



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

**ANÁLISIS DE LA DINÁMICA TEMPORAL Y ESPACIAL DE LOS  
CUERPOS DE AGUA EN MARISMAS NACIONALES, SINALOA-  
NAYARIT POR SENSORES REMOTOS**

**TESIS**

QUE PARA OPTAR POR EL GRADO ACADÉMICO DE:  
**MAESTRA EN CIENCIAS**  
(LIMNOLOGÍA)

PRESENTA:

**BERENICE VAZQUEZ BALDERAS**

TUTOR:

**DR. FRANCISCO JAVIER FLORES DE SANTIAGO**  
INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA

COMITÉ TUTOR:

**DR. MARTIN MERINO IBARRA**

INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA, UNAM

**DR. LUIS VALDERRAMA LANDEROS**

COMISIÓN NACIONAL PARA EL CONOCIMIENTO Y USO DE LA BIODIVERSIDAD

**DR. FERNANDO A. GONZÁLEZ FARÍAS**

INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA, UNAM

**DR. RAÚL AGUIRRE GÓMEZ**

INSTITUTO DE GEOGRAFÍA, UNAM

ASESOR(A) EXTERNO(A):

**DR. INDER RAFAEL TECUAPETLA GÓMEZ**

CONSEJO NACIONAL DE CIENCIA Y TECNOLOGÍA

**MÉXICO, CD. MX., junio, 2023**



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

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

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



**ANÁLISIS DE LA DINÁMICA TEMPORAL Y ESPACIAL DE LOS  
CUERPOS DE AGUA EN MARISMAS NACIONALES, SINALOA-  
NAYARIT POR SENSORES REMOTOS**

**TESIS**

QUE PARA OBTENER EL GRADO ACADÉMICO DE:  
**MAESTRA EN CIENCIAS**  
(LIMNOLOGÍA)

PRESENTA:  
**BERENICE VAZQUEZ BALDERAS**

**TUTOR:**  
**DR. FRANCISCO JAVIER FLORES DE SANTIAGO**  
INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA

**COMITÉ TUTOR:**  
**DR. MARTIN MERINO IBARRA**  
INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA, UNAM  
**DR. LUIS VALDERRAMA LANDEROS**  
COMISIÓN NACIONAL PARA EL CONOCIMIENTO Y USO DE LA BIODIVERSIDAD  
**DR. FERNANDO A. GONZÁLEZ FARÍAS**  
INSTITUTO DE CIENCIAS DEL MAR Y LIMNOLOGÍA, UNAM  
**DR. RAÚL AGUIRRE GÓMEZ**  
INSTITUTO DE GEOGRAFÍA, UNAM

**ASESOR(A) EXTERNO(A):**  
**DR. INDER RAFAEL TECUAPETLA GÓMEZ**  
CONSEJO NACIONAL DE CIENCIA Y TECNOLOGÍA

**MÉXICO, CD. MX., junio, 2023**

## **AGRADECIMIENTOS**

Al Posgrado en Ciencias del Mar y Limnología y a sus académicos por permitirme continuar con mi formación profesional, y así enriquecer mi experiencia laboral con todas sus enseñanzas y experiencias compartidas.

A la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO), que me brindó todos los medios necesarios para el desarrollo de este proyecto.

Al Dr. Francisco Javier Flores de Santiago, por su paciencia y confianza durante el desarrollo de este proyecto, por compartir sus conocimientos y experiencia, por siempre ser respetuoso y guiarme en mis propios intereses académicos y profesionales.

Al Dr. Martin Merino Ibarra, por interesarse en este proyecto y con su experiencia ayudarme a tener una perspectiva integral. Todas sus palabras fueron siempre para aportar a mi desarrollo académico.

Al Dr. Luis Humberto Valderrama Landeros, por su amistad e incansable capacidad de transmitir experiencia y conocimiento a quien se lo solicite.

Al Dr. Inder Rafael Tecuapetla Gómez, quien fue fundamental para el desarrollo de este trabajo sobre todo en la propuesta metodológica.

Al Dr. Fernando A. González Farías y al Dr. Raúl Aguirre Gómez, por aceptar participar como miembros del jurado de tesis y sus valiosas recomendaciones para la mejora de este trabajo.

A mis jefes, el Dr. Rainer Ressler y la Dra. Isabel Cruz, por su paciencia y el apoyo que me brindaron para poder cumplir este pendiente profesional.

Al Dr. Rene R. Colditz, quien me permitió retomar esta línea de trabajo que propuso antes de retirarse de la CONABIO.

## **DEDICATORIA**

A mis padres por estar siempre presentes y su apoyo para mi desarrollo personal y profesional.  
A mis hermanos por ser inspiración y amor.

A Bernardo, por apoyarme incondicionalmente durante esta etapa, gracias por caminar conmigo.

A ti hija mía, porque sin saber que vendrías a mitad de este camino te convertiste en fuente de risas y aprendizaje, y la mejor de mis maestras.

# ÍNDICE

<b>AGRADECIMIENTOS .....</b>	<b>3</b>
<b>DEDICATORIA .....</b>	<b>4</b>
<b>ÍNDICE.....</b>	<b>5</b>
<b>ÍNDICE DE FIGURAS .....</b>	<b>7</b>
<b>ÍNDICE DE TABLAS .....</b>	<b>9</b>
<b>RESUMEN .....</b>	<b>10</b>
<b>ABSTRACT .....</b>	<b>11</b>
<b>1. INTRODUCCIÓN.....</b>	<b>12</b>
<b>2. ANTECEDENTES .....</b>	<b>15</b>
<b>3. JUSTIFICACIÓN E IMPORTANCIA.....</b>	<b>19</b>
<b>4. PREGUNTAS DE INVESTIGACION E HIPÓTESIS .....</b>	<b>20</b>
<b>5. OBJETIVOS .....</b>	<b>21</b>
<b>6. ÁREA DE ESTUDIO .....</b>	<b>22</b>
<b>7. MATERIALES Y MÉTODOS .....</b>	<b>24</b>
<b>Datos satelitales usados .....</b>	<b>25</b>
<b>Calidad de datos de referencia .....</b>	<b>26</b>
<b>Integración de la serie de datos espectrales.....</b>	<b>28</b>
<b>Disponibilidad de datos .....</b>	<b>29</b>

	<b>Selección de variables del modelo de regresión.....</b>	<b>31</b>
	<b>Datos de precipitación y temperatura.....</b>	<b>34</b>
	<b>Datos de ciclones tropicales.....</b>	<b>34</b>
	<b>Datos de episodios El Niño – La Niña .....</b>	<b>34</b>
<b>8.</b>	<b>RESULTADOS.....</b>	<b>36</b>
	<b>Calidad de datos de referencia .....</b>	<b>36</b>
	<b>Selección de variables del modelo de regresión.....</b>	<b>42</b>
	<b>Aplicación del modelo de regresión.....</b>	<b>49</b>
	<b>Precipitación y temperatura .....</b>	<b>54</b>
	<b>Ciclones tropicales .....</b>	<b>57</b>
	<b>Episodios El Niño – La Niña .....</b>	<b>58</b>
<b>9.</b>	<b>DISCUSIÓN.....</b>	<b>59</b>
<b>10.</b>	<b>CONCLUSIONES .....</b>	<b>67</b>
<b>11.</b>	<b>REFERENCIAS.....</b>	<b>69</b>

# ÍNDICE DE FIGURAS

<b>Figura 1.</b> Localización del área de estudio Marismas Nacionales en Sinaloa y Nayarit. ....	23
<b>Figura 2.</b> Diagrama de flujo. ....	25
<b>Figura 3.</b> Representación de un cubo de información espectral para cada una de las bandas de interés (A y B), y el índice calculado a partir de ellas, en este caso, MNDWI donde los colores más azules corresponden a valores mayores y, por lo tanto, a píxeles con mayor contenido de agua (C). ....	29
<b>Figura 4.</b> Porcentaje de datos válidos para cada píxel en toda la serie (2000 – 2017). Cada píxel representa el valor para todas las fechas (6,575 días). ....	30
<b>Figura 5.</b> Porcentaje de píxeles válidos para cada fecha, considerando el total de píxeles en la escena (13,741 píxeles). ....	31
<b>Figura 6.</b> Localización de estaciones del Servicio Meteorológico Nacional consultadas. ....	35
<b>Figura 7.</b> Distribución espacial de las calidades y los valores de fracciones de agua por píxel para la temporada de estiaje (22/03/2008). ....	37
<b>Figura 8.</b> Distribución espacial de las calidades y los valores de fracciones de agua por píxel para la temporada de lluvias (16/10/2008). ....	38
<b>Figura 9.</b> Gráfico de dispersión de las fracciones respecto al índice seleccionado por Colditz et al. (2018), para cada calidad de datos, A) para la temporada de estiaje (22/03/2008) y B) para la temporada de lluvias (16/10/2008). ....	39
<b>Figura 10.</b> Comparación de la dispersión de los valores de fracción en diferentes índices espectrales, estratificando calidades, temporada de estiaje (22/03/2008). ....	41
<b>Figura 11.</b> Correlación entre 14 índices espectrales usados para el mapeo de cuerpos de agua. Fecha de estiaje (22/03/2008). ....	43
<b>Figura 12.</b> Correlación entre 14 índices espectrales usados para el mapeo de cuerpos de agua. Fecha de lluvias (16/10/2008). ....	44
<b>Figura 13.</b> Porcentaje explicado de la varianza por cada componente y tabla de eigenvalores en la fecha de estiaje (22/03/2008). ....	45
<b>Figura 14.</b> Porcentaje explicado de la varianza por cada componente y tabla de eigenvalores en la fecha de lluvias (16/10/2008). ....	46
<b>Figura 15.</b> Circulo de correlaciones con la contribución de cada variable en la fecha de estiaje (22/03/2008). ....	48
<b>Figura 16.</b> Circulo de correlaciones con la contribución de cada variable en la fecha de lluvias (16/10/2008). ....	48
<b>Figura 17.</b> Serie de tiempo de superficie de cuerpos de agua, estimada con los modelos seleccionados (D4W11), y su comparativa con el modelo de regresión simple (D0W0) y serie de datos binarios obtenida a partir de este último. ....	52
<b>Figura 18.</b> Precipitación diaria (línea azul) y serie de área de cuerpos de agua obtenida con el modelo (línea negra). ....	55
<b>Figura 19.</b> Temperaturas máximas y mínimas en tres estaciones climatológicas: A) 25049-La Concha, B) 18036-Tecuala y C) 18022-Mexcaltitan y serie de área de cuerpos de agua obtenida con el modelo (línea negra). ....	56
<b>Figura 20.</b> Presencia de ciclones tropicales (puntos azules) y serie de cuerpos de agua. A) Categoría máxima y B) Categoría de contacto a tierra o más cercana a la costa. Para las categorías, 0 =	

Depresión tropical, 0.5 = Tormenta tropical, 1 = Huracán1, 2 = Huracán2, 3 = Huracán3, 4 = Huracán4, 5=Huracán5.....	57
<b>Figura 21.</b> Índice Oceánico del El Niño. Se indica la intensidad de eventos de El Niño (rojo) y La Niña (azul).....	58

## ÍNDICE DE TABLAS

Tabla 1. Productos MODIS utilizados.....	26
Tabla 2. Categorías de calidad por pixel (producto MCD43A2). .....	27
Tabla 3. Categorías de calidad asignadas por pixel en los datos de referencia. ....	28
Tabla 4. Bandas espectrales de los datos MODIS. ....	28
Tabla 6. Contribución de las variables en los Componentes 1 y 2, para ambas temporadas. ....	47
Tabla 7. Variables consideradas en los modelos, temporada de estiaje (22/03/2008). ....	50
Tabla 8. Variables consideradas en los modelos, temporada de lluvias (16/10/2008). ....	50

## RESUMEN

El sistema lagunar-estuarino de Marismas Nacionales es considerado el humedal costero más importante de la costa este del Océano Pacífico. Sin embargo, este sistema está bajo una constante degradación debido principalmente a proyectos de infraestructura costera y represamiento de los ríos. Marismas Nacionales tiene una extensión territorial de 343,525 ha, por lo tanto, las técnicas *in situ*, son generalmente ineficientes. Debido a lo anterior, las técnicas de percepción remota pueden llegar a ser un método alternativo para poder analizar el humedal costero en su totalidad. En el presente trabajo se determinó la variabilidad temporal de los cuerpos de agua mediante el uso de espectrorradiómetros de alta resolución temporal. Se analizaron productos diarios provenientes del sensor MODIS Terra-Aqua (MCD43A4) a una resolución espacial de 500 m/pixel, desde enero de 2000 hasta diciembre de 2017. Para cada fecha se calculó la superficie total de cuerpos de agua en el sitio (fracción de agua por pixel) a partir de un modelo de regresión lineal múltiple. Las variables para el modelo se seleccionaron a partir de 14 índices espectrales. Los índices con la mayor contribución en la regresión fueron los índices normalizados que usan las bandas con longitudes de onda en el SWIR (MNDWI y NDMI). En ambas temporadas (estiaje y lluvias), se usaron los índices MNDWI6, NDMI6 y NDMI7, mientras que el MNDWI5 se usó sólo en la temporada lluviosa. La extensión del cuerpo de agua osciló entre 42,400 y 126,075 ha durante las temporadas de estiaje y lluvias, respectivamente. Estos resultados fueron contrastados con datos de precipitación de estaciones climatológicas cercanas a la zona de estudio. Aparentemente, los huracanes, al igual que los eventos de El Niño y La Niña, no tuvieron una contribución importante respecto a la dinámica del cuerpo de agua. Por otro lado, la extensión del cuerpo de agua presentó un incremento gradual durante los 18 años de estudio. Es muy probable que esta tendencia sea un reflejo indirecto de la degradación constante del bosque de manglar y de otros humedales, en donde pixeles previamente clasificados como manglar son remplazados por pixeles clasificados como agua debido a la disminución del dosel de vegetación. Finalmente, los datos MODIS y el análisis multispectral generado en esta tesis fueron adecuados para poder cuantificar la extensión de los cuerpos de agua.

## **ABSTRACT**

The estuarine system of Marismas Nacionales is considered the most important coastal wetland on the eastern coast of the Pacific Ocean. However, this system is under constant degradation mainly due to coastal infrastructure projects and river damming. Traditional field techniques are inefficient because of their large territorial extension (343,525 ha), therefore, remote sensing techniques could be an alternative approach to analyze the entire coastal wetland. The temporal variability of the water bodies was determined by using a high temporal resolution spectroradiometer. Daily products from the MODIS Terra-Aqua sensor (MCD43A4) were analyzed at a spatial resolution of 500 m, from January 2000 to December 2017. For each date, the total surface area of water bodies at the site (water fraction per pixel) was calculated from a multiple linear regression model. Several variables for the model were selected from 14 spectral indices. The indices with the greatest contribution in the regression were the normalized indices with wavelengths in the SWIR (MNDWI and NDMI). During both seasons (dry and rainy), the MNDWI6, NDMI6, and NDMI7 indices were used, while the MNDWI5 was used only during the rainy season. The extension of the body of water ranged between 42,400 and 126,075 ha during the dry and rainy seasons, respectively. These results were contrasted with precipitation data from weather stations nearby. Apparently, hurricanes, as well as the El Niño and La Niña events, did not make a significant contribution to the dynamics of the body of water. On the contrary, the extension of the body of water showed a gradual increase during the 18 years of study. This trend is most likely an indirect reflection of the constant degradation of the mangrove forest and other wetlands, where pixels previously classified as mangroves are now replaced by pixels classified as water due to the decrease in the vegetation canopy. Finally, the MODIS data and the multispectral analysis generated in this dissertation were adequate to be able to quantify the extension of the waterbodies.

# 1. INTRODUCCIÓN

Los humedales costeros presentan un alto valor económico y ecológico debido a los bienes y servicios ambientales que proporcionan (Blanco y Correa 2011). Entre los beneficios que aportan los humedales costeros a la sociedad, destacan la importancia para comunidades locales en términos de producción pesquera (e.g., ictiofauna, crustáceos y moluscos), la extracción de madera para construcción, la protección costera contra tormentas tropicales y huracanes (Menéndez et al. 2020), la remoción de nutrientes inorgánicos disueltos (De-León-Herrera et al. 2015), el refugio para juveniles de especies de importancia ecológica y económica (Ferreira et al. 2015), el ecoturismo sustentable (Mukherjee et al. 2014) y el almacenamiento de carbono orgánico (Espinoza-Tenorio et al. 2019). Sin embargo, los humedales costeros están bajo amenazas constantes debido a proyectos de desarrollo, tales como la planeación turística ineficiente y la construcción de granjas para acuicultura (Xiao et al. 2020). Por otro lado, los humedales costeros también son susceptibles a impactos paulatinos que no se aprecian a simple vista, pero ocasionan una degradación y fragmentación constante con resultados visibles a largo plazo (Bryan-Brown et al. 2020). Por ejemplo, el incremento constante en el nivel del mar y la temperatura superficial del océano pueden llegar a afectar a los organismos que se desarrollan dentro de los humedales costeros (Duke et al. 2017), pero no es posible apreciar sus efectos negativos en una escala de tiempo muy corta (i.e., semanas a meses). Otra situación perjudicial consiste en cambios en el régimen hidrosedimentario, los cuales generalmente son ocasionados en la cuenca del sistema como resultado de procesos hidrológicos (Serrano et al. 2020), construcción de caminos (Flores-Verdugo et al. 2007) y represamiento de los ríos (Ezcurra et al. 2019; Valderrama-Landeros y Flores-de-Santiago 2019).

Debido a la importancia ecológica y económica de los humedales costeros, existe una creciente necesidad de evaluar y monitorear su condición ambiental y distribución geográfica; con la finalidad de generar información actualizada y así reforzar los trabajos de conservación y rehabilitación (Dronova 2015). Sin embargo, los humedales costeros son considerados uno de los ambientes más desafiantes para trabajar en el campo. De acuerdo con la última cartografía de la CONABIO, el área de estudio definida en este trabajo, considerada en este trabajo tiene una cobertura de 24% de bosques de manglar (Valderrama-Landeros et al., 2017). Estos árboles y arbustos crecen en ambientes donde existe una inundación constante, el suelo presenta

sedimento blando salino (Bukoski et al. En prensa) por lo que se debe tener mucho cuidado al momento de utilizar equipo electrónico (Flores-de-Santiago et al. 2013a). Debido a estas condiciones adversas en campo, el uso de herramientas y técnicas basadas en sensores remotos permite la optimización de recursos económicos y humanos, y no sustituyen en absoluto el trabajo *in situ*, el cual complementa y en muchos casos valida los resultados obtenidos en gabinete (Kovacs et al. 2009), pero definitivamente facilita el estudio de grandes extensiones geográficas en un tiempo mucho más eficiente (Flores-de-Santiago et al. 2020).

Los sensores remotos son considerados herramientas fundamentales para estudios ambientales y presentan una serie de ventajas comparadas con métodos de campo tradicionales. Por ejemplo, las imágenes de satélites pueden proveer información espacial y temporal sobre áreas extensas a nivel global. De hecho, los acervos históricos satelitales pueden ser descargados desde inicios de los años 1970. Sin embargo, la capacidad de obtener imágenes históricas depende de la disposición de datos de la zona geográfica de interés (Wulder et al. 2016). Asimismo, existen varias técnicas para procesar la información de imágenes satelitales y dependiendo de su resolución, pueden proporcionar clasificaciones temáticas con exactitudes muy altas (Friess y Webb 2014). Consecuentemente, no es sorprendente encontrar en la literatura una gama amplia de estudios ambientales en humedales costeros mediante técnicas de percepción remota a diferentes escalas espaciales y temporales (Guo et al. 2017). Sin embargo, los estudios que consideran variaciones temporales son escasos (e.g., Shrestha et al. 2019), principalmente en humedales costeros subtropicales en donde la extensión de los cuerpos de agua depende no sólo del aporte fluvial temporal, sino también del hidropериодо (frecuencia, duración e intensidad de la inundación) y en algunos sitios, del aporte subterráneo (Serrano et al. 2020).

Los humedales costeros están caracterizados por tres elementos clave: suelos hídricos, vegetación hidrófila y presencia de cuerpos de agua (Chávez et al. 2020). Específicamente, la identificación de los cuerpos de agua en humedales costeros resulta relativamente sencilla si se trata de estudios de una sola fecha. Por ejemplo, una propiedad óptica del agua consiste en absorber rápidamente las longitudes de onda en la región del infrarrojo. Por lo tanto, la cuantificación de cuerpos de agua por medio de diferentes técnicas multispectrales ha sido una práctica convencional a lo largo de las últimas décadas (Rahman y Di 2017). Entre las principales técnicas utilizadas se puede encontrar a las clasificaciones supervisadas o no

supervisadas, índices espectrales (i.e., algoritmos con longitudes de onda específicas) y análisis multivariado (e.g., componentes principales, canónico, factor). En el caso específico de los índices espectrales, está una pregunta a responder: ¿cuáles son los índices que mejor permiten separar los cuerpos de agua en una escena? La mayoría de los estudios indican recomendaciones generales, pero no lo definen de manera cuantitativa, como es el caso de Wang et al. (2016), quienes temáticamente clasificaron cuerpos de agua temporalmente al discriminar aquellos píxeles con un valor mayor o igual a cero por medio del índice de vegetación de diferencia normalizada (NDVI, por sus siglas en inglés) con datos del sensor Moderate Resolution Imaging Spectroradiometer (MODIS). Sin embargo, el uso de un solo índice no siempre permitirá la discriminación adecuada de los cuerpos de agua, sobre todo cuando tienen variabilidad espacial y temporal en sus características físicas y químicas.

Los criterios utilizados para la cuantificación de cuerpos de agua dentro de humedales costeros también dependen de la resolución espacial, la cual generalmente es muy baja y puede llegar a generar resultados contradictorios. En este sentido, Valderrama-Landeros et al. (2018) sugieren el uso de imágenes WorldView-2 (1.8 m/píxel) para clasificar dos especies de manglares degradados debido a la limitante espacial al momento de usar datos provenientes de Sentinel-2 (10 m/píxel), SPOT-5 (10 m/píxel) y Landsat-8 (30 m/píxel). A pesar de que es recomendable utilizar datos de resolución espacial muy fina (e.g., IKONOS, QuickBird, GeoEye, WorldView), es importante considerar el aumento relacionado con el costo de adquisición de los datos, el incremento en el volumen de información y el tiempo de procesamiento.

Por lo tanto, la relación costo-beneficio en la resolución espacial, espectral y temporal deberá ser plasmado cuando el contenido de la información por píxel se maximice (Pham et al. 2019). Debido a lo anterior, la presente propuesta integra conceptos de limnología y percepción remota mediante la aplicación de una técnica para analizar temporalmente la extensión de cuerpos de agua en el humedal costero de Marismas Nacionales a partir de imágenes de satélite.

## 2. ANTECEDENTES

Las primeras plataformas y técnicas de clasificación de humedales costeros con datos provenientes de sensores remotos se remontan a la época analógica de la fotografía aérea. A pesar de ser considerada una técnica obsoleta en la actualidad, la fotografía aérea es en muchas ocasiones la única fuente de información histórica (Turner et al. 2003). Además, en su momento fue considerada una plataforma ideal para obtener información rápida comparada con técnicas de muestreo en campo (Honkavaara et al. 2009). Sin embargo, la fotografía aérea presentaba desafíos logísticos (e.g., pista de aterrizaje cercana, cantidad de fotografías por vuelo) por lo que históricamente la fotografía aérea generalmente se ha utilizado para el mapeo de humedales costeros en áreas relativamente pequeñas. Una vez que se obtenía la secuencia fotográfica, el método de interpretación consistía en una clasificación visual. Por lo que no era sorprendente encontrar una serie de inconsistencias al momento de clasificar la cobertura de los humedales y cuerpos de agua tales como la variabilidad en los niveles de agua, fenológica y densidad de la vegetación (Gómez et al. 2016). Después del lanzamiento de los primeros satélites durante la década de 1970, especialmente el lanzamiento de Landsat TM, la fotografía aérea fue utilizada principalmente para evaluar los procedimientos de clasificación derivada de la baja resolución espacial de las imágenes iniciales (Pettorelli et al. 2014; Dronova et al. 2015). Actualmente las técnicas de interpretación de fotografía aérea y el software desarrollado para ello, permiten realizar procesos automatizados para un conjunto de datos relativamente extenso. Sin embargo, sigue siendo costosa su implementación y análisis en grandes extensiones.

A partir de este párrafo, las plataformas de percepción remota satelital serán clasificadas de acuerdo con su resolución espacial en gruesa ( $> 250$  m/pixel), media (10-30 m/pixel) y alta ( $<10$  m). Esta decisión se basa en la gran cantidad de estudios publicados sobre humedales costeros con imágenes de satélite. Respecto a los estudios en humedales con datos de resolución espacial gruesa, la mayoría utilizan imágenes provenientes de los sensores MODIS y Advanced Very High Resolution Radiometer (AVHRR). El sensor MODIS, a bordo de los satélites Aqua y Terra de la Administración Nacional de la Aeronáutica y del Espacio (NASA, por sus siglas en inglés), proporciona una cobertura repetida de la superficie de la Tierra casi diaria con 36 bandas espectrales y un ancho de franja de aproximadamente 2,330 km. Siete bandas son específicamente diseñado para la teledetección terrestre con una resolución espacial de 250 m

(bandas 1–2) y 500 m (bandas 3–7) (Pham et al. 2019). Guo et al. (2017) reporta un total de 5,719 artículos publicados sobre humedales con datos satelitales, de los cuales 331 trabajos son con datos MODIS y 127 usaron datos AVHRR. A pesar de su resolución espacial gruesa, los datos MODIS han sido ampliamente utilizados debido a que proporcionan una herramienta ideal para detectar cuerpos de agua debido a la posibilidad de obtener imágenes diarias (Savtchenko et al. 2004).

Las plataformas espaciales con resolución espacial media comprenden el intervalo de 10 a 30 m. Estos datos forman parte de la serie Landsat TM/Enhanced Thematic Mapper Plus (ETM+), Systeme Probatoire D’Observation De La Terre (SPOT 1-4), Advanced visible and near infrared radiometer (AVNIR-2) y Sentinel-2 (entre otros). No es sorprendente encontrar en la literatura una mayor cantidad de estudios de humedales con datos Landsat. Específicamente, Guo et al. (2017) indican que, de los 5,719 artículos publicados relacionados a humedales, 1,259 trabajos fueron realizados con datos Landsat. Sin embargo, el escáner multiespectral Landsat (MSS) es el que menos se usó en estudios de humedales debido a su resolución más gruesa (60 m/pixel), y su baja resolución temporal. Es evidente que los estudios que usan datos Landsat TM generalmente han resultado con una mayor exactitud al momento de clasificar humedales comparados con el MSS debido a la resolución espacial y el mayor número de bandas (Mafi-Gholami et al. 2019). De hecho, independientemente de estudios en humedales, varios trabajos se han realizado con la finalidad de clasificar superficies del planeta por medio del análisis detallado de ciertas regiones del espectro electromagnético a partir del lanzamiento del primer satélite para analizar los recursos naturales en 1972 (Bannari et al. 1995). Específicamente, NASA fue una de las primeras agencias en analizar el potencial de la primera generación de imágenes de satélite Landsat-MSS por medio del programa “Monitoring the vernal advancement and retrogradation of Natural Vegetation.” Esta iniciativa ha demostrado que el uso de los canales del rojo e infrarrojo cercano, proveniente de los sensores a bordo del satélite, son particularmente adecuados para estudiar a la vegetación y los cuerpos de agua (Li et al. 2019).

Robinove (1978) fue el pionero en clasificar zonas inundadas en Queensland, Australia. A partir de ese estudio, la mayoría de los trabajos realizados hasta la actualidad sugieren el *uso de datos* Landsat para caracterizar las zonas inundadas dentro de los humedales (Wulder et al. 2016). Uno de los primeros trabajos en el área de estudio corresponde a Kovacs et al. (2001) quienes

realizaron un monitoreo con tres imágenes Landsat TM de 1986, 1993 y 1999. Este estudio fue uno de los principales en determinar la degradación del bosque de manglar a lo largo del sistema lagunar-estuarino de Teacapán-Agua Brava, Nayarit. El lanzamiento del sensor Landsat 8 Operational Land Imager (OLI) en el 2013 no ha desencadenado una serie de estudios relacionados con humedales (Arshad et al. 2020). De hecho, uno de los pocos trabajos con Landsat-8 OLI fue llevado a cabo por Valderrama-Landeros et al (2018) al comparar una misma técnica de clasificación de humedales costeros entre Landsat-8, SPOT-5, Sentinel-2 y WorldView-2. Respecto al sensor gratuito Sentinel-2, durante los primeros dos años posteriores a su lanzamiento en 2015, hubo muy pocos trabajos publicados sobre humedales con este sensor (Younes-Cardenas et al., 2017). Recientemente se han obtenido buenos resultados con su uso en el estudio de cuerpos de agua (Lefebvre et al., 2019 y Pena-Regueiro et al., 2020), sin embargo, aún es posible realizar estudios a largo plazo.

Las imágenes con un tamaño de píxel menor a 10 m se refieren generalmente como imágenes de alta resolución espacial. En el caso de los estudios sobre humedales costeros, las plataformas principales han sido IKONOS, Quickbird, GeoEye y WorldView. Comparado con imágenes con resoluciones gruesas y medias, las imágenes de alta resolución espacial proporcionan información mucho más detallada sobre la superficie del terreno y han sido consideradas un avance primordial en la forma de observar imágenes de satélite (Kamal et al. 2016). Sin embargo, generalmente presentan una resolución espectral muy baja (pocos canales) y su costo de adquisición es muy elevado, por lo que es de esperarse una menor cantidad de estudios publicados (Manna y Raychaudhuri, 2020). Aunado a lo anterior, el procesamiento de imágenes de alta resolución espacial conduce a nuevos desafíos al momento de realizar clasificaciones de superficie. Por ejemplo, las clasificaciones tradicionales (supervisadas y no supervisadas) se basan en matrices de información espectral. Es de esperarse que la cantidad de información para una misma escena se incremente al momento de aumentar la resolución espacial, por lo que se necesitan computadoras con alto rendimiento para disminuir el tiempo de procesamiento y almacenamiento (Koedsin y Vaiphasa, 2013). A pesar de estas limitaciones, las imágenes de alta resolución espacial ofrecen ventajas sin precedentes para la identificación de límites de humedales y especies vegetales (Nikolakopoulos et al. 2019). Por lo que varios estudios han utilizado este tipo de imágenes para mejorar la exactitud o como técnicas de verificación cuando

se realizan clasificaciones temáticas con insumos de resoluciones espaciales gruesas (Wan et al. 2019).

Independientemente de la resolución espacial de las imágenes, los datos provenientes de satélites de observación de la tierra presentan diferentes bandas multispectrales y a menudo contienen más del 90% de la información relacionada con la vegetación y los cuerpos de agua (Sobel et al. 2020). Sin embargo, trabajar banda por banda al momento de analizar imágenes de satélite puede ser un método que implica mucho tiempo de análisis, por lo que comúnmente se analizan índices espectrales (Friess y Webb, 2014). Un índice espectral es un valor numérico que examina la diferencia en intensidades de dos o más canales del espectro electromagnético los cuales generalmente mejoran la visibilidad de la superficie terrestre o acuática (Pettorelli et al. 2014). Por ejemplo, las diferentes coberturas vegetales y los cuerpos de agua se pueden distinguir fácilmente según su comportamiento espectral. Específicamente, la radiación visible en la región del rojo (630-690 nm) es absorbida por los pigmentos fotosintéticos y se pierde rápidamente en la columna de agua, por el contrario, la radiación en el infrarrojo cercano (760-1000 nm) es altamente reflejada por las estructuras celulares vegetales. Cuando se examinan ambas regiones del espectro, el cambio entre el rojo e infrarrojo cercano constituye una variable sensible a la presencia de vegetación y cuerpos de agua. Por tal motivo, la combinación de estos dos dominios espectrales permite diferenciar fácilmente cuerpos de agua de superficies terrestres (Sobel et al. 2020). Por lo que no es sorprendente encontrar en la literatura muchos trabajos sobre el uso de estas regiones del espectro electromagnético con la finalidad de analizar humedales y zonas costeras (Li et al. 2019; McCarthy et al. 2017; Pham et al. 2019; Pettorelli et al. 2014).

Para el monitoreo de la vegetación, Bannari et al. (1995) reporta más de cuarenta índices para imágenes multispectrales a mediados de la década de 1990. Es claro que muchos científicos han desarrollado índices relacionados a su campo específico de investigación con resultados ideales al correlacionar índices espectrales con variables independientes. Sin embargo, existen desacuerdos entre los diferentes autores debido a las ventajas y desventajas encontradas entre los cientos de estudios relacionados con índices espectrales (Asbridge et al. 2019).

### **3. JUSTIFICACIÓN E IMPORTANCIA**

El sistema lagunar-estuarino de Marismas Nacionales es una región muy notable en la costa Este del Océano Pacífico caracterizada por sus 346,525 ha de llanuras aluviales interconectadas, un complejo sistema de lagunas costeras formadas por cordones interdunarios y la presencia de 12 ríos. Debido a lo anterior, este humedal costero ha captado el interés de varios investigadores nacionales y extranjeros desde la década de 1960. La gran cantidad de estudios históricos y recientes en Marismas Nacionales expresan una priorización en su conservación y rehabilitación debido a los servicios ecosistémicos que provee. A pesar de la importancia de Marismas Nacionales, este humedal costero presenta una notable degradación debido a procesos naturales y antropogénicos. Por lo tanto, las herramientas de percepción remota son clave en identificar cambios en el cuerpo de agua del sistema costero a lo largo del tiempo y así contribuir con información espacial eficaz para la toma de decisiones en términos de conservación. Además, se puede llegar a determinar la tendencia en el cuerpo de agua y así poder hacer un enlace con sucesos naturales tales como la presencia de huracanes y el efecto de El Niño y La Niña.

## 4. PREGUNTAS DE INVESTIGACION E HIPÓTESIS

**Pregunta:** ¿Qué índices espectrales provenientes del sensor MODIS-Terra/Aqua son los más adecuados para cuantificar cuerpos de agua en una matriz de datos de Marismas Nacionales.

**Hipótesis:** Índices que utilicen la información de las longitudes de onda entre 1,600 y 1,650 nm presentarán la mayor exactitud para cuantificar cuerpos de agua en Marismas Nacionales.

**Pregunta:** Tomando en cuenta la alta resolución temporal (imágenes diarias) y resolución espacial (500 m por pixel) del sensor MODIS-Terra/Aqua, ¿Podría detectarse el efecto de los eventos extremos (huracanes, El Niño, La Niña) y variables climáticas (precipitación y temperatura), en una serie de tiempo de 18 años de los cuerpos de agua en Marismas Nacionales?

**Hipótesis:** En una serie de tiempo de 18 años, se observará el efecto de los eventos de El Niño y La Niña, así como de variables climáticas (precipitación y temperatura), en la variabilidad temporal y espacial de los cuerpos de agua en Marismas Nacionales.

## **5. OBJETIVOS**

### **Objetivo General**

Determinar la variabilidad temporal de los cuerpos de agua de Marismas Nacionales en un intervalo de tiempo de 18 años que considere variables climáticas, mediante el uso de espectrorradiómetros de alta resolución temporal.

### **Objetivos Específicos**

- Generar datos de referencia a partir de imágenes satelitales Landsat para calcular la fracción de agua en los pixeles de imágenes MODIS Terra-Aqua (MCD43A4) en Marismas Nacionales.
- Definir el(los) índice(s) espectral(es) más adecuados para clasificar cuerpos de agua en Marismas Nacionales con imágenes de alta resolución temporal MODIS Terra-Aqua.
- A partir de los índices espectrales seleccionados generar una serie de tiempo en un intervalo de 18 años (enero 2000 – diciembre 2017).
- Relacionar la serie de tiempo con otras variables abióticas como impactos de huracanes, precipitación, temperatura ambiental y presencia de eventos de El Niño y La Niña.

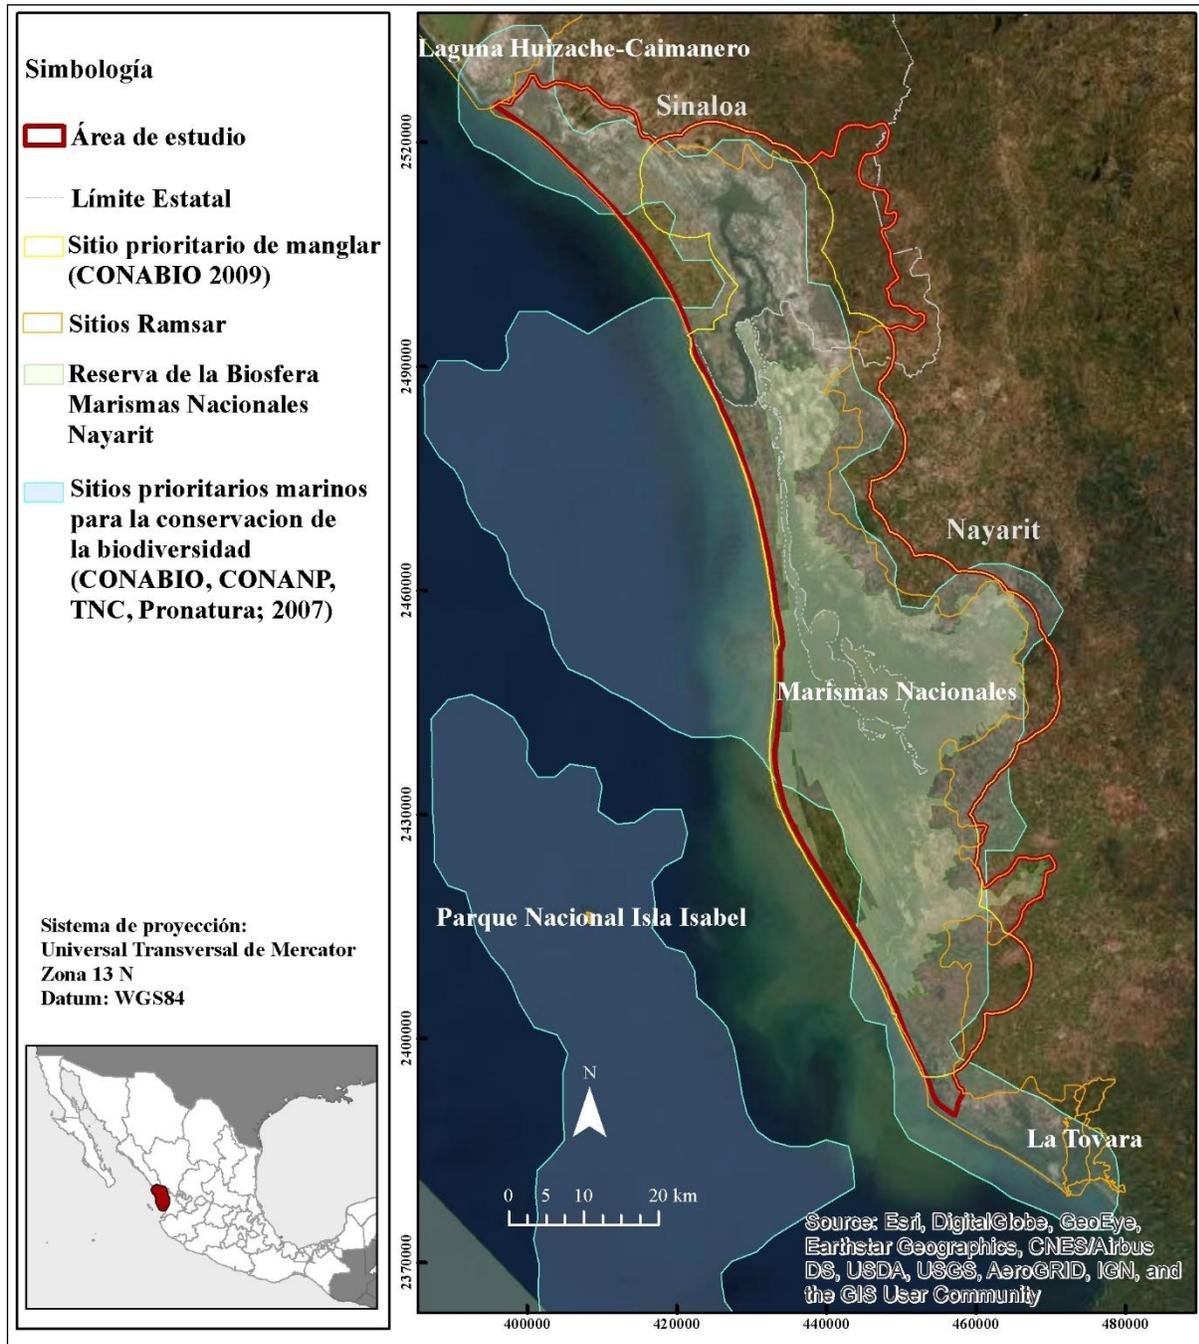
## 6. ÁREA DE ESTUDIO

El área de estudio se localiza en el litoral del Pacífico de México, en los estados de Sinaloa y Nayarit, con una superficie total de 343,525 ha (Figura 1). Fue delimitada a partir del sitio prioritario de manglar PN10 Teacapán–Agua Brava–Marismas Nacionales de la Comisión Nacional para el Conocimiento y uso de la Biodiversidad (CONABIO), el cual es considerado un sitio con relevancia biológica y con necesidades de rehabilitación ecológica. También se incluyó como parte del sitio, el Área Natural Protegida federal con categoría de Reserva de la Biósfera de Marismas Nacionales Nayarit con decreto en 2010 y el 95% del Sitio Ramsar Marismas Nacionales designado en 1995. En 2007, la CONABIO y otras instituciones identificaron el sitio marino prioritario para la conservación Corredor Pesquero Laguna El Caimanero–Marismas Nacionales.

El clima del lugar es cálido subhúmedo (Awo) con una temperatura media anual mayor de 22° C y temperatura del mes más frío mayor de 18° C. Precipitación del mes más seco entre 0 y 60 mm; lluvias de verano con índice P/T menor de 43.2 y porcentaje de lluvia invernal del 5% al 10.2% del total anual. Marismas Nacionales se encuentra en las cuencas del Río Acaponeta, Río San Pedro y Río Santiago–Aguamilpa. Los principales cuerpos de agua suman una superficie aproximada de 280 km<sup>2</sup>, y los más conocidos son la Laguna de Agua Brava, Estero Teacapán, Laguna Los Bueyes, Humedales de Agua Grande, Laguna El Valle, Estero Cuautla y Laguna Grande de Mexcaltitán (Blanco y Correa et al. 2011). Los principales ríos que desembocan en el sitio son de norte a sur, el Acaponeta, Bejuco, San Pedro y Santiago. Los usos de suelo y vegetación asociados a estos cuerpos de agua son principalmente manglar, agricultura y otros tipos de vegetación halófila hidrófila.

Las costas son acumulativas, con llanuras de inundación, manglares y cordones litorales de playas antiguas. Como proceso oceanográfico relevante se presenta la surgencia de Cabo Corrientes que se extiende a lo largo de las costas de Jalisco y Nayarit.

Las costas de Nayarit proporcionan la mayor producción de especies de importancia pesquera y acuícola, junto con el resto de los estados del Noroeste, lo que ha provocado que el sitio esté sometido a fuertes presiones de uso acuícola al paso de los años (Rubio-Cisneros et al. 2017).



**Figura 1.** Localización del área de estudio Marismas Nacionales en Sinaloa y Nayarit.

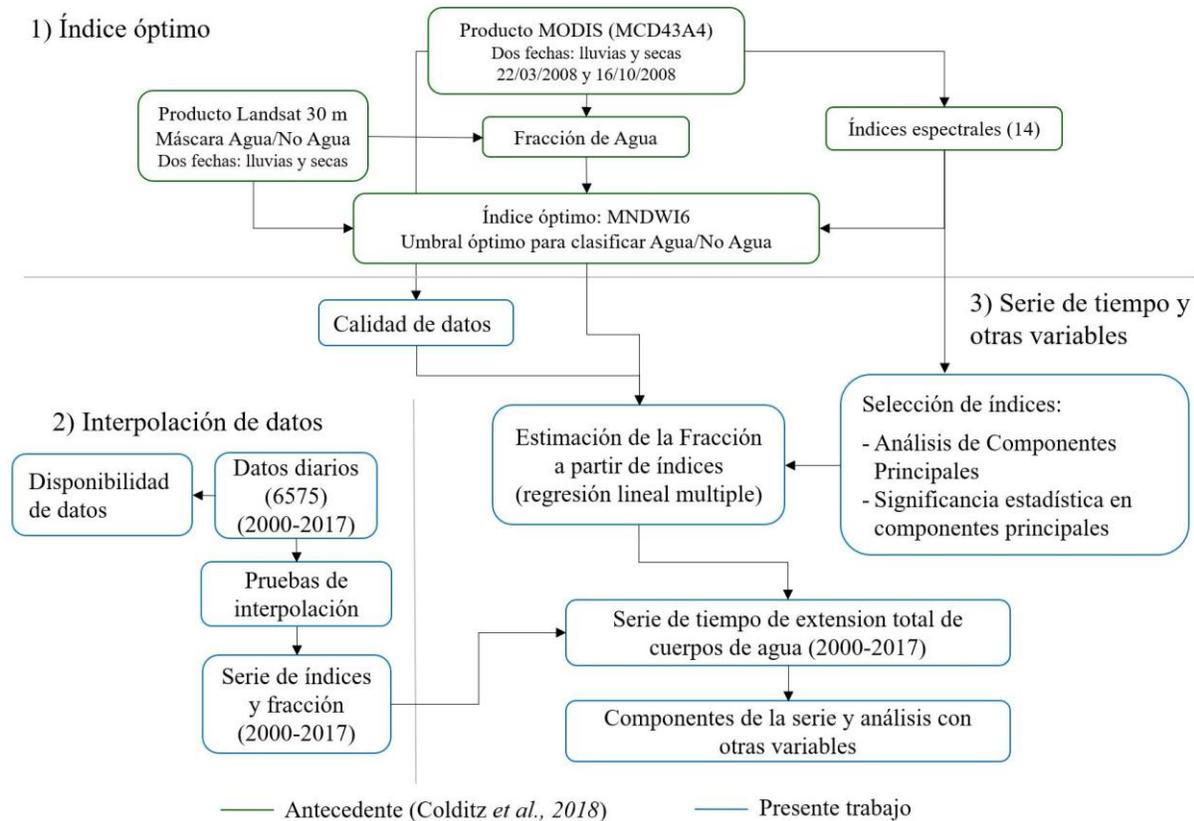
## 7. MATERIALES Y MÉTODOS

Colditz et al. (2018), identificaron de entre 14 índices espectrales, al MNDWI (Modified Normalized Difference Water Index) de Xu (2006), calculado con las bandas 4 y 6 de MODIS, como el más adecuado para mapear la superficie de agua en dos sitios en México: Marismas Nacionales en Nayarit y Laguna Madre – Río Grande en Tamaulipas.

El método empleado en ese estudio se basa en el modelo del Óptimo de Pareto (Boschetti 2004), el cual se ha usado en sensores remotos para evaluar la exactitud de las clasificaciones dicotómicas, en donde los objetivos a cumplir son obtener los valores máximos de exactitud del usuario y de exactitud del productor (mínimos errores de omisión y de comisión), a partir de datos de referencia de alta resolución, en este caso, datos del sensor Landsat. El método permite evaluar los errores de omisión y comisión de diferentes clasificaciones, de manera que se puede seleccionar un índice y un valor de éste con el menor error de omisión y comisión posibles.

A partir de esta información, se buscó un método de regresión lineal múltiple que identificara si, además del índice seleccionado por Colditz, et al. (2018), hay otros que contribuyan y mejoren la estimación de fracciones de cuerpos de agua por píxel en los datos utilizados.

Mediante la CONABIO se tuvo acceso a la información generada en el trabajo antes mencionado, la cual ha sido parte de los insumos para el desarrollo del presente proyecto. La Figura 2 muestra el diagrama de flujo empleado en esta tesis, considerando dicha información.



**Figura 2.** Diagrama de flujo.

## Datos satelitales usados

El producto utilizado es el MCD43A4, del sensor MODIS, que contiene los valores de reflectancias espectrales ajustadas al nadir a partir del modelo de distribución de reflectividad bidireccional o BRDF (Bidirectional Reflectance Distribution Function), cuya aplicación permite remover los efectos del ángulo de visión del sensor. Este modelo define el comportamiento de la dispersión de la luz en una superficie como función de los ángulos de visión en una longitud de onda particular. Se utilizan los datos Terra y Aqua de 16 días (Schaff *et al.* 2002).

El producto MCD43A4 contiene información de la calidad para cada una de las bandas espectrales que contiene, sin embargo, se trata de valores simplificados ( $0 = \text{procesado con buena calidad}$ ,  $1 = \text{procesado con otra calidad}$  y  $255 = \text{dato faltante}$ ).

Para conocer mejor la información de la calidad de los datos usados en las dos fechas de referencia (estiaje y lluvias del año 2008), se consultó el producto MCD43A2. el cual proporciona información más detallada sobre los datos procesados *con otra calidad*, como se verá más adelante.

Las principales características de ambos productos se muestran en la **¡Error! No se encuentra el origen de la referencia.** La descarga de los datos, así como la consulta de características a detalle se realizó en la página del Land Processes Distributed Active Archive Center (LP DAAC)<sup>1</sup>, que está en colaboración con el Servicio Geológico de los Estados Unidos (USGS) y NASA.

**Tabla 1.** Productos MODIS utilizados.

<b>Grupo</b>	<b>Producto</b>	<b>Descripción general</b>	<b>Resolución temporal</b>	<b>Resolución espacial</b>
MCD43 (Terra + Aqua)	MCD43A2	Calidad de los productos de Albedo y Reflectancias ajustadas	Diario (modelado de 16 días)	500 m
	MCD43A4	Reflectancias espectrales ajustadas al Nadir		

## Calidad de datos de referencia

Los datos de referencia usados en este estudio, considerados como mapas *ground-truth*, fueron los proporcionados por Colditz et al., (2018), que consisten en dos mapas binarios (Agua y No agua) del año 2008 (temporada de estiaje y temporada de lluvias), una resolución espacial de 500 m/píxel, con valores de fracción de agua por píxel y generados a partir de imágenes Landsat de 30 metros de resolución espacial.

Un píxel de una imagen Landsat representa el 0.36% de un píxel MODIS, pues el primero tiene una superficie de 0.09 ha y el segundo 25 ha. Por lo anterior, es posible obtener valores de referencia, en términos de fracción de agua ocupada por el dato de mayor resolución espacial o

<sup>1</sup> <https://lpdaac.usgs.gov/products/mcd43a3v006/>

en valores discretos (0 = No agua, 1 = Agua). Esto último a partir de definir un umbral de fracción ya sea de manera arbitraria o mediante un análisis como el de costo/beneficio propuesto por Colditz et al., (2018). Para el caso de este proyecto, se estimaron fracciones de pixel para mantener la información de mayor resolución.

Debido a que estos datos de referencia serán los que determinarán la selección de un modelo para estimar la fracción de agua, resultó relevante revisar su calidad. Las fechas de referencia usadas son: 16 de octubre de 2008 para la temporada húmeda (corresponde al día del año número 290) y 22 de marzo de 2008 (corresponde al día del año número 082).

Como se mencionó anteriormente, el producto MCD43A2 contiene información más detallada sobre la calidad del producto MCD43A4. Para cuantificar esta calidad, se considera el número de observaciones disponibles, la distancia temporal a la fecha de interés (corresponde al día 9 de los 16 considerados en el modelo). Esta información permite una de cuatro categorías de calidad, que identifican la magnitud de la inversión del modelo para cada píxel en cada una de las bandas espectrales. Las categorías se muestran en la Tabla 2.

**Tabla 2.** Categorías de calidad por pixel (producto MCD43A2).

Valor del pixel	Descripción
0	Mejor calidad (Best). Inversión completa del modelo
1	Buena Calidad (Good). Inversión completa del modelo, pero hay presencia de bruma o hay un ángulo de observación grande
2	No se logró la inversión completa del modelo. Número de observaciones mayores a 7 (de 16)
3	No se logró la inversión completa del modelo. Número de observaciones mayores a 2 pero menores a 7 (de 16)

Nota: Los colores usados en esta tabla se mantendrán en el resto del documento y figuras para identificar mejor cada una de las calidades.

Para asegurarse que se usaron los pixeles de la mejor calidad posible, fue necesario recodificar la calidad para los datos de referencia. La calidad asignada correspondió a la peor calidad entre las bandas 4 y 6, que son las usadas para calcular el MNDWI. La Tabla 2Tabla 3 muestra cuál fue el nuevo valor de un pixel, dependiendo de los valores originales. Con esta nueva

recodificación a partir de dos bandas, se generó una nueva capa de información que contiene un valor de calidad para cada pixel dentro del área de estudio.

**Tabla 3.** Categorías de calidad asignadas por pixel en los datos de referencia. Se muestran en color los posibles valores de calidad.

Categoría		Valor de calidad en B6				
		0	1	2	3	255
Valor de calidad en B4	0	0	1	2	3	Fill value
	1	1	1	2	3	
	2	2	2	2	3	
	3	3	3	3	3	
	255	Fill value (No Data)				

A partir de esta información, se generaron gráficos de dispersión de los valores de cada índice estudiado respecto a la fracción observada, en las dos fechas de referencia y categorizados por su calidad.

## Integración de la serie de datos espectrales

El Tile utilizado fue el h08v06 del producto MCD43A4. Posterior a su descarga fueron reproyectados y recortados para el área de estudio. En el acervo de la CONABIO se contaba con la serie diaria del periodo 2000 – 2016, la cual fue completada hasta el año 2017, teniendo un total de 6,575 imágenes diarias.

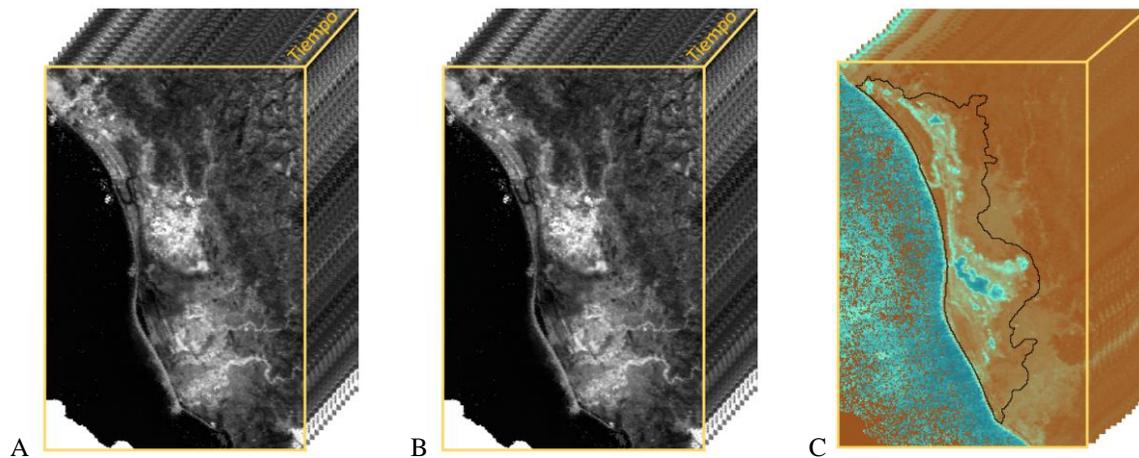
A partir de este acervo, se integraron los cubos de información para cada una de las siete bandas espectrales del producto utilizado (Tabla 4).

**Tabla 4.** Bandas espectrales de los datos MODIS.

Banda	Nombre	Rango espectral [nm]
B <sub>1</sub>	Rojo (R)	620 – 670
B <sub>2</sub>	Infrarrojo cercano (NIR)	841 – 876
B <sub>3</sub>	Azul (A)	459 – 479
B <sub>4</sub>	Verde (V)	545 – 565
B <sub>5</sub>	Infrarrojo de onda corta 1 (SWIR1)	1,230 – 1,250

B <sub>6</sub>	Infrarrojo de onda corta 2 (SWIR2)	1,628 – 1,652
B <sub>7</sub>	Infrarrojo de onda corta 3 (SWIR3)	2,105 – 2,155

Para ilustrar cada cubo de información, se observa en la Figura 3, los ejes X y Y, los cuales se refieren a la localización geográfica de los datos, mientras que el eje Z corresponde a la dimensión temporal en escala diaria, es decir, Z es igual a 6,575 días.



**Figura 3.** Representación de un cubo de información espectral para cada una de las bandas de interés (A y B), y el índice calculado a partir de ellas, en este caso, MNDWI donde los colores más azules corresponden a valores mayores y, por lo tanto, a píxeles con mayor contenido de agua (C).

### Disponibilidad de datos

Si bien es cierto que el producto MCD43A4 permite obtener mayor cantidad de datos válidos, es posible que haya falta de información en el cubo, debido a las condiciones de nubosidad en el sitio, lo cual es muy frecuente en zonas costeras, incrementándose en la temporada de lluvias.

Por lo anterior, se contabilizó en términos de porcentaje, el total de datos válidos a nivel de píxel y además el total para cada una de las fechas, sin importar su calidad, la cual está definida por el número de observaciones usadas para la inversión del modelo BRDF (Tabla 2). Los rangos

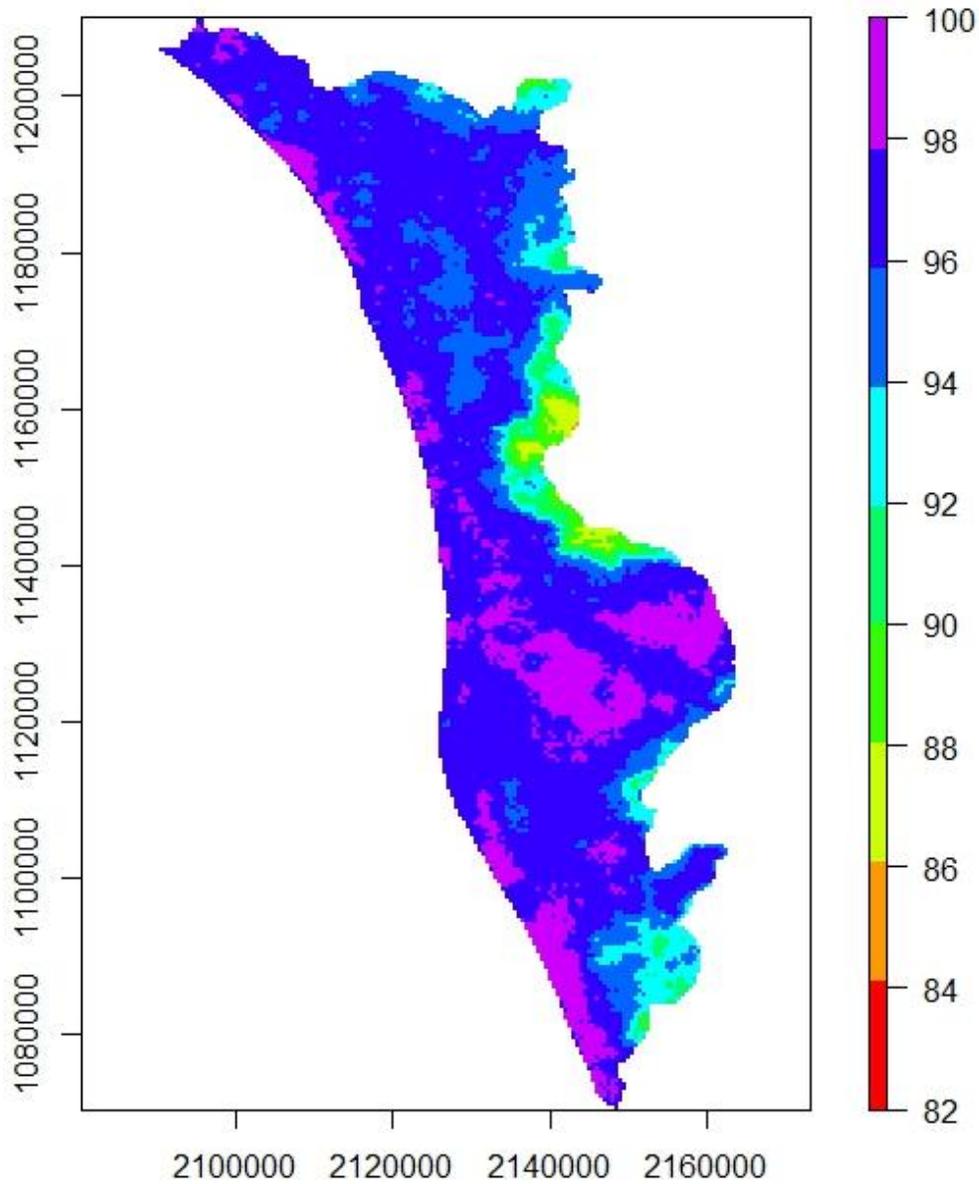
de valores para considerar un dato válido son definidos en los manuales de usuario para cada producto satelital<sup>2</sup>.

La

Figura 4 muestra la información a nivel de píxel, da una perspectiva espacial y se observa que la mayoría del sitio tiene entre el 94 y el 100% de los datos disponibles, en zonas que coinciden con la presencia de los principales complejos de humedales y cuerpos de agua.

---

<sup>2</sup> [https://www.umb.edu/spectralmass/terra\\_aqua\\_modis/v006/mcd34a4\\_nbar\\_product](https://www.umb.edu/spectralmass/terra_aqua_modis/v006/mcd34a4_nbar_product)

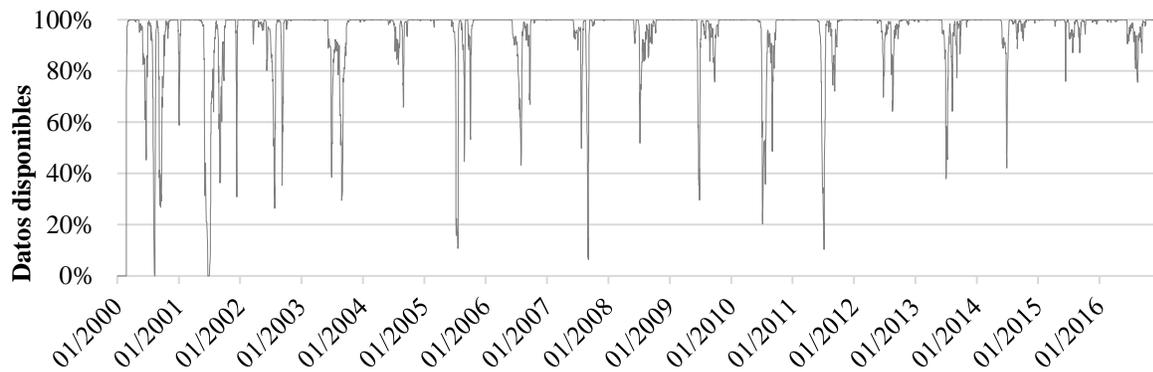


**Figura 4.** Porcentaje de datos válidos para cada píxel en toda la serie (2000 – 2017). Cada píxel representa el valor para todas las fechas (6,575 días).

La Figura 5 muestra el porcentaje de datos válidos para cada fecha, da una perspectiva temporal y se observa que en los dos primeros años (2000 y 2001), hay menor cantidad de información disponible, lo cual corresponde a los años de lanzamiento de los instrumentos. Mientras que de

manera intra-anual, la información disminuye notablemente después de la mitad del año, coincidiendo con mayor nubosidad en la temporada de lluvias.

Para llenar los datos faltantes a nivel de píxel, cada cubo fue interpolado con el método lineal por resultar con la menor desviación respecto a los datos reales, para cuantificarlo se utilizó el estimador del Error Cuadrático Medio (EMC).



**Figura 5.** Porcentaje de píxeles válidos para cada fecha, considerando el total de píxeles en la escena (13,741 píxeles).

## Selección de variables del modelo de regresión

Para seleccionar los índices que contribuyen mejor al modelo de regresión lineal múltiple, se usaron los datos de las dos mejores calidades, que son en las que se logró la inversión completa del modelo BRDF.

Las variables predictivas para considerar para su selección en el modelo fueron los 14 índices analizados por Colditz et al. (2018) (**Tabla 5**), y fueron usados los siguientes criterios:

1. Menor costo en función de errores de omisión y comisión, previamente identificado por Colditz et al. (2018), por lo que el MNDWI6 es el primer índice seleccionado, además en el mismo estudio resultó como el más estable ante las variaciones de los valores del índice.
2. Análisis de Componentes Principales (ACP) de 14 índices, para identificar cuántos componentes contienen la mayor cantidad de información y los índices que tienen mayor contribución a dichos componentes.
3. Prueba de significancia estadística de la contribución de cada variable predictora (índice) en el modelo de regresión, con un valor de  $\alpha < 0.05$ .

A partir de los tres criterios anteriores, se seleccionaron los índices más adecuados para ser probados en todos los modelos posibles para cada temporada. Dados los coeficientes de determinación ( $R^2$ ) entre los valores de fracción observados en los datos de referencia y los valores calculados, se seleccionó el mejor modelo para cada temporada y se aplicaron a la serie de datos, para obtener la serie completa de superficie de agua en el sitio de estudio.

**Tabla 5.** Índices espectrales utilizados (tomado de Colditz et al. (2018)).

Índice	Nombre en inglés	Ecuación usando bandas MODIS	Referencia
NDVI	Normalized Difference Vegetation Index	$\frac{B_2 - B_1}{B_2 + B_1}$	Tucker 1978
EVI	Enhanced Vegetation Index	$2.5 * \frac{B_2 - B_1}{B_2 + 6.0 * B_1 - 7.5 * B_3 + 1}$	Huete et al. (2002)
SAVI	Soil-Adjusted Vegetation Index	$1.5 * \frac{B_2 - B_1}{B_2 + B_1 + 0.5}$	Huete (1988)
MSAVI2	Modified SAVI 2	$\frac{2 * B_2 + 1 - \sqrt{(2 * B_2 + 1)^2 - 8 * (B_2 - B_1)}}{2}$	Qi et al. (1994)
NDWI	Normalized Difference Water Index	$\frac{B_4 - B_2}{B_4 + B_2}$	McFeeters (1996)
MNDWI5	Modified NDWI B <sub>5</sub>	$\frac{B_4 - B_5}{B_4 + B_5}$	Ji et al. (2009)
MNDWI6	Modified NDWI B <sub>6</sub>	$\frac{B_4 - B_6}{B_4 + B_6}$	Xu (2006)
MNDWI7	Modified NDWI B <sub>7</sub>	$\frac{B_4 - B_7}{B_4 + B_7}$	Ji et al. (2009)
NDMI5	Normalized Difference Moisture Index B <sub>5</sub>	$\frac{B_2 - B_5}{B_2 + B_5}$	Gao (1996)
NDMI6	Normalized Difference Moisture Index B <sub>6</sub>	$\frac{B_2 - B_6}{B_2 + B_6}$	Wilson and Sader (2002), Xiao et al. (2004)
NDMI7	Normalized Difference Moisture Index B <sub>7</sub>	$\frac{B_2 - B_7}{B_2 + B_7}$	Chandrasekar et al. (2010)
OWL	Open Water Likelihood	$\frac{1}{1 + e^f}$ $f = -3.4137 - B_6 * 0.9597 + B_7 * 4.1795 + NDVI * 14.1927 - NDMI6 * 0.4304 - MRVBF * 0.0961$	Guerschman et al. (2011), Chen et al. (2013)
TCW1	Tasseled Cap Wetness 1	$B_1 * 0.1147 + B_2 * 0.2489 + B_3 * 0.2408 + B_4 * 0.3132 - B_5 * 0.3122 - B_6 * 0.6416 - B_7 * 0.5087$	Lobser and Cohen (2007)
TCW2	Tasseled Cap Wetness 2	$B_1 * 0.1084 + B_2 * 0.0912 + B_3 * 0.5065 + B_4 * 0.4040 - B_5 * 0.2410 - B_6 * 0.4658 - B_7 * 0.5306$	Zhang et al. (2002)

B1=Rojo, B2=NIR, B3=Azul, B4=Verde, B5=SWIR1, B6=SWIR2, B7=SWIR3

## **Datos de precipitación y temperatura**

Mediante solicitud directa al Servicio Meteorológico Nacional (SMN), se obtuvieron los registros diarios de precipitación y temperatura de dos Estaciones Meteorológicas Automáticas (EMA: Acaponeta y Marismas Nacionales), y cuatro Estaciones Climatológicas (25049, 18036, 18072 y 18022) (Figura 6). De la misma fuente, y por consulta en línea, se obtuvieron los registros de precipitación acumulada mensual para todo el estado<sup>3</sup>.

## **Datos de ciclones tropicales**

Mediante el portal del SMN, se consultó la información sobre lluvias asociadas a ciclones tropicales<sup>4</sup>, así como información histórica de los mismos<sup>5</sup>. También se consultaron los registros para el Pacífico Oriental del Centro Nacional de Huracanes de Estados Unidos (NHC las siglas de National Hurricane Center), de la NOAA (National Oceanic and Atmospheric Administration)<sup>6</sup>. Se generó un registro de todos los eventos que fueron identificados con “afectación directa” o “afectación indirecta” en el estado de Nayarit.

Debido a que la afectación en el sitio de interés no necesariamente se dio cuando el evento estuvo en su máxima categoría, se consideró también la categoría de contacto a tierra o la más cercana a la costa para los casos en los que no hubo contacto a tierra.

## **Datos de episodios El Niño – La Niña**

En el portal web del Centro de Predicción Climática de la NOAA, se obtuvieron los registros del Índice Oceánico de El Niño (ONI, por las siglas de Oceanic Niño Index), que se calcula como la media móvil de tres meses de anomalías de la temperatura superficial del mar para la región 3.4 (franja comprendida entre los 5 °N – 5 °S y 120 – 170 °W).

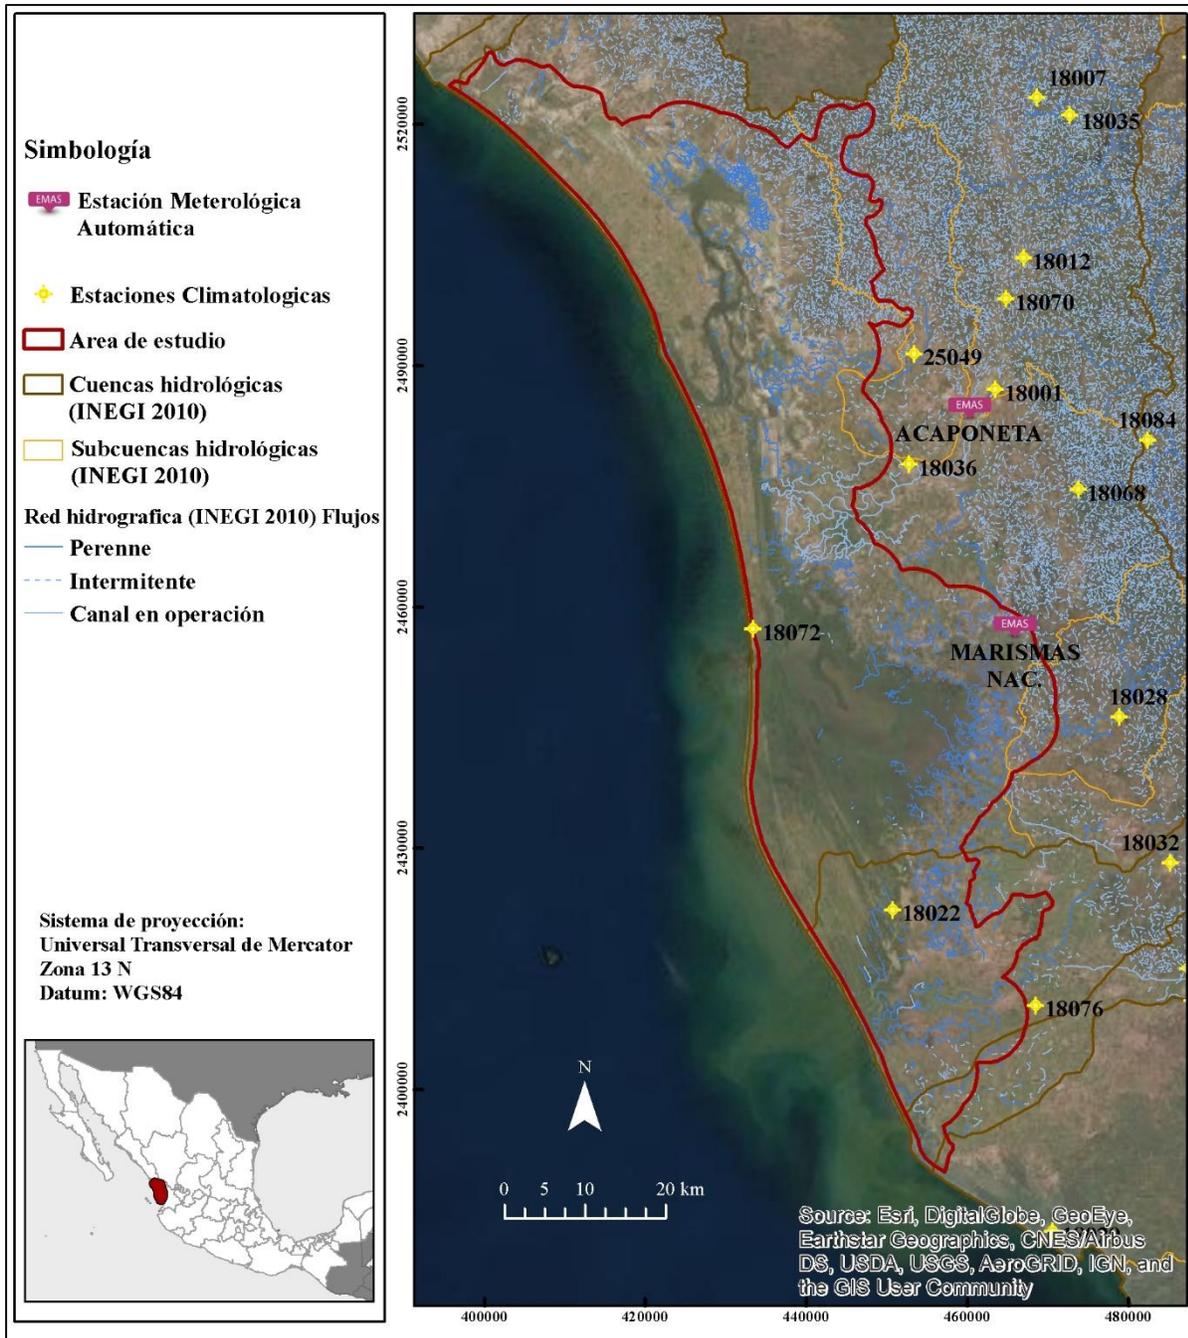
---

<sup>3</sup> <https://smn.conagua.gob.mx/es/climatologia/temperaturas-y-lluvias/resumenes-mensuales-de-temperaturas-y-lluvias>

<sup>4</sup> <https://smn.conagua.gob.mx/es/ciclones-tropicales/lluvias-asociadas-a-ciclones-tropicales>

<sup>5</sup> <https://smn.conagua.gob.mx/es/ciclones-tropicales/informacion-historica>

<sup>6</sup> <https://www.nhc.noaa.gov/>



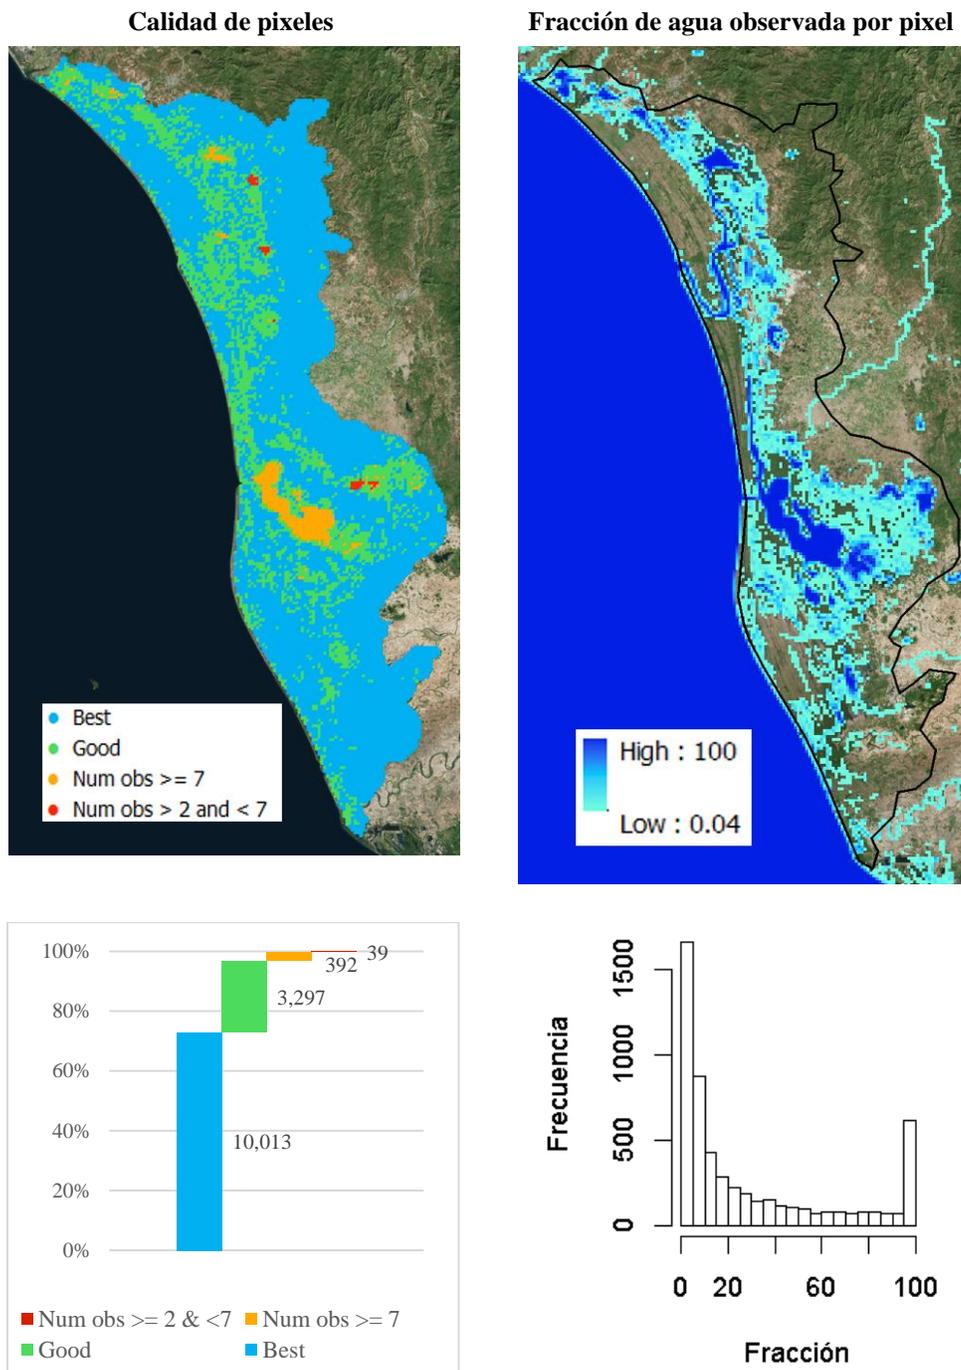
**Figura 6.** Localización de estaciones del Servicio Meteorológico Nacional consultadas.

## **8. RESULTADOS**

### **Calidad de datos de referencia**

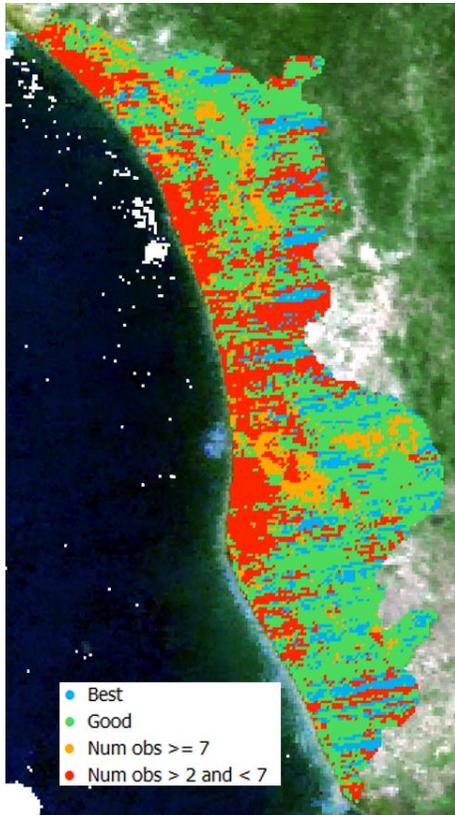
Después de revisar la calidad de las imágenes que fueron usadas como referencia, así como la fracción de agua por píxel correspondiente, se observó una mejor calidad de datos en la temporada de estiaje, debido a la menor presencia de nubes en esta temporada. Esto proporcionó en total 13,310 observaciones disponibles para generar la matriz de análisis para los componentes principales y la prueba de significancia, y un total de 8,236 observaciones para la temporada lluviosa, ya que se usaron los datos de las dos mejores calidades (Figura 7 y Figura 8).

Como es de esperarse, hay menor cantidad de píxeles con presencia de agua (40%) en estiaje que en lluvias (65%). Respecto a cuáles fueron las fracciones de agua observadas en cada temporada, excluyendo las fracciones iguales a 0 (píxeles sin presencia de agua), el 50% de los datos se encuentra en la fracción 12.24 para la temporada de estiaje y en 30.80 para la temporada lluviosa. Esto es porque la planicie de inundación del sitio permite la expresión de muchos cuerpos de agua de menor tamaño en esta última temporada.

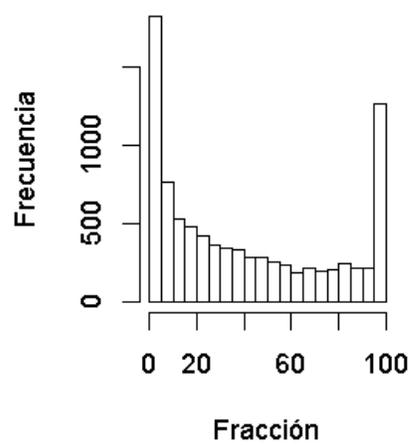
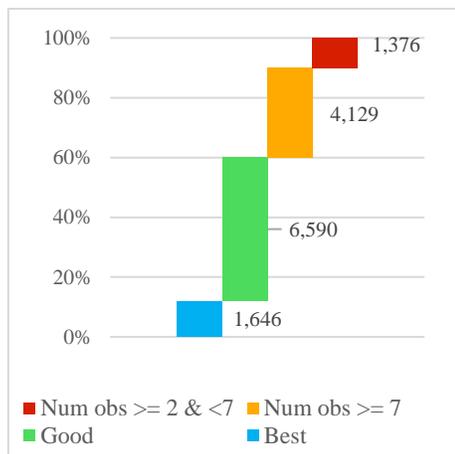
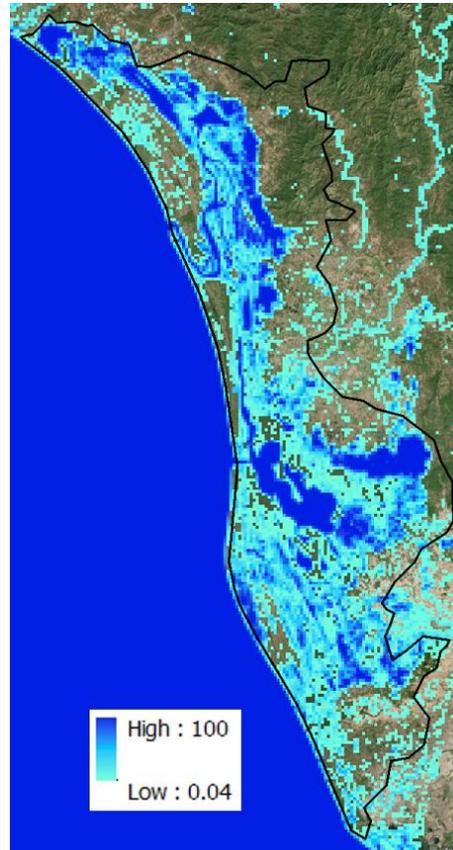


**Figura 7.** Distribución espacial de las calidades y los valores de fracciones de agua por pixel para la temporada de estiaje (22/03/2008).

Calidad de pixeles



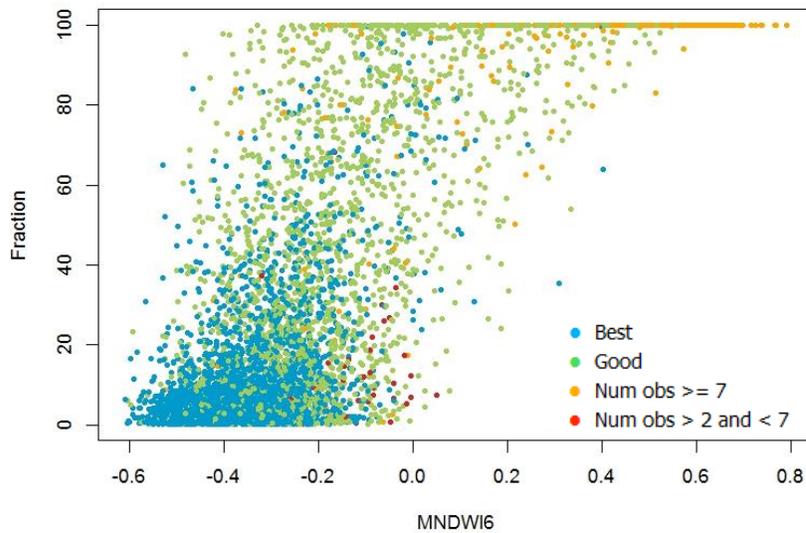
Fracción de agua observada por píxel



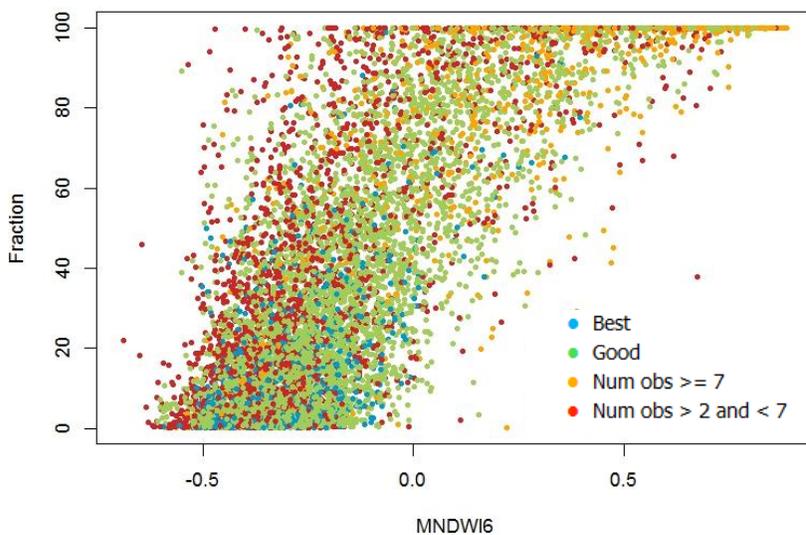
**Figura 8.** Distribución espacial de las calidades y los valores de fracciones de agua por píxel para la temporada de lluvias (16/10/2008).

Los gráficos de la

Figura 9 muestran que, al incrementar la fracción de agua por píxel, la dispersión se incrementa sobre todo en las peores calidades.



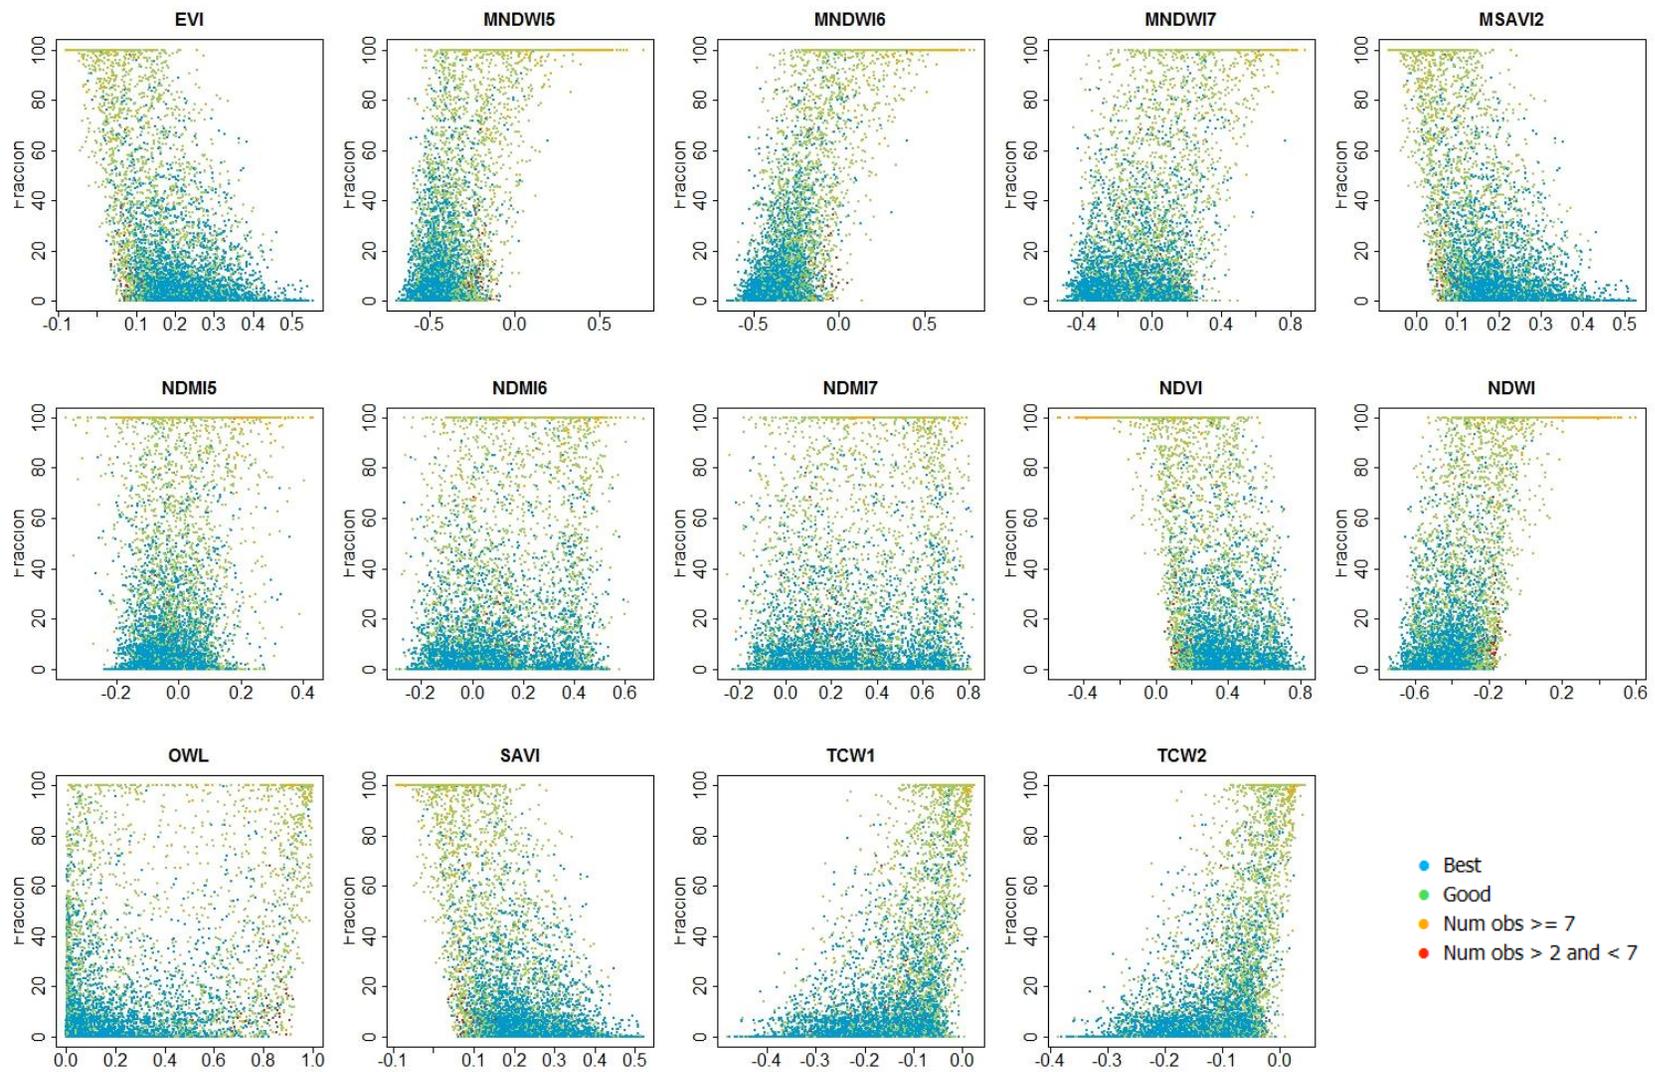
A



B

**Figura 9.** Gráfico de dispersión de las fracciones respecto al índice seleccionado por Colditz et al. (2018), para cada calidad de datos, A) para la temporada de estiaje (22/03/2008) y B) para la temporada de lluvias (16/10/2008).

En la Figura 10, se observa lo anterior en los otros índices, y como debe esperarse, se distingue una relación inversa de las fracciones entre los índices que describen cuerpos de agua (MNDWI, NDWI, TCW), *versus* los que describen la vegetación (EVI, MSAVI, SAVI, NDVI). Las dispersiones se hacen aún mayores en algunos de ellos, sobre todo en los NDMI, y el OWL.



**Figura 10.** Comparación de la dispersión de los valores de fracción en diferentes índices espectrales, estratificando calidades, temporada de estiaje (22/03/2008).

## **Selección de variables del modelo de regresión**

Las Figuras Figura 11 y Figura 12 muestran las matrices de correlación entre todas las variables, y se observa que la mayor correlación de la fracción de agua por pixel es con el MNDWI6, tanto para la temporada de estiaje (0.73) como para la de lluvias (0.84).

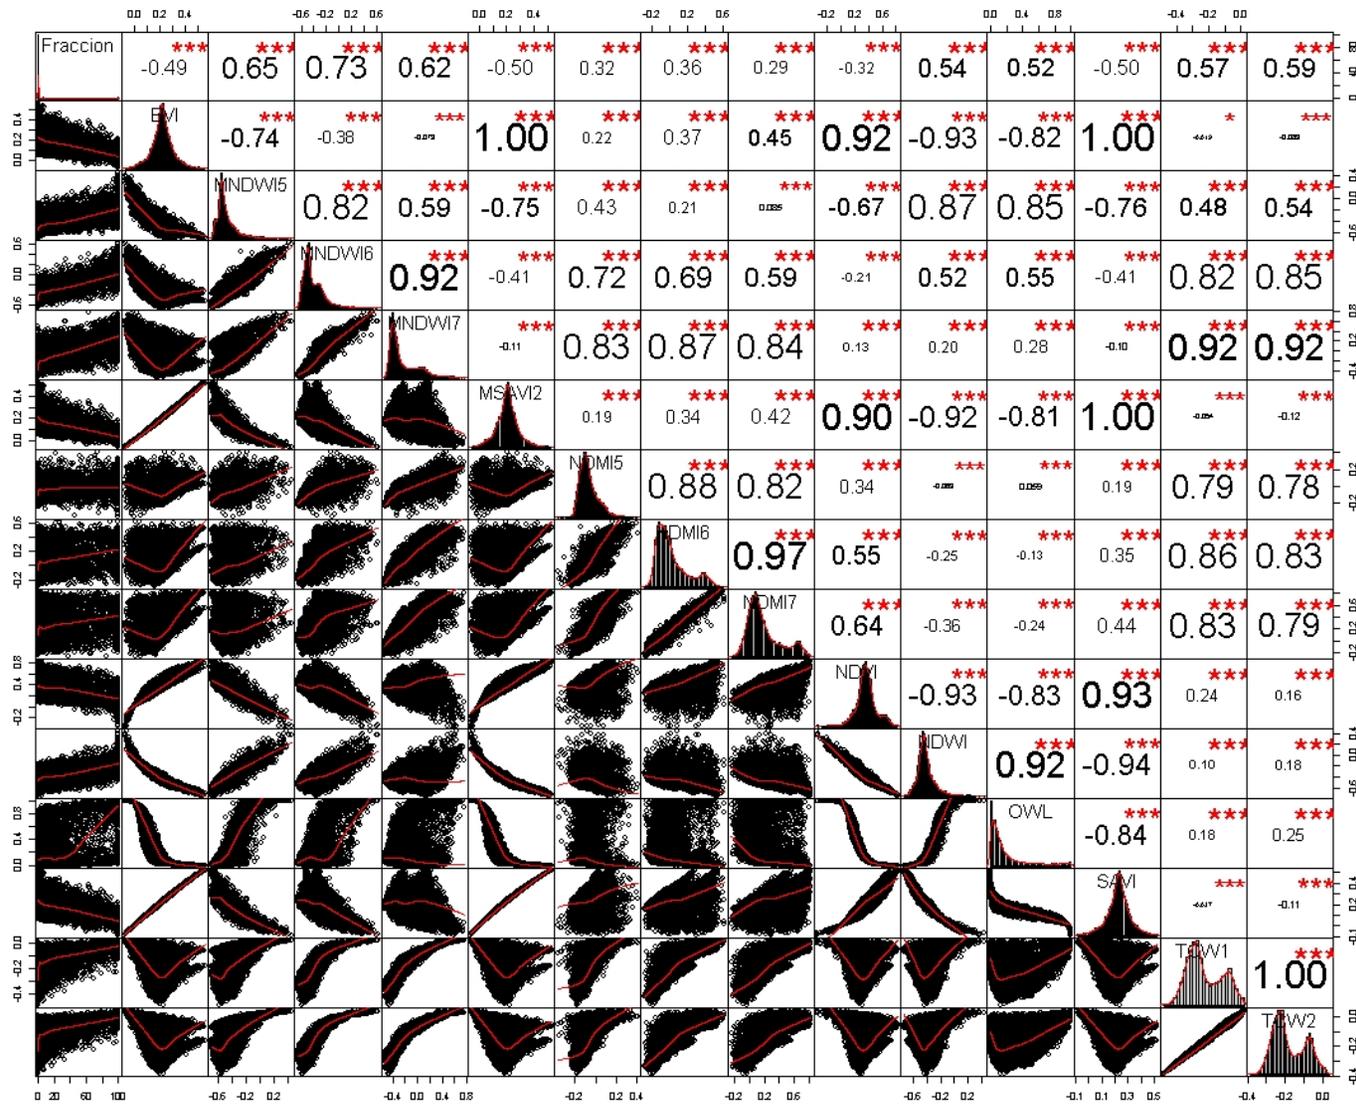


Figura 11. Correlación entre 14 índices espectrales usados para el mapeo de cuerpos de agua. Fecha de estiaje (22/03/2008).

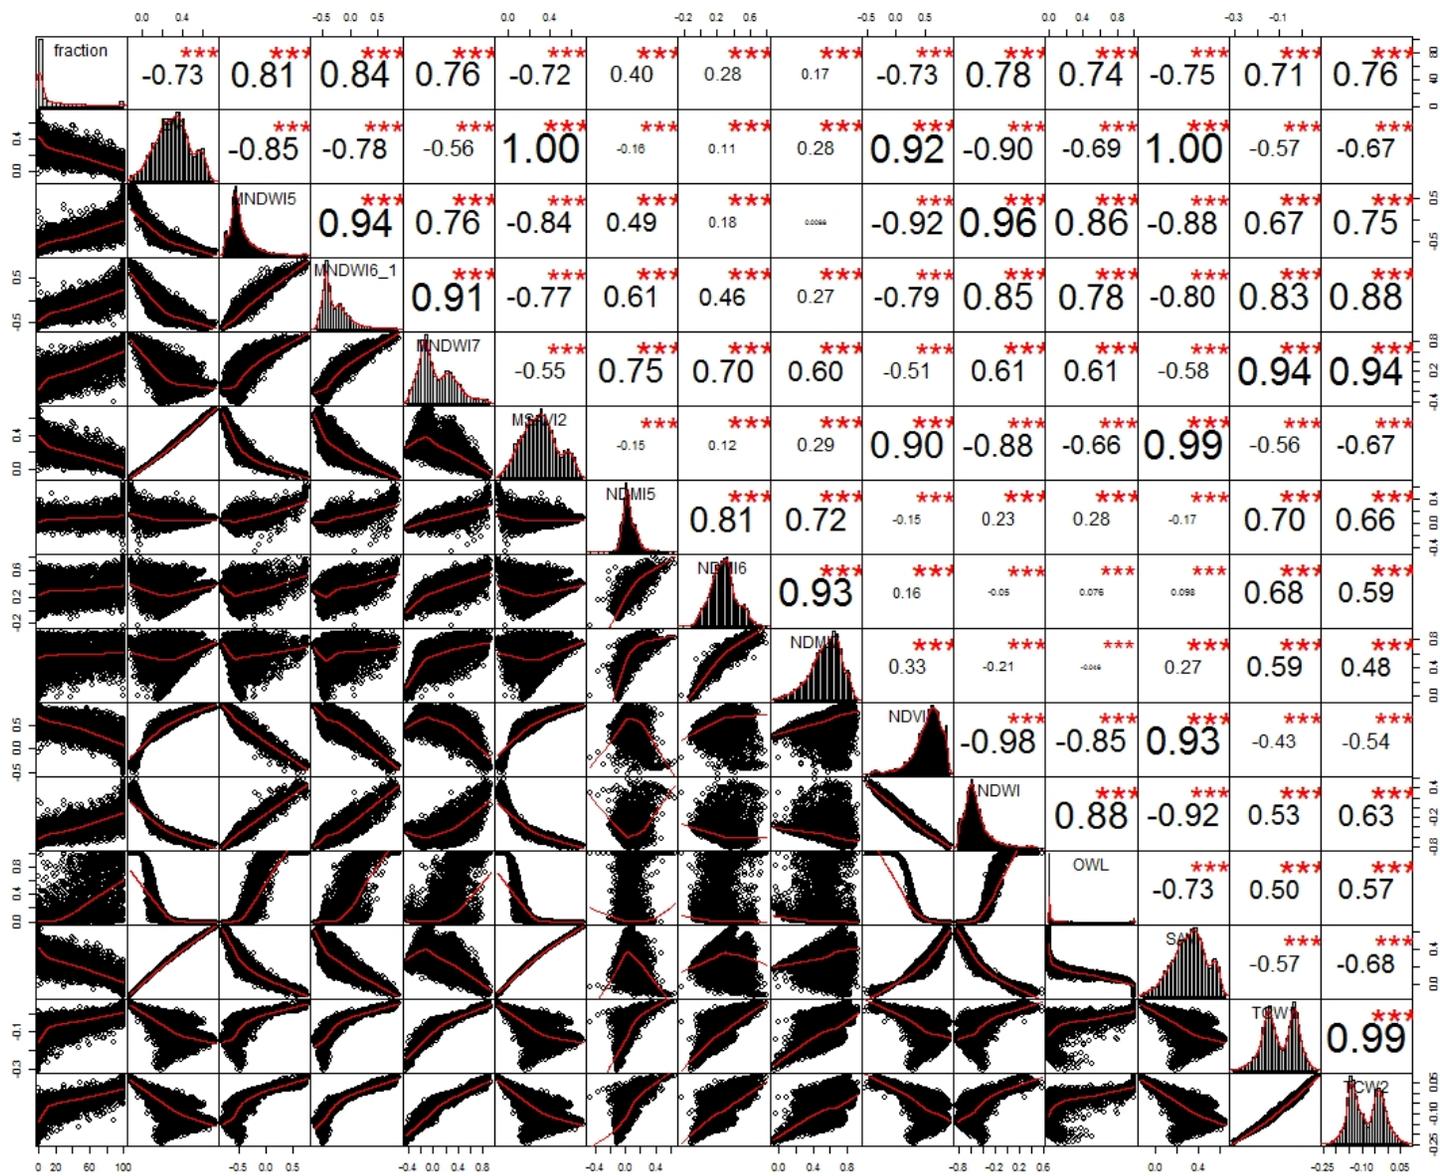


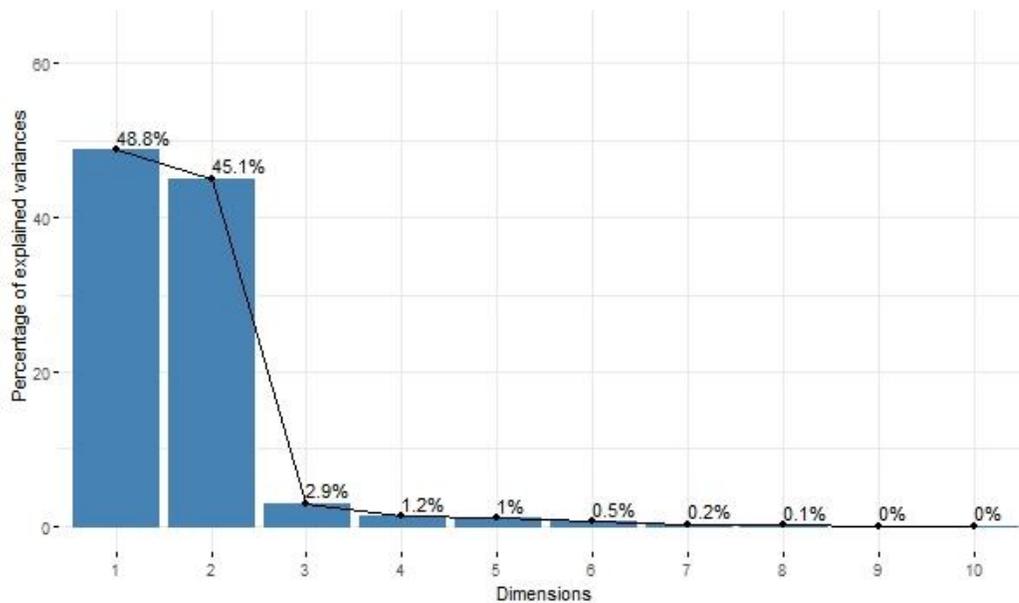
Figura 12. Correlación entre 14 índices espectrales usados para el mapeo de cuerpos de agua. Fecha de lluvias (16/10/2008).

## Análisis de Componentes Principales

En ambas temporadas son los dos primeros componentes o dimensiones los que contienen la mayor varianza explicada. Sin embargo, la proporción es mayor para el primer componente en la temporada lluviosa (64.4%) (Figuras

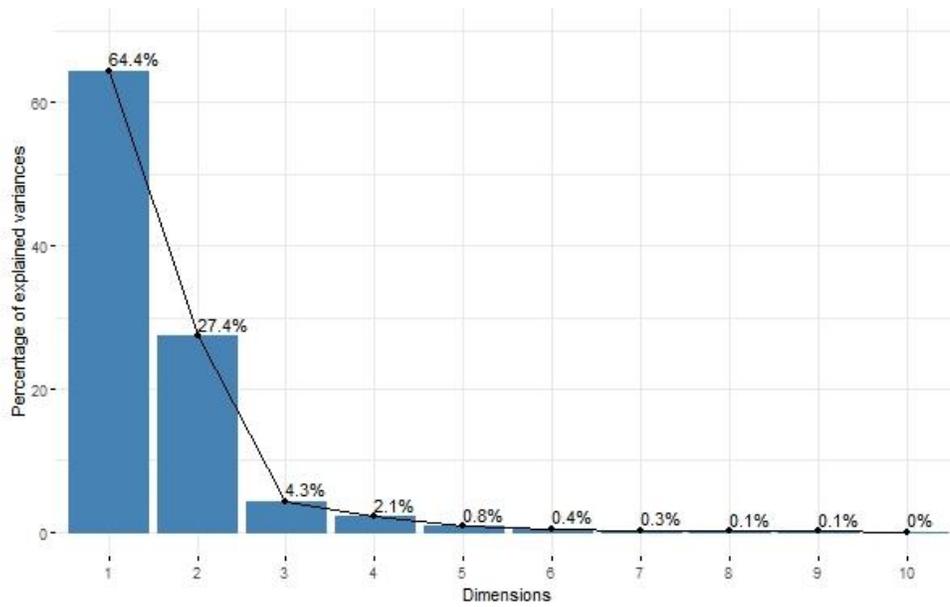
	PC1	PC2	PC3
SD	2.61366	2.51295	0.64049
Proporción de la varianza	0.48794	0.45107	0.02930
Proporción acumulada	0.48794	0.93901	0.96831

Figura 13 y Figura 14).



	PC1	PC2	PC3
SD	2.61366	2.51295	0.64049
Proporción de la varianza	0.48794	0.45107	0.02930
Proporción acumulada	0.48794	0.93901	0.96831

**Figura 13.** Porcentaje explicado de la varianza por cada componente y tabla de eigenvalores en la fecha de estiaje (22/03/2008).



	PC1	PC2	PC3
SD	3.003150	1.958149	0.775473
Proporción de la varianza	0.644210	0.273880	0.042950
Proporción acumulada	0.644210	0.918090	0.961040

**Figura 14.** Porcentaje explicado de la varianza por cada componente y tabla de eigenvalores en la fecha de lluvias (16/10/2008).

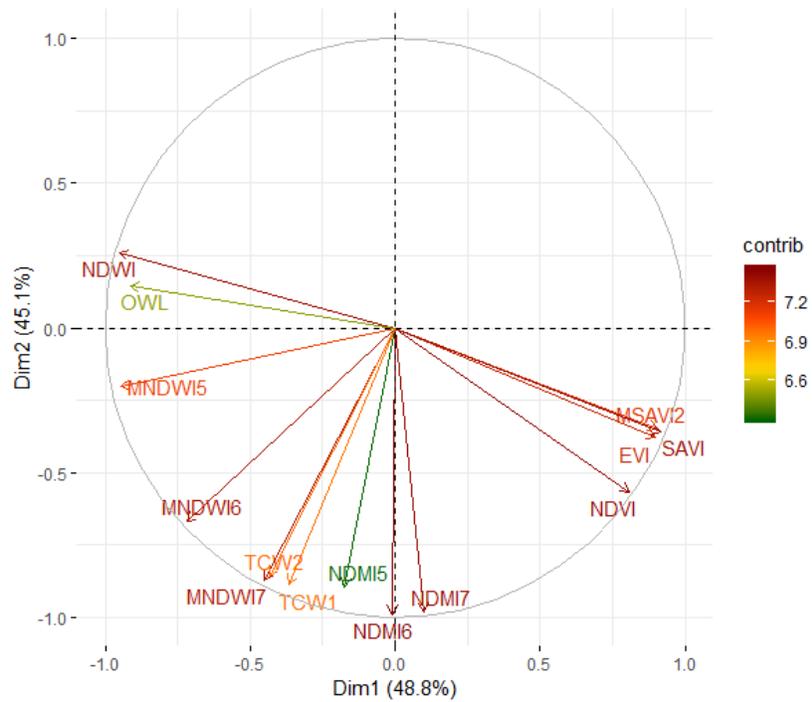
En lo que respecta a la contribución de las variables en cada uno de los dos primeros componentes, se muestra la Tabla 7 con esta información.

**Tabla 6.** Contribución de las variables en los Componentes 1 y 2, para ambas temporadas.

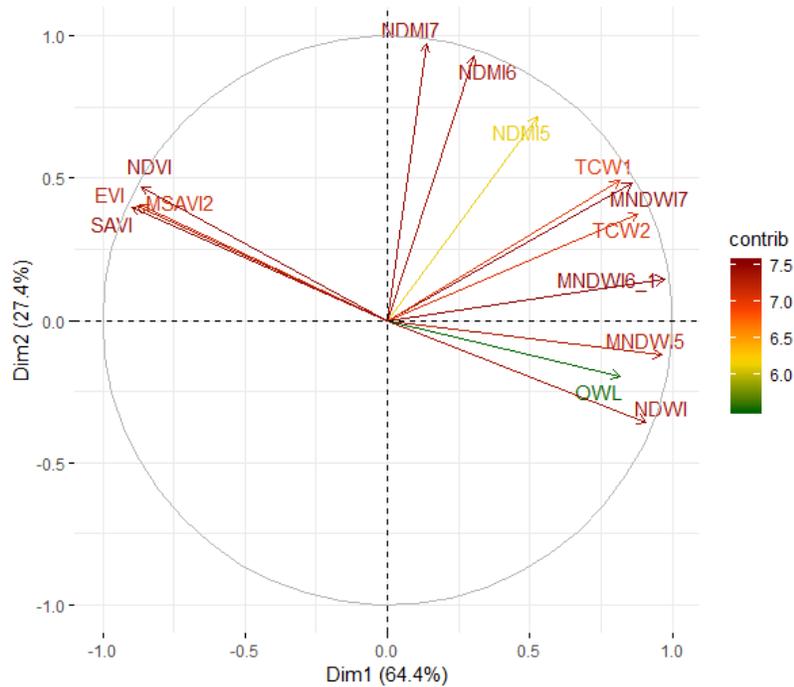
Variable	Estiaje (22/03/2008)		Lluvias (16/10/2008)	
	PC1	PC2	PC1	PC2
EVI	0.344099	-0.151139	-0.293451	0.206140
MNDWI5	<b>-0.361878</b>	-0.080710	<b>0.320616</b>	<b>-0.061962</b>
MNDWI6	-0.275269	-0.266404	<b>0.324253</b>	0.073961
MNDWI7	-0.171900	-0.347116	<b>0.285787</b>	<b>0.246121</b>
MSAVI2	<b>0.346490</b>	<b>-0.138899</b>	<b>-0.289299</b>	0.207017
NDMI5	<b>-0.066884</b>	<b>-0.355694</b>	0.175288	<b>0.364735</b>
NDMI6	-0.004014	<b>-0.393654</b>	<b>0.101487</b>	<b>0.474125</b>
NDMI7	<b>0.038328</b>	<b>-0.390227</b>	<b>0.045081</b>	<b>0.496092</b>
NDVI	0.308969	-0.225881	-0.287405	0.239255
NDWI	<b>-0.363406</b>	<b>0.103876</b>	0.302830	-0.182744
OWL	-0.349211	0.057567	<b>0.272462</b>	<b>-0.100881</b>
SAVI	0.350779	-0.143550	-0.298536	0.203171
TCW1	<b>-0.139486</b>	<b>-0.352411</b>	0.271651	0.250030
TCW2	-0.165307	-0.340887	<b>0.293368</b>	<b>0.190323</b>

En rojo se señalan los valores de los índices con significancia estadística. En negritas, los valores mayores de contribución.

En las Figuras Figura 15 y Figura 16 se observan los círculos de correlaciones para cada temporada. En ambas temporadas, los índices que tienen una contribución importante en son: NDVI, SAVI, NDWI, NDMI6, NDMI7, MNDWI6 y MNDWI7.



**Figura 15.** Circulo de correlaciones con la contribución de cada variable en la fecha de estiaje (22/03/2008).



**Figura 16.** Circulo de correlaciones con la contribución de cada variable en la fecha de lluvias (16/10/2008).

## **Significancia Estadística**

Para la temporada de estiaje los índices que resultaron significativos fueron: MSAVI2, NDMI5, NDWI, TCW1 y NDMI7, de los cuáles el NDWI y el NDMI7 tuvieron las mayores contribuciones en los componentes 1 y 2.

Mientras que para la temporada lluviosa fueron: MNDWI5, MNDWI7, NDMI6, NDMI7, OWL y TCW2, de los cuáles los cuatro primeros resultaron también con las mayores contribuciones en los dos primeros componentes.

## **Aplicación del modelo de regresión**

### **Modelos probados**

Considerando los análisis anteriores, se seleccionaron las variables a considerar en los modelos de cada temporada. Seleccionando aquellas variables que resultaron con significancia estadística pero además, tuvieron las mayores contribuciones en los dos primeros componentes principales. La Tabla 7 y la Tabla 8 muestran los resultados del ajuste ( $R^2$ ), para 8 modelos de regresión lineal en la temporada de estiaje y 17 modelos en la temporada lluviosa. Los mejores resultados se obtienen con el modelo que incluye los índices MNDWI6, NDMI6 y NDMI7 en la temporada de estiaje, mientras que, en la temporada lluviosa, a estos índices se adiciona el MNDWI5 para obtener el mejor modelo. Por lo que los modelos seleccionados para ser aplicados son los que se identifican en las tablas como D4 para los datos de la temporada de estiaje y W11 para los de la temporada lluviosa.

**Tabla 7.** Variables consideradas en los modelos, temporada de estiaje (22/03/2008).

ID modelo	Variable 1	Variable 2	Variable 3	R <sup>2</sup>	R <sup>2</sup> Ref
DS*	MNDWI6			0.5881	0.6605
D0	MNDWI6			0.5376	0.6605
D1	MNDWI6	NDMI6		0.5803	0.6605
D2	MNDWI6	NDMI7		0.5670	0.6789
D3	MNDWI6	MNDWI7		0.5567	0.6709
<b>D4</b>	<b>MNDWI6</b>	<b>NDMI6</b>	<b>NDMI7</b>	<b>0.5907</b>	<b>0.6936</b>
D5	MNDWI6	NDMI6	MNDWI7	0.5844	0.6914
D6	MNDWI6	NDMI7	MNDWI7	0.5710	0.6833

D = Dry

Se identifica con color rojo el modelo con mejor ajuste para la temporada

R<sup>2</sup> Ref = Coeficiente de determinación en entre el valor observado y el valor estimado

\* Sin usar filtro de calidad en los datos para estimar los coeficientes

**Tabla 8.** Variables consideradas en los modelos, temporada de lluvias (16/10/2008).

ID modelo	Variable 1	Variable 2	Variable 3	Variable 4	Variable 5	R <sup>2</sup>	R <sup>2</sup> Ref
WS*	MNDWI6					0.7435	0.7435
W0	MNDWI6					0.7057	0.7435
W1	MNDWI6	NDMI6				0.7193	0.7435
W2	MNDWI6	NDMI7				0.7095	0.7448
W3	MNDWI6	MNDWI7				0.7058	0.7426
W15	MNDWI6	MNDWI5				0.7105	0.7419
W4	MNDWI6	NDMI6	NDMI7			0.7412	0.7717
W5**	MNDWI6	NDMI6	MNDWI7			0.7359	0.7768
W6	MNDWI6	NDMI7	MNDWI7			0.7198	0.7648
W8	MNDWI6	MNDWI7	MNDWI5			0.7126	0.7442
W9	MNDWI6	MNDWI5	NDMI6			0.7208	0.7583
W10	MNDWI6	MNDWI5	NDMI7			0.7107	0.7431
W7	MNDWI6	NDMI6	NDMI7	MNDWI7		0.7416	0.7743
<b>W11**</b>	<b>MNDWI6</b>	<b>NDMI6</b>	<b>NDMI7</b>	<b>MNDWI5</b>		<b>0.7458</b>	<b>0.7824</b>
W12**	MNDWI6	MNDWI5	MNDWI7	NDMI6		0.7365	0.7799
W13	MNDWI6	MNDWI5	MNDWI7	NDMI7		0.7216	0.7625
W14	MNDWI6	MNDWI7	MNDWI5	NDMI6	NDMI7	0.7458	0.7819

W = Wet

En rojo el modelo con mejor ajuste para la temporada

R<sup>2</sup> Ref = Coeficiente de determinación en entre el valor observado y el valor estimado

\* Sin usar filtro de calidad en los datos para estimar los coeficientes

\*\* La aplicación del modelo en la serie de datos resulta con *ruido* en la temporada lluviosa del año 2000.

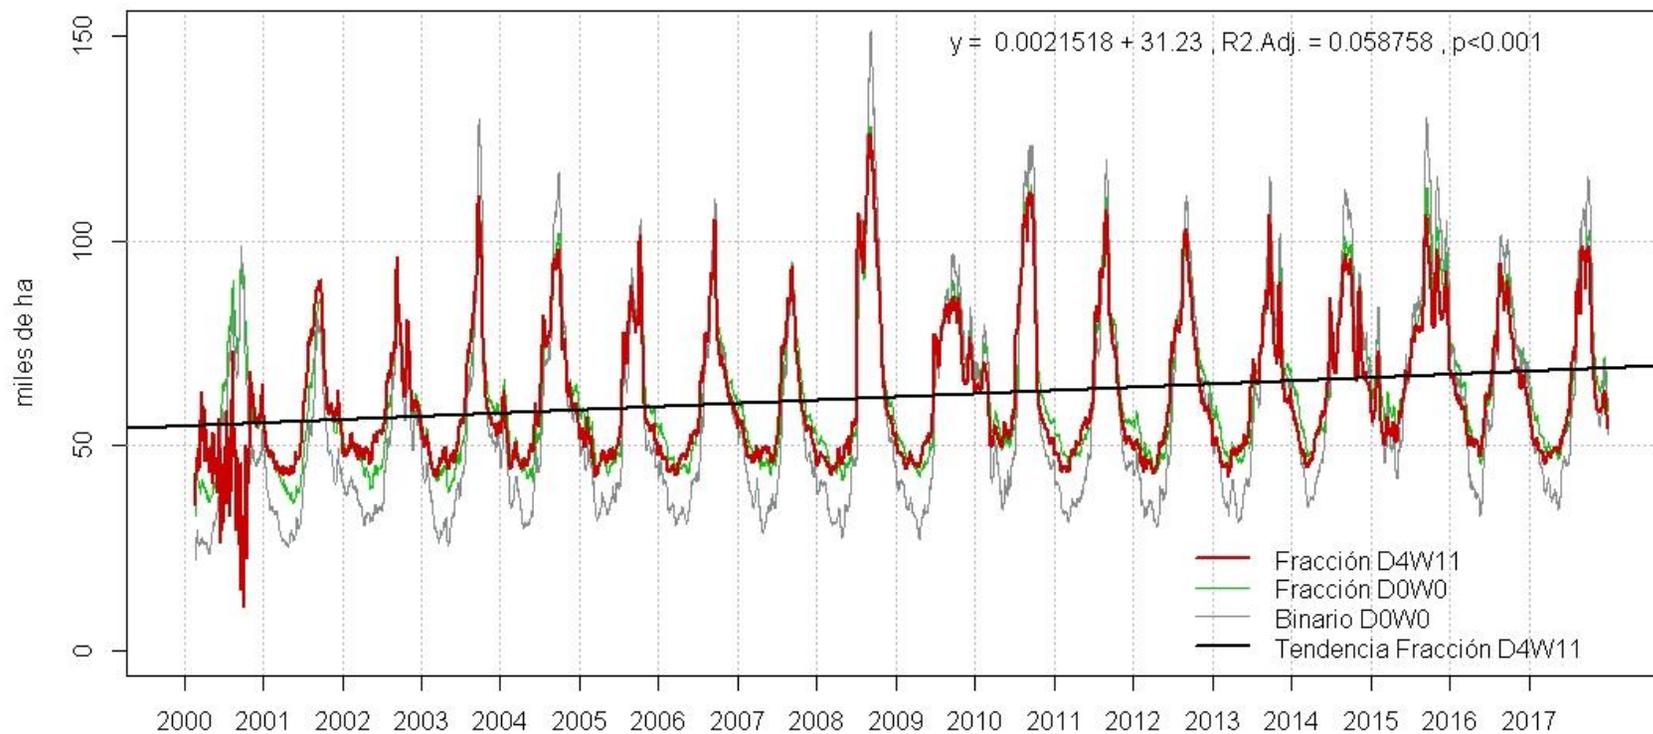
En ambas temporadas, se observó que cuando se trata de regresiones que consideran solamente el MNDWI6 o el MNDWI6+NDMI6, los valores de ajuste no cambian, incluso no importa si se aplica o no el filtro de calidad. Además, el considerar el máximo número de variables no necesariamente incrementó el valor de ajuste con los datos de referencia.

Entre temporadas, se obtuvieron los mejores valores de ajuste en la temporada lluviosa.

### **Serie de tiempo de superficie de cuerpos de agua**

En la Figura 17 se contrastan tres series de tiempo calculadas con diferentes aproximaciones: el modelo simple con una sola variable (D0 y W0), serie con valores binarios obtenido al discretizar las fracciones del modelo anterior, y el modelo seleccionado en esta tesis (D4 y W11, estiaje y lluvias respectivamente). La serie con datos binarios se discretiza a partir de valores determinados del índice, tomados de Colditz et al., (2018), asignando un valor de pixel igual a 1 (Agua), si el valor del MNDWI6 es mayor a -0.14 y -0.16 para las temporadas de estiaje y lluvias respectivamente, de acuerdo con Colditz et al., (2018).

Las tres series mantienen el mismo comportamiento inter e intra-anual, de manera que describen la dinámica de manera muy similar, aunque si hay diferencia en los ajustes. Se observa que las series obtenidas con el modelo más simple sobreestiman la superficie en casi todas las temporadas lluviosas y la subestima en todas las temporadas de estiaje.



**Figura 17.** Serie de tiempo de superficie de cuerpos de agua, estimada con los modelos seleccionados (D4W11), y su comparativa con el modelo de regresión simple (D0W0) y serie de datos binarios obtenida a partir de este último.

En el año 2000, se observa “ruido” en el modelo que incluye varios índices, lo cual se observó para varios de los modelos bien evaluados y coincide con los años de menor disponibilidad de datos (Figura 5).

En el periodo entre 2001-2017, los valores máximos de superficie en cada año, ordenados de mayor a menor, se observaron en los años 2008, 2010, 2003 y 2015, además de tener mayor variabilidad ( $SD = 9,460$ ), respecto a los valores mínimos ( $SD = 2,419$ ).

Las temporadas de lluvias de 2009, 2014 y 2015 muestran las mayores permanencias de los cuerpos de agua en el sitio.

En el periodo entre 2001-2017, la superficie inundada varió entre 12.4% y 14.6% del total del área de estudio en la temporada de estiaje y entre 25.2% y 36.7% en la temporada lluviosa.

La tendencia lineal de toda la serie muestra un ligero incremento a lo largo de los años.

## **Precipitación y temperatura**

La Figura 18 muestra los registros de precipitación disponibles y los resultados de la serie de tiempo de cuerpos de agua con el modelo seleccionado (D4W11). De manera general se puede observar la clara estacionalidad tanto a nivel estatal como a nivel local y una sincronización entre el inicio del periodo lluvioso con un posterior incremento en la superficie de agua. También se observa que un incremento en los meses con lluvia coincide con el incremento en la permanencia de los cuerpos de agua (años 2008, 2013-2015).

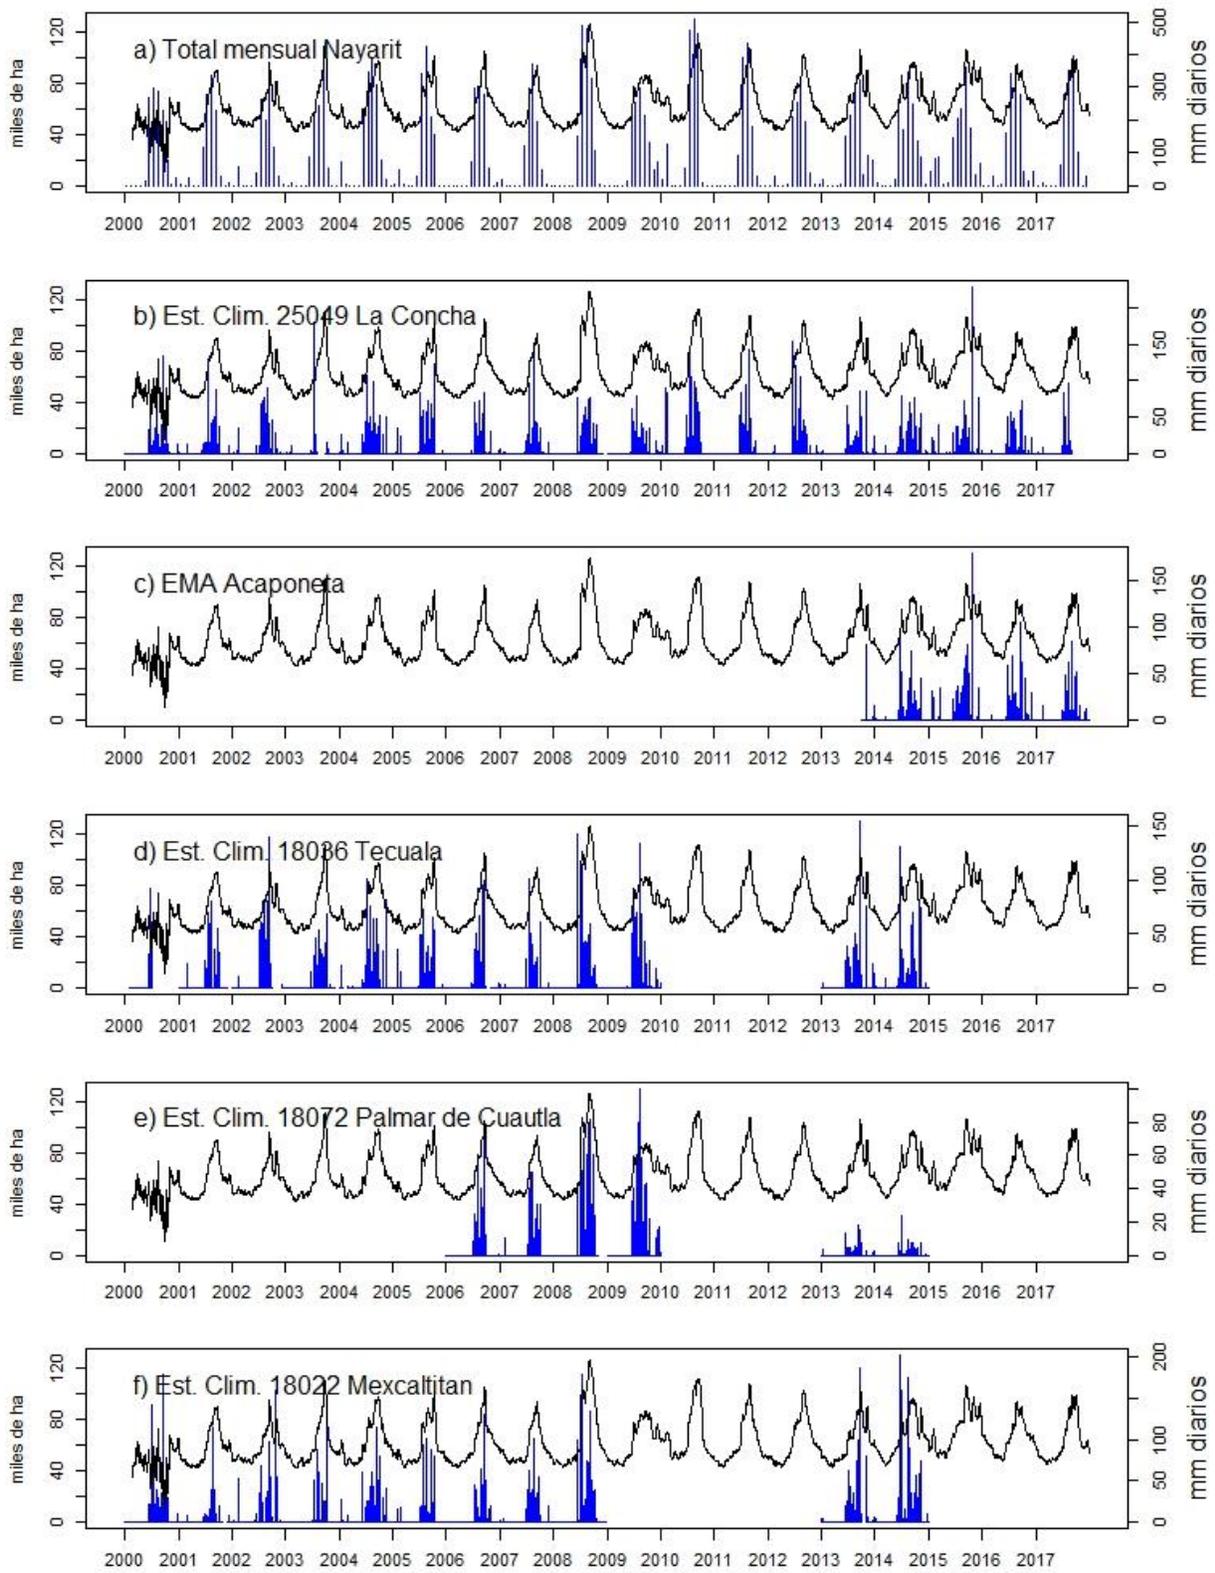
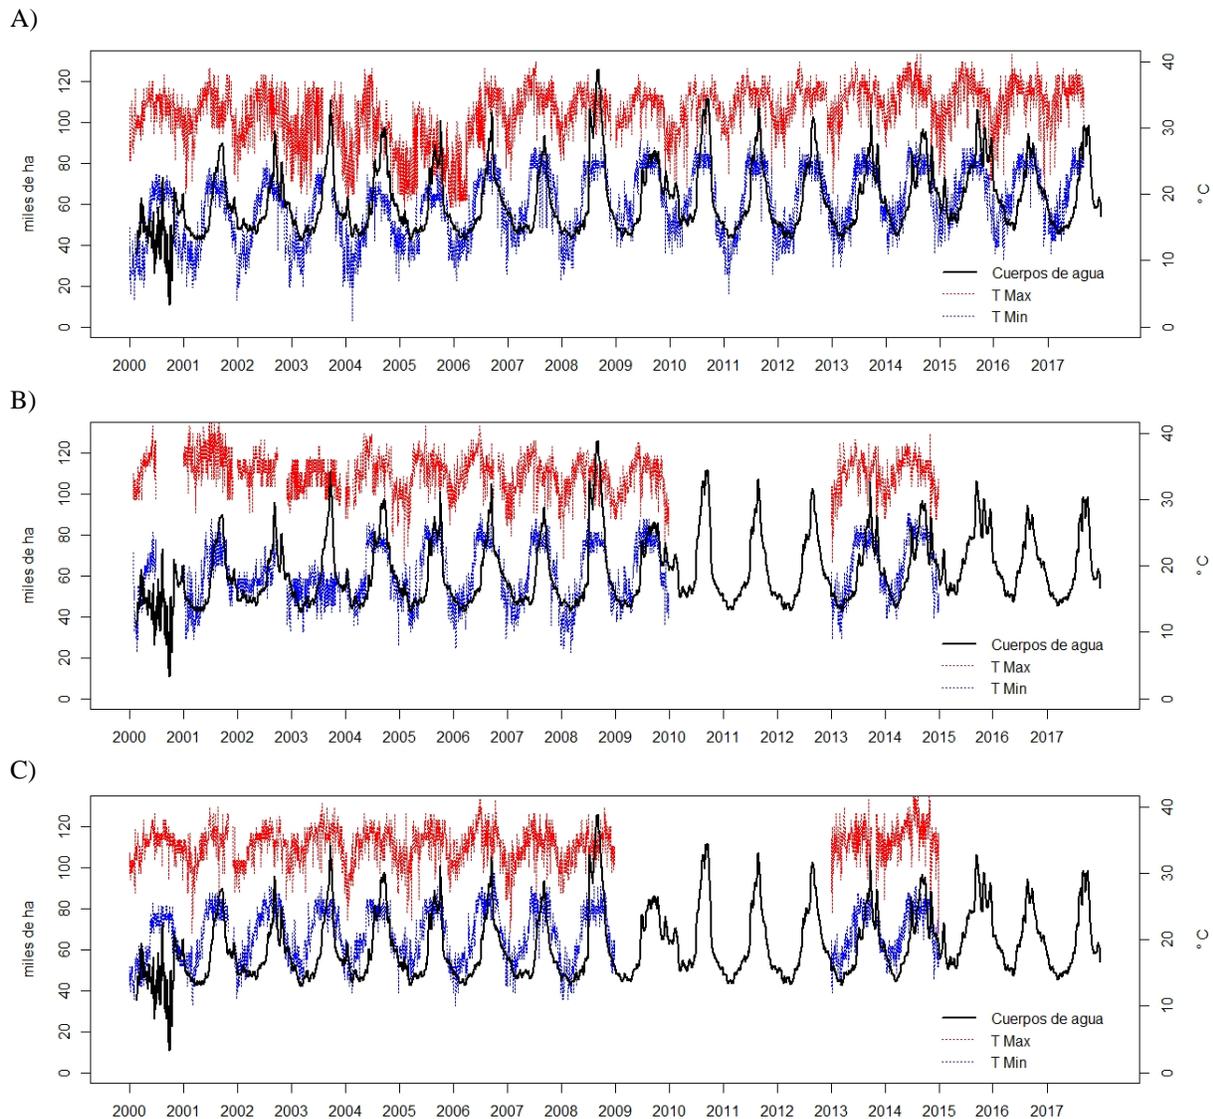


Figura 18. Precipitación diaria (línea azul) y serie de área de cuerpos de agua obtenida con el modelo (línea negra).

Los dos picos más altos de superficie inundada (2008 y 2010), coinciden con las mayores precipitaciones a nivel estatal y en la estación climatológica más cercana a la costa (18072 Palmar de Cuautla). Para el caso de la temperatura atmosférica, ésta muestra una estacionalidad muy definida en donde las mayores temperaturas se presentan al final de la temporada de lluvia en el verano. Es en esta época cuando los cuerpos de agua empiezan a incrementar su superficie (Figura 19).

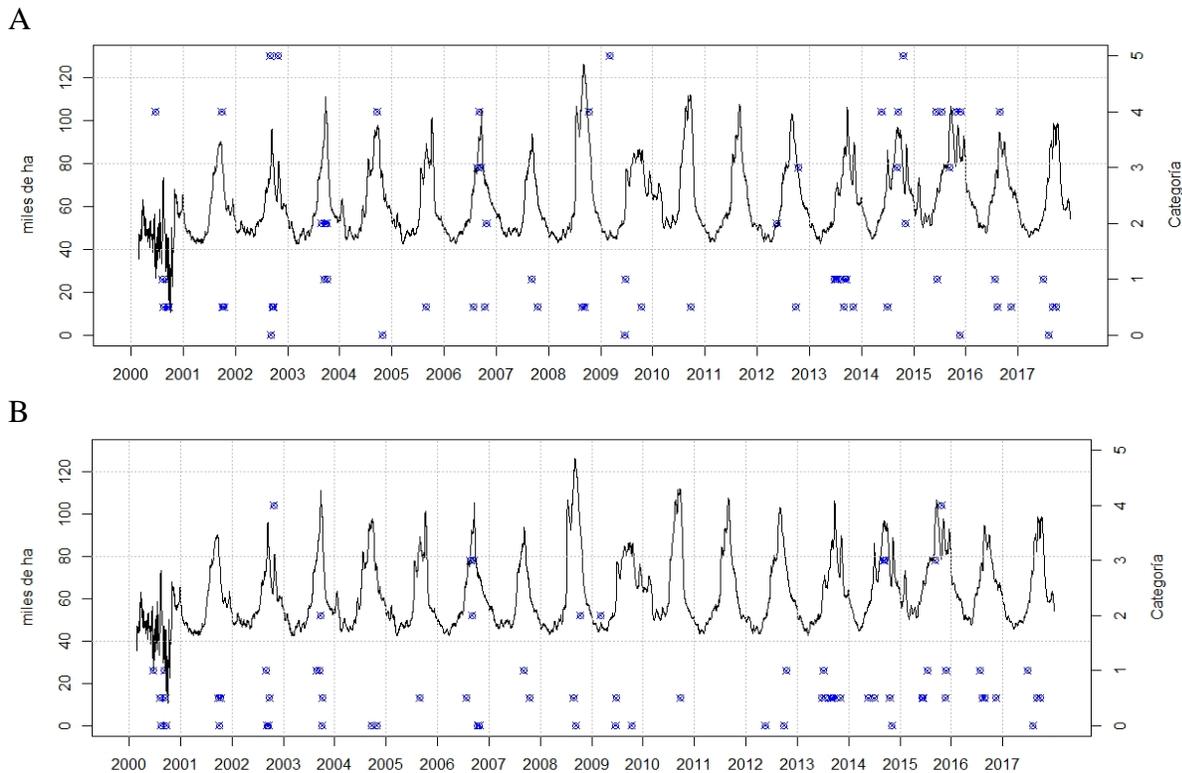


**Figura 19.** Temperaturas máximas y mínimas en tres estaciones climatológicas: A) 25049-La Concha, B) 18036-Tecuala y C) 18022-Mexcaltitan y serie de área de cuerpos de agua obtenida con el modelo (línea negra).

## Ciclones tropicales

En lo que respecta a los ciclones tropicales, en los años 2013 y 2015 se observaron la mayor cantidad de eventos (siete en cada año), sin embargo, en 2015 tuvieron mayor intensidad, pues cinco fueron huracanes con categoría igual o mayor a 3. La Figura 20-A sobreponen la serie de tiempo de la superficie inundada y las categorías máximas alcanzadas de cada evento. En ella se observa que las categorías mayores no están relacionadas con los picos más altos.

Por otro lado, si se considera cuál fue la categoría en la cual el evento se encontraba cuando tuvo contacto a tierra o cuando estuvo más cercana a la costa, la mayoría fueron tormentas tropicales y huracanes de categoría 1. La Figura 20-B sobrepone la serie, esta categorización y se observa que en los primeros años, los eventos se presentaron en un intervalo de tiempo menor, mientras que entre 2013 y 2016, los eventos ocurrieron durante una mayor cantidad de meses del año y coinciden con mayores amplitudes en la permanencia de los cuerpos de agua.

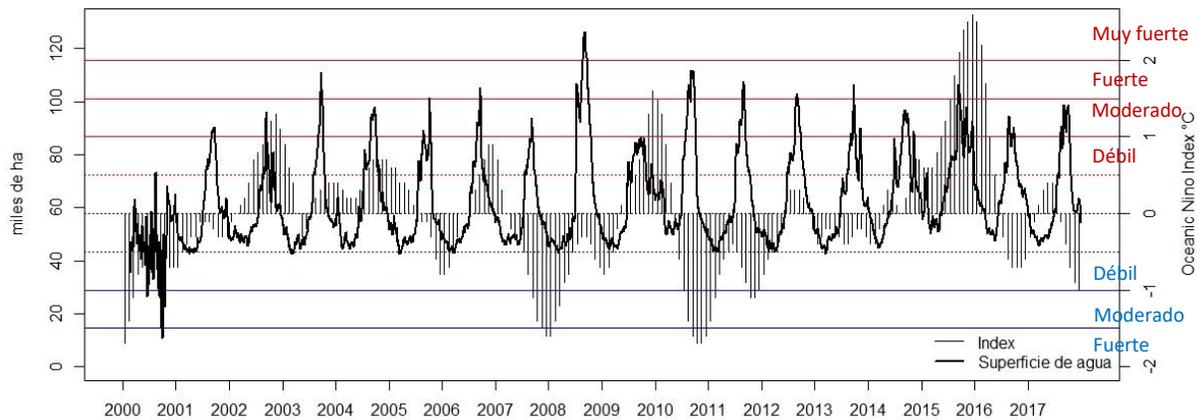


**Figura 20.** Presencia de ciclones tropicales (puntos azules) y serie de cuerpos de agua. A) Categoría máxima y B) Categoría de contacto a tierra o más cercana a la costa. Para las categorías, 0 = Depresión tropical, 0.5 = Tormenta tropical, 1 = Huracán1, 2 = Huracán2, 3 = Huracán3, 4 = Huracán4, 5=Huracán5.

## Episodios El Niño – La Niña

En la temporada de 1997-1998 fue el último evento muy extremo de El Niño previo al periodo de análisis la serie de datos. El siguiente es el de la temporada 2015-2016. En 2009-2010, hubo un evento fuerte. Respecto a eventos de La Niña, ha habido eventos fuertes en 1999-2000, 2007-2008 y 2010-2011.

Los incrementos en la superficie de agua no tienen una relación clara con estos eventos (Figura 21). Sin embargo, para dos temporadas (2009-2010 y 2015-2016), se observa una sobreposición entre eventos intensos de El Niño y una mayor permanencia de la superficie de agua.



**Figura 21.** Índice Oceánico del El Niño. Se indica la intensidad de eventos de El Niño (rojo) y La Niña (azul) y serie de área de cuerpos de agua obtenida con el modelo (línea negra).

## 9. DISCUSIÓN

En esta tesis se empleó un análisis espacial basado en datos multiespectrales para crear un perfil temporal de índices derivados del sensor MODIS (MCD43A4 Terra-Aqua), y así poder identificar cambios temporales en los cuerpos de agua de Marismas Nacionales. Al igual que estudios anteriores (e.g., Kuenzer et al. 2015; Di-Vittorio y Georgakakos 2018; Bansal et al. 2017; Hu et al. 2017; Wolski et al. 2017), los resultados de esta tesis indican que el sensor MODIS fue adecuado para monitorear la variabilidad temporal en el patrón de inundación. A pesar de su baja resolución espacial (500 m/pixel), presenta una muy alta resolución temporal y espectral. Además, el método de regresión lineal múltiple proporciona un mecanismo para comprender la naturaleza de los resultados y mitigar algunos errores provenientes del análisis tal como la presencia de nubes, la resolución espacial propia del sensor y la inconsistencia respecto a la disposición de datos consecutivos. Por lo tanto, el análisis multiespectral utilizado en esta tesis proporcionó resultados confiables los cuales se vieron reflejados en la relación directa con variables ambientales.

El comportamiento del cuerpo de agua dentro de Marismas Nacionales fue cíclico al oscilar entre 43,400 y 126,075 ha inundables a lo largo de los 18 años de estudio. Esta área ocupa un porcentaje aproximado entre el 12.3 y 36.7% del área de estudio de Marismas Nacionales. Por lo tanto, el comportamiento estacional del cuerpo de agua del sistema costero debe tener implicaciones ecológicas de gran relevancia. Por ejemplo, cada especie de la comunidad de manglar adyacente depende del hidropериodo para su desarrollo óptimo e incluso para la colonización de propágulos y así incrementar la extensión de este ecosistema costero tan importante (Flores-de-Santiago et al. 2016). Aparte, el proceso de inundación ocasiona una mezcla del sedimento proveniente de las llanuras de inundación, los cuales son transportados al cuerpo de agua principal durante la época de lluvias y así contribuir al aporte de nutrientes a la columna de agua e incluso pueden llegar a ser exportados hacia la zona costera de Marismas Nacionales (Serrano et al. 2020).

La validación de los productos MODIS es un desafío debido a la falta de observaciones en campo. Por lo tanto, Di-Vittorio y Georgakakos (2018) sugieren una evaluación entre los mapas de cuerpos de agua y zonas inundadas utilizando los siguientes métodos: (i) comparación

cualitativa con la literatura y (ii) comparación del comportamiento de píxeles clasificados como cuerpos de agua y datos de variables ambientales in situ. Al contrastar el ciclo de inundación con variables ambientales se ve que el sistema costero es primeramente controlado por el patrón de precipitación y como consecuencia depende de dos temporadas principales (lluvia y estiaje). Es importante destacar el desfase que existe entre la acumulación por lluvia y el incremento en la extensión del cuerpo de agua. Este comportamiento estacional ha sido ampliamente identificado para humedales costeros de regiones semiáridas (e.g., Flores-de-Santiago et al. 2012; Feng et al. 2012; Flores-de-Santiago et al. 2016). Las inundaciones comienzan con el inicio de la temporada de lluvia, alrededor de mayo y junio, y su magnitud se incrementa a medida que aumenta el flujo del río y la acumulación de agua, de octubre a diciembre. Las inundaciones ocurren con mayor intensidad hacia la parte sur de Marismas Nacionales a principios de año y progresan hacia el norte. Esta observación concuerda con trabajos en la literatura (e.g., Hernández-Guzmán et al. 2016) y es lógica considerando que los ríos de mayor caudal fluyen hacia el sur (Santiago, San Pedro, Acaponeta), la laguna más grande se encuentra en el sur (Agua Brava) y la lluvia generalmente tiene mayor intensidad en la zona sur (Blanco y Correa et al. 2011).

Durante el proceso de inundación en la época de lluvias, es de esperarse que muchas marismas temporales permanezcan secas durante los meses de estiaje y se inunden y aumenten su extensión inundable durante la temporada de verano y otoño (Bansal et al. 2017). Por otro lado, es probable que algunos humedales permanentes, que eran demasiado pequeños para ser detectados en la temporada de estiaje, incrementaron su tamaño y pudieron ser detectados durante la época de lluvias (Wolski et al. 2017). Por el contrario, la desaparición de cuerpos de agua de humedales temporales durante la época de estiaje se puede deber a que la poca agua en el sistema se almacena en el cuerpo de agua principal dentro de la laguna Agua Brava (sur) y Agua Grande (norte). Por lo tanto, se puede esperar que las imágenes de la temporada de estiaje contengan predominantemente cuerpos de agua grandes los cuales permanecen inundados durante todo el año.

Las diferencias observadas en la dinámica local de las inundaciones pueden deberse también a fuertes aplicaciones en la gestión del agua subsuperficial para agricultura y superficial para acuicultura (Ogilvie et al. 2015). De hecho, el comprender los procesos hidrodinámicos y

extensión del cuerpo de agua pudiera ayudar en cierta medida a mitigar las prácticas de drenes agrícolas, por medio de la identificación de los momentos clave para las descargas y así facilitar su exportación del sistema.

Existen múltiples sensores para clasificar cuerpos de agua en humedales costeros tales como imágenes MODIS, Landsat, SPOT, Sentinel, RapidEye, IKONOS, QuickBird y WorldView. No es sorprendente encontrar en la literatura una amplia gama de trabajos en donde imágenes de muy-alta resolución espacial (menores a 4 m/pixel) se han utilizado para la identificación de cuerpos de agua muy angostos, tales como canales intermareales, los cuales no son posible identificar en las imágenes utilizadas en esta tesis. Sin embargo, debido al alto costo de adquisición, la mayoría de estos trabajos se utilizaron principalmente en pequeñas áreas de estudio con el propósito de explorar métodos nuevos o cuantificar el error potencial de la clasificación temática del humedal particular (e.g., Valderrama-Landeros et al. 2018; Hu et al. 2017). El problema con las imágenes de muy-alta resolución espacial consiste en la poca capacidad de obtener imágenes consecutivas y generalmente los estudios son puntuales sin considerar la variabilidad estacional.

En la práctica, la capacidad de construir series de tiempo de cuerpos de agua o áreas inundadas con los productos gratuitos de MODIS está limitada en gran medida por la confusión espectral con zonas adyacente de vegetación mixta, la profundidad del cuerpo de agua, así como en lugares donde la extensión del cuerpo de agua no pueda ser captada por el tamaño mínimo del pixel (Kuenzer et al. 2015). Por tal motivo, es menos probable que se pueda detectar un cuerpo de agua donde la inundación es poco profunda, o en isletas donde el cuerpo de agua está sobre una pequeña proporción de su área. Estas condiciones son típicas durante la temporada de estiaje, lo cual lleva a identificar algunos pixeles como no-inundados cuando en realidad estos pixeles pueden estar parcialmente cubiertos de agua. Además, no es posible detectar cuerpos de agua e inundaciones debajo de la vegetación (e.g., dosel de manglar denso) con sensores pasivos. Es de esperarse que los datos MODIS subestimen la extensión de la inundación en comparación con datos de mayor resolución espacial como Landsat o Sentinel (Chen et al. 2013). En esta tesis la mínima disponibilidad de datos por cada pixel fue del 86% y la calidad de dichos datos, varió entre la temporada de estiaje y lluvias, en donde la temporada de estiaje presentó una mejor calidad.

Existen en la literatura una gran cantidad de índices espectrales con propósitos diferentes. Los más utilizados son índices normalizados debido a que su resultado se encuentra en el intervalo de -1 a +1 y por lo tanto son fáciles de interpretar e incluso se pueden comparar los resultados entre imágenes de diferente plataforma y sensor (Ogilvie et al. 2015). Dentro de los índices normalizados, el más utilizado para estudios de vegetación y discriminación de cuerpos de agua es el NDVI debido a que utiliza información de las bandas del rojo e infrarrojo cercano (Wolski et al. 2017). Sin embargo, los resultados indican que el NDVI no fue seleccionado para analizar el cuerpo de agua de Marismas Nacionales. Este resultado concuerda con el estudio de Bansal et al. (2017) donde el NDVI no fue capaz de separar vegetación de humedales del cuerpo de agua porque la vegetación del humedal tiende a tener una baja reflectancia en el NIR comparada con la vegetación terrestre. Por otro lado, índices con longitudes de onda en el SWIR tienden a separar mejor el cuerpo de agua al presentar un contraste mayor. Los resultados indican que índices tales como los MNDWI y NDMI, ambos considerados en los modelos seleccionados y con información dentro del SWIR y NIR, fueron capaces de contribuir en mayor medida al análisis del cuerpo de agua de este sistema durante ambas temporadas. Este resultado satisfactorio también se puede deber a su sensibilidad al contenido de humedad (Di-Vittorio y Georgakakos 2018). De hecho, Ogilvie et al. (2015) sugieren el uso del NDWI por ser el más adecuado para la detección de todo tipo de agua e incluso fue capaz de identificar ciertas partes de la vegetación inundada y podría usarse sin la necesidad de otro índice para analizar cuerpos de agua relativamente profundos. Sin embargo, a medida que la inundación retrocede y las áreas de vegetación inundada se vuelven proporcionalmente más grandes, el crecimiento de la vegetación condujo a dificultades en la detección del cuerpo de agua, y el NDWI no contribuyó lo suficiente para estimar las superficies de agua. Por lo que se sugiere que periodos de transición son más complicados de analizar y presentarían un incremento en el error de discriminación. Es importante recalcar que espectrorradiómetros, tales como el sensor MODIS, presentan mayor número de bandas en el NIR y SWIR, por lo tanto, la capacidad de otras plataformas y sensores para identificar cuerpos de agua sin la presencia de la banda 7 del MODIS (SWIR3) va a requerir estudios posteriores para determinar su posible aplicación en esta área de estudio.

En general, las zonas permanentemente inundadas en Marismas Nacionales fueron fáciles de distinguir, pero las zonas estacionalmente inundadas presentaron más similitudes con las zonas

terrestres. Probablemente esta situación se deba al cambio en el dosel de la vegetación terrestre caducifolia durante la temporada de lluvias. Estas áreas se inundan rápidamente y son clasificadas como píxeles terrestres cuando realmente son zonas inundadas que no pueden ser identificables por la densidad del dosel (incremento en el número de hojas). Por esta razón, Di-Vittorio y Georgakakos (2018) también sugiere el uso del SWIR debido a que esta longitud de onda puede llegar a distinguir más fácilmente el contenido de humedad de vegetación que probablemente está inundada por debajo del dosel incluso durante periodos cortos de meses.

Se ha reportado que estos patrones de inundación tienen una importancia ecológica relevante respecto a las tasas de producción, descomposición y exportación de materia orgánica a la zona costera por medio de los canales de inundación (Hess et al. 1990). Sin embargo, este comportamiento cíclico no se vio afectado por la presencia de tormentas tropicales y huracanes, al igual que los resultados reportados por Hernández-Guzmán et al. (2016) con datos Landsat TM y ETM+ a lo largo de 16 años de muestreo (1993-2008). Esto se puede deber a varios factores, por ejemplo, es indiscutible que los huracanes proporcionan una cantidad de agua considerable al momento de impactar en la zona costera. Sin embargo, se ha visto que esta cantidad de agua si bien es considerable, es muy puntual y no dura más allá de un par de días dentro del cuerpo de agua el cual es desplazado rápidamente hacia el océano por efecto de gravedad. Serrano et al. (2020) analizaron los vectores de corrientes superficiales dentro del sistema de Marismas Nacionales y concluyeron que gran parte del aporte terrígeno por los ríos es expulsado hacia el océano por medio del Canal de Cuautla. Este proceso se vio en el campo al momento del impacto del huracán Willa en octubre de 2018, donde la parte norte del sistema de Marismas Nacionales fue inundada de forma considerable, sin embargo, la gran cantidad de sedimento y el incremento en el nivel del agua no se vieron reflejados una semana posterior al impacto (com. pers., Flores de Santiago).

El uso del producto MCD43A4 de MODIS permite corregir los valores de reflectancia y disminuir la presencia de nubosidad, siempre y cuando se tengan las observaciones suficientes para la inversión del modelo. Sin embargo, de acuerdo a lo anterior descrito, puede resultar difícil que los cuerpos de agua sean capturados por la imagen en su máxima extensión si la nubosidad permanece por varios días en el sitio.

Respecto a los eventos de El Niño y La Niña, se ha reportado que la precipitación disminuye en la costa de Nayarit durante el evento El Niño (Bravo-Cabrera et al. 2017) al igual que se presenta un incremento anómalo en la temperatura superficial del mar (Sánchez-Velasco et al. 2017), principalmente durante El Niño Godzilla (2015-2016). Sin embargo, los resultados nos indican que la precipitación no disminuyó notablemente durante el verano del 2015, al igual que no se notaron cambios drásticos en la extensión del cuerpo de agua de Marismas Nacionales. Al parecer, los efectos del ENSO 2015-2016 no tuvieron un efecto considerable en los cuerpos de agua de este sistema costero.

El aumento gradual del cuerpo de agua de Marismas Nacionales se puede deber a dos condiciones las cuales consistirían en un aumento en el nivel del mar o una disminución de la cobertura vegetal. A pesar de que el incremento en el nivel del mar es un problema fundamental para la zona costera a largo plazo, es probable que el incremento en el nivel del cuerpo de agua dentro de Marismas Nacionales no se deba al incremento en el nivel del mar. Esta suposición se basa en el trabajo reciente por Valderrama-Landeros et al. (2020) donde se analizó los cambios en la línea de costa de Marismas Nacionales desde la boca de Teacapán (norte) hasta la boca del Río San Pedro (sur) desde 1970 al 2019. Los resultados indican que no se percibe una pérdida significativa en la línea de costa, por lo que, si bien el incremento en el nivel del mar puede llegar a tener una afectación considerable, no fue posible detectar dicho cambio en el análisis con las imágenes MODIS por el corto tiempo de estudio (18 años). Por otro lado, es más probable es que el incremento en el cuerpo de agua dentro de Marismas Nacionales se deba a una cuestión de cambio en los píxeles clasificados relacionada con la constante degradación del bosque de manglar y otros humedales. El sistema de Marismas Nacionales ha sido ampliamente impactado por el represamiento de los ríos y la apertura del Canal de Cuautla (Serrano et al. 2020). Por lo tanto, la degradación del dosel del bosque ocasiona una disminución en la reflectancia de píxeles clasificados como vegetación, lo cual hace posible capturar el cuerpo de agua debajo del dosel y así se substituyen los píxeles previamente clasificados como vegetación por píxeles clasificados como cuerpos de agua. Si bien esta es una suposición que se basa en resultados de la CONABIO (Valderrama-Landeros et al. 2017), no existen trabajos publicados a detalle sobre la degradación del bosque de manglar a largo plazo (decadalmente) dentro de

Marismas Nacionales. La mayoría consisten en estudios de zonas específicas y en intervalos de tiempo relativamente cortos.

Al igual que cualquier técnica de percepción remota, es importante destacar los posibles errores y limitaciones del estudio. Por ejemplo, una consideración puede ser la exactitud de la geolocalización de la imagen. Es muy común generar errores al momento de realizar la georreferenciación de varias imágenes dependiendo de la herramienta empleada y la exactitud del GPS. Estos problemas ocasionan una inconsistencia al momento de analizar series de tiempo sobre una misma área. Sin embargo, teniendo en cuenta la resolución gruesa de los píxeles MODIS (500 m) se generaliza que los errores de geolocalización no son motivo de gran preocupación en este tipo de imágenes (Di-Vittorio y Georgakakos 2018). Por el contrario, una fuente más importante de incertidumbre se relaciona con el método empleado para discriminar las áreas del cuerpo de agua. Debido a la falta de datos disponibles *in situ*, esta tarea tuvo que realizarse de manera algo subjetiva y puede haber píxeles clasificados incorrectamente. Sin embargo, es relativamente bajo el error cuando únicamente se discrimina el cuerpo de agua en forma binaria. Aun cuando en este caso se trata de fracciones de píxel, las clases son solo agua y no agua. Por ejemplo, Flores-de-Santiago et al. (2013b) identificó una disminución de 92% a 63% en la exactitud del cuerpo de agua al momento de incrementar las clases dentro del mapa temático. Una opción pudiera ser la disposición de imágenes de alta resolución espacial, como las disponibles en Google Earth o en los mapas de uso de suelo derivados de Landsat. Sin embargo, la validación cuantitativa directa y multitemporal de los productos para áreas de tal extensión es imposible, como es el caso de la mayoría de los productos de información global derivados de imágenes costosas (Kuenzer et al. 2015). En general, los patrones de inundación y las curvas de inundación (intraanuales, interanuales) presentadas para Marismas Nacionales coinciden bien con el enfoque de validación indirecta y directa.

Actualmente existen herramientas de acceso libre que permitirían optimizar tanto los recursos de hardware y software, como el tiempo de procesamiento en análisis multitemporales, como Google Earth Engine y TATSSI (Tools for Analysing Time Series of Satellite Imagery), esta última permite filtrar la calidad de datos y llenar huecos en cubos de información MODIS y VIIRS. Y aunque estas herramientas están limitadas al *expertise* del analista, y a los tiempos de entrenamiento que se requieran según el caso, existen los algoritmos básicos necesarios para el

desarrollo de proyectos que requieren un manejo de información en grandes cantidades, lo cual es necesario para análisis multitemporales.

## 10. CONCLUSIONES

La presente tesis consiste en un esfuerzo para evaluar la importancia y utilidad de los datos multiespectrales gratuitos de resolución gruesa MODIS (500 m/pixel) con la finalidad de clasificar y cuantificar cuerpos de agua en el sistema lagunar más importante de la costa del Pacífico Mexicano. Se desarrolló un método adecuado y se comprobó su aplicación para capturar e interpretar la información espacial de forma confiable analizando las contribuciones de 14 índices en un modelo de regresión lineal múltiple. Los resultados obtenidos de la validación del mapeo de la extensión del cuerpo de agua, por medio del  $R^2$  entre la variable observada (valores de fracción en Landsat) *versus* la variable calculada (valores de fracción predicha con la regresión), revelan que el modelo seleccionado proporciona una contribución razonable, y por lo tanto factible, en este humedal costero.

Los resultados de la clasificación del cuerpo de agua demuestran que la magnitud de la extensión de área estimada, usando datos MODIS, osciló aproximadamente entre 42,400 y 126,075 ha durante los periodos de mínima y máxima ocurrencia a lo largo de los 18 años de estudio (2000-2017). Sin embargo, existen desventajas espaciales y espectrales en el mapeo de dicha área con los productos MODIS. Por ejemplo, la limitación espectral consiste en que los índices espectrales seleccionados no garantizan identificar la inundación debajo del dosel de vegetación. Por otro lado, la limitación espacial (resolución gruesa) es un resultado inherente del sensor y dificulta la clasificación de zonas inundadas pequeñas o estrechas.

La serie de tiempo del cuerpo de agua presenta una tendencia directa respecto al patrón de precipitación, por lo que este sistema depende principalmente del aporte fluvial. Además, se presenta un desfase esperado entre el inicio de la temporada de lluvias y el incremento en la extensión del cuerpo de agua. Por el contrario, los huracanes y los eventos de El Niño y La Niña no tuvieron una contribución relevante en la dinámica del cuerpo de agua de Marismas Nacionales. En este sentido, la posibilidad de obtener una serie temporal de áreas inundadas es fundamental para desarrollar modelos hidrológicos confiables, los cuales que puedan usarse como herramientas complementarias durante la planificación costera y el manejo de los recursos hídricos.

Los índices que mayor contribución tuvieron fueron MNDWI6, NDMI6 y NDMI7 durante ambas temporadas (estiaje y lluvias) y además el MNDWI5 en la temporada lluviosa, debido a que sus ecuaciones presentan información de la banda SWIR, la cual es de gran relevancia para determinar humedad, y por consiguiente, identificar eficientemente los píxeles que corresponden al cuerpo de agua. Además, esta tesis ilustra cómo los datos MODIS complementan las observaciones hidrológicas para monitorear la dinámica de las inundaciones en áreas grandes. Los resultados de esta tesis sugieren que la tendencia positiva en el incremento en la extensión del cuerpo de agua de Marismas Nacionales se puede deber a la degradación constante del bosque de manglar. En otras palabras, los píxeles que se clasificaron como bosque de manglar pueden estar siendo reemplazados por píxeles clasificados como cuerpo de agua debido a la disminución del dosel de vegetación. Sin embargo, es necesario realizar análisis complementarios para poder corroborarlo.

Finalmente, los datos MODIS y el análisis multiespectral empleado tienen la capacidad de cuantificar los efectos de las inundaciones en los humedales costeros. Estos productos son necesarios para cuantificar los patrones espaciales y la dinámica temporal en los procesos de inundación en las marismas y pronosticar cambios de cobertura, a partir de procesos naturales o de degradación antrópica que ocurre en otros humedales costeros.

## 11. REFERENCIAS

- Arshad M., Eid E.M., Hasan M. 2020. Mangrove health along the hyper-arid southern Red Sea coast of Saudi Arabia. *Environmental, Monitoring and Assessment* 192, 189.
- Asbridge E.F., Bartolo R., Finlayson C.M., Lucas R.M., Rogers K., Woodroffe C.D. 2019. Assessing the distribution and drivers of mangrove dieback in Kakadu National Park, northern Australia. *Estuarine, Coastal and Shelf Science* 228, 106353.
- Bannari A., Morin D., Bonn F. 1995. A review of vegetation indices. *Remote Sensing Reviews* 13, 95-120.
- Blanco y Correa M., Flores-Verdugo F., Ortiz-Pérez M. A., de la Lanza-Espino G., López-Portillo J., Valdez-Hernández I. 2011. Diagnostico funcional de Marismas Nacionales. Nayarit, México: Informe de los convenios de coordinación entre la Universidad Autónoma de Nayarit y la Comisión Nacional Forestal con el patrocinio del Gobierno del Reino Unido.
- Bansal S., Katyal D., Garg J.K. 2017. A novel strategy for wetland area extraction using multispectral MODIS data. *Remote Sensing of Environment* 200, 183-205.
- Boschetti L., Flasse S.P., Brivio P.A. 2004. Analysis of the conflict between omission and commission in low spatial resolution dichotomic thematic products: The Pareto Boundary. *Remote Sensing of Environment* 91, 280-292.
- Bravo-Cabrera J.L., Azpra-Romero E., Zarraluqui-Such V., Gay-García C. 2017. Effects of El Niño in Mexico during rainy and dry seasons: an extended treatment. *Atmosfera* 30(3), 221-232.
- Bryan-Brown D.N., Connolly R.M., Richards D.R., Adame F., Friess D.A., Brown C.J. 2020. Global trends in mangrove forest fragmentation. *Scientific Reports* 10, 7117.
- Bukoski J.J., Elwin A., MacKenzie R.A., Sharma S., Purbopuspito J., Kopania B., Apwong M., Poolsiri R., Potts M.D. 2020. The role of predictive model data in designing mangrove forest carbon programs. *Environmental Research Letters*. <https://doi.org/10.1088/1748-9326/ab7e4e>
- Chávez D., Gallardo-Cruz J.A., Solórzano J.V., Peralta-Carreta C., Enríquez M., Meave J.A. 2020. Spatial correlates of floristic and structural variation in a Neotropical wetland forest. *Wetlands, Ecology and Management* 28, 341-356.
- Chen Y., Huang C., Ticehurst C., Merrin L., Thew P. 2013. An evaluation of MODIS daily and 8-day composite products for floodplain and wetland inundation mapping. *Wetlands* 33, 823-835.
- Colditz R.R., Llamas R.M., Ressler R.A. 2014. Detecting change areas in Mexico between 2005 and 2010 using 250 m MODIS images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7(8), 3358-3372.

- Colditz R.R., Souza C.T., Vazquez B., Wickel A.J., Ressler R. 2018. Analysis of optimal threshold for identification of open water using MODIS-derived spectral indices for two coastal wetland systems in Mexico. *International Journal of Applied Earth Observation and Geoinformation* 70, 13-24.
- De-León-Herrera R., Flores-Verdugo F., Flores-de-Santiago F., González-Farías F. 2015. Nutrient removal in a closed silvofishery system using three mangrove species (*Avicennia germinans*, *Laguncularia racemosa*, and *Rhizophora mangle*). *Marine Pollution Bulletin* 91, 243-248.
- Di-Vittorio C.A., Georgakakos A.P. 2018. Land cover classification and wetland inundation mapping using MODIS. *Remote Sensing of Environment* 204, 1-17.
- Dronova I. 2015. Object-based image analysis in wetland research: A review. *Remote Sensing* 7, 6380-6413.
- Duke N.C., Kovacs J.M., Griffiths A.D., Preece L., Hill D.J.E., Oosterzee P., Mackenzie J., Morning H.S., Burrows D. 2017. Large-scale dieback of mangroves in Australia's Gulf of Carpentaria: a severe ecosystem response, coincidental with an unusually extreme weather event. *Marine and Freshwater Research* 68, 1816-1829.
- Espinoza-Tenorio A., Millan-Vasquez N.I., Vite-Garcia N., Alcalá-Moya G. 2019. People and blue carbón: Conservation and settlements in the mangrove forests of Mexico. *Human Ecology* 47, 877-892.
- Ezcurra E., Barrios E., Ezcurra P., Ezcurra A., Vanderplank S., Vidal O., Villanueva-Almanza L., Aburto-Oropeza O. 2019. *Science Advancements* 5, eaau9875.
- Feng L., Hu C., Chen X., Cai X., Tian L., Gan W. 2012. Assessment of inundation changes of Poyang Lake using MODIS observations between 2000 and 2010. *Remote Sensing of Environment* 121, 80-92.
- Ferreira A.C., Ganade G., Attayde J.L. 2015. Restoration versus natural regeneration in a neotropical mangrove: Effects on plant biomass and crab communities. *Ocean & Coastal Management* 110, 38-45.
- Flores-de-Santiago F., Kovacs J.M., Flores-Verdugo F. Seasonal changes in leaf chlorophyll a content and morphology in a sub-tropical mangrove forest of the Mexican Pacific. *Marine Ecology Progress Series* 444, 57-68.
- Flores-de-Santiago F., Kovacs J.M., Flores-Verdugo F. 2013a. The influence of seasonality in estimating mangrove leaf chlorophyll-a content from hyperspectral data. *Wetlands, Ecology and Management* 21, 193-207.
- Flores-de-Santiago F., Kovacs J.M., Lafrance P. 2013b. An object-oriented classification method for mapping mangroves in Guinea, West Africa, using multipolarized ALOS PALSAR L-band data. *International Journal of Remote Sensing* 34(2), 563-586.
- Flores-de-Santiago F., Kovacs J.M., Wang J., Flores-Verdugo F., Zhang C., González-Farías F. 2016. Examining the influence of seasonality, condition, and species composition on mangrove leaf pigment contents and laboratory based spectroscopy data. *Remote Sensing* 8, 226.

- Flores-de-Santiago F., Valderrama-Landeros L., Rodríguez-Sobreyra R., Flores-Verdugo F. 2020. Assessing the effect of flight altitude and overlap on orthoimage generation for UAV estimates of coastal wetlands. *Journal of Coastal Conservation* 24, 35.
- Flores-Verdugo F., Moreno-Casasola P., Agraz-Hernández C.M., López-Rosas H., Benítez-Pardo D., Travieso-Bello A.C. 2007. La topografía y el hidropereodo: Dos factores que condicionan la restauración de los humedales costeros. *Boletín de la sociedad Botánica de México* 80, 33-47.
- Friess D.A., Webb E.L. 2014. Variability in mangrove change estimates and implications for the assessment of ecosystem service provision. *Global Ecology and Biogeography* 23, 715-725.
- Gomez C., White J.C., Wulder M.A. 2016. Optical remotely sensed time series data for land cover classification: A review. *ISPRS Journal of Photogrammetry and Remote Sensing* 116, 55-72.
- Guo M., Li J., Sheng C., Xu J., Wu L. 2017. A review of wetland remote sensing. *Sensors* 17, 777.
- Hernández-Guzmán R., Ruiz-Luna A., Berlanga-Robles C.A., Ponce-Palafox J.T. 2016. Analysis of flood pulse dynamics in the lower basin of the San Pedro River (northwestern Mexico) using remote sensing. *Latin America Journal of Aquatic Research* 44(2), 293-304.
- Hess L.L., Melack J.M., Simonett D.S. 1990. Radar detection of flooding beneath the forest canopy: a review. *International Journal of Remote Sensing* 11(7), 1313-1325.
- Honkavaara E., Arbiol R., Markelin L., Martinez L., Cramer M., Bovet S., Chandelier L., Ilves R., Klonus S., Marshal P., Schlapfer D., Tabor M., Thom C., Veje N. 2009. Digital airborne photogrammetry - A new tool for quantitative remote sensing? - A state-of-the-art review on radiometric aspects of digital photogrammetric images. *Remote Sensing* 1, 577-605.
- Hu S., Niu Z., Chen Y., Li L., Zhang H. 2017. Global wetlands: Potential distribution, wetland loss, and status. *Science of the Total Environment* 586, 319-327.
- Kamal M., Phinn S., Johansen K. 2016. Assessment of multi-resolution image data for mangrove leaf area index mapping. *Remote Sensing of Environment* 176, 242-254.
- Koedsin W., Vaiphasa C. 2013. Discrimination of tropical mangroves at the species level with EO-1 Hyperion data. *Remote Sensing* 5, 3562-3582.
- Kovacs J.M., Wang J., Blanco-Correa M. 2001. Mapping disturbances in a mangrove forest using multi-date Landsat TM imagery. *Environmental Management* 27(5), 763-776.
- Kovacs J.M., King J.M.L., Flores-de-Santiago F., Flores-Verdugo F. 2009. Evaluating the condition of a mangrove forest of the Mexican Pacific based on an estimated leaf area index mapping approach. *Environmental, Monitoring and Assessment* 157, 137-149.

- Kuenzer C., Klein I., Ullmann T., Georgiou E.F., Baumhauer R., Dech S. 2015. Remote sensing of river delta inundation: Exploiting the potential of coarse spatial resolution, temporally-dense MODIS time series. *Remote Sensing* 7, 8516-8542.
- Lefebvre G., Davranche A., Willm L., Cambagna J., Redmond L., Merle C., Guelmami A., Poulin B. 2019. Introducing WIW for Detecting the Presence of Water in Wetlands with Landsat and Sentinel Satellites. *Remote Sensing* 11, 2210.
- Li H., Jia M., Zhang R., Ren Y., Wen X. 2019. Incorporating the plant phenological trajectory into mangrove species mapping with dense time series Sentinel-2 imagery and the Google Earth Engine platform. *Remote Sensing* 11, 2479.
- Mafi-Gholami D., Zenner E.K., Jaafari A., Ward R.D. 2019. Modeling multi-decadal mangrove leaf area index in response to drought along the semi-arid southern coasts of Iran. *Science of the Total Environment* 656, 1326-1336.
- Manna S., Raychauhuri B. 2020. Retrieval of leaf area index and stress conditions for Sundarban mangroves using Sentinel-2 data. *International Journal of Remote Sensing* 41(3), 1019-1039.
- McCarthy M.J., Colna K.E., El-Mezayen M.M., Laureano-Rosario A.E., Méndez-Lázaro P., Otis D.B., Toro-Farmer G., Vega-Rodríguez M., Muller-Karger F. 2017. Satellite remote sensing for coastal management: A review of successful applications. *Environmental Management* 60, 323-339.
- Menéndez P., Losada I.J., Torres-Ortega S., Narayan S., Beck M.W. 2020. The global flood protection benefits of mangroves. *Scientific Reports* 10, 4404.
- Mukherjee N., Sutherland W.J., Dicks L., Hoge J., Koedam N., Dahdouh-Guebas F. 2014. Ecosystem service valuations of mangrove ecosystems to inform decision making and future valuation exercises. *PLoS ONE* 9(9), e107706.
- Nikolakopoulos K., Kyriou A., Koukouvelas I., Zygouri V., Apostolopoulos D. 2019. Combination of aerial, satellite, and UAV photogrammetry for mapping the diachronic coastline evolution: The case of Lefkada Island. *ISPRS International Journal of Geoinformation* 8, 489.
- Ogilvie A., Belaud G., Delenne C., Bailly J.S., Bader J.C., Oleksiak A., Ferry L., Martin D. Decadal monitoring of the Niger Inner Delta flood dynamics using MODIS optical data. *Journal of Hydrology* 523, 368-383.
- Pena-Regueiro J., Sebastián-Frasquet M. T., Estornell J., Aguilar-Maldonado J. A., 2020. Sentinel-2 Application to the Surface Characterization of Small Water Bodies in Wetlands. *Water* 12, 1487.
- Pettorelli N., Laurance W.F., O'Brien T.G., Wegmann M., Nagendra H., Turner W. 2014. Satellite remote sensing for applied ecologists: Opportunities and challenges. *Journal of Applied Ecology* 51, 839-848.

- Pham T.D., Xia J., Ha N.T., Bui D.T., Le N.N., Tekeuchi W. 2019. A review of remote sensing approaches for monitoring blue carbon ecosystems: Mangroves, seagrasses and salt marshes during 2010-2018. *Sensors* 19, 1933.
- Rahman M.S., Di L. 2017. The state of the art of spaceborne remote sensing in flood management. *Natural Hazards* 85, 1223-1248.
- Robinove C.J. 1978. Interpretation of a Landsat image of an unusual flood phenomenon in Australia. *Remote Sensing of Environment* 7, 219-225.
- Rubio-Cisneros N.T., Aburto-Oropeza O., Jackson J., Ezcurra E. 2017. Coastal exploitation throughout Marismas Nacionales wetlands in Northwest Mexico. *Tropical Conservation Science* 10, 1-26.
- Sánchez-Velasco L., Beier E., Godínez V.M., Barton E.D., Santamaria-del-Angel E., Jimenez-Rosemberg S.P.A., Marinone S.G. 2017. Hydrographic and fish larvae distribution during the “Godzilla El Niño 2015-2016” in the northern end of the shallow oxygen minimum zone of the Eastern tropical Pacific Ocean. *Journal of Geophysical Research Oceans* 122, 1-15.
- Savtchenko A., Ouzounov D., Ahmed S., Acker J., Leptoukh G., Koziana J., Nickless D. 2004. Terra and Aqua MODIS products available from NASA GES DAAC. *Advances in Space Research* 34, 710-714.
- Schaaf, C. B., Gao, F., Strahler, A. H., Lucht, W., Li, X., Tsang, T., Strugnell, N. C., Zhang, X., Jin, Y., Muller, J.-P., Lewis, P., Barnsley, M., Hobson, P., Disney, M., Roberts, G., Dunderdale, M., Doll, C., d'Entremont, R., Hu, B., Liang, S., and Privette, J. L., 2002. First Operational BRDF, Albedo and Nadir Reflectance Products from MODIS. *Remote Sensing of Environment*, 83, 135–148
- Serrano D., Flores-Verdugo F., Ramírez-Félix E., Kovacs J.M., Flores-de-Santiago F. 2020. Modeling tidal hydrodynamic changes induced by the opening of an artificial inlet within a subtropical mangrove dominated estuary. *Wetlands, Ecology and Management* 28, 103-118.
- Shrestha S., Miranda I., Kumar A., Escobar-Pardo M.L., Dahal S., Rashid T., Remillard C., Mishra D.R. 2019. Identifying and forecasting potential biophysical risk areas within a tropical mangrove ecosystem using multi-sensor data. *International Journal of Applied Earth Observation and Geoinformation* 74, 281-294.
- Sobel R.S., Kiagadi A., Rifai H.S. 2020. Modeling water quality impacts from hurricanes and extreme weather events in urban coastal systems using Sentinel-2 spectral data. *Environmental, Monitoring and Assessment* 192, 307.
- Turner W., Spector S., Gardiner N., Fladeland M., Sterling E., Steininger M. 2003. Remote sensing for biodiversity science and conservation. *Trends in Ecology and Evolution* 18(5), 306-314.
- Valderrama-Landeros L. H., Rodríguez-Zúñiga M.T., Troche-Souza C., Velázquez-Salazar, S., Villeda-Chávez, E., Alcántara-Maya, J.A., Vázquez-Balderas B., Cruz-López M. I., Ressler R., 2017. Manglares de México: actualización y exploración de los datos del sistema de monitoreo 1970/1980–2015. Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. Ciudad de México, 128 pp.

- Valderrama-Landeros L., Flores-de-Santiago F., Kovacs J.M., Flores-Verdugo F. 2018. Assessment of commonly employed satellite-based remote sensors for mapping mangrove species in Mexico using an NDVI-based classification scheme. *Environmental, Monitoring and Assessment* 190, 23.
- Valderrama-Landeros L., Flores-de-Santiago F. 2019. Assessing coastal erosion and accretion trends along two contrasting subtropical rivers based on remote sensing data. *Ocean & Coastal Management* 169, 58-67.
- Valderrama-Landeros L., Blanco y Correa M., Flores-Verdugo F., Álvarez-Sánchez L.F., Flores-de-Santiago F. 2020. Spatiotemporal shoreline dynamics of Marismas Nacionales, Pacific coast of Mexico, based on a remote sensing and GIS mapping approach. *Environmental, Monitoring and Assessment* 192, 123.
- Wan L., Zhang H., Lin G., Lin H. 2019. A small-patched convolutional neural network for mangrove mapping at species level using high-resolution remote-sensing image. *Annals of GIS* 25, 1.
- Wang Y., Qi S., Xu J. 2016. Multitemporal remote sensing for inland water bodies and wetland monitoring. En: Ban Y. (Ed.) *Multitemporal remote sensing Methods and applications*. Springer. 357.
- Wolski P., Murray-Hudson M., Thito K., Cassidy L. 2017. Keeping it simple: Monitoring flood extent in large data-poor wetlands using MODIS SWIR data. *International Journal of Applied Earth Observation and Geoinformation* 57, 224-234.
- Wulder M.A., White J.C., Loveland T.R., Woodcock C.E., Belward A.S., Cohen W.B., Fosnight E.A., Shaw J., Masek J.G., Roy D.P. 2016. The global Landsat archive: Status, consolidation, and direction. *Remote Sensing of Environment* 185, 271-283.
- Xia Q., Qin C.Z., Li H., Huang C., Su F.Z., Jia M.M. 2020. Evaluation of submerged mangrove recognition index using multi-tidal remote sensing data. *Ecological Indicators* 113, 106196.
- Xiao Y., Xiao Q., Sun X. 2020. Ecological risks arising from the impact of large-scale afforestation on the regional water supply balance in southwest China. *Scientific Reports* 10, 4150.
- Xu H. 2006. Modification of normalized difference water index (NDWI) to enhance open water features in remotely sensed imagery. 2006. *International Journal of Remote Sensing* 27(14), 3025-3033.
- Yunes-Cardenas N., Joyce K.E., Maier S.W. 2017. Monitoring mangrove forests: Are we taking full advantage of technology? *International Journal of Applied Earth Observation and Geoinformation* 63, 1-14.