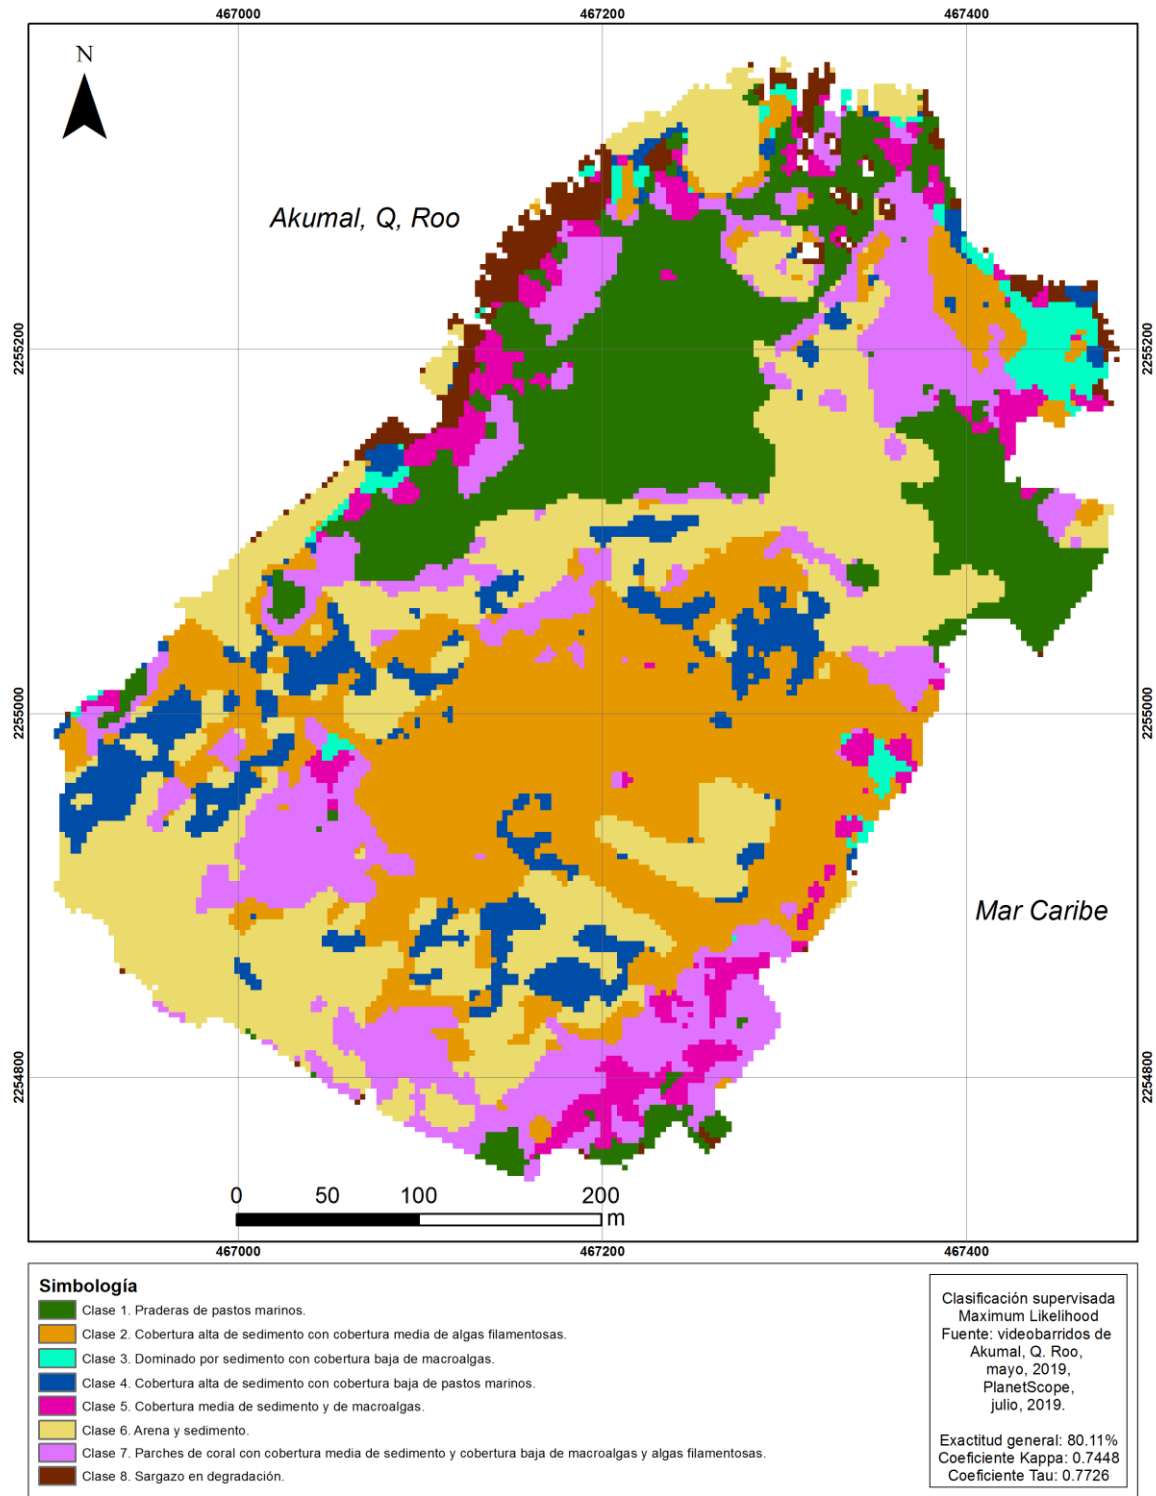


Figura 16. Clasificación supervisada de imagen satelital PlanetScope Analytic Ortho Scene, de cobertura bentónica en la laguna arrecifal de Akumal, Q. Roo, 2019, mediante el clasificador Maximum Likelihood.

10. DISCUSIÓN

10.1. Evaluación de exactitud

En las imágenes satelitales (WV-3, 2016/PlanetScope, 2016-19) y el ortomosaico multiespectral (2019), se observa el mismo comportamiento entre las medidas de exactitud. Siendo más elevada la exactitud general (P_o), seguido del coeficiente Tau (T_e) y finalmente el coeficiente Kappa (K). La exactitud general es más elevada debido a que solo considera los píxeles dentro de la matriz clasificados correctamente. Si bien tanto T_e como K consideran las distribuciones marginales de los datos de referencia, se miden de distinta manera, por lo que su valor es diferente, siendo el coeficiente Kappa más bajo porque tiende a sobrestimar el acuerdo aleatorio (P_c), por lo que la exactitud a través de K es subestimada. Tau es un ajuste de la exactitud general al igual que Kappa, pero es más sencillo de calcular e interpretar que Kappa (Ma & Redmond, 1995). Por lo que se tomó la decisión de incluir esta medida y conservar las otras dos para tener métricas comparativas con otros estudios que no utilizan Tau, incluyendo productos generados anteriormente en el laboratorio de PIESACOM (Programa de Investigación Espacial en Ambientes Costeros y Marinos).

Existen algunas situaciones que influyen en la exactitud de una clasificación, por ejemplo, los errores de posición, los cuales incluyen inexactitudes del GPS, observaciones de los buzos no exactamente debajo de la posición registrada cuando entran al agua y debido a la corriente la cámara puede alejarse de la lancha y por lo tanto de la ubicación registrada (Purkis *et al.*, 2019). Estas circunstancias pueden sobrepasar el ancho de píxel de imágenes de satélite y por supuesto de imágenes multiespectrales capturadas a través de un dron, lo que resultaría en que los datos de referencia no estén perfectamente registrados en el punto exacto. Sin embargo, en los productos de clasificación supervisada generados a través de los cuatro insumos (WV-3 2016, PlanetScope 2016-19, ortomosaico multiespectral) en el presente estudio se obtuvieron exactitudes elevadas: $P_o \geq 80\%$, $K \geq 0.69$ y $T_e \geq 0.77$, al tomar en cuenta los algoritmos de clasificación que representaban la distribución espacial de cobertura bentónica de una manera más realista; tanto la exactitud general como el coeficiente Kappa, son valores aceptables para la clasificación de imágenes (Congalton & Green, 2009) teniendo valores Kappa que indican una concordancia de substancial a excelente (Sim & Wright, 2005).

10.2. Diferencias entre PlanetScope Analytic Ortho Scene y WorldView-3, 2016

Debido a que ninguno de los dos insumos de percepción remota de 2016, contaba originalmente con correcciones ambientales, se les tuvieron que aplicar tres correcciones: atmosférica, del brillo de las olas y de la columna de agua. En ninguno de los dos casos, hubo complicaciones para realizarlo. En el caso de las clasificaciones supervisadas, la complicación que se presentó fue con la imagen satelital WorldView-3, la cual no fue posible clasificar mediante el algoritmo Support Vector Machine, situación a la que no se encontró explicación, y que se intentó en diferentes equipos de cómputo.

La clasificación de la imagen PlanetScope generada a través del algoritmo SVM presentó una mayor exactitud general (95.70%), sin embargo, con este algoritmo se observó una sobrestimación de arenas y sedimentos y subestimación de algunas clases de cobertura (2 y 6). Mientras que en el caso de la WV-3 (2016), donde Minimum Distance y Neural Network presentaron mayor exactitud general (87.74 y 96.53%, respectivamente), con el primer clasificador la distribución de las clases estaba sobreestimada particularmente en la clase de pendiente arrecifal y la de arena y sedimento, que se confundía con la porción del frente arrecifal. En el caso del segundo clasificador hubo una sobreestimación de arenas y sedimentos (Figura 5). Por lo que para ambas imágenes de este año (2016), se decidió elegir el algoritmo Maximum Likelihood, como el clasificador que mejor representaba la realidad y con una exactitud elevada (Figura 6). El algoritmo de Maximum Likelihood es uno de los clasificadores basados en píxeles con más éxito utilizado en clasificaciones supervisadas de imágenes satelitales (Naidu *et al.*, 2018).

Con el clasificador de Maximum Likelihood, la imagen satelital PlanetScope (2016), obtuvo una exactitud general de 92.37% y Kappa de 0.85. Mientras que para la imagen WV-3 (2016), la exactitud general fue de 82.21% y Kappa de 0.69. El coeficiente Tau fue de 91 y 79%, respectivamente (Tabla 7), si bien ambos valores de exactitud son elevados, el de la imagen satelital PlanetScope fue mayor por 12%. Y de acuerdo con la prueba de significancia, podemos decir que estadísticamente la clasificación supervisada de la imagen PlanetScope fue mejor que la WorldView-3.

Las imágenes satelitales (PlanetScope Analytic Ortho Scene y WorldView-3), son fuentes de información con diferentes resoluciones espectrales y espaciales, por lo que incluso con el mismo clasificador (Figura 6), se presentó una diferencia en la distribución espacial de

las clases de fondos bentónicos y exactitud. Además, esto también lo atribuimos a la diferencia en la temporalidad de cada uno de estos insumos; la imagen PlanetScope es del mes de octubre, mes en el que fue realizado el muestreo de la cobertura del arrecife, mientras que la imagen WV-3 corresponde al mes de mayo. Por lo que esta diferencia temporal entre la verificación en campo y la adquisición de la imagen WV-3, es un factor que influye en la exactitud del mapeo, siendo más alta para la imagen PlanetScope. A pesar de esto, la imagen WV-3, también tuvo exactitudes altas en el mapeo de la cobertura bentónica, lo que puede deberse por una parte a que cinco de sus bandas espectrales tienen una longitud de onda lo suficientemente corta para poder penetrar en el agua (Purkis *et al.*, 2019), de las cuales tres fueron utilizadas para la clasificación (coastal blue, blue & green), y por otra parte la mayor resolución espacial de WV-3 permite una diferenciación más clara, con píxeles menos mezclados de los diferentes tipos de fondos. En 2010, Garza-Pérez (-datos no publicados-), realizó la cartografía del arrecife Akumal, mediante una clasificación supervisada de una imagen satelital WV-2 (con las mismas bandas aquí utilizadas), obteniendo un mapa con una exactitud general de 92% (exactitud similar a la generada en PlanetScope, 2016), si bien esta exactitud es mayor a la obtenida en la imagen WV-3 del presente estudio, la clasificación de Garza-Pérez (2010), se realizó en una imagen del mismo mes en que fueron generados los datos de entrenamiento, por lo que podemos asumir que la exactitud baja cuando la imagen y los muestreos no son cercanos a la misma fecha; esto concuerda con Phinn *et al.*, (2008) quienes mencionan que el uso de imágenes satelitales cercanas a la fecha del muestreo es importante para obtener una mejor exactitud de mapeo.

Las imágenes satelitales WorldView han demostrado alta efectividad en el mapeo de cobertura bentónica arrecifal (Cerqueira-Estrada *et al.*, 2012; Collin, 2012; Guoqiang *et al.*, 2016; Naidu *et al.*, 2018). Purkis y colaboradores (2019), clasificando hábitats arrecifales en imágenes WorldView-2, reportaron exactitudes similares a las obtenidas en este trabajo en la imagen WV-3. Sus valores fueron Po: 81-90%, K: 71-87% y Te: 72-89%, mientras que las obtenidas aquí fueron: Po=82.21%, K=69% y Te=79%. Si bien, ellos realizaron clasificaciones basadas en objetos, las exactitudes obtenidas aquí se encuentran dentro de sus rangos, exceptuando por el valor de Kappa, siendo menor solo por un 2%. Por otro lado, Guoqiang *et al.*, (2016), mapearon un arrecife de coral en una imagen satelital WV-3, mediante una clasificación supervisada (SVM), obteniendo una exactitud general de 95.28% y Kappa de 0.90.

En cuanto a las imágenes PlanetScope, Wicaksono y Lazuardi (2018), se preguntaron si las imágenes PlanetScope podrían tener el éxito de sus predecesores: WorldView-2, IKONOS y Quickbird, en el mapeo de hábitats bentónicos y pastos marinos en aguas someras, por lo que fueron los primeros en evaluar las imágenes satelitales PlanetScope para estos fines, obteniendo exactitudes generales entre 47.13 y 50%, un año después (2019), volvieron a realizar clasificaciones de estas imágenes mediante arboles de decisión (Random Forest), obteniendo exactitudes de 60.6 y 78.6%. Si bien, ellos no obtuvieron exactitudes tan prometedoras, de acuerdo con nuestros resultados, este insumo es capaz de competir con imágenes satelitales de mayor resolución espectral y espacial, tradicionalmente utilizadas para el mapeo de hábitats bentónicos.

Tanto las imágenes WV-3 como PlanetScope, son buenas opciones para el mapeo de un sistema arrecifal. Sin embargo, hay una gran ventaja que tienen los insumos de PlanetScope sobre las imágenes satelitales de otras corporaciones geoespaciales, y es que estas imágenes cambian el paradigma de la obtención de datos de percepción remota, ya que existe un catálogo en línea de sus productos donde el usuario puede elegir directamente la imagen más adecuada de acuerdo con los intereses de la investigación, o uso esperado. Lo cual es una limitación de las imágenes WV, que requieren la intervención de un intermediario (distribuidor local) para la exploración de las imágenes de archivo, y se requiere la comisión de la captura de nuevas imágenes con un par de meses de anticipo, y de las cuales no se tiene mucho control sobre parámetros ambientales importantes en la percepción remota marina como oleaje o turbidez, exceptuando por el porcentaje de nubosidad <10%, por lo que obtener imágenes con condiciones atmosféricas y marinas ideales, puede ser difícil, especialmente de los trópicos, donde la cantidad de nubes es alta y encontrar imágenes libres de nubes es complicado (Naidu *et al.*, 2018; Wicaksono & Lazuardi, 2018).

10.3. Caracterización del área de estudio, 2019

De las estaciones previamente definidas para realizar el muestreo de la caracterización del área de estudio, se tuvieron que modificar algunas estaciones; si bien los datos de la zona del frente y pendiente no fueron utilizados para entrenar las clasificaciones supervisadas del ortomosaico multiespectral y la imagen satelital PlanetScope 2019, durante el muestreo algunas no se realizaron y se seleccionaron otros sitios, principalmente porque la profundidad era mayor a 15 m, o porque se encontraban muy cerca a la cresta arrecifal.

Para el caso de la laguna, la limitante para llevar a cabo los videobarridos predefinidos, fue el sistema de boyas y redes que delimitan el área de nado y el área para el tránsito de lanchas. Por lo que la mayoría de las estaciones fueron modificadas, y a través del ortomosaico multiespectral se delimitaron sitios de entrenamiento adicionales para clases subrepresentadas en el muestreo, como: arenas y sedimentos, pastos marinos, parches de coral, sargazo flotante o en degradación y pavimento calcáreo. De los sitios de muestreo, la cobertura bentónica estuvo dominada en casi un 60% por arenas y sedimentos, 26% por pastos marinos, 13% por algas marinas y menos del 2% de cobertura se compuso por coral duro, octocorales, esponjas y pedacería.

Finalmente, se obtuvieron ocho clases de cobertura para la laguna, donde en la mitad de estas dominaron las arenas y sedimentos (Tabla 8).

10.4. Diferencias entre ortomosaico multiespectral e imagen satelital PlanetScope Analytic Ortho Scene, 2019

Una de las mayores diferencias entre los ortomosaicos multiespectrales e imágenes satelitales, es la capacidad de cobertura de estas últimas, ya que, por cuestiones de autonomía de vuelo (asociadas a la capacidad de las baterías) y distancia de conexión con el mando de control, actualmente no es posible cubrir áreas tan grandes con un dron como con las imágenes satelitales. Por lo que, al menos con el dron utilizado en este estudio, se deben realizar varios vuelos para cubrir todas las zonas geomorfológicas del arrecife (desde la laguna, hasta el frente y pendiente). A diferencia de las imágenes satelitales, como las PlanetScope, que gracias a su elevada resolución espacial brindan información detallada para grandes áreas, y por su alta resolución temporal es posible obtener imágenes de la misma fecha que los muestreos en campo (Wicaksono & Lazuardi, 2018).

Casella *et al.*, (2017), mencionaron que el uso de drones en el monitoreo de arrecifes de coral podría ser efectivo a profundidades donde generalmente se realiza snorkel y buceo, y a escalas de la cartografía aérea o satelital marina. Sin embargo, nuestros resultados sugieren lo contrario, ya que los ortomosaicos del frente y pendiente no pudieron ser resueltos por el software, al parecer debido a que el fondo arrecifal es poco visible en las imágenes capturadas, esto puede ser atribuido a el efecto de la profundidad (>5 m), en combinación con la turbidez, pero en el caso específico de los vuelos realizados en nuestra área de estudio, pudo estar asociado principalmente a la turbulencia producida por la fuerte corriente presente durante las fechas de los vuelos (actividades de buceo síncronas con los

vuelos confirmaron este punto). Cabe mencionar, que la investigación llevada a cabo por Casella y colaboradores (2017), fue de una laguna de la Polinesia Francesa, lugar donde no se presenta oleaje ni corrientes marinas y el ortomosaico obtenido solo alcanzó una profundidad máxima de 1.8 m, en aguas con una visibilidad muy alta. Una diferencia importante adicional es que en dicho estudio el dron estaba equipado con una cámara digital, con cuyos insumos de datos es posible resolver ortomosaicos en aguas más profundas (*Comm. Pers. Rioja-Nieto R. & Garza-Pérez J.R*). El no obtener los ortomosaicos de la zona del frente y pendiente, fue la mayor limitante que se presentó para poder realizar una comparación más completa entre los ortomosaicos multiespectrales y las imágenes satelitales en el mapeo de arrecifes coralinos.

No obstante, uno de los resultados que se obtuvieron en esta investigación, es que el ortomosaico multiespectral generado pudo resolver el fondo marino a una profundidad máxima de ~4.5 - 5 m; una profundidad mayor a la registrada por otros trabajos en lagunas arrecifales: ~1.8 m Casella *et al.*, (2017) y 2 m por Collin *et al.*, (2018), e igual que la reportada por Ventura *et al.*, (2018) y Kabiri y colaboradores (2020) que fue de entre 4 y 5 m aproximadamente, pero con datos de fotografía digital, y no con imágenes multiespectrales.

Como se mencionó anteriormente, se tuvo que hacer un re-escalamiento espacial de 8 a 32 cm del ortomosaico multiespectral de la laguna, debido a que el ortomosaico original presentaba una alta divergencia espectral entre píxeles contiguos lo que generaba un efecto de sal y pimienta, que afectaba la exactitud de las clasificaciones. Al aplicar las clasificaciones supervisadas en el ortomosaico multiespectral re-escalado la exactitud aumentó considerablemente. Lechner *et al.*, (2012), mencionan que los clasificadores de percepción remota basados en píxeles (como las que se aplicaron aquí), son generalmente inadecuados para clasificar imágenes con una resolución espacial muy alta (VHR), debido a que a medida que la resolución espacial se vuelve más fina, aumenta la variación en los valores espectrales dentro de las clases de cobertura, lo que dificulta la separación espectral entre ellas, y resulta en una menor exactitud general de clasificación.

Respecto a la corrección de la columna del agua del ortomosaico multiespectral de la laguna, no hubo mayor problema. Lo mismo para todos los tipos algoritmos de clasificación, donde la exactitud general más elevada fue de 85.35%, Kappa de 0.70 y Tau de 0.83 con el clasificador Support Vector Machine y a diferencia de la imagen satelital PlanetScope de 2016, el producto de clasificación supervisada aplicando este clasificador al ortomosaico

multiespectral si coincidió con una distribución coherente de las clases de cobertura (Figura 14). En clasificaciones supervisadas en productos de cámaras multiespectrales en drones, ya se había registrado exactitudes generales altas (94.5%) con el algoritmo SVM (Liu *et al.*, 2018). Ventura *et al.*, (2018) generaron un ortomosaico de una zona costera, con una cámara digital (RGB) instalada en un dron, y después de aplicarles una clasificación basada en objetos reportaron una exactitud general >80% y Kappa de 0.77, valores muy similares a los aquí reportados.

Aunque, la exactitud general del ortomosaico (85.35%) fue elevada, las exactitudes de producción y de usuario no fueron favorables para la mayoría de las clases (Tabla 12), lo que podría deberse, por la parte metodológica, al método de clasificación utilizado (clasificación supervisada basada en píxeles). Debido a la muy alta resolución espacial del ortomosaico (32 cm), sería conveniente utilizar un método más poderoso de análisis de imágenes, como el OBIA (Ventura *et al.*, 2018), y tal vez en ese caso no sería necesario un ajuste de resolución de píxel. Desde la parte ecológica de las clases definidas en la laguna de Akumal, solo dos clases no estaban dominadas por arena/sedimento: la clase 1 dominada por pastos marinos >90%, y la clase 8 correspondiente al sargazo flotante. La alta proporción de arena/sedimento en todas las otras clases (>55%) y la alta similitud entre las clases definidas por el análisis clúster (>60%) probablemente tuvieron un efecto en la capacidad de discriminación del método, para diferenciar de manera efectiva los píxeles de las diferentes clases.

Para la imagen satelital PlanetScope Analytic Ortho Scene (2019) el algoritmo de Maximum Likelihood fue el que ofreció mayor exactitud: $Po=80.11\%$, $K=0.74$ y $Te= 0.77$ (Tabla 13), además también proveyó una distribución visual coherente de las clases de cobertura, exceptuando porque hubo una sobreestimación de la clase 4 (Cobertura alta de sedimento con cobertura baja de pastos marinos) (Tabla 14, Figura 16), la exactitud obtenida, fue cercana a las obtenidas por Hang *et al.*, (2019), quienes mapearon la distribución de algas y pastos marinos con imágenes PlanetScope, obteniendo exactitudes generales de 83.33 a 92.52%. En segundo lugar, estuvo SVM ($Po=76.7\%$), sin embargo, este tuvo una sobreestimación considerable de arenas y sedimentos (clase 6), tal y como se observa en la figura. Tanto la exactitud de producción, como la de usuario fueron mayores para la mayoría de las clases de cobertura en la imagen PlanetScope (2019). Este aumento en las exactitudes de producción y usuario podría deberse a que la resolución de las imágenes satelitales PlanetScope es 10 veces menor a la del ortomosaico multiespectral utilizado, lo

cual es favorable para las clasificaciones basadas en píxeles. Las razones ecológicas de las exactitudes en la clasificación son las mismas que para el ortomosaico multiespectral, una alta similitud entre clases y un mismo sustrato dominante presente en la mayoría de ellas.

Haciendo una comparación de exactitud a través del coeficiente Tau, el ortomosaico multiespectral obtuvo una exactitud mayor a la de la imagen satelital PlanetScope Analytic Ortho Scene (0.83 y 0.77, respectivamente), sin embargo, de acuerdo con la prueba de significancia: $z = 1.70$ ($\alpha = 0.05$), no existen diferencias significativas en la exactitud de ambas clasificaciones. No obstante, existen una serie de circunstancias que deben de ser consideradas, antes de elegir que plataforma utilizar para el mapeo de un sistema arrecifal. En términos del limitado éxito en la obtención de insumos de imagen multiespectral a través del dron, en conjunto con la limitación impuesta por la profundidad, es importante mencionar el mayor esfuerzo requerido para realizar los vuelos de dron. En primer lugar, está el desplazamiento de un equipo de trabajo hasta el sitio de interés, tal vez en más de una ocasión (lo cual implica tiempo y recursos económicos), en segundo lugar, el procesamiento computacional de los ortomosaicos; para lo cual es necesario invertir varias horas de trabajo en equipos de cómputo de alta gama y finalmente, el riesgo de la pérdida de equipo (dron y cámara multiespectral), debido a accidentes durante la obtención de imágenes.

De acuerdo con los resultados generados, podríamos decir que tanto los ortomosaicos multiespectrales, como las imágenes PlanetScope, tienen altas exactitudes y un buen desempeño en la clasificación de cobertura bentónica arrecifal. Sin embargo, hay que considerar que durante este estudio y debido a limitaciones de los ortomosaicos multiespectrales solo se mapeo parte de la laguna arrecifal con este insumo, por lo que si la intención fuera realizar un monitoreo de sistema arrecifal completo (laguna, frente y pendiente), los ortomosaicos no serían la mejor opción para generar un estudio extenso y riguroso, pero si para realizar un mapeo de lagunas arrecifales y zonas costeras someras y claras. Se requieren estudios adicionales con plataformas aéreas (drones) que permitan adquirir imágenes a mayor altura y sensores con mayor número de bandas para tener el espectro completo y obtener mucha más información del fondo bentónico. O tecnologías más avanzadas que ofrezcan solución a las distorsiones causadas por la columna de agua (Chirayath & Earle, 2016).

La muy alta resolución espacial y potencial resolución temporal de los productos de VANTs brinda la posibilidad de detectar cambios locales rápidamente, por lo que son una herramienta efectiva en manejo y conservación de ecosistemas (Ventura *et al.*, 2018). En el caso de Akumal, donde una gran parte de las actividades turísticas (snorkel y avistamiento de tortugas marinas) se llevan a cabo en las zonas poco profundas y que son de las actividades que más afectan la composición de la cobertura bentónica, los ortomosaicos podrían funcionar bien para monitorear las afectaciones o recuperación que estas zonas puedan presentar, o servir como una base geográfica para realizar futuros muestreos. O bien, los ortomosaicos multiespectrales también pueden ser utilizados para generar datos de entrenamiento, para posteriormente ser utilizados en otros insumos de percepción remota como imágenes satelitales (Hegarty-Craver *et al.*, 2020) o datos LiDAR (Collin *et al.*, 2018).

En la Tabla 15, se resumen las ventajas y desventajas que se observaron durante el estudio de los insumos de percepción remota utilizados.

Tabla 15. Tabla comparativa entre insumos de percepción remota: imágenes satelitales WorldView-3 vs PlanetScope (2016) y ortomosaicos multiespectrales (2019).

Insumo	Ventajas	Desventajas
WorldView-3	<ul style="list-style-type: none"> • Mayor resolución espacial (1.2 m). • Temporalidad de 1 día. • 8 bandas espectrales, de las cuales cinco, penetran bien en la columna de agua. • Las clasificaciones realizadas sobre estos insumos tienen buena exactitud. 	<ul style="list-style-type: none"> • Al solicitar una imagen no se garantiza que las condiciones ambientales sean las adecuadas para realizar un mapeo. Exceptuando por el porcentaje de nubosidad (<10%). • Costo más elevado: 84 USD x 1 km².
PlanetScope Analytic Ortho Scene	<ul style="list-style-type: none"> • Temporalidad de 1 día. • Acceso a catálogo para la selección previa de imágenes. • Cuentan con correcciones radiométricas y atmosféricas. • Las clasificaciones realizadas sobre estos insumos tienen buena exactitud. • Costo menor, con posibilidades de convenios académicos (50¢ USD x 1 km², en los productos de SkySat a una resolución espacial de 72 cm). 	<ul style="list-style-type: none"> • La resolución espacial es menor comparada con las otras dos fuentes (3 m). • Cuenta con menos bandas espectrales (4 bandas).
Ortomosaicos multiespectrales generados a partir de la cámara multiespectral RedEdge-M.	<ul style="list-style-type: none"> • Alta resolución espacial (8 cm) a 120 m de altitud. • Resolución temporal mínima de 1 h. • Las interferencias atmosféricas como neblina o nubes no son consideradas como obstáculos, como para las imágenes satelitales. • Una vez teniendo tu equipo de dron, más cámara multiespectral y softwares necesarios, puedes realizar un número elevado de vuelos. • En comparación los muestreos en campo, los drones pueden abarcar una mayor área en un menor tiempo y costo. 	<ul style="list-style-type: none"> • Menor área de cobertura a la de una imagen satelital. • Penetración en la columna de agua ~<5 m en condiciones óptimas. • Mayor tiempo de preprocesamiento – aprox. 30 h-, en relación con el necesario para una imagen satelital. • Implica inversión de tiempo, dinero y personal el desplazamiento al sitio en el que se van a realizar los vuelos. • Costo (2019) de cámara multiespectral y dron: \$213, 300 MXN/ \$10,400 USD. • Existe la posibilidad de la pérdida total del equipo, debido a accidentes en campo.

11. CONCLUSIONES

Ambos insumos de datos (ortomosaicos multiespectrales e imágenes satelitales) obtuvieron altas exactitudes generales de clasificación del fondo bentónico, inclusive al enfrentarse a factores adversos como la alta similitud estadística entre clases y la presencia de un mismo componente bentónico dominante en la mayoría de las clases, siendo la exactitud del ortomosaico más alta (exactitud general y coeficiente Tau), pero no estadísticamente ($\alpha=0.05$) mejor que las imágenes PlanetScope. Sin embargo, hay que considerar que con el ortomosaico multiespectral solo se evaluó la zona de la laguna arrecifal, por lo que basado en este estudio no sería pertinente concluir que para el mapeo y monitoreo de arrecifes de coral el mejor insumo son los drones y cámaras multiespectrales.

Aunque los drones aún no pueden competir con las imágenes satelitales en términos de cobertura espacial, los ortomosaicos tienen una resolución espacial y temporal excepcional. Considerando las limitaciones de los drones y los ortomosaicos multiespectrales, el mapeo a través de éstos puede ser muy exacto y de muy buena calidad para aguas marinas poco profundas (<5 m), claras y tranquilas, gracias a que los ortomosaicos cuentan con una resolución espacial muy fina (cm), por lo que a simple vista y sin necesidad de aplicarle correcciones se puede observar muy bien la variación en la cobertura de hábitats marinos someros: pastos marinos, arenas y parches de coral, lo que ayuda a que después de realizar clasificaciones se obtengan altas exactitudes. En este contexto, los drones tienen un gran potencial para optimizar el monitoreo de estos ambientes, proveyendo datos para la producción de cartografía a una escala espacial y temporal muy fina.

No obstante, si se quiere mapear áreas más grandes y profundas, los ortomosaicos multiespectrales se verían sumamente limitados, ya que en este estudio no fue posible resolver los ortomosaicos multiespectrales más allá de los ~5 m de profundidad, y fue complicado apreciar el fondo bentónico en las imágenes capturadas. Además, con la plataforma que empleamos (Matrice 100 DJI) es complicado planear vuelos en áreas extensas, debido a limitantes como batería y distancia de comunicación con el dron. Temporalmente tampoco es fácil la planeación de misiones de vuelo de un dron ya que se requieren condiciones atmosféricas y marinas muy favorables, cielos despejados y con poco viento, mientras que en el mar es necesario que el oleaje sea mínimo, y que en la columna de agua no haya turbidez, ni turbulencia. Los vuelos requieren una planeación muy cuidadosa en conjunto con el monitoreo de las condiciones climáticas del área, y aun así

estando en campo estas condiciones pueden cambiar y no ser óptimas para realizar los vuelos, por lo que muy probablemente se tengan que hacer otros vuelos en días o semanas posteriores, lo que representa una gran limitante adicional en cuestión de tiempo y costo.

Para un monitoreo de arrecifes coralinos del Caribe, de acuerdo con los resultados generados en esta investigación, consideramos que las imágenes multiespectrales PlanetScope Analytic Ortho Scene son la mejor opción, ya que cuentan con una corrección radiométrica y atmosférica por default, y no hubo complicaciones al aplicarles las correcciones del brillo de olas y de la columna de agua y tampoco dificultad con ninguno de los algoritmos de clasificación. Tienen una alta resolución espacial (3 m), por lo que se pueden mapear y monitorear extensiones muy grandes de arrecife (km²) y su resolución temporal de un día, aumenta las posibilidades de tener una buena imagen satelital con buenas condiciones atmosféricas y marinas cercanas a la fecha que se realizan las observaciones en campo, característica que aumenta la probabilidad de tener información casi en tiempo real ante eventos causados por desastres naturales o antropogénicos. Por lo que consideramos que es un insumo sumamente prometedor para el monitoreo de arrecifes de coral.

Por las características y limitaciones de cada fuente de datos, mis resultados sugieren que la información que cada una brinde no es comparable, sin embargo, los ortomosaicos pueden ser un buen complemento a la información generada por las imágenes satelitales. Es decir, se pueden realizar estudios extensos del sistema arrecifal, con una alta exactitud con las imágenes satelitales PlanetScope y en caso de que se tenga interés en una zona específica, y si está área cuenta con las características necesarias para poder realizar un vuelo en dron, principalmente profundidad alrededor a los 5 m, el estudio podría complementarse con información más detallada brindada por ortomosaicos multiespectrales, los cuales tendrían una alta exactitud y un aumento considerable de resolución espacial.

En cuanto al algoritmo de clasificación que generó mejores resultados, para las imágenes satelitales fue el de Maximum Likelihood, mientras que para el ortomosaico multiespectral SVM presento un gran desempeño. Ambos algoritmos con exactitud numérica y visual elevada en los insumos correspondientes, por lo que se representó muy bien la realidad de la distribución de las distintas clases de cobertura en cada clasificación.

Si bien ambas aproximaciones tienen sus fortalezas y debilidades, aquí se presenta el desempeño de cada una de ellas en el mapeo de arrecifes de coral someros mediante clasificaciones supervisadas basadas en píxeles, para que los tomadores de decisiones elijan cual sería mejor de acuerdo con los objetivos a alcanzar y a la información que se espera obtener.

12. RECOMENDACIONES

Se proporcionan una serie de recomendaciones para el mapeo de cobertura bentónica arrecifal, con base en los insumos utilizados: imágenes satelitales PlanetScope Analytic Ortho Scene/WorldView-3 y ortomosaicos multiespectrales generados a partir de la cámara multiespectral RedEdge-M instalada en el dron Matrice 100 DJI.

1. Una vez que se tenga el esquema de clasificación (clases), realizar un análisis de separabilidad de las firmas espectrales, para determinar qué tan diferentes espectralmente son entre ellas y definir la conveniencia de mantener ese esquema de clases o modificarlo uniendo algunas de ellas.
2. En caso de considerar que no se tiene un muestreo que represente todas las clases de cobertura bentónica del área, con la ayuda de las imágenes obtenidas a través del dron, y si se tiene previo conocimiento del área podrían generarse sitios de entrenamiento adicionales, aunque es recomendable hacer una revisita en campo.
3. En el caso del Caribe Mexicano donde se presentan arribazones de sargazo sería importante considerar generar una clase de cobertura para éste (de acuerdo con la temporada y severidad del arribazón en el momento del vuelo), ya que el sargazo flotante y el agua marrón asociada impiden la observación del fondo.
4. Generar u obtener insumos de percepción remota (imágenes satelitales u ortomosaicos multiespectrales), lo más cercano a las fechas de muestreo, para el entramiento de clasificaciones supervisadas.
5. Para decidir qué insumo de los propuestos aquí, sería más conveniente utilizar, es conveniente considerar la extensión del área de interés, ya que los drones se ven limitados en este sentido, principalmente por la capacidad de las baterías del dron y distancia de conexión con el mando de control. Por lo que, si la intención es mapear áreas muy grandes, hay que tener en cuenta que probablemente se necesitara realizar varios vuelos, lo que derivaría en mayor trabajo en campo, pero principalmente una mayor inversión de tiempo y recursos computacionales para el procesamiento de las imágenes.
6. Al plantear una investigación que requiera datos multiespectrales obtenidos a través de drones, también es importante considerar tiempo y recursos económicos adicionales a las campañas estrictamente necesarias, para desplazarse hasta el sitio de interés, probablemente en más de una ocasión, en caso de que las condiciones ambientales sean adversas durante estas campañas.

7. Antes de realizar los vuelos de dron, es importante considerar las condiciones atmosféricas y marinas durante los vuelos, ya que se requiere que haya poco viento y nubosidad, y en el mar que haya poco oleaje, turbidez y turbulencia.
8. Es recomendable cargar mapas y planes de vuelo en los dispositivos de control de dron previamente a la salida a campo, por cuestiones de conectividad y acceso a internet en campo.
9. Otra variable para considerar es la profundidad del área de interés, ya que, con el dron y la cámara multiespectral utilizados, no se pudieron resolver las porciones de los ortomosaicos multiespectrales en donde la profundidad rebasaba los ~5 m. Por lo que en estas circunstancias la mejor opción sería utilizar imágenes satelitales.
10. Una vez obtenidas las imágenes multiespectrales a través del dron, si no es posible realizar la alineación automática de éstas, mediante el software utilizado (p.ej. Agisoft Metashape), vale la pena optimizar el proceso de alineación, mediante marcadores manuales de ubicación (*-apartado 8.2-*).
11. En caso de que el método de clasificación supervisada sea basado en píxeles, el aumentar el tamaño del píxel de los ortomosaicos multiespectrales podría mejorar la exactitud de clasificación. Ya que al tener una resolución espacial tan alta (~ 8 cm), la clasificación basada en píxeles se ve afectada por las variaciones de los valores radiométricos de píxeles contiguos y esto a su vez perjudica la exactitud de clasificación, por lo que tal vez sería conveniente aplicar una clasificación de imágenes basada en objetos (OBIA).
12. Finalmente, para imágenes satelitales cuando se aplica la clasificación supervisada basada en píxeles, se recomienda utilizar principalmente el algoritmo de Maximum Likelihood y Support Vector Machine. Mientras que para los ortomosaicos multiespectrales el algoritmo Support Vector Machine tiene mejor desempeño y en menor medida Maximum Likelihood. De acuerdo con las exactitudes numéricas y distribución espacial de coberturas bentónicas, la aplicación del resto de los clasificadores tal vez no sea necesario: Neural Network, Mahalanobis Distance y Minimum Distance.

13. REFERENCIAS

- Álvarez-Filip, L., Dulvy, N. K., Gill, J. A., Côté, I. M., & Watkinson, A. R. (2009). Flattening of Caribbean coral reefs: region-wide declines in architectural complexity. *Proceedings of the Royal Society of London. Series B, Biological Sciences*, 276, 3019-3025.
- Andréfouët, S., Berkelmans, R., Odriozola, L., Done, T., Oliver, J., & Muller-Karger, F. E. (2002). Choosing the appropriate spatial resolution for monitoring coral bleaching events using remote sensing. *Coral Reefs*, 21, 147-154.
- Andréfouët, S., Kramer, P., Torres-Pulliza, D., Joyce, K. E., Hochberg, E. J., Garza-Pérez, R., . . . Muller-Karger, F. E. (2003). Multi-site evaluation of IKONOS data for classification of tropical coral reef environments. *Remote Sensing of Environment*, 88, 128-143.
- Bellwood, D. R., Hughes, T. P., Folke, C., & Nyström, M. (2004). Confronting the coral reef crisis. *Nature*, 429, 827-833.
- Bour, W., Loubersac, L., & Rual, P. (1986). Thematic mapping of reefs by processing of simulated SPOT satellite data: application to the *Trochus niloticus* biotope on Tetembia Reef (New Caledonia). *Marine Ecology*, 243-249.
- Bryson, M., Duce, S., Harris, D., Webster, J. M., Thompson, A., Vila-Concejo, A., & Williams, S. B. (2016). Geomorphic changes of a coral shingle cay measured using Kite Aerial Photography. *Geomorphology*, 270, 1-8.
- Bryson, M., Ferrari, R., Figueira, W., Pizarro, O., Madin, J., Williams, S., & Byrne, M. (2017). Characterization of measurement errors using structure-from-motion and photogrammetry to measure marine habitat structural complexity. *Ecology and Evolution*, 7(15), 5669–5681.
- Casella, E., Collin, A., Harris, D., Ferse, S., Bejarano, S., Parravicini, V., . . . Rovere, A. (2017). Mapping coral reefs using consumer-grade drones and structure from motion photogrammetry techniques. *Coral Reefs*, 36, 269-235.

- Casella, E., Rovere, A., Pedroncini, A., Colin P, S., Casella, M., Ferrari, M., & Firpo, M. (2016). Drones as tools for monitoring beach topography changes in the Ligurian Sea (NW Mediterranean). *Geo-Marine Letters*, 36, 151-163.
- Casella, E., Rovere, A., Pedroncini, A., Mucerino, L., Casella, M., Cusati, A. L., . . . Firpo, M. (2014). Study of wave runup using numerical models and low-altitude aerial photogrammetry: A tool for coastal management. *Estuarine, Coastal and Shelf Science*, 149, 160-167.
- Cerdeira-Estrada, S., Heege, T., Kolb, M., Ohlendorf, S., Uribe, A., Müller, A., . . . Martell, R. (2012). Benthic habitat and bathymetry mapping of shallow waters in Puerto Morelos reefs using remote sensing with physics based data processing. *2012 IEEE. International Geoscience and Remote Sensing Symposium (IGARSS)*, (págs. 4383-4386). Munich, Alemania.
- Chavez, P. S. (1988). An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sensing Environment*, 24(3), 459-479.
- Chirayath, V., & Earle, S. A. (2016). Drones that see through waves - preliminary results from airborne fluid lensing for centimeter-scale aquatic conservation. *Aquatic Conservation: Marine and Freshwater ecosystems*, 26, 237-250.
- Clarke, K. R., Somerfield, P. J., & Gorley, R. N. (2008). Testing of null hypotheses in exploratory community analyses: similarity profiles and biota-environment linkage. *Journal of Experimental Marine Biology and Ecology*, 366, 56-69.
- Cohen, J. (1960). A coefficient of agreement for nominal scale. *Educational and Psychological Measurement*, 20(1), 37-46.
- Collin, A. (2012). Enhancing coral health detection using spectral diversity indices from WorldView-2 imagery and machine learners. *Remote Sensing*, 4, 1-23.
- Collin, A., Ramambason, C., Pastol, Y., Casella, E., Alessio, R., Thiault, L., . . . Davies, N. (2018). Very high resolution mapping of coral reef state using

airborne bathymetric LiDAR surface-intensity and drone imagery. *International Journal of Remote Sensing*, 2-13.

CONABIO. (2018). *Mares mexicanos*. Obtenido de Comisión Nacional para el Conocimiento y Uso de la Biodiversidad: https://www.biodiversidad.gob.mx/pais/mares/simar/caricomx/hab_bat.html

Congalton, R. G. (1991). A review of assessing the accuracy of classification of remotely sensed data. *Remote Sensing Environment*, 37, 35-46.

Congalton, R. G., & Green, K. (2009). *Assessing the Accuracy of Remotely Sensed Data. Principles and Practices* (Segunda ed.). New York: CRC Press.

Congalton, R. G., & Mead, R. A. (1983). A quantitative method to test for consistency and correctness in photo interpretation. *Photogrammetric Engineering & Remote Sensing*, 49(1), 69-74.

Congalton, R. G., Oderwald, R. G., & Mead, R. A. (1983). Assessing Landsat Classification Accuracy Using Discrete Multivariate Analysis Statistical Techniques. *Photogrammetric Engineering & Remote Sensing*, 49(12), 1671-1678.

Contreras-Silva, A. I., López-Caloca, A., Tapia-Silva, F. O., & Cerdeira-Estrada, S. (2012). Satellite remote sensing of coral reef habitats mapping in shallow waters at Banco Chinchorro Reefs, México: a classification approach. En B. Escalante, *Remote Sensing Applications* (págs. 331-354). Croacia: InTech.

Cruz-Vázquez, C., Rioja-Nieto, R., & Enriquez, C. (2019). Spatial and temporal effects of management on the reef seascape of a marine protected area in the Mexican Caribbean. *Ocean and Coastal Management*, 169, 50-57.

Cuevas-Jiménez, A., & Ardisson, P. L. (2002). Mapping of shallow coral reefs by colour aerial photography. *International Journal of Remote Sensing*, 23, 3697-3712.

- Digital Globe. (2014). *WorldView3 above + beyond*. Obtenido de Digital Globe: <http://worldview3.digitalglobe.com/>
- DOF. (2015). *ACUERDO por el que se estable una zona de refugio pesquero en aguas marinas de jurisdicción federal ubicadas en la zona de Akumal en el Estado de Quintana Roo*. México: Diario Oficial de la Federación.
- DOF. (2017). *ACUERDO por el que se da a conocer el Programa de Protección del Área de Refugio para la Protección de Especies Marinas denominada Bahía de Akumal*. México: Diario Oficial de la Federación.
- DOF. (2019). *NORMA Oficial Mexicana NOM-107-SCT3-2019, Que establece los requerimientos para operar un sistema de aeronave pilotada a distancia (RPAS) en el espacio aéreo mexicano*. México: Diario Oficial de la Federación.
- Duffy, J. P., & Anderson, K. (2016). A 21st-century renaissance of kites as platforms for proximal sensing. *Progress in Physical Geography: Earth and Environment*, 40, 352-361.
- European Space Agency. (2020). *WorldView-3*. Obtenido de <https://earth.esa.int/eogateway/missions/worldview-3>
- Foody, G. M. (1992). On the compensation for Chance Agreement in image classification accuracy assessment . *Photogrammetric Engineering & Remote Sensing*, 58(10), 1459-1460.
- García-Salgado, M., Camarena, T., Gold, G., Vasquez, M., Galland, G., Nava, G., . . . Ceja, V. (2006). *Línea Base del Estado del Sistema Arrecifal Mesoamericano*. Belice: Documento Técnico del SAM, No. 18.
- Gardner, T. A., Côté, I. M., Gill, J. A., Grant, A., & Watkinson, A. R. (2003). Long-term region-wide declines in Caribbean corals. *Science*, 301, 958-960.

- Garza-Pérez, J. R., Lehmann, A., & Arias-González, J. E. (2004). Spatial prediction of coral reef habitats: integrating ecology with spatial modeling and remote sensing. *Marine Ecology Progress Series*, 269, 141-152.
- Gil , M. A., Renfro, B., Figueroa-Zavala, B., Penié, I., & Dunton, K. H. (2015). Rapid tourism growth and declining coral reefs in Akumal, Mexico. *Marine Biology*, 162, 2225-2233.
- Goodman, J. A., Purkis, S. J., & Phinn, S. R. (2013). *Coral Reef Remote Sensing. A guide for Mapping, Monitoring and Management*. Nueva York: Springer.
- Green, E. P., Mumby, P. J., Edwards, A. J., Clark, C. D., & (Ed. A. J. Edwards). (2000). *Remote Sensing Handbook for Tropical Coastal Management*. . Paris: UNESCO.
- Guoqiang, Y., Yi, M., Guangbo, R., & Yuhai, B. (2016). High resolution remote sensing classification of coral reef substrate, base on SVM-taken Xisha Zhaoshu Island as example. *IEEE International Symposium on Geoscience and Remote Sensing (IGARSS)*, (págs. 759-762). Beijing, China.
- Hamylton, S. M., Carvalho, R. C., Duce, S., Roelfsema, C. M., & Vila-Concejo, A. (2016). Linking pattern to process in reef sediment dynamics at Lady Musgrave Island, southern Great Barrier Reef. *Sedimentology*, 63, 1634-1650.
- Hamylton, S. M., Pescud, A., Leon, J. X., & Callaghan, D. P. (2013). A geospatial assessment of the relationship between reef flat community calcium carbonate production and wave energy. *Coral Reefs*, 32, 1025/1039.
- Hang, N., Hoa, N., Nguyen, T., & Nguyen-Ngoc, L. (2019). Spatial distribution of submerged aquatic vegetation in an Chan coastal waters, Phu Yen province using PlanetScope satellite image. *Vietnam Journal of Earth Sciences*, 41(4), 358-373.

- Harris Geospatial Solutions, Inc. (2020). *Resize Data*. Obtenido de Harris Geospatial Solutions, Inc: <https://www.harrisgeospatial.com/docs/ResizeData.html>
- Healthy Reefs. (2020). *Mesoamerican Reef Report Card*. Healthy Reefs.
- Hedley, J. D., Harborne, A. R., & Mumby, P. J. (2005). Simple and robust removal of sun glint for mapping shallow-water benthos. *International Journal of Remote Sensing*, 26(10), 2107-2112.
- Hedley, J., Roelfsema, C., Chollett, I., Harbone, A., Heron, Z., Weeks, S., . . . Mumby, P. J. (2016). Remote Sensing of Coral Reefs for Monitoring and Management: A Review. *Remote Sensing*, 8(2).
- Hegarty-Craver, M., Polly, J., O'Neil, M., Ujeneza, N., Rineer, J., Beach, R. H., . . . Temple, D. S. (2020). Remote Crop Mapping at Scale: Using Satellite Imagery and UAV-Acquired Data as Ground Truth. *Remote Sensing*, 12.
- Hochberg, E. (2011). Remote Sensing of Coral Reefs Processes. *Coral Reefs: An Ecosystem in Transition*, 25-35.
- Hochberg, E. J., & Atkinson, M. J. (2000). Spectral discrimination of coral reef benthic communities. *Coral Reefs*, 19, 164-171.
- Hochberg, E. J., & Atkinson, M. J. (2003). Capabilities of remote sensors to classify coral, algae, and sand as pure and mixed spectra. *Remote Sensing of Environment*, 85, 174-189.
- Hochberg, E. J., Andréfouët, S., & Tyler, M. R. (2003). Sea surface correction of high spatial resolution IKONOS images to improve bottom mapping in near-shore environments. *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING* Hochberg, E. J., Andrefouet, S., & Tyler, M. R. (2003). Sea surface correction of high spatilIEEE Transactions on Geoscience and Remote Sensing, 41, págs. 1724-1729.
- Holden, H., & Ledrew, E. (1999). Hyperspectral identification of coral reef features. *International Journal of Remote Sensing*, 20(13), 2545-2563.

- Hughes, T. P., Baird, A. H., Bellwood, D. R., Card, M., Connolly, S. R., Folke, C., . . . Roughgarden, J. (2003). Climate Change, Human Impacts, and Resilience of Coral Reefs. *Science*, *301*, 929-933.
- Jackson, J., Donovan, M., Cramer, K., & Lám, V. (editores). (2014). *Status and trends of caribbean coral reefs 1970 - 2012*. Gland, Switzerland: Global Coral Reef Monitoring Network, IUCN.
- Johansen, K., Duan, Q., Tu, Y.-H., Searle, C., Wu, D., Phinn, S., . . . McCabe, M. F. (2020). Mapping de condition of macadamia tree crops using multi-spectral UAV and WorldView-3 imagery. *Journal of Photogrammetry and Remote Sensing*, *165*, 28-40.
- Jordan-Dahlgren, E. (1993). *Atlas de los arrecifes coralinos del Caribe mexicano.. Parte I, El sector Continental*. CIQRO e ICML, UNAM.
- Kabiri, K., Rezai, H., & Moradi, M. (2020). A drone-based method for mapping the coral reefs in the shallow coastal waters - case study: Kish Island, Persian Gulf. *Earth Science Informatics*.
- Khatami, R., Mountrakis, G., & Stehman, S. V. (2016). A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*, *177*, 89-100.
- Lechner, A. M., Fletcher, A., Johansen, K., & Erskine, P. (2012). Characterizing upland swamps using object-based classification methods and hyper-spatial resolution imagery derived from an unmanned aerial vehicle. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, *1-4*, págs. 101-106. Melbourne, Australia.
- Lee, Z., Carder, K. L., Mobley, C. D., Steward, R. G., & Patch, J. S. (1999). Hyperspectral remote sensing for shallow waters: 2. Deriving bottom depths and water properties by optimization. *Applied Optics*, *38*(18), 3831-3843.

- Liu, B., Duan, Y., & Wu, W. (2018). UAV-based Crops Classification with joint from Orthoimage and DSM data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-3, 2018*, (págs. 1023-1028). Beijing, China.
- López, A. (2014). *Análisis comparativo entre dos arrecifes coralinos bajo diferentes presiones antropogénicas en un decenio*. Sisal, Yuc.: (Tesis de Maestría). UNAM.
- Lyzenga, D. R. (1978). Passive remote sensing techniques for mapping water depth and bottom features. *Applied Optics*, 17(3), 379-383.
- Lyzenga, D. R. (1981). Remote sensing of bottom reflectance and water attenuation parameters in shallow water using aircraft and Landsat data. *Remote Sensing*, 2(1), 71-82.
- Lyzenga, D. R. (1985). Shallow-water bathymetry using combined lidar and passive multispectral scanner data. *International Journal of Remote Sensing*, 6(1), 115-125.
- Ma, Z., & Redmond, R. L. (1995). Tau Coefficients for Accuracy Assessment of Classification of Remote Sensing. *Photogrammetric Engineering & Remote Sensing*, 61(1), 435-439.
- Maritorena, S., Morel, A., & Gentili, B. (1994). Diffuse reflectance of oceanic shallow waters: Influence of water depth and bottom albedo. *Limnology and Oceanography*, 39(7), 1689-1703.
- Mata-Lara, M., Garza-Pérez, J. R., Aranda-Fragoso, A., & Salles, P. (2018). Social alienation and environmental decline in a coral reef: Challenges to coastal management in the Mexican Caribbean. *Ocean and Coastal Management*, 155, 30-39.
- MicaSense, Inc. (2017). *MicaSense RedEdge-M. Multispectral Camera. User Manual*. MicaSense, Inc.

- Molina-Hernández, A. L., Garza-Pérez, J. R., & Aranda-Fragoso, A. (2018). Identifying management challenges and implementation shortcomings of a new fishing refuge: Akumal reef, Mexico. *Ocean and Coastal Management*, 161, 127-140.
- Mumby, P. J., & Edwards, A. J. (2002). Mapping marine environments with IKONOS imagery: enhanced spatial resolution can deliver greater thematic accuracy. *Remote Sensing of Environment*, 82, 248-257.
- Mumby, P. J., Chisholm, J. R., Clark, C. D., Hedley, J. D., & Jaubert, J. (2001). A bird's-eye view of the health of coral reefs. *Nature*, 413, 36.
- Mumby, P. J., Green, E. P., Edwards, A. J., & Clark, C. D. (1999). The cost-effectiveness of remote sensing for tropical coastal resources assessment and management. *Journal of Environmental Management*, 55, 157-166.
- Murugan, D., Garg, A., Ahmed, T., & Singh, D. (2016). Fusion of Drone and Satellite Data for Precision Agriculture Monitoring. *11th International Conference on Industrial and Information Systems (ICIIS)*, 910-914.
- Naidu, R., Muller-Karger, F., & McCarthy, M. (2018). Mapping of benthic habitats in Komave, coral coast using WorldView-2 satellite imagery. En W. Leal Filho, *Climate change impacts and adaptation strategies for coastal communities* (págs. 337-354). Hamburgo, Alemania: Springer International Publishing.
- NOAA. (2018). *What is remote sensing?* (National Oceanic and Atmospheric Administration, Editor) Obtenido de <https://oceanservice.noaa.gov/facts/remotesensing.html>
- Ortiz, C. A. (2019). *Priorización sistemática del Parque Nacional Arrecifes de Cozumel mediante el uso de Sistemas de Información Geográfica y percepción remota (Tesis de Maestría)*. México: Universidad Nacional Autónoma de México.

- Ortiz, C. A., Hinojosa-Arango, G., Garza-Pérez, J. R., & Rioja-Nieto, R. (2020). Seascape metrics, spatio-temporal change, and intensity of use for the spatial conservation prioritization of a Caribbean marine protected area. *Ocean and Coastal Management*, 194.
- Palandro, D., Andréfouët, S., Dustan, P., & Muller-Karger, F. E. (2003). Change detection in coral reef communities using Ikonos satellite sensor imagery and historic aerial photographs. *Remote Sensing*, 24(4), 873-878.
- Pettorelli, N., Laurance, W. F., O'Brien, T. G., Wegmann, M., Nagendra, H., & Turner, W. (2014). Satellite remote sensing for applied ecologist: opportunities and challenges. *Journal of Applied Ecology*, 51, 839-848.
- Phelan, M. (2012). *Coral Reefs: Underwater Structures*. Delhi: Research World.
- Phinn, S., Roelfsema, C., Dekker, A., Brando, V., & Anstee, J. (2008). Mapping seagrass species, cover and biomass in shallow waters: An assessment of satellite multi-spectral and airborne hyper-spectral imaging systems in Moreton Bay (Australia). *Remote Sensing of Environment*, 112, 3413-3425.
- Planet Labs Inc. (2018). Planet Imagery Product Specifications. (Planet Labs Inc, Ed.)
- Polcyn, F. C., Brown, W. L., & Sattinger, I. J. (1970). *The Measurement of Water Depth by Remote Sensing Techniques*. Michigan: Willow Run Laboratories, The University of Michigan.
- Purkis, S. J., Gleason, A. C., Purkis, C. R., Dempsey, A. C., Renaud, P. G., Faisal, M., . . . Kerr, J. M. (2019). High-resolution habitat and bathymetry maps for 65,000 sq. km of Earth's remotest coral reefs. *Coral Reefs*(38), 467-488.
- Raeva, P. L., Šedina, J., & Dlesk, A. (2018). Monitoring of crop fields using multispectral and thermal imagery from UAV. *European Journal of Remote Sensing*.

- Rioja-Nieto, R., & Sheppard, C. (2008). Effects of management strategies of the landscape ecology of a Marine Protected Area. *Ocean Coastal Management*, 51, 397-404.
- Roelfsema, C., Kovacs, E., Ortiz, J. C., Wolff, N. H., Callaghan, D., Wettle, M., . . . Phinn, S. (2018). Coral reef habitat mapping: A combination of object-based image analysis and ecological modelling. *Remote Sensing of Environment*, 208, 27-41.
- Rosenfield, G. H., & Fitzpatrick-lins, K. (1986). A coefficient of agreement as a measure of thematic classification accuracy. *Photogrammetric Engineering and Remote Sensing*, 52(2), 223-227.
- Shihavuddin, A. S., Gracias, N., Garcia, R., Gleason, A. C., & Gintert, B. (2013). Image-Based Coral Reef Classification and Thematic Mapping. *Remote Sensing*, 5, 1809-1841.
- Sim, J., & Wright, C. C. (2005). The Kappa Statistic in Reliability Studies: Use, Interpretation, and Sample Size Requirements. *Physical Therapy*, 85(3), 257-268.
- Smith, V. R., Rogers, R. H., & Reed, L. E. (1975). Automated mapping and inventory of Great Barrier zonation with LANDSAT data. *IEEE 'OCEAN 75 Conference*, (págs. 775-780).
- Story, M., & Congalton, R. G. (1986). Accuracy Assessment: A User's perspective. *Photogrammetric Engineering and Remote Sensing*, 52(3), 397-399.
- Teja, T., Venkata, M., Mahendra, R., & Kumar, T. (2013). Evaluation of various image classification techniques on Landsat to identify coral reefs. *Geomatics, Natural Hazards and Risk*, 5(2), 173-184.
- USGS. (2019). *What is remote sensing and what is it used for?* Obtenido de US Geological Survey: https://www.usgs.gov/faqs/what-remote-sensing-and-what-it-used?qt-news_science_products=0#qt-news_science_products

- Ventura, D., Bonifazi, A., Gravina, M. F., Belluscio, A., & Ardizzone, G. (2018). Mapping and Classification of Ecologically Sensitive Marine Habitats Using Unmanned Aerial Vehicle (UAV) Imagery and Object-Based Image Analysis (OBIA). *Remote Sensing*, 10, 1-23.
- Wahidin, N., Siregar, V. P., Nababan, B., Jaya, I., & Wouthuyzen, S. (2015). Object-based image analysis for coral reef benthic habitat mapping with several classification algorithms. *Procedia Environmental Sciences*, 24, 222-227.
- Wezernak, C. T., & Lyzenga, D. R. (1975). Analysis of Cladophora distribution in Lake Ontario using remote sensing. *Remote Sensing Environment*, 4, 37-48.
- Wicaksono, P., & Lazuardi, W. (2018). Assessment of PlanetScope images for benthic habitat and seagrass species mapping in a complex optically shallow water environment. *International Journal of Remote Sensing*, 39(17), 5739-5765.
- Wicaksono, P., & Lazuardi, W. (2019). Random Forest classification scenarios for benthic habitat mapping using PlanetScope image. *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, (págs. 8245-8248). Yokohama, Japón.
- Wilkinson, C. (2008). *Status of Coral Reefs of the World: 2008*. Townsville, Australia: Global Coral Reef Monitoring Network and Reef and Rainforest Research Centre.
- Witze, A. (2016). Reefs mapped from above. *Nature*, 534, 13-14.