



CENTRO DE INVESTIGACIONES BIOLÓGICAS
DEL NOROESTE, S.C.

Programa de Estudios de Posgrado

DETECCION REMOTA DE PROLIFERACIONES
ALGALES EN BAJA CALIFORNIA SUR, MÉXICO

TESIS

Que para obtener el grado de

Doctor en Ciencias

Uso, Manejo y Preservación de los Recursos Naturales
(Orientación en Biotecnología)

Presenta

Miguel Ángel Matus Hernández

La Paz, Baja California Sur, abril de 2019

ACTA DE LIBERACIÓN DE TESIS

En la Ciudad de La Paz, B. C. S., siendo las 10:00 horas del día 5 del Mes de abril del 2019, se procedió por los abajo firmantes, miembros de la Comisión Revisora de Tesis avalada por la Dirección de Estudios de Posgrado y Formación de Recursos Humanos del Centro de Investigaciones Biológicas del Noroeste, S. C., a liberar la Tesis de Grado titulada:

"Detección remota de proliferaciones algales en Baja California Sur, México"

Presentada por el alumno:

Miguel Ángel Matus Hernández

Aspirante al Grado de DOCTOR EN CIENCIAS EN EL USO, MANEJO Y PRESERVACIÓN DE LOS RECURSOS NATURALES CON ORIENTACIÓN EN

BIOTECNOLOGÍA

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

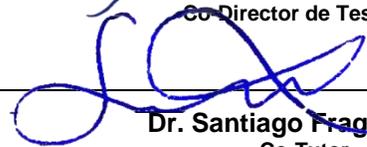
LA COMISIÓN REVISORA



Dra. Norma Y. Hernández Saavedra
Co-Director de Tesis



Dr. Raúl O. Martínez Rincón
Co-Director de Tesis



Dr. Santiago Fraga Rivas
Co-Tutor



Daniel B. Lluch Cota
Co-Tutor

Dr. Salvador E. Lluch Cota
Co-Tutor



Dra. Norma Yolanda Hernández Saavedra,
Directora de Estudios de Posgrado y
Formación de Recursos Humanos

Conformación de Comités

Comité Tutorial

Dra. Norma Yolanda Hernández Saavedra
Centro de Investigaciones Biológicas del Noroeste, S.C.
Co-Director

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

Dr. Santiago Fraga Rivas
Instituto Español de Oceanografía.
Co-Tutor

Dr. Daniel Bernardo Lluch Cota
Centro de Investigaciones Biológicas del Noroeste, S.C.
Co-Tutor

Dr. Salvador Emilio Lluch Cota
Centro de Investigaciones Biológicas del Noroeste, S.C.
Co-Tutor

Comité Revisor de Tesis

Dra. Norma Yolanda Hernández Saavedra
Dr. Raúl Octavio Martínez Rincón
Dr. Santiago Fraga Rivas
Dr. Daniel Bernardo Lluch Cota
Dr. Salvador Emilio Lluch Cota

Jurado de Examen

Dra. Norma Yolanda Hernández Saavedra
Dr. Raúl Octavio Martínez Rincón
Dr. Santiago Fraga Rivas
Dr. Daniel Bernardo Lluch Cota
Dr. Salvador Emilio Lluch Cota

Suplentes

Dr. Fausto Valenzuela Quiñonez
Dr. César Augusto Salinas Zavala

Resumen

El fitoplancton es un importante productor primario que se encuentra en la base de la cadena alimentaria de los ecosistemas marinos y costeros. Sin embargo, nuestra limitada capacidad de monitoreo y comprensión cuantitativa de la distribución de la mayoría de los grupos que lo conforman, limita la capacidad de comprender su contribución al funcionamiento de los ecosistemas. Por ello, se requiere del desarrollo de técnicas modernas que permitan el monitoreo y la comprensión de los mecanismos y procesos que influyen en el dominio de una población dentro de los ecosistemas. En este trabajo se propone el uso de imágenes satelitales de alta resolución espacial (30 m) para el estudio, y su posible uso en el monitoreo, de proliferaciones algales (PA). Para ello, se evaluó la capacidad predictiva de los modelos de regresión (Regresión Lineal Simple [RLS], Regresión Lineal Múltiple [RLM] y Modelos Aditivos Generalizados [MAG]) para estimar la concentración de Clorofila-a (Chl-a) a partir de datos *in situ* y valores de reflectancia de las bandas espectrales de imágenes Landsat 8. Adicionalmente, se evaluaron los patrones de distribución espacial y temporal de cuatro de los principales grupos formadores de proliferaciones algales, encontrados durante un ciclo anual de monitoreo en la Bahía de La Paz (*Tripos*, *Prorocentrum*, *Pseudo-nitzschia* y *Gymnodinium*). De acuerdo a los estadísticos de prueba, el modelo RLM que fue construido con cuatro bandas espectrales (1, 2, 3 y 5) fue considerado el mejor método para predecir la Chl-a, explicando el 87% de la variabilidad de los datos. Los modelos de distribución de especies (MDE) sugieren que los géneros seleccionados presentan una fuerte variabilidad espacial y estacional, observándose la mayor abundancia de *Tripos* y *Gymnodinium* de mayo a junio, *Prorocentrum* de junio a noviembre y *Pseudo-nitzschia* de enero a junio. La evaluación de la capacidad predictiva indica que estos modelos pueden explicar entre 65 y 92% de la variabilidad de los datos de cada uno de los géneros analizados. Los resultados de este trabajo sugieren que las imágenes Landsat 8 podrían aplicarse de manera efectiva para estimar la concentración de Chl-a en ambientes costeros, mientras que los MDE podrían ser una herramienta útil para describir las preferencias de hábitat de las comunidades de fitoplancton, permitiendo, en su conjunto, implementar programas de monitoreo para la detección de PA. En su conjunto, ambas metodologías podrían ser utilizadas como un sistema de alerta temprano para la detección de proliferaciones algales nocivos (PAN) en ecosistemas costeros.

Palabras clave: Fitoplancton, Landsat-8, Detección remota, Modelos de distribución de especies, Clorofila-a


Dra. Norma Y. Hernández Saavedra
Co-Director

Vo. Bo.


Dr. Raúl O. Martínez Rincón
Co-Director

Summary

Phytoplankton is an important primary producer that lies at the base of the food chain of marine and coastal ecosystems. However, our limited ability to monitor and quantitatively understand the distribution of most of the groups that comprise it, limits the capability to understand their contribution to the functioning of ecosystems. Thus, the reason for developing modern techniques required to allow monitoring and understanding the mechanisms and processes that influence the domain of a population within ecosystems. This study used satellite images of high spatial resolution (30 m) proposed for the study and possible use in monitoring algal blooms (AB). For this purpose, the predictive performance of regression models (Simple Linear Regression [SLR], Multiple Linear Regression [MLR] and Generalized Additive Models [GAMs]) was assessed to estimate the concentration of chlorophyll-a (Chl-a) from *in situ* data and reflectance values of the spectral bands of Landsat 8 images. In addition, the spatial and temporal distribution patterns of four of the main algal proliferation (*Tripos*, *Prorocentrum*, *Pseudo-nitzschia* and *Gymnodinium*) groups recorded were assessed during an annual monitoring cycle in the Bahía de La Paz. According to the test statistics, the MRL model that was constructed with four spectral bands (1, 2, 3 and 5) was considered the best method to predict Chl-a, explaining 87% of datum variability. The species distribution models (SDM) suggested that the selected genera had a strong spatial and seasonal variability, observing a greater abundance of *Tripos* and *Gymnodinium* from May to June; *Prorocentrum* from June to November; *Pseudo-nitzschia* from January to June. The assessment of predictive performance indicated that these models could explain from 65-92% of variability of the data of each analyzed genus. The results obtained in this study suggested that Landsat 8 images could be applied effectively to estimate Chl-a concentrations in coastal environments while SDM could be a useful tool to describe habitat preferences of phytoplankton communities, which as a whole, allows implementing monitoring programs for the detection of AB. Together, both methodologies could be used as an early warning system for harmful algal bloom (HAB) detection in coastal ecosystems.

Keywords: Phytoplankton, Landsat 8, Remote sensing, Species distribution models, Chlorophyll-a


Dra. Norma Y. Hernández Saavedra
Co-Director

Vo. Bo.


Dr. Raúl O. Martínez Rincón
Co-Director

Agradecimientos

Al **Centro de Investigaciones Biológicas del Noroeste, S. C.** (CIBNOR) por permitirme realizar mis estudios de posgrado, por el uso de sus instalaciones para la realización de este trabajo y por las facilidades otorgadas para realizar mis estudios de doctorado.

Al **Consejo Nacional de Ciencia y Tecnología** (CONACYT), por la beca (379029) otorgada.

Al personal de posgrado del CIBNOR (Lic. Leticia González, Lic. Osvelia Ibarra, Tania Vázquez, Claudia Olachea y Horacio Sandoval) por hacer más amena la parte burocrática durante mi estancia en el CIBNOR.

A la Dra. Norma Y. Hernández-Saavedra por depositar nuevamente su confianza y creer en mí para realizar este trabajo, así como también por su apoyo y críticas siempre constructivas.

Al Dr. Raúl O. Martínez Rincón, por su tiempo y dedicación a este trabajo, por transmitir sus conocimientos y experiencias, por su invaluable apoyo, consejos, asesorías e innumerables correcciones que hicieron de este un mejor trabajo.

A mi comité tutorial, Dr. Santiago Fraga Rivas, Dr. Daniel Bernardo Lluch Cota y Dr. Salvador Emilio Lluch Cota por sus atinadas observaciones, comentarios y sugerencias que permitieron enriquecer y mejorar la calidad de este trabajo.

A la M.C. Diana Leticia Dorantes Salas por su ayuda y consejos en la edición del inglés de los artículos.

A la M.C. Delia Rojas Posadas por su apoyo, consejos, orientación, y sobre todo por la amistad brindada.

A Todas las personas que participaron en las salidas a campo, Judith Aviña Hernández, Mario Cota Castro, Salvador Meza Jiménez, Horacio Bervera León y Mauricio Pérez Lizárraga, por su entusiasmo y buena disposición que hicieron de esta etapa una gran experiencia llena de anécdotas y momentos inolvidables.

A Arturo Sierra Beltrán, por su apoyo, consejos y por transmitir sus conocimientos y experiencias.

A Cecilia Montes Onofre por el apoyo brindado en cada uno de mis trámites y por la disposición de siempre ayudar.

| | |
|--|-----|
| Contenido | |
| Resumen | i |
| Summary | ii |
| Agradecimientos | iii |
| Contenido | iv |
| Lista de figuras | vi |
| Lista de tablas | vii |
| 1. INTRODUCCIÓN | 1 |
| 2. ANTECEDENTES | 6 |
| 2.1 Percepción remota | 6 |
| 2.2 Color del océano | 7 |
| 2.3 Landsat..... | 11 |
| 2.4 Modelos de distribución de especies..... | 13 |
| 2.5 Detección remota de proliferaciones algales | 15 |
| 3. JUSTIFICACIÓN | 19 |
| 4. HIPÓTESIS | 19 |
| 5. OBJETIVOS | 20 |
| 5.1 Objetivo general: | 20 |
| 5.2 Objetivos específicos:..... | 20 |
| 6. MATERIAL Y MÉTODOS | 21 |
| 6.1 Área de estudio | 21 |
| 6.2 Origen de la información | 22 |
| 6.2.1 Datos de campo | 22 |
| 6.2.2 Imágenes satelitales..... | 24 |
| 6.3 Modelación estadística | 26 |
| 6.3.1 Modelos de Regresión Lineal | 26 |
| 6.3.2 Modelos Aditivos Generalizados | 27 |
| 6.3.3 Estimación de clorofila-a a partir de imágenes Landsat | 28 |
| 6.3.4 Modelos de distribución de especies..... | 29 |
| 6.3.5 Bondad de ajuste y capacidad predictiva de los modelos | 31 |

| | |
|--|-----------|
| 6.3.6 Variabilidad espacio-temporal | 32 |
| 7. RESULTADOS | 33 |
| 7.1 Parámetros ambientales..... | 33 |
| 7.2 Composición de especies de fitoplancton | 34 |
| 7.3 Clorofila-a <i>in situ</i> | 35 |
| 7.4 Estimación de la concentración de clorofila-a basada en imágenes Landsat | 37 |
| 7.4.1 Selección del mejor modelo ajustado | 37 |
| 7.4.2 Evaluación de la capacidad predictiva de los modelos | 38 |
| 7.4.3 Modelo óptimo para la estimación de clorofila-a | 40 |
| 7.4.4 Variabilidad temporal de la clorofila-a estimada | 41 |
| 7.4.5 Variabilidad espacial de la clorofila-a estimada..... | 42 |
| 7.5 Detección de proliferaciones algales | 43 |
| 7.6 Modelación estadística de la comunidad de fitoplancton..... | 45 |
| 7.6.1 Selección del mejor modelo ajustado | 45 |
| 7.7 Preferencias ambientales del fitoplancton | 47 |
| 7.8 Predicción espacial de la abundancia de fitoplancton | 48 |
| 8. DISCUSIÓN | 53 |
| 8.1 Estimación de clorofila-a | 53 |
| 8.2 Relaciones entre los principales grupos de fitoplancton y parámetros ambientales | 56 |
| 9. CONCLUSIONES | 61 |
| 10. LITERATURA CITADA | 62 |
| 11. ANEXOS..... | 77 |

Lista de figuras

| | |
|--|-----------|
| Figura 1. Mapa de localización geográfica del área de estudio..... | 22 |
| Figura 2. Variación estacional de los parámetros ambientales en la superficie de la columna de agua durante el período de estudio. | 34 |
| Figura 3. Abundancia estacional estimada para cada uno de los géneros de fitoplancton identificados en el área de estudio..... | 35 |
| Figura 4. Valores observados de clorofila-a durante un año de monitoreo en el área de estudio.. | 37 |
| Figura 5. Análisis de los residuales de los mejores modelos ajustados RLS (arriba), RLM (centro) y MAG (abajo)..... | 40 |
| Figura 6. Predicciones de Chl-a obtenidas a partir del modelo mejor ajustado y las imágenes Landsat del período 2013 a 2017.. | 42 |
| Figura 7. Predicción espacial de Chl-a ($\mu\text{g}\cdot\text{L}^{-1}$) en el área de estudio, correspondiente al mes de junio del 2013 al 2017..... | 43 |
| Figura 8. Propuesta de un sistema de monitoreo basado en valores de referencia establecidos a partir de un ciclo anual de monitoreo.. | 44 |
| Figura 9. Gráficos de efectos parciales de MAG. A) <i>Triplos</i> , B) <i>Prorocentrum</i> , C) <i>Pseudo-nitzschia</i> , D) <i>Gymnodinium</i> | 48 |
| Figura 10. Predicción espacial estimada mediante MAG para el género <i>Triplos</i> en la Bahía de La Paz..... | 49 |
| Figura 11. Predicción espacial estimada mediante MAG para el género <i>Prorocentrum</i> en la Bahía de La Paz. | 50 |
| Figura 12. Predicción espacial estimada mediante MAG para el género <i>Pseudo-nitzschia</i> en la Bahía de La Paz..... | 51 |
| Figura 13. Predicción espacial estimada mediante MAG para el género <i>Gymnodinium</i> en la Bahía de La Paz..... | 52 |

Lista de tablas

| | |
|---|-----------|
| Tabla I. Especificaciones técnicas de las bandas espectrales y sensores del satélite Landsat 8..... | 13 |
| Tabla II. Modelos de regresión múltiple para parámetros ambientales de la columna de agua de mar, estimados a partir de Landsat 8.. .. | 31 |
| Tabla III. Estadísticos descriptivos de las mediciones <i>in situ</i> de concentraciones de clorofila-a..... | 36 |
| Tabla IV. Bondad de ajuste de los tres modelos RLS, RLM y MAG mejor ajustados, respectivamente, para la estimación de Chl-a transformada mediante el uso de la función logaritmo natural. | 38 |
| Tabla V. Desempeño predictivo de los tres RLS, RLM y MAG mejor ajustados, aplicados para estimar valores de Chl-a transformada a mediante el uso de la función logaritmo natural..... | 39 |
| Tabla VI. Estadísticos descriptivos de los coeficientes del mejor modelo ajustado para la estimación de Chl-a..... | 41 |
| Tabla VII. Estadísticos de evaluación del desempeño predictivo de los modelos MAG..... | 46 |

1. INTRODUCCIÓN

Los ambientes costeros son ecosistemas marinos que se caracterizan por presentar una amplia gama de hábitats que albergan la mayor diversidad de especies, como fitoplancton, zooplancton, pastos marinos, arrecifes de coral, etc. (Kaliraj *et al.*, 2019; Mishra y Gould, 2016). Dentro de los ecosistemas marinos, el fitoplancton es un importante productor primario que se encuentra en la base de la cadena alimentaria que contribuye a los principales recursos pesqueros. Sin embargo, nuestra limitada capacidad de monitoreo y comprensión cuantitativa de la distribución de la mayoría de los grupos que lo conforman, limita la capacidad de comprender su contribución al funcionamiento de los ecosistemas (Flombaum *et al.*, 2013). En consecuencia, existe la necesidad de métodos precisos, rentables, frecuentes y sinópticos que permitan obtener información sobre la variación y abundancia espacio-temporal de grupos funcionales para caracterizar y monitorear estos ecosistemas complejos (McClain, 2009; Mishra y Gould, 2016).

La estructura de la comunidad, la composición y la diversidad de especies de fitoplancton, se encuentran determinadas por diversos parámetros físico-químicos como temperatura, salinidad, pH, nitrato, nitrito, amoníaco, silicatos, fosforo, etc. (Duarte *et al.*, 2006; Madhu *et al.*, 2007; Sin *et al.*, 1999; Vajravelu *et al.*, 2018). Así como también, por factores externos como la presión atmosférica y el viento, que afectan principalmente a las corrientes y la turbulencia (Ghinaglia *et al.*, 2004). Sin embargo, las especies de fitoplancton pueden ser muy sensibles ante pequeñas variaciones de uno o más parámetros ambientales de su entorno, respondiendo de manera rápida y exhibiendo un efecto diferencial en su distribución y abundancia (Shekhar *et al.*, 2008); en este sentido, el conocimiento de los factores que controlan la distribución espacial y temporal de las especies de fitoplancton, es un requisito esencial para comprender los mecanismos y los procesos que influyen en el dominio de una determinada población dentro de los ecosistemas (Reiss *et al.*, 2011; Smayda y Reynolds, 2001). A menudo, estos

requisitos son abordados con información fragmentada sobre las especies y los hábitats, principalmente en ambientes marinos donde la información es más difícil de controlar; siendo los métodos de regresión una herramienta ampliamente utilizada para realizar predicciones cuantitativas de las distribuciones de las especies (Austin, 2007; Reiss *et al.*, 2011).

En la actualidad existe un amplio interés en el estudio de los ecosistemas costeros, cuya variabilidad ambiental ha sido descrita utilizando métodos tradicionales, como la medición de las propiedades físicas, químicas y biológicas *in situ*, que ofrecen la generación de datos detallados en escalas temporales y espaciales delimitadas; sin embargo, presenta grandes limitaciones debido a que demanda altos costos (en equipos de medición y trabajo de campo) y tiempos de ejecución; aunado a esto, la dinámica compleja que existe en estos ecosistemas hace que los protocolos y las mediciones *in situ* no sean del todo efectivas y sólo representan estimaciones puntuales en tiempo y espacio, siendo difícil identificar variaciones espaciales o temporales (Gholizadeh *et al.*, 2016; Miller *et al.*, 2007). En consecuencia existe la necesidad del desarrollo de técnicas modernas, como alternativa a los métodos tradicionales para caracterizar y monitorear la variabilidad ambiental de estos ecosistemas complejos.

El monitoreo de la zona costera abarca un gran número de disciplinas y en este estudio, se presenta un enfoque sobre el uso de técnicas de detección remota; las cuales en las últimas décadas se han convertido en herramientas útiles que han permitido tener un mayor acercamiento a la complejidad de diversos procesos costeros, gracias a los avances en la ciencia espacial y el uso de aplicaciones informáticas a partir de computadoras de mayor capacidad, proporcionando así, una herramienta que puede ser utilizada para estimar características ópticas relacionadas con parámetros ambientales de diversos cuerpos de agua (Gens, 2010; Gholizadeh *et al.*, 2016; Miller *et al.*, 2007). Si bien la capacidad de los sensores remotos para el estudio de ambientes costeros es

innegable, esta técnica por sí sola no es suficientemente precisa y se debe utilizar de manera integrada con métodos de monitoreo tradicionales (Gholizadeh *et al.*, 2016; McCarthy *et al.*, 2017).

Los sensores de color del océano se utilizan ampliamente por su contribución a la comprensión de diferentes aspectos ambientales, como las propiedades físicas, químicas y biológicas del agua. Dentro de los principales sensores utilizados para el estudio de ambientes marinos se encuentran el escáner de color de la zona costera (CZCS, por sus siglas en inglés), que midió la reflectancia en 6 bandas espectrales con una resolución espacial de 825 m y se mantuvo en operación de 1978 a 1986; el sensor de campo de visión amplia para la observación del mar (SeaWiFS, por sus siglas en inglés) que estuvo operando de 1997 al 2010 y midió la reflectancia en 8 bandas espectrales con una resolución espacial de 1.1 a 4.5 km; el espectroradiómetro de imágenes de resolución moderada (MODIS, por sus siglas en inglés), que es un sensor lanzado a bordo del satélite Terra (1999) y AQUA a partir del 2002), que obtiene información a partir de 9 bandas espectrales a una resolución espacial de 250, 500 y 1000 m; el espectroradiómetro de imágenes de resolución media (MERIS, por sus siglas en inglés) que fue un sensor que estuvo en operación del 2002 al 2012 y obtuvo información en 15 bandas espectrales a una resolución espacial de 300 m y el radiómetro de imágenes del visible al infrarrojo (VIIRS, por sus siglas en inglés) que fue puesto en órbita en octubre del 2011, tiene 22 bandas espectrales que van desde los 412 nm hasta los 12 μm , con una resolución espacial de 750 y 350 (Nazeer y Nichol, 2016; Shen *et al.*, 2012; Zhao *et al.*, 2015). A partir de estos sensores se han desarrollado una amplia variedad de algoritmos para estimar parámetros ambientales tales como: clorofila-a (Chl-a), temperatura superficial del mar (TSM), sólidos totales en suspensión (TSS), turbidez, salinidad (Sal), fósforo total (TP), profundidad del disco Secchi (PDS), pH, carbono orgánico disuelto (COD), materia orgánica disuelta coloreada (MODC) y oxígeno disuelto (OD), etc. (Gholizadeh *et al.*, 2016; McCarthy *et al.*, 2017).

La medición de la reflectancia espectral de cuerpos de agua mediante sensores remotos, es un método que se ha aplicado de manera eficaz para monitorear el fitoplancton, debido a sus características espectrales únicas generadas por los pigmentos fotosintéticos (Klemas, 2012). La clorofila es el pigmento fotosintético presente en todas las algas y se ha utilizado como una aproximación para construir herramientas de monitoreo. Investigadores han demostrado que el aumento de la concentración de Chl-a causa una disminución en la respuesta espectral de longitudes de onda cortas, particularmente en la banda azul y un gran número de estudios se han centrado en la estimación de la concentración de Chl-a mediante algoritmos generados a partir de sensores de primera y segunda generación (CZCS y SeaWiFS) (O'Reilly *et al.*, 1998; Tyler y Stumpf, 1989; Yoder *et al.*, 2001). Sin embargo, la mayoría de los enfoques desarrollados son para ambientes oceánicos, donde el fitoplancton y sus productos de descomposición son los únicos que determinan las propiedades ópticas del agua, y no se encuentran desarrollados para su aplicación en aguas costeras ópticamente complejas, debido a que la absorción de la materia orgánica tiende a enmascarar la región espectral azul-verde (Gholizadeh *et al.*, 2016).

En aguas costeras e interiores, la región roja del espectro electromagnético es importante para la detección de concentraciones de Chl-a, se ha reportado la existencia de un pico de reflectancia cerca de los 700 nanómetros (nm), que en comparación con otras proporciones, permite la discriminación del fitoplancton con respecto a otros componentes de la columna de agua y basados en la fluorescencia de la clorofila obtenida a partir de sensores de tercera generación (MODIS y MERIS), se han desarrollado una amplia variedad de enfoques y algoritmos para estimar concentraciones de Chl-a en aguas ópticamente complejas (Gitelson, 1992; Gitelson *et al.*, 2008; Gower *et al.*, 2005; Zhao *et al.*, 2010). Algunos de los cuales han sido propuestos por diversos autores como una opción viable para la detección y el uso potencial en la predicción de proliferaciones algales, esto debido a que comparado con los métodos

convencionales ha demostrado ser más eficaz en tiempo y costo, gracias a su amplia cobertura espacial y temporal sobre grandes escalas, aunado a esto las detecciones por satélite pueden abarcar regiones de difícil acceso para los seres humanos (Cullen *et al.*, 1997; Stumpf, 2001; Tyler y Stumpf, 1989).

A pesar de la existencia de una gran variedad de sensores disponibles para la evaluación de la calidad del agua, las imágenes Landsat han sido ampliamente utilizadas debido a su bajo costo, cobertura temporal y resolución espacial, lográndose desarrollar con éxito una variedad de índices espectrales basados en la información obtenida de una sola banda, combinación de bandas o la relación de cada una de las bandas presentes en este satélite, los cuales se han convertido en un gran esfuerzo para el monitoreo a escala global, regional y local (Boucher *et al.*, 2018; Gholizadeh *et al.*, 2016). Lográndose estimar importantes parámetros ambientales como Chl-a, temperatura, oxígeno disuelto, fósforo total, partículas totales suspendidas, turbidez, salinidad, pH (Aviña-Hernández, 2018; Boucher *et al.*, 2018; Brivio *et al.*, 2001; Giardino *et al.*, 2001; Patra *et al.*, 2016). No obstante, a pesar del gran esfuerzo que se ha invertido en el desarrollo de algoritmos confiables para estimar la calidad del agua a partir de datos espectrales, sigue siendo un desafío estimar con precisión cada uno de estos parámetros, aunado a esto los algoritmos no pueden aplicarse de manera precisa en cuerpos de agua fuera del área de estudio original (Ligi *et al.*, 2017), debido a que cada uno de los cuerpos de agua presenta características bio-ópticas particulares. Sin embargo, la combinación de bandas puede ser apropiada, implementándose nuevas validaciones *in situ*.

En la actualidad existe una perspectiva limitada sobre la distribución de las especies ante los cambios ecológicos y climáticos, por lo que existe la necesidad de comprender las respuestas de las especies y las comunidades ante estos cambios, con la finalidad de predecir los patrones de biodiversidad (Maguire *et al.*, 2015). En años recientes una de las herramientas ampliamente utilizadas en la

ecología, son los modelos de distribución de especies (MDS). Los MDS son herramientas numéricas que combinan información de presencia o abundancia de especies con las condiciones ambientales en que se encuentran, para predecir el rango potencial de distribución geográfico y ambiental, proporcionando un enfoque potencialmente rentable para el estudio de grandes áreas (Elith y Leathwick, 2009; Robinson *et al.*, 2017). Los MDS se han utilizado en ambientes terrestres, de agua dulce y marinos, con una amplia gama de aplicaciones, dentro de las cuales se incluye evaluaciones de impacto del cambio climático sobre la biodiversidad, epidemiología, identificación de áreas para la conservación, estudio de especies crípticas, localización de poblaciones de especies poco conocidas, el estudio de especies en peligro de extinción, selección de áreas de conservación, determinar riesgo de especies invasoras, etc. (Eaton *et al.*, 2018; Fois *et al.*, 2018; Robinson *et al.*, 2017; Rodríguez *et al.*, 2007).

En este contexto, la presente investigación aportará información sobre el uso de imágenes satelitales de alta resolución espacial obtenidas del satélite Landsat 8, como una herramienta de rutina para la evaluación de los cambios en la concentración de Chl-a y la distribución y abundancia de los principales grupos de fitoplancton presentes en las zonas costeras. Esto podría sentar las bases para la implementación de programas de monitoreo de eventos de proliferaciones algales y como uno de los primeros esfuerzos para describir las preferencias de hábitat de las comunidades de fitoplancton a nivel de microescala (30 m).

2. ANTECEDENTES

2.1 Percepción remota

La detección remota se puede definir como la recopilación de información relacionada a objetos sin estar en contacto físico con ellos, y se refiere al esfuerzo multifacético y multidisciplinario para adquirir información sobre las características de la superficie de la Tierra y la estimación de sus propiedades geo-biofísicas

utilizando la radiación electromagnética como medio de interacción (Clark y Rilee, 2010; Khorram *et al.*, 2016; Reddy, 2018). La radiación electromagnética, se define como la energía que se mueve con la velocidad de la luz en un patrón de onda armónico (es decir, espaciadas de manera equitativa y repetitiva en el tiempo) y se representa mediante el espectro electromagnético, que abarca desde longitudes de onda cortas (rayos gamma) hasta longitudes de onda más largas (ondas de radio) (Khorram *et al.*, 2016; Reddy, 2018).

La mayoría de los sensores registran información de la superficie de la Tierra midiendo la transmisión de energía (reflectancia) en diferentes regiones del espectro electromagnético y como la superficie de la Tierra varía en la naturaleza, cada objeto o material tiene propiedades particulares de emisión y/o reflectancia, conocidas como firma espectral, que lo distingue de otros objetos y materiales. Esta variación en la energía permite crear múltiples imágenes tomadas al mismo tiempo y cada una de las regiones exploradas del espectro electromagnético se denominan “bandas”, que se identifican en nanómetros (nm) (Khorram *et al.*, 2016; Reddy, 2018).

En la actualidad, se han implementado una gran variedad de sensores en numerosos satélites y plataformas aéreas que recopilan grandes cantidades de datos de diversas características en resolución espectral, espacial, radiométricas y temporales alrededor de todo el mundo [Ver (Gholizadeh *et al.*, 2016; McCarthy *et al.*, 2017)]; Información que es utilizada comúnmente en las áreas de gestión ambiental, recursos naturales, calidad del agua, cambio climático, gestión de desastres, inteligencia militar, etc. (Khorram *et al.*, 2016; McCarthy *et al.*, 2017).

2.2 Color del océano

El color del agua, es decir la radiación espectral que emite el agua, es el resultado de la dispersión y absorción de la luz visible por el agua pura, así como

por las propiedades de componentes orgánicos e inorgánicos particulado y disuelto presente en el agua (Hu *et al.*, 2005; Sathyendranath *et al.*, 2000). Para la detección remota de las propiedades bio-ópticas, la superficie del agua ha sido clasificada en dos tipos (Caso I y Caso II), basados en la variabilidad óptica de las propiedades presentes en la columna de agua (Morel y Prieur, 1977). Las aguas de Caso I, representan las áreas oceánicas profundas, lejos de la influencia terrestre, son ópticamente menos complejas y se han definido como aquellas donde el fitoplancton y sus derivados son la principal influencia en el campo óptico; mientras que las aguas de Caso II representan a las aguas costeras e interiores más turbias, tienden a tener constituyentes ópticos independientes de los niveles de fitoplancton y son ópticamente complejas (Miller *et al.*, 2007; Sathyendranath, 2000).

En cualquier cuerpo de agua, la mayoría de la radiación que incide sobre su superficie no se refleja, es transmitida o absorbida selectivamente y retrodispersada por los componentes del agua, pasando nuevamente por la superficie; considerándose como una muestra derivada del campo de luz subacuática y al estudiarla con instrumentos de detección sobre la superficie, se puede obtener información sobre ese campo y, por lo tanto, sobre los componentes ópticamente significativos del medio (Kirk, 1994; Liu *et al.*, 2003; Reddy, 2018). La detección remota implica el análisis de las variaciones en la magnitud y la calidad espectral de la radiación que refleja el agua, para obtener información cualitativa y cuantitativa sobre el tipo de sustancias presentes en el agua (Sathyendranath, 2000). La luz que es capturada por un sensor, comprende dos componentes: energía dispersada por la atmosfera, considerada como ruido y la energía radiante reflejada por el cuerpo de agua, que es el indicativo de las propiedades ópticas inherentes de los constituyentes de la columna de agua luz (Liu *et al.*, 2003). Estos componentes crean una amplia variación en la reflectancia espectral y basados en el conocimiento de sus características espectrales, se han

desarrollado modelos de reflectancia y algoritmos de color del océano para estimar las propiedades del agua a partir de sensores remotos.

La función principal de los sensores es captar la radiación electromagnética incidente y convertirla en una representación almacenada útil para el análisis de detección remota. Estos sensores operan en la región óptica del espectro electromagnético definido como radiación, con longitudes de onda entre 400 y 15000 nm, en este rango incluye la parte visible (400 a 700 nm), el infrarrojo cercano (NIR, 700 a 1100 nm), el infrarrojo corto (SWIR, 1100 a 2500 nm), el infrarrojo de onda media (MWIR, 2500 a 7500 nm) y el largo de onda infrarrojo (LWIR, 7500 a 15000 nm) (Teodoro, 2016). Los satélites y sensores ópticos con distintos grados de resolución espacial, espectral y temporal más relevantes utilizados en el estudio de los ambientes costeros son el CZCS, SeaWiFS, MODIS y MERIS, estos sensores están optimizados para medir la reflectancia de la mayoría de los océanos, pero no para ambientes costeros y aguas interiores, sin embargo, proporcionan imágenes de color del océano que se han aplicado con éxito en la estimación de parámetros ambientales como la clorofila y la temperatura superficial del mar (Shen *et al.*, 2012; Teodoro, 2016).

La clorofila es ciertamente uno de los parámetros más comúnmente obtenidos a partir de las imágenes satelitales, y diversas técnicas y algoritmos han sido aplicados para estimar la concentración de Chl-a en diversos ambientes. La Chl-a, el pigmento fotosintético primario en el fitoplancton presenta dos picos de absorbancia cerca de 450 nm (azul) y 680 nm (rojo), un máximo de reflectancia cerca de los 550 nm (verde) y alrededor de 690 a 700 nm del espectro electromagnético, haciendo que el color del océano cambie progresivamente de azul a verde, a medida que incrementa la concentración de fitoplancton, debido a que las altas concentraciones de clorofila reducen la reflectancia en longitudes de onda azules e incrementa en el verde (Babin *et al.*, 2008; Gitelson, 1992; Jensen, 2007; O'Reilly *et al.*, 1998).

La Chl-a se ha estudiado ampliamente en diversas ubicaciones geográficas, en la literatura existen reportes de trabajos que demuestran el uso efectivo de imágenes satelitales para estimar concentraciones de Chl-a. O'Reilly *et al.* (1998) evaluaron la eficiencia, precisión y la idoneidad de 2 algoritmos semianalíticos y 15 empíricos, para estimar la concentración de Chl-a a partir de imágenes SeaWiFS, obteniendo la mejor capacidad predictiva con el algoritmo formado por la relación de cuatro bandas (443, 490, 510, 555 nm), estableciendo un nuevo enfoque en los algoritmos empíricos.

Yoder *et al.* (2001) utilizaron correlaciones lineales múltiples, funciones de estructura y funciones ortogonales empíricas para analizar patrones temporales y espaciales de la concentración de Chl-a superficial en la costa este de Estados Unidos, a partir de información obtenida del sensor CZSC, mediante un algoritmo bio-óptico de 3 bandas (443, 520 y 550 nm), reportando una alta variabilidad en escalas de tiempo de días a semanas, baja variabilidad interanual y una alta coherencia espacial en el componente estacional.

Gitelson *et al.* (2008), evaluaron el uso de un modelo para la estimación de Chl-a en aguas turbias (Caso II). El modelo relaciona la concentración de Chl-a con la reflectancia (λ) en dos bandas espectrales del sensor MODIS ($\lambda_1 = 662$ a 672 , $\lambda_3 = 743$ a 753 nm), la relación entre la Chl-a estimada y la cuantificada *in situ* fue de $r^2 = 0.99$ y un error cuadrático medio (RMSE) = 2.78 mgm^{-3} , demostrando que es posible estimar la concentración de Chl-a en aguas turbias mediante el uso de longitudes de onda roja e infrarrojo cercano (NIR).

González *et al.* (2011) basados en técnicas de redes neuronales, desarrollaron algoritmos para la estimación de la concentración de Chl-a en ambientes costeros, a partir de información obtenida de imágenes MERIS y datos *in situ*. El modelo que presentó la mejor capacidad predictiva obtuvo un $R^2 = 0.86$ y $\text{RMSE} = 0.75 \text{ mgm}^{-3}$, detectando con precisión valores de Chl-a y demostrando

que las imágenes satelitales combinadas con datos in situ es un método eficaz y confiable para la obtención de mapas de Chl-a.

Recientemente se ha implementado el uso de plataformas multiespectrales de nueva generación con una resolución espectral más alta comparada con los sensores tradicionales, potencialmente viables para el desarrollo de algoritmos que permiten el estudio de parámetros de calidad del agua, dentro de estos satélites se encuentra WorldView-2, quien realiza operaciones desde el 2009, cuenta con 8 bandas multiespectrales de 1.9 m de resolución y ha sido utilizado para estudios de sedimentos suspendidos (Dorji y Fearn, 2017); IKONOS, puesto en órbita en 1999 y captura imágenes a una resolución espacial de 1 y 4 m y ha sido utilizado para estimar parámetros de calidad del agua, obteniendo valores de correlación altos [$R > 0.97$] (Ekercin, 2007); Sentinel-2, fue lanzado en el 2015, es el primer satélite en observar la zona costera a una resolución espacial de 10, 20 y 60 m, con una resolución temporal de 5 días y ha sido utilizada para medir parámetros de calidad del agua como: la transparencia (Bonansea *et al.*, 2018) y partículas suspendidas (Caballero *et al.*, 2018; Gernez *et al.*, 2015), obteniendo resultados prometedores para el estudio de los ecosistemas costeros.

2.3 Landsat

La serie de satélites Landsat de la NASA, fue el primer programa específicamente diseñado para la detección remota de las características ambientales de la Tierra y ha estado monitoreando durante más de cuatro décadas, siendo el satélite que proporciona un registro temporal de imágenes multiespectrales más largo de la historia. La primera versión (Landsat 1) fue lanzado en 1972 y años posteriores fueron lanzadas las misiones Landsat 2, 3, 4, 5, y 7, que proporcionaron observaciones de longitud de onda térmica y reflectiva de cobertura casi global con un aumento de la fidelidad espectral y espacial, que

ha sido ampliamente utilizado para diversas aplicaciones, gubernamentales, públicas y privadas (Roy *et al.*, 2014; Zanter, 2018).

El último satélite de esta serie es Landsat 8, el cual fue puesto en órbita el 11 de febrero del 2013 y hasta la fecha continua en operación. El satélite mantiene una órbita polar heliosíncronica, a una altura de 705 km, los datos son adquiridos en franjas de 185 km y posteriormente segmentadas en 185 km×180 km, con una resolución temporal de 16 días (Roy *et al.*, 2014). Landsat 8 es un satélite equipado con dos sensores el primero de ellos denominado Operational Land Imager (OLI) y el segundo Thermal Infrared Sensor (TIRS). En total el satélite mide la reflectancia en 11 longitudes de onda del espectro de la luz (Tabla I). El sensor OLI recopila datos en 9 bandas espectrales (B01 a B09) que abarcan desde el espectro ultravioleta, visible, infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR), con una resolución de 15 m en pancromático (B08) y de 30 m en las otras bandas. Esta nueva versión, comparada con las anteriores cuenta con dos bandas adicionales que miden la reflectancia cerca del ultravioleta (B01, aerosol/costero) y el infrarrojo de onda corta (B09), que fueron diseñadas específicamente para observaciones de zonas costeras y para detectar nubes respectivamente. El sensor TIRS mide la temperatura de la superficie terrestre mediante dos bandas del infrarrojo térmico (10 y 11), a una resolución de 100 m (Zanter, 2018).

Los sensores OLI y TIRS obtienen datos de forma conjunta para proporcionar imágenes de la superficie terrestre, incluyendo las regiones costeras, hielo polar, las islas y zonas continentales (Jiménez-Muñoz *et al.*, 2014). Aunque este satélite está diseñado para el estudio de procesos terrestres y limitado en resolución espectral y temporal para aplicaciones oceánicas, su alta resolución espacial (30 m) lo hace ideal para aplicaciones en cuerpos de agua pequeños (Joshi y D'Sa, 2015). Estudios recientes han demostrado el amplio potencial de las imágenes Landsat en lagos y ambientes costeros (bahías y ensenadas); basados

en las correlaciones existentes entre la reflectancia de las bandas y las diversas propiedades del agua, como son: la transparencia a partir del disco de Secci (SDT) (Dekker y Peters., 1993; Kloiber *et al.*, 2002; Masocha *et al.*, 2017); concentración de sedimentos suspendidos (Kong *et al.*, 2015; Ouillon *et al.*, 2008; Schiebe *et al.*, 1992; Teodoro, 2016); turbidez (Brezonik *et al.*, 2005; Hellweger *et al.*, 2004; Masocha *et al.*, 2017; Olmanson *et al.*, 2008); el estudio de materia orgánica disuelta (CDOM) (Brezonik *et al.*, 2005; Griffin *et al.*, 2011; Joshi y D'Sa, 2015; Slonecker *et al.*, 2016), el estudio de proliferaciones de macroalgas (Xing y Hu, 2016) y para cuantificar la concentración de Chl-a (Allan. *et al.*, 2011; Allan *et al.*, 2015; Giardino *et al.*, 2001; Han y Jordan, 2005; Kim *et al.*, 2016; Masocha *et al.*, 2017).

Tabla I. Especificaciones técnicas de las bandas espectrales y sensores del satélite Landsat 8.

| Sensor | Banda | Resolución espectral (micrómetros) | Resolución espacial (metros) |
|--------|--------------------------------|---------------------------------------|---------------------------------|
| OLI | B01 – Aerosol costero | 0.43-0.45 | 30 |
| | B02 – Azul | 0.45-0.51 | 30 |
| | B03 – Verde | 0.53-0.59 | 30 |
| | B04 – Rojo | 0.64-0.67 | 30 |
| | B05 – Infrarrojo cercano (NIR) | 0.85-0.88 | 30 |
| | B06 – SWIR 1 | 1.57-1.65 | 30 |
| | B07 – SWIR2 | 2.11-2.29 | 30 |
| | B08 – Pancromático | 0.50-0.68 | 15 |
| | B09 – Cirrus | 1.36-1.38 | 30 |
| TIRS | B10 - Infrarrojo térmico 1 | 10.60-11.19 | 100 |
| | B11 - Infrarrojo térmico 2 | 11.50-12.51 | 100 |

2.4 Modelos de distribución de especies

Los modelos de distribución de especie (MDE), son una herramienta que se utiliza ampliamente en ecología para describir la distribución geográfica de las especies y sus preferencias ambientales. En ambientes marinos, estos modelos han sido aplicados para varios organismos como el fitoplancton (Barton *et al.*,

2016; Irwin *et al.*, 2012; Jensen *et al.*, 2017; Krug *et al.*, 2018). Los MDE han evolucionado desde la aplicación de modelos lineales simples a métodos más complejos, aumentando el número de estudios que comparan el rendimiento y las predicciones de los modelos por múltiples métodos, demostrando que es posible proporcionar predicciones espaciales y temporales confiables (Grenouillet *et al.*, 2011; Jensen *et al.*, 2017). Debido a que la información detallada y precisa sobre la distribución espacial de las especies en grandes áreas y en múltiples períodos de tiempo es fundamental para una respuesta rápida y una gestión eficaz sobre cambios ambientales (Chen *et al.*, 2018).

Los principales enfoques estadísticos que se utilizan comúnmente son modelos lineales generalizados (MLG), modelos aditivos generalizados (MAG), genéticos (algoritmo genético para la producción de conjuntos de reglas, GARP) y algoritmos de aprendizaje automático como MaxEnt (Wiens *et al.*, 2009). En la última década, varios estudios han sido desarrollados para llevar a cabo estimaciones globales de la estructura del fitoplancton, utilizando detección remota debido a que las comunidades de fitoplancton marino parecen sensibles al cambio climático, pero la comprensión de cómo las especies de manera individual pueden responder ante el cambio climático antropogénico sigue siendo limitada. Barton *et al.* (2016), a partir de observaciones históricas de parámetros ambientales y fitoplancton, caracterizaron el nicho ecológico de 87 taxones de diatomeas y dinoflagelados, para proporcionar una estimación de la dirección y magnitud de los cambios biogeográficos y de la composición de la comunidad, observando que debido al efecto del cambio climático antropogénico la biogeografía de las especies se encuentra en constante cambio y el 74% de los taxones analizados se desplazan hacia los polos en una tasa promedio de 12.9 km por década.

De igual manera Jensen *et al.* (2017) examinaron el potencial de los MDS para describir la distribución global actual y futura de dos especies de fitoplancton, *Chaetoceros diadema* y *Emiliana huxleyi*. Los resultados sugieren que los

cambios en las condiciones ambientales de las próximas décadas podrían disminuir el área de distribución de estas especies en un 8 y 16 % respectivamente, demostrando que los MDE pueden ser una herramienta viable para describir las distribuciones de fitoplancton. Townhill *et al.* (2019) utilizaron MDE para analizar la respuesta de las especies productoras de eventos de proliferaciones ante el cambio climático y establecer qué especies serán más o menos problemáticas en el futuro. Las proyecciones sugieren que el hábitat de la mayoría de las especies se encuentra definido por la temperatura, la salinidad, la profundidad y la estratificación.

Estos estudios demuestran que los SDM son una herramienta viable para describir las distribuciones de fitoplancton y tiene implicaciones en diversas áreas como acuicultura y esquemas de protección de la salud, dando prioridad al monitoreo de especies en áreas susceptibles, lo que permitiría establecer sistemas de alerta temprana, mediante la implementación de medidas de vigilancia y mitigación.

2.5 Detección remota de proliferaciones algales

Numerosos esfuerzos de monitoreo han sido llevados a cabo para documentar el origen, destino, duración, frecuencia y distribución de proliferaciones algales, la mayoría de los cuales se basa en mediciones de campo y taxonomía para identificar entre especies y determinar la concentración individual, siendo limitados tanto en espacio como en tiempo (Hu *et al.*, 2005). Una de las estrategias para minimizar esto ha sido el estudio de estos eventos mediante sensores satelitales de color del océano, que brindan cobertura sinóptica del océano. Como resultado se han desarrollado diversos algoritmos para medir índices de biomasa de fitoplancton, concentración de Chl-a y diversos parámetros de la columna de agua, basados en la relación que existe entre la reflectancia de diferentes longitudes de onda a partir de sensores diseñados específicamente

para el monitoreo de ambientes marinos, tales como el sensor CZCS (Antoine *et al.*, 1996), SeaWiFS (O'Reilly *et al.*, 2000); MERIS (González *et al.*, 2011), MODIS (Gitelson *et al.*, 2008; Liu y Wang, 2013). Generándose importantes logros en la detección y caracterización de la localización y extensiones de las proliferaciones, a partir diversos modelos numéricos que ofrecen simulaciones que permiten una importante oportunidad de comprender los mecanismos que regulan el inicio y la evolución de la formación de proliferaciones en diversas regiones del mundo (Cannizzaro *et al.*, 2008; Carvalho *et al.*, 2010; He *et al.*, 2008; McGillicuddy *et al.*, 2011; Olascoaga *et al.*, 2008; Schofield *et al.*, 1999; Stumpf *et al.*, 2003; Tomlinson *et al.*, 2004).

El uso potencial de los sensores remotos para la detección de eventos de proliferaciones, fue demostrado por Steidinger y Haddad (1981) quienes se encuentran dentro de los pioneros en utilizar concentraciones de Chl-a a derivada de imágenes satelitales del sensor CZCS para el estudio de eventos de proliferaciones algales. Recientemente investigadores han demostrado que el aumento en la concentración de Chl-a presenta una correlación con la respuesta espectral de ciertas longitudes de onda, centrando sus estudios en la cuantificación de Chl-a. Stumpf *et al.* (2003) propusieron el uso de anomalías en la concentración de Chl-a estimadas a partir de imágenes SeaWiFS, como un indicador de un potencial evento de proliferación algal. Las anomalías fueron determinadas como la diferencia entre el valor observado y la media de 2 meses anteriores y fue implementado con éxito en un programa para el monitoreo de *Karenia brevis* en la región de Florida. De igual manera Hu *et al.* (2005) utilizó información de las proporciones de las bandas 443/555, 490/555 y 520/55 nm del sensor MODIS para detectar y monitorear un evento de proliferación, obteniendo una alta correlación ($r = 0.92$) con la concentración de Chl-a in situ. Carvalho *et al.* (2010), desarrollaron la propuesta de un algoritmo múltiple para llevar a cabo mejoras en la predicción de eventos de proliferaciones. El algoritmo fue realizado utilizando una serie de datos MODIS, logrando identificar correctamente eventos

de proliferaciones con una eficiencia de hasta un 80%, mismos que fueron validados mediante datos de campo.

Sin embargo, la concentración de Chl-a no es suficiente para discriminar entre varias proliferaciones (Tomlinson *et al.*, 2004), por lo que la detección remota y el monitoreo de organismos causantes de proliferaciones algales ha tomado diversos enfoques. Se han desarrollado técnicas para detectar grupos fitoplanctónicos con firmas espectrales únicas o proliferaciones de alta biomasa asociada con una sola especie, como el caso de *Karenia brevis* en el Golfo de México, donde se han utilizado una amplia variedad de enfoques, que van desde la detección de anomalías de la biomasa hasta el modelado bio-óptico más complejo, aplicado con éxito en el monitoreo de eventos de proliferaciones. Cannizzaro *et al.* (2002) determinaron que las proliferaciones de *K. brevis* tiene propiedades de retrodispersión más bajas que las proliferaciones de otras especies de fitoplancton como las diatomeas y dinoflagelados, y propusieron un nuevo algoritmo para identificar proliferaciones, sin embargo esta separación sólo es efectiva en cuerpos de agua con bajas concentraciones de materia orgánica disuelta.

Anderson *et al.* (2009) a partir de modelos estadísticos alimentados con información de los sensores MODIS-Aqua, SeaWiFS y AVHRR estimaron la probabilidad de detectar eventos de proliferaciones de *Pseudo-nitzschia*. La información fue utilizada para definir rangos de condiciones ambientales asociadas con *Pseudo-nitzschia spp* y los modelos presentaron una eficiencia del 98%, con una tasa de 7 a 29% de falsos positivos. Kin *et al.* (2009) propusieron la aplicación de un nuevo algoritmo para la detección de proliferaciones, basado en los datos normalizados de la radiación del agua y de la temperatura superficial del mar, obtenidos del sensor MODIS, logrando detectar la ubicación y distribución de un evento de *Margalefidinium polykrikoides*, mejorando con ello la precisión que se tiene al emplear algoritmos que usan solamente Chl-a.

Lou y Hu (2014), desarrollaron un índice de marea roja a partir de la reflectancia de las bandas 443, 490 y 555 nm de del generador geoestacionario de imágenes a color del océano (GOCI, por sus siglas en inglés) para estudiar la evolución de un evento de proliferación de *Prorocentrum donghaiense* en aguas costeras(turbias), logrando dar seguimiento espacial y temporal a este evento durante dos días. Y recientemente Shin *et al.* (2018) determinaron que es posible detectar eventos de proliferaciones de *Margalefidinium polykrikoides* a partir de espectros de marea roja obtenidos de múltiples sensores; los cuales son similares a los valores encontrados en la forma espectral calculada a partir de espectros *in situ* y de la abundancias de células de *M. polykrikoides*, observando que la sensibilidad en la detección de estos eventos incrementa cuando se utilizan datos de múltiples sensores comparados con el uso de sensores únicos.

A pesar de las múltiples ventajas de los sensores de color del océano sobre los métodos tradicionales, estos métodos aun presentan ciertas desventajas o limitaciones como la como las incertidumbres en la corrección atmosférica, la interferencia de materia orgánica y la presencia de otros tipos de fitoplancton, algunas especies de proliferaciones tienen señales débiles de clorofila, no se puede determinar si las proliferaciones son tóxicas y muy pocos son los estudios que se han enfocado en el desarrollo de algoritmos para la detección de grupos fitoplanctónicos específicos, la información a menudo no se puede adquirir en áreas costeras debido a la baja resolución espacial (Brown y Yoder, 1994; Cannizzaro *et al.*, 2008; Dwivedi *et al.*, 2015; Lubac *et al.*, 2008; Stumpf, 2001; Subramaniam *et al.*, 2002; Tomlinson *et al.*, 2004). Aunado a esto, estos trabajos requieren de validación en campo, debido a que la mayoría de los algoritmos se encuentran limitados a determinadas condiciones regionales y, por tanto, a condiciones oceanográficas específicas.

3. JUSTIFICACIÓN

A pesar del amplio conocimiento científico que ya se ha construido sobre las proliferaciones algales, las causas de la intensidad, frecuencia, dinámica espacial y temporal del ciclo de vida, así como la naturaleza de este fenómeno en relación con los desafíos asociados a los ambientes acuáticos y, eventualmente a la sociedad humana, siguen siendo poco claras y, en general, se atribuyen a la acción combinada de la variabilidad de los ecosistemas naturales, el impacto antropogénico, y cambio climático. Siendo estos factores que en conjunto justifican la necesidad de desarrollar un sistema integrado eficaz de monitoreo, detección temprana, predicción y alerta de eventos de proliferaciones algales, con el fin de tomar las medidas de mitigación necesarias para la prevención del daño asociado a eventos de proliferaciones algales. Aunado a esto, en México no existe un programa establecido formalmente para el monitoreo, siendo la taxonomía convencional el método clásico para la detección y enumeración de especies formadoras de proliferaciones algales, sin embargo este método demanda mucho tiempo y taxónomos expertos, por lo cual es necesario el desarrollo de métodos complementarios que permitan una detección, identificación y enumeración en tiempo casi real. Siendo la detección remota una opción viable para generar un sistema de alerta temprana.

4. HIPÓTESIS

Si el ciclo de vida de las especies de fitoplancton que forman proliferaciones algales se encuentra estrechamente relacionado con la interacción de factores físicos-químicos-biológicos que ocurren en la columna de agua, entonces es posible implementar técnicas estadísticas y metodológicas que permitan determinar los principales factores que dan origen y que constituyen un evento de proliferación algal.

5. OBJETIVOS

5.1 Objetivo general:

- Proponer un sistema de monitoreo de proliferaciones algales en la Bahía de La Paz, a partir de las propiedades bio-ópticas del océano y los sistemas de detección remota (imágenes de satélite).

5.2 Objetivos específicos:

- Construir un modelo estadístico para estimar la concentración de clorofila-a en ambientes costeros mediante el uso de imágenes satelitales de alta resolución y datos *in situ*.
- Determinar las principales condiciones ambientales responsables de las fluctuaciones en la abundancia y la dinámica de la comunidad de fitoplancton dando origen a eventos de proliferaciones algales.
- Analizar y describir la distribución espacio-temporal de los principales géneros formadores de proliferaciones algales presentes en el área de estudio.
- Establecer un protocolo para la implementación de un sistema de monitoreo de variables biológico-ambientales, que permita detectar cambios asociados a eventos proliferaciones algales a partir de información de sensores remotos y datos *in situ*

6. MATERIAL Y MÉTODOS

6.1 Área de estudio

El área de estudio se encuentra localizada dentro de la Bahía de La Paz, la cual se ubica en la costa occidental de Baja California Sur, entre los 24°09' y 24°47' de latitud norte y 110°18' y 110°45' de longitud oeste (Fig. 1A). La Bahía de La Paz es un cuerpo de agua costero de aproximadamente 90 km de largo y 60 Km de ancho, lo que equivale a aproximadamente 4,500 km². Tiene dos bocas que la comunican con la región oeste del Golfo de California. La boca principal se encuentra ubicada al noroeste (boca grande), es amplia y con una profundidad de 300 m; mientras que la boca del este (boca chica o canal de San Lorenzo), es estrecha y somera, asociada con canales de 20 m de profundidad (Álvarez–Arellano *et al.*, 1997; Jiménez-Illescas *et al.*, 1997).

La Ensenada de La Paz, es una laguna costera que se localiza en la parte sur de la Bahía de La Paz, entre las coordenadas 24°06' y 24°11N, y 110°19', y 110°25' O. Es un cuerpo de agua protegido, que se encuentra separado de la Bahía de La Paz por una barrera arenosa de origen marino, llamada "El Mogote", de aproximadamente 11 km de longitud en el sentido este-oeste, 2.7 km en su parte más amplia (Cervantes-Duarte y Guerrero-Godínez, 1987). La longitud de la Ensenada de La Paz es de 12 Km, el ancho de 5 Km y su área es de 45 Km², con respecto al nivel medio del mar. Morfológicamente hablando, la boca está formada por dos canales paralelos en su conexión con la Bahía de La Paz de aproximadamente 4 km de longitud y 0.6 Km de ancho en total, con una profundidad media de 7.0 m (Jiménez-Illescas *et al.*, 2008).

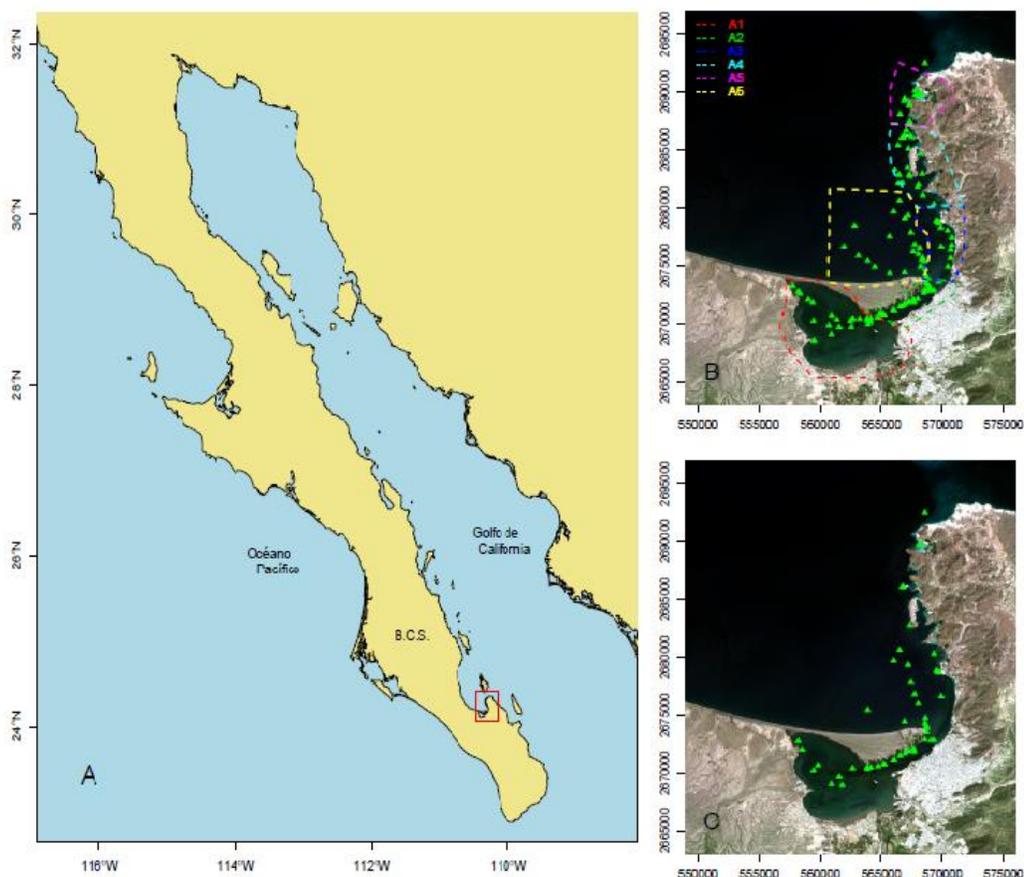


Figura 1. Mapa de localización geográfica del área de estudio. A) Macro localización del área de estudio. B) Distribución de los sitios de muestreo de parámetros ambientales y de toma de datos de Chl-a *in situ* (triángulos verdes) y los polígonos usados para el análisis de series de tiempo. C) Sitios de muestreo de fitoplancton.

6.2 Origen de la información

6.2.1 Datos de campo

6.2.1.1 Parámetros ambientales

La colecta de datos *in situ* fue realizada de manera sincrónica con el paso del satélite Landsat 8. El satélite pasa en esta zona cada 16 días aproximadamente a las 17:47 UTC, por lo que la colecta de datos en campo se realizó 2 horas antes y

2 horas después del paso del satélite, con la intención de evitar el efecto de la variabilidad de la Chl-a relacionada con mareas, corrientes locales y el ciclo circadiano. La medición de la concentración de Chl-a se realizó a nivel de superficie de la columna de agua (~50cm de profundidad), con el sensor multiparámetros RBR-maestro modelo XRX-420, fabricado por RBR Ltd, en Ottawa Canadá. El cual fue programado para registrar datos con una frecuencia de 3 segundos, durante un periodo de 2 minutos. El multiparámetros RBR-maestro modelo XRX-420, se encuentra equipado con un sensor de fluorescencia Seapoint, que presenta una alta sensibilidad, y permite medir la clorofila en un volumen de aproximadamente 340 mm^3 dentro de un rango de 0.02 a $150 \mu\text{g} \cdot \text{L}^{-1}$, con una exactitud de $\pm 2 \%$ y una sensibilidad de $0.033 \text{ V}/\mu\text{g/l}$.

En total se obtuvo información de 12 salidas de campo durante un año de monitoreo; debido al mal tiempo (principalmente alta nubosidad) no fue posible realizar salidas a campo en algunas fechas del periodo de estudio. La tabla III muestra las fechas de las salidas de campo realizadas durante el periodo de estudio, así como también algunos estadísticos descriptivos de la Chl-a medida *in situ* para cada uno de los seis polígonos en los que se sub-dividió el área de estudio (Fig. 1B) para el análisis de series de tiempo.

6.2.1.2 Fitoplancton

De manera sincrónica con la colecta de datos ambientales, se obtuvieron muestras de fitoplancton mediante arrastres horizontales, con una red para fitoplancton de luz de malla de $20 \mu\text{m}$, a una velocidad de 1.02 ms^{-1} durante 60s; Colectándose un total de 55 muestras (Fig. 1C), las cuales fueron divididas en volúmenes iguales y preservadas en una solución de Lugol ácido y alcohol al 70% para su posterior análisis. El análisis cualitativo y cuantitativo del fitoplancton presente en las muestras se realizó mediante taxonomía convencional, utilizando un microscopio óptico OLYMPUS BX43, Olympus Corp., Tokyo Japón, con

aumentos de 20x y 40x. La cuantificación del fitoplancton se llevó a cabo utilizando una cámara de conteo Sedgewick-Rafter y las especies presentes se identificaron al nivel más bajo posible utilizando las guías taxonómicas especializadas (Balech, 1988; Kofoid y Swezy, 1921; Licea *et al.*, 1995; Moreno *et al.*, 1996; Round *et al.*, 1990; Tomas, 1996). El número de células totales fue estimado a partir de la siguiente fórmula:

$$N_o mL^{-1} = \frac{C * 1000mm^3}{L * D * W * S} \quad (1)$$

Dónde, C = número de células contadas, L = largo de la banda en mm, D = profundidad de la banda mm, W = ancho de la banda mm, y S = el número de bandas contadas.

Para la obtención de la biomasa celular, se estimó el volumen de agua filtrada mediante la fórmula (2) y posteriormente la biomasa celular fue estimada mediante la fórmula (3) (Sournia, 1978), y transformada a $cel \cdot L^{-1}$.

$$Vol = A * D * Cf \quad (2)$$

Dónde, A = área de boca de la red, D = distancia, Cf = coeficiente de filtración, y N = número de células contadas.

$$Biomasa = \frac{NV_2}{V_1V_3} \quad (3)$$

Dónde, V1 = volumen de agua filtrada, V2 = volumen final de agua colectada, y V3 = 1 mL (alícuota contada en la cámara de Sedgewick-Rafter).

6.2.2 Imágenes satelitales

6.2.2.1 Landsat 8

Imágenes de satélite de Landsat 8 nivel 1 fueron utilizados en el presente trabajo. Landsat 8 tiene dos sensores abordo Operational Land Imager (OLI) y

Thermal Infrared Sensor (TIRS). En total estos sensores cuentan con 11 bandas espectrales, 9 del sensor OLI y 2 del sensor TIRS. La resolución espacial de las bandas 1 a 7 y 9 es de 30 m, la banda 8 (pancromática) es de 15 m y las bandas 10 a 11 es de 100 m (Tabla I). Estos datos se encuentran incluidos en el conjunto de datos Landsat 8 OLI / TIRS C1 Nivel-1 y fueron descargados del servidor de US Geological Survey (USGS, <https://www.usgs.gov>) utilizando la plataforma Earth Explorer (<https://earthexplorer.usgs.gov>).

El área de estudio se encuentra en la escena Landsat ID: LC08_L1TP_034043 (Path = 34, Row = 43). Las imágenes fueron adquiridas del periodo del 2013 al 2017 y solamente fueron seleccionadas aquellas que no presentaran alta nubosidad en el agua. Posteriormente fueron importadas y procesadas con la librería *raster* (Hijmans, 2016) del lenguaje de programación R (R Core Team, 2016) versión 3.3.2, para obtener los valores de reflectancia espectral de la parte superior de la atmósfera (TOA por sus siglas en inglés) de cada una de las bandas seleccionadas. Las imágenes Landsat 8 de nivel 1 son presentadas en unidades de números digitales (DN) que permiten convertirse fácilmente a radiancia espectral o reflectancia; el proceso para obtener la reflectancia fue el siguiente:

La conversión de los valores de DN a radiancia fue llevada a cabo utilizando los factores de escala proporcionados en el archivo de metadatos, mediante la siguiente ecuación:

$$L\lambda = M_L * Q_{cal} + A_L \quad (4)$$

Dónde: $L\lambda$ = valor de radiancia espectral medida en ($\text{Watts/m}^2 \cdot \text{srad} \cdot \mu\text{m}$); M_L = factor de escala multiplicativo de radiancia específico de cada banda; Q_{cal} = valores de pixel de nivel 1 en DN (valor de cada una de las bandas de la imagen); A_L = factor aditivo escalado específico de cada banda.

De manera similar a la conversión de radiancia, los valores de DN fueron convertidos a valores de reflectancia utilizando los factores de escala de reflectancia proporcionados en el archivo de metadatos, mediante la siguiente ecuación:

$$\rho\lambda' = M_{\rho} * Q_{cal} + A_{\rho} \quad (5)$$

Dónde: $\rho\lambda'$ = valor de reflectancia planetaria, sin corrección por ángulo solar; M_{ρ} = factor de escala multiplicativa específico de cada una de las bandas; A_{ρ} = factor de escala aditiva específico para cada una de las bandas; Q_{cal} = valores de pixel de nivel 1 en DN.

El valor de reflectancia calculado ($\rho\lambda'$) no corresponde al verdadero valor de reflectancia TOA, por lo que la conversión a la Reflectancia TOA real fue realizada con la siguiente ecuación:

$$\rho\lambda = \frac{\rho\lambda'}{\sin \theta_{SE}} \quad (6)$$

Dónde: $\rho\lambda$ = valor reflectancia planetaria y θ_{se} = ángulo de elevación solar local.

En este trabajo se utilizaron las siguientes bandas espectrales de la parte visible de la luz (B1 (aerosol costero) 0.435 a 0.451 μm), B2 (azul) 0.452 a 0.512 μm), B3 (verde) 0.533 a 0.590 μm), B4 (rojo) 0.636 a 0.673 μm)) y el infrarrojo cercano (B5 (NIR, por sus siglas en inglés) 0.851 a 0.879 μm).

6.3 Modelación estadística

6.3.1 Modelos de Regresión Lineal

En este trabajo, los modelos de Regresión Lineal (RL) exploraron la relación lineal entre la variable respuesta y las variables predictivas, asumiendo que los residuales son independientes de las variables predictivas, que presentan una

distribución normal con media 0 y homocedasticidad (Zuur *et al.*, 2009). Estos modelos fueron construidos usando una o más variables predictivas y para diferenciar entre el número de variables predictivas utilizadas, se denominó Regresión Lineal Simple (RLS) a los modelos que utilizan una sola variable predictiva y Regresión Lineal Múltiple (RLM) a los modelos que emplean dos o más variables predictivas. En general, los modelos RLS y RLM pueden ser representados de la siguiente manera:

$$y_i = \alpha + \beta X + \varepsilon_i \quad (7)$$

$$y_i = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_p X_p + \varepsilon_i \quad (8)$$

Donde y_i es el valor esperado de la concentración de Chl-a transformada mediante el uso de la función logaritmo natural ($\mu\text{g}\cdot\text{L}^{-1}$); α = intercepto; β_p son los coeficientes de las variables predictoras (X_p), que corresponden a las bandas 1 a 5; y ε_i término del error (residuales).

En el caso particular de los RLS se utilizaron las bandas anteriormente mencionadas de manera directa o mediante algún tipo de transformación (cuadrática o proporción de bandas).

6.3.2 Modelos Aditivos Generalizados

Los modelos aditivos generalizados (MAG), son considerados como una variación de los modelos lineales generalizados, en donde el predictor lineal (variable respuesta) se especifica en términos de una suma de las funciones suavizadoras de las covariantes (variables predictivas), funciones que son especificadas por el usuario, y están relacionadas con la variable dependiente mediante una función de enlace (Hastie y Tibshirani, 1990). La forma general de un MAG puede ser representada de la siguiente manera:

$$y_i = \alpha + f_1 X_1 + f_2 X_2 + f_3 X_3 + \dots + f_p X_p + \varepsilon_i \quad (9)$$

Donde y_i es el valor esperado de la concentración de Chl-a transformada mediante el uso de la función logaritmo natural ($\mu\text{g}\cdot\text{L}^{-1}$); α = intercepto; f_p son funciones suaves de las covariables (X_p); ε_i es el término del error (residuales). En este trabajo se utilizó la función suavizadora “thin plate regression spline”, debido a que varios autores sugieren que captura de una manera más adecuada la relación entre la variable dependiente y las independientes sin sobreparametrizar al modelo (Wood, 2003).

6.3.3 Estimación de clorofila-a a partir de imágenes Landsat

Con el fin de desarrollar un modelo para estimar concentraciones de Chl-a a partir de datos *in situ* y la reflectancia espectral de las bandas 1 a 5 correspondientes a las imágenes satelitales de Landsat 8, se aplicaron dos técnicas estadísticas conocidas como modelos RL y MAG. Para llevar a cabo la modelación, se utilizaron 147 registros de Chl-a, transformados mediante el uso de la función logaritmo natural, como variable de respuesta y las bandas espectrales de la parte visible de la luz (B1 [costera / aerosol], B2 [azul], B3 [verde] y B4 [roja]) e infrarrojo cercano (NIR, B5) como variables de predictivas. Los valores de concentración de Chl-a fueron transformados logarítmicamente y se usaron como variables dependientes, esto debido a que algunos autores han descrito ampliamente que la Chl-a presenta una relación exponencial con las bandas de Landsat (Chang *et al.*, 2004; Han y Jordan, 2005). Todos los modelos estadísticos y procesamiento de datos se realizaron en R (R Core Team, 2016); para los MAG se utilizó la librería *mgcv* (Wood, 2006)

Estudios previos sobre la estimación de Chl-a a partir de imágenes Landsat sugieren que la adición, multiplicación, proporción o transformación cuadrática de las bandas 1 a 5 presentan los mejores resultados en RLS (Brezonik *et al.*, 2005; Han y Jordan, 2005; Lim y Choi, 2015; Nazeer y Nichol, 2016; Patra *et al.*, 2016). Es por ello, que se utilizaron como variables predictivas para los modelos RLS

todas las combinaciones posibles obtenidas a través de permutaciones de hasta dos bandas espectrales, dando un total de 250 modelos diferentes (Anexo, Tabla A1). Para los modelos RLM se usó la combinación de dos, tres, cuatro y cinco bandas espectrales sin transformación, dando un total de 26 modelos diferentes (Anexo, Tabla A2). Mientras que para los MAG se utilizaron cada una de las bandas individuales y la combinación de dos, tres, cuatro y cinco bandas espectrales, por lo que se crearon un total de 31 modelos diferentes (Anexo, Tabla A3). Los términos de error para todos los modelos se consideraron como independientes de las variables predictivas y se asumió que tienen una distribución normal con media 0 y homogeneidad de varianzas (homoscedasticidad). Para evaluar los supuestos estadísticos de los modelos no se aplicaron estadísticos de prueba, en su lugar se utilizaron figuras de diagnóstico. Este procedimiento se aplicó únicamente para cada uno de los modelos (RLS, RLM y MAG) con el mejor ajuste.

6.3.4 Modelos de distribución de especies

Modelos MAG fueron utilizados para describir la relación entre las variables predictoras (Chl-a, TSM, Sal, pH y OD) y las variables respuesta (abundancia estimada de los géneros seleccionados [*Prorocentrum*, *Triplos*, *Pseudo-nitzschia*, *Gymnodinium*]). Los parámetros ambientales utilizados para construir los modelos estadísticos fueron obtenidos directamente en campo, en conjunto con los arrastres de fitoplancton. Los modelos MAG fueron usados debido a que es un método que puede describir relaciones complejas y no lineales entre la variable respuesta y las predictoras.

El proceso de construcción de los modelos se llevó a cabo utilizando un enfoque progresivo (forward stepwise, en inglés), el cual consiste en construir un modelo nulo (utilizando la media general de la variable respuesta) y posteriormente agregar una variable predictiva a la vez, evaluando si su

contribución es significativa para el nuevo modelo. La contribución de la variable predictiva se evaluó con el coeficiente de determinación ajustado (R^2_{ajust}) y el Criterio de Información de Akaike (AIC). Basado en estos criterios, se retiene una variable en el modelo si el R^2_{ajust} se incrementa y el valor de AIC disminuye. El R^2_{ajust} es una medida de bondad de ajuste, que mide el porcentaje de varianza explicado, mediante una penalización por el número de parámetros en el modelo, tomando en cuenta los grados de libertad y, por lo tanto, los parámetros de regresión adicionales (James *et al.*, 2013; Zuur *et al.*, 2007). El AIC es un valor que mide la bondad del ajuste y la complejidad del modelo, conocida como una probabilidad de registro penalizada, que pondera la máxima probabilidad de registro del modelo, con el número de parámetros (Akaike, 1974). Todos los modelos fueron realizados y evaluados en el lenguaje de programación R (R Core Team, 2016), para los MAG se utilizó la librería *mgcv* versión 1.8-620 (Wood, 2006). Como las variables de respuesta son enteros y positivos, la familia de distribución utilizada en MAG fue Poisson, con la función de enlace log. Esto asegura que las predicciones de los modelos siempre sean positivos en una escala exponencial.

Para realizar predicciones en el área de estudio, se utilizaron parámetros ambientales derivados de imágenes Landsat 8, utilizando modelos de regresión múltiple (MRM) descritos por Aviña-Hernández (2018) en el área de estudio, donde las variables de respuesta fueron los parámetros medidos *in situ* (Chl-a, TSM, Sal, pH y OD) y las variables predictoras las bandas espectrales de Landsat 8. Usando el MRM mejor ajustado (Tabla II), se estimaron parámetros ambientales para el área de estudio durante el período del 2013 al 2017. Con las predicciones espaciales se calculó el promedio mensual de cada uno de los parámetros ambientales con una resolución espacial de 30 m (Fig. 2) (Aviña-Hernández, 2018).

Tabla II. Modelos de regresión múltiple para parámetros ambientales de la columna de agua de mar, estimados a partir de Landsat 8. Tomado y editado de Aviña-Hernández (2018).

| Parámetros ambientales | Ecuación | R^2_{ajust} |
|---------------------------------|--|---------------|
| Clorofila-a | $1.20 + 81.69 *B01 - 189.91*B02 + 99.81*B03 + 15.66*B05$ | 0.759 |
| Oxígeno disuelto | $8.29 - 0.40*B10 + 0.27*B11$ | 0.572 |
| pH | $3.50 + 106.26*B01 - 50.07*B02 - 9.8*B04 - 334.37*B01^2 + 167.97*B02^2 - 0.26*B10 + 0.27*B11$ | 0.863 |
| Salinidad | $36.39 - 276.64*B01 + 290.58.4*B02 + 106.75*B04 - 101.60*B05 + 949.37.6*B01^2 - 1206.86*B02^2$ | 0.558 |
| Temperatura superficial del mar | $2.15 + 3.74*B10 - 2.93*B11$ | 0.936 |

6.3.5 Bondad de ajuste y capacidad predictiva de los modelos

La bondad del ajuste de los modelos se evaluó usando el coeficiente de determinación (R^2) y el R^2_{ajust} . Estos estadísticos se usaron para describir la proporción de varianza explicada y pueden tomar valores entre 0 y 1. La diferencia entre R^2 y R^2_{ajust} se basa en que este último usa una penalización basada en el número de parámetros (variables predictivas); se utilizó esta variación del R^2 debido a que se ha demostrado que este estadístico siempre aumenta cuando se agrega una nueva variable al modelo, lo que provoca una sobre-parametrización de los modelos. Por lo tanto, R^2_{ajust} es preferido para los modelos con dos o más variables de predictivas.

Para evaluar la capacidad predictiva de los modelos se utilizó la división de los datos, considerado como un método eficaz debido a que una parte de los datos (datos de entrenamiento) se utiliza para estimar los coeficientes del modelo, y el resto de los datos (datos de prueba) se utiliza para medir que tan bien se

desempeña el modelo prediciendo datos conocidos, esto es conocido en estadística como la evaluación de la capacidad predictiva del modelo. En el caso de los modelos para la estimación de Chl-a a partir de imágenes Landsat, los datos fueron separados arbitrariamente por fecha en dos subconjuntos, datos de entrenamiento (24/08/2016, 09/09/2016, 25/09/2016, 27/10/2016, 28/11/2016, 31/01/2017, 16/02/2017 y 20/03/2017) y datos de prueba (05/04/2017, 21/04/2017, 23/05/2017 y 08/06/2017). Para los modelos de distribución de especies los datos fueron divididos en datos de entrenamiento (75%) y datos de prueba (25%).

La capacidad predictiva de los modelos se evaluó utilizando valores estadísticos como: la raíz del error cuadrático medio (RMSE, por sus siglas en inglés), el coeficiente de correlación (R) y el AIC (Tablas A4-A6); estos valores se calcularon usando los datos observados y predichos del conjunto de datos de prueba.

RMSE se define como:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i^{observado} - X_i^{ajustado})^2} \quad (10)$$

Dónde: $X_i^{observado}$ = valores observados; $X_i^{ajustado}$ = valores predichos; n = número de datos.

Los datos predichos (ajustados) se calcularon usando coeficientes de las funciones suavizadas de todos los modelos, por lo que el RMSE de todos los modelos se encuentran en la escala de la Chl-a (transformada logarítmicamente).

6.3.6 Variabilidad espacio-temporal

6.3.6.1 Clorofila-a

Utilizando el mejor modelo ajustado y todas las escenas de Landsat 8 disponibles y libres de nubes dentro del área de estudio, se estimaron valores de

Chl-a en escala logaritmo natural para el período de mayo de 2013 a octubre de 2017; posteriormente los valores de Chl-a fueron regresados a su escala original aplicando la función exponencial.

Para describir la variabilidad espacial y temporal de la Chl-a estimada, se analizaron datos de series de tiempo sobre seis polígonos en el área de estudio (Fig. 1B). Estos polígonos se definieron tomando en cuenta las características geográficas. El área 1 corresponde a la laguna costera semi-cerrada (Ensenada de La Paz); el área 2 fue el canal que comunica la Ensenada de La Paz con Bahía de La Paz; el área 3 corresponde a la parte más al norte de la ciudad de La Paz; el área 4 es la zona portuaria; el área 5 se encuentra dentro del área natural protegida Balandra y el área 6 corresponde a la parte más al sur de Bahía de La Paz conocida localmente como El Mogote.

6.3.6.2 Fitoplancton

Para describir la variabilidad espacial y temporal de la abundancia del fitoplancton en el área de estudio, se llevaron a cabo predicciones espacio-temporales de cada grupo, utilizando el MAG con el mejor desempeño estadístico de cada género de fitoplancton (Tabla VII) y el promedio estacional de los parámetros ambientales estimados a partir de la tabla II.

7. RESULTADOS

7.1 Parámetros ambientales

Los parámetros ambientales medidos in situ a lo largo de un año de estudio son representados de manera estacional en la figura 2. La temperatura superficial del mar presentó una variación estacional bien definida con un rango de 18.9 (invierno) a 30.1 (verano). La salinidad varió poco entre estaciones, con valores mínimos de 34.9 y máximos de 37.9 UPS (primavera). El pH varió de 7.5 (verano)

a 8.2 (primavera), observándose diferencias entre cada una de las estaciones. El oxígeno disuelto varió en un rango de 3.6 (verano) a 12.8 mg*L⁻¹ (invierno). La Chl-a presentó valores relativamente bajos, en un rango de 0.13 (invierno) a 2.74 µg*L⁻¹ (verano).

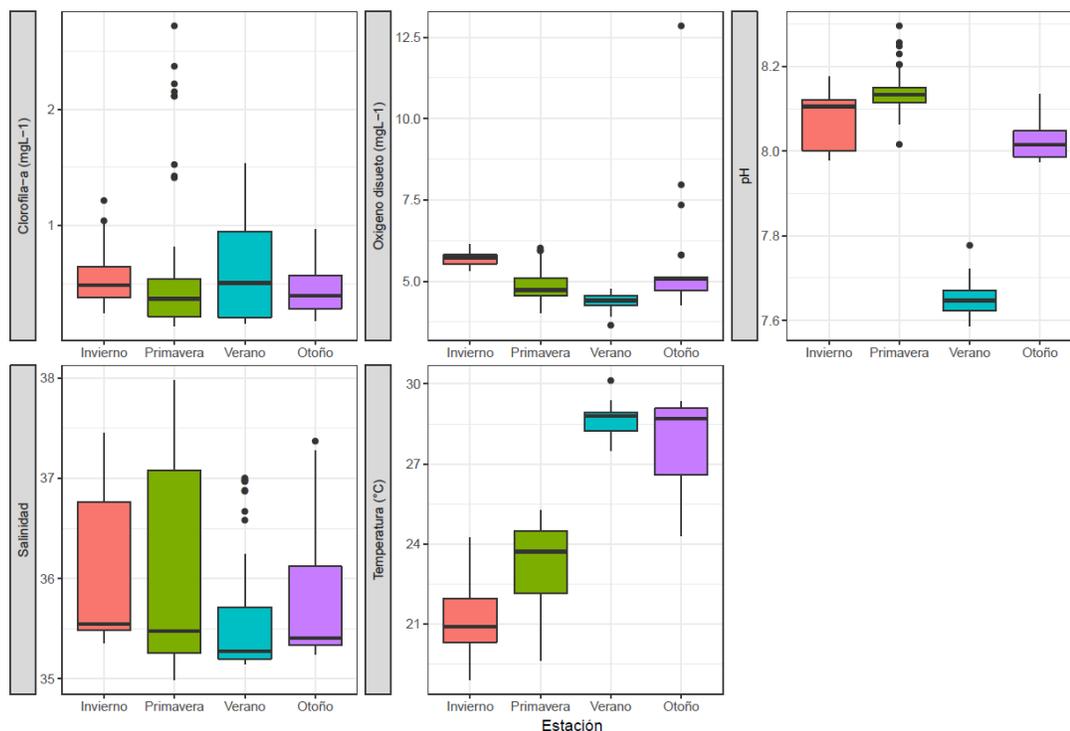


Figura 2. Variación estacional de los parámetros ambientales en la superficie de la columna de agua durante el período de estudio. La línea horizontal muestra la mediana; la caja representa el primer y tercer cuartil; las líneas verticales mínimo y máximo o 1.5 veces el rango intercuartil. Los puntos son los valores atípicos.

7.2 Composición de especies de fitoplancton

Durante el periodo de estudio se identificaron un total de 86 especies de fitoplancton, representadas en cinco clases, Bacillariophyceae (58.1%), Dinophyceae (34.9%), Cyanophyceae (4.7%), Chrysophyceae (2.3%). Los géneros más representativos fueron *Protoperdinium*, *Rhizosolenia*, *Tripos*, *Prorocentrum*, *Chaetoceros*, *Pleurosigma* y *Navicula*, en donde el género más

La variabilidad espacial y temporal de Chl-a observada durante el período de estudio se muestra en la figura 4, los valores de Chl-a fueron usualmente más altos en el área 1 y 2 con respecto a las otras áreas. Los valores más altos de Chl-a se registraron el 08/06/2017 en las áreas 1 a 3, debido a que durante este periodo se registró un evento de proliferación en el área de estudio.

Tabla III. Estadísticos descriptivos de las mediciones *in situ* de concentraciones de clorofila-a.

| Fecha | A1 | | | A2 | | | A3 | | |
|------------|------|------|------|------|------|------|------|------|------|
| | Min | Prom | Max | Min | Prom | Max | Min | Prom | Max |
| 24/08/2016 | | | | 0.33 | 0.44 | 0.55 | 0.18 | 0.19 | 0.20 |
| 09/09/2016 | 1.37 | 1.37 | 1.37 | 0.43 | 0.72 | 1.34 | 0.37 | 0.51 | 0.61 |
| 25/09/2016 | 0.95 | 1.14 | 1.41 | 0.61 | 0.79 | 1.05 | | | |
| 27/10/2016 | 0.41 | 0.58 | 0.79 | 0.30 | 0.33 | 0.38 | | | |
| 28/11/2016 | 0.58 | 0.58 | 0.58 | 0.51 | 0.54 | 0.56 | | | |
| 31/01/2017 | 0.42 | 0.47 | 0.52 | 0.39 | 0.39 | 0.39 | 0.52 | 0.52 | 0.52 |
| 16/02/2017 | 0.37 | 0.37 | 0.37 | 0.38 | 0.38 | 0.38 | 0.36 | 0.36 | 0.36 |
| 20/03/2017 | 0.51 | 0.85 | 1.04 | 0.59 | 0.75 | 0.99 | 0.33 | 0.33 | 0.34 |
| 05/04/2017 | 0.33 | 0.33 | 0.33 | 0.39 | 0.44 | 0.47 | 0.19 | 0.19 | 0.19 |
| 21/04/2017 | 0.50 | 0.59 | 0.68 | 0.52 | 0.52 | 0.53 | | | |
| 23/05/2017 | 0.35 | 0.47 | 0.59 | 0.26 | 0.31 | 0.37 | 0.33 | 0.33 | 0.33 |
| 08/06/2017 | 2.12 | 2.12 | 2.12 | 2.11 | 2.23 | 2.37 | 1.42 | 2.10 | 2.71 |
| Fecha | A4 | | | A5 | | | A6 | | |
| | Min | Prom | Max | Min | Prom | Max | Min | Prom | Max |
| 24/08/2016 | 0.16 | 0.28 | 0.66 | | | | 0.25 | 0.25 | 0.25 |
| 09/09/2016 | 0.61 | 0.61 | 0.61 | | | | | | |
| 25/09/2016 | | | | | | | 0.17 | 0.24 | 0.41 |
| 27/10/2016 | 0.18 | 0.18 | 0.18 | | | | 0.20 | 0.23 | 0.27 |
| 28/11/2016 | 0.40 | 0.41 | 0.41 | 0.38 | 0.42 | 0.45 | 0.34 | 0.36 | 0.37 |
| 31/01/2017 | 0.42 | 0.42 | 0.42 | 0.33 | 0.36 | 0.41 | 0.43 | 0.43 | 0.43 |
| 16/02/2017 | 0.49 | 0.60 | 0.71 | 0.64 | 0.66 | 0.68 | 0.25 | 0.25 | 0.25 |
| 20/03/2017 | 0.49 | 0.51 | 0.53 | 0.43 | 0.50 | 0.58 | | | |
| 05/04/2017 | 0.24 | 0.28 | 0.33 | 0.36 | 0.36 | 0.36 | 0.22 | 0.22 | 0.22 |
| 21/04/2017 | 0.16 | 0.16 | 0.17 | 0.15 | 0.17 | 0.20 | 0.18 | 0.25 | 0.40 |
| 23/05/2017 | 0.14 | 0.17 | 0.24 | 0.14 | 0.17 | 0.23 | 0.22 | 0.22 | 0.22 |
| 08/06/2017 | 0.46 | 0.94 | 1.52 | | | | | | |

Min (Mínimo); Prom (promedio); Max (Máximo); A1 a A6 polígonos del área de estudio (ver Fig. 1B para detalles).

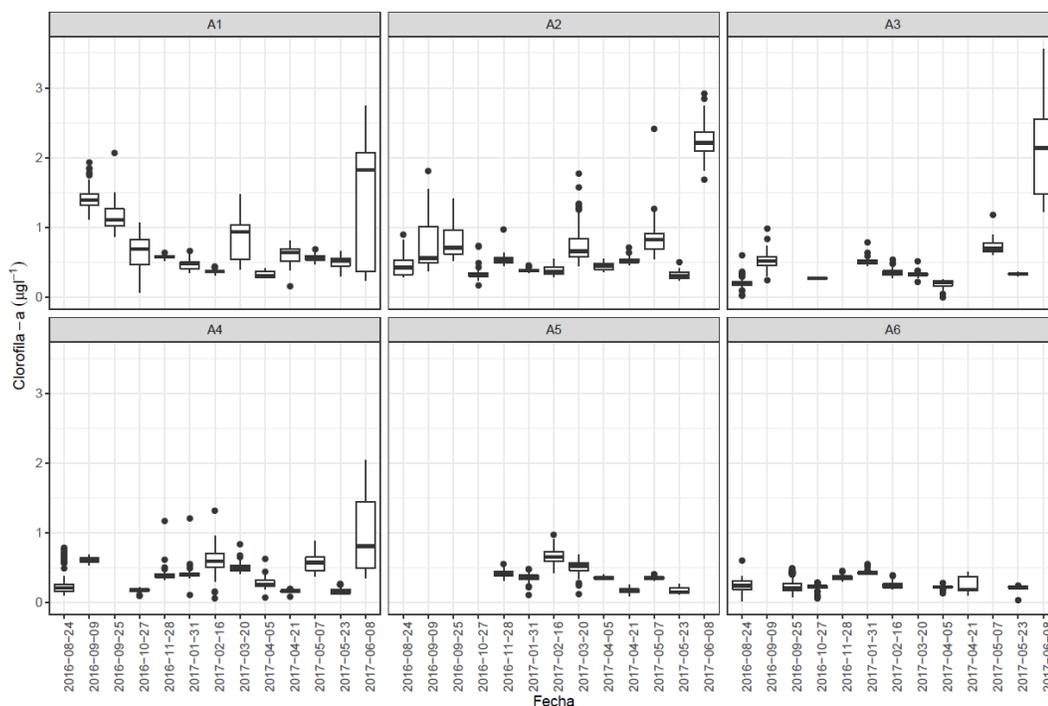


Figura 4. Valores observados de clorofila-a durante un año de monitoreo en el área de estudio. La línea horizontal muestra la mediana; la caja representa el primer y tercer cuartil; las líneas verticales mínimo y máximo o 1.5 veces el rango intercuartil. Los puntos son los valores atípicos. A1-A6 polígonos del área de estudio (ver la Fig. 1B para más detalles).

7.4 Estimación de la concentración de clorofila-a basada en imágenes Landsat

7.4.1 Selección del mejor modelo ajustado

Se construyeron y evaluaron un total de 307 modelos para identificar cuál de ellos podría explicar la proporción de varianza más alta de Chl-a transformada con logaritmo natural, inferida a partir de R^2 y R^2 ajustada. La tabla IV muestra los tres RLS, RLM y MAG mejor ajustados, respectivamente. La menor proporción de varianza explicada se observó con los modelos RLS ($R^2 = 0$ a 0.542 ; $R^2_{ajust} = -0.009$ a 0.538); mientras que con los RLM se obtuvo una mayor proporción de varianza explicada ($R^2 = 0.061$ a 0.764 ; $R^2_{ajust} = -0.044$ a 0.753) y finalmente con los MAG se obtuvo como resultado la mayor proporción de varianza explicada ($R^2_{ajust} = 0.216$ a 0.854). El modelo RLS con el R^2 y R^2 ajustado más alto fue la

relación entre las bandas B4 y B1², explicando el 54.2% de la varianza total, mientras que el modelo RLM con el R² y R² ajustado más alto fue el que incluyó las cinco bandas espectrales, explicando el 76.4% de la varianza total. Finalmente el modelo MAG con el R² ajustado más alto fue el que incluyó cuatro bandas espectrales (B1, B2, B3 y B4), explicando el 88.7% de la devianza total.

Tabla IV. Bondad de ajuste de los tres modelos RLS, RLM y MAG mejor ajustados, respectivamente, para la estimación de Chl-a transformada mediante el uso de la función logaritmo natural.

| Modelo | R ² | R ² _{ajust} |
|---|----------------|---------------------------------|
| Regresión Lineal Simple | | |
| $y = 1.84 - 6.54 \cdot (B1^2/B4)$ | 0.506 | 0.502 |
| $y = -3.6 + 1.09 \cdot (B4/B1^2)$ | 0.542 | 0.538 |
| $y = -3.06 + 5.55 \cdot (B4/B2)$ | 0.477 | 0.473 |
| Regresión Lineal Múltiple | | |
| $y = 0.94 + 88.45 \cdot B1 - 194.77 \cdot B2 + 97.55 \cdot B3 + 10.79 \cdot B4$ | 0.735 | 0.725 |
| $y = 1.54 + 79.56 \cdot B1 - 191.62 \cdot B2 + 102.22 \cdot B3 + 13.17 \cdot B5$ | 0.757 | 0.748 |
| $y = 1.05 + 103.37 \cdot B1 - 221.63 \cdot B2 + 119.1 \cdot B3 - 19.09 \cdot B4 + 21.39 \cdot B5$ | 0.764 | 0.753 |
| Modelos Aditivos Generalizados | | |
| $y = f(B1) + f(B2) + f(B3) + f(B4)$ | | 0.854 |
| $y = f(B1) + f(B2) + f(B3) + f(B5)$ | | 0.848 |
| $y = f(B1) + f(B2) + f(B3) + f(B4) + f(B5)$ | | 0.847 |

R² (coeficiente de determinación); R²_{ajust.} (coeficiente de determinación ajustado). En negrita, el RLS, RLM y MAG mejor ajustadas, respectivamente.

7.4.2 Evaluación de la capacidad predictiva de los modelos

Como se menciona en la sección de Métodos, la capacidad predictiva de los modelos se evaluó utilizando el coeficiente de correlación de Pearson (R) y la raíz del error cuadrático medio (RMSE) obtenidos de las predicciones del modelo de entrenamiento en un conjunto de datos de prueba. Como se muestra en la tabla V, el RLS con el R más alto y RMSE más bajo fue el modelo que se construyó con la relación entre las bandas B4 y B1²; El RLM con el R más alta y el RMSE más bajo fue el modelo que incluyó cuatro bandas (B1, B2, B3 y B5); y el MAG con la R más alta y el RMSE más bajo fue el modelo que incluyó las bandas B1, B2 y B3. Estos

resultados indican que tres enfoques de modelado podrían predecir concentraciones de Chl-a transformada logarítmicamente con alta precisión.

Tabla V. Desempeño predictivo de los tres RLS, RLM y MAG mejor ajustados, aplicados para estimar valores de Chl-a transformada a mediante el uso de la función logaritmo natural.

| Modelo | R | MSRE |
|--|--------------|--------------|
| Regresión Lineal Simple | | |
| $y = 1.84 - 6.54*(B1^2/B4)$ | 0.791 | 0.288 |
| $y = -3.6 + 1.09*(B4/B1^2)$ | 0.858 | 0.255 |
| $y = -3.06 + 5.55*(B4/B2)$ | 0.849 | 0.303 |
| Regresión Lineal Múltiple | | |
| $y = 1.48 + 81.53*B1 - 187.8*B2 + 98.22*B3$ | 0.856 | 0.209 |
| $y = 2.13 + 66.02*B1 - 174.51*B2 + 95.85*B3 + 5.23*B5$ | 0.875 | 0.191 |
| $y = 1.39 + 95.99*B1 - 211.35*B2 + 117.22*B3 - 22.85*B4 + 13.2*B5$ | 0.866 | 0.194 |
| Modelos Aditivos Generalizados | | |
| $y = f(B1) + f(B2) + f(B3)$ | 0.835 | 0.239 |
| $y = f(B2) + f(B3) + f(B4)$ | 0.821 | 0.286 |
| $y = f(B1) + f(B2) + f(B3) + f(B4)$ | 0.798 | 0.274 |

R (coeficiente de correlación de Pearson); RMSE (raíz del error cuadrático medio). En negrita, el RLS, RLM y MAG con la mayor capacidad predictiva respectivamente.

El análisis gráfico de los residuales de los modelos RLS, RLM y MAG mejor ajustados, se muestran en la figura 5. En esta figura los residuales de los tres modelos se sugieren que tienen una distribución normal con media 0, sin una tendencia marcada con respecto a los valores ajustados (homocedasticidad), también sugieren ausencia de valores atípicos. Por lo tanto, se considera que los modelos cumplen con los supuestos estadísticos.

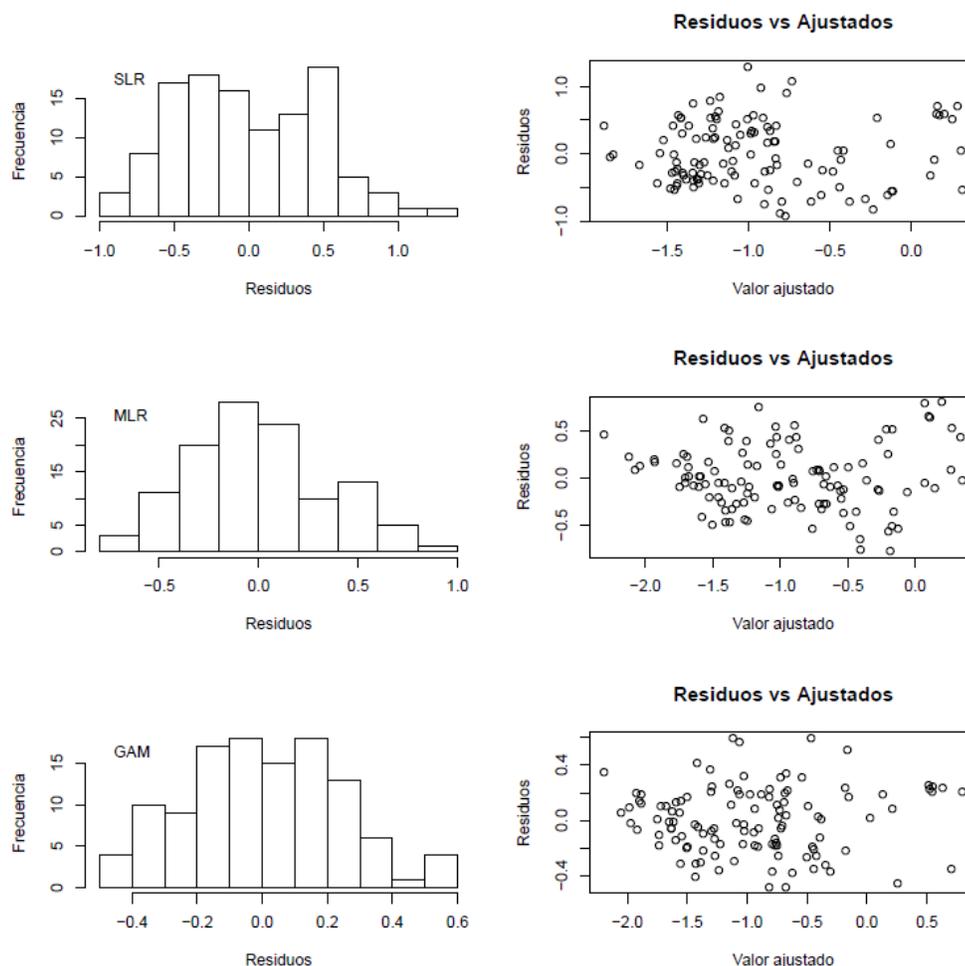


Figura 5. Análisis de los residuales de los mejores modelos ajustados RLS (arriba), RLM (centro) y MAG (abajo). Histogramas de frecuencia (izquierda) y gráficas de dispersión (derecha) de los residuales comparados con los valores ajustados.

7.4.3 Modelo óptimo para la estimación de clorofila-a

Tomando en cuenta los resultados de las tablas IV y V, el modelo RLM con cuatro bandas espectrales (B1, B2, B3 y B5) fue considerado como el mejor para predecir valores de Chl-a transformados logarítmicamente en el área de estudio. Los coeficientes de este modelo se muestran en la tabla VI. A partir de este modelo, podemos inferir que los valores de Chl-a transformados logarítmicamente

tiene una relación lineal positiva con las bandas B1, B3 y B5 y una relación lineal negativa con la banda B2. Los coeficientes de este modelo sugieren que B2, B3 y B1 tienen la relación lineal más fuerte con Chl-a transformada logarítmicamente; por el contrario, B5 tuvo la relación lineal más débil con la Chl-a transformada mediante el uso de la función logaritmo natural.

Tabla VI. Estadísticos descriptivos de los coeficientes del mejor modelo ajustado para la estimación de Chl-a.

| | Coeficiente | Error estándar | Valor de T | P |
|-------------------|--------------------|-----------------------|-------------------|----------|
| Intercepto | 1.54 | 0.77 | 2.13 | 0.036 |
| B1 (c/a) | 79.56 | 14.96 | 5.32 | <0.001 |
| B2 (blue) | -191.62 | 15.55 | -11.58 | <0.001 |
| B3 (green) | 102.22 | 6.65 | 15.36 | <0.001 |
| B5 (NIR) | 13.17 | 3.70 | 3.56 | <0.001 |

7.4.4 Variabilidad temporal de la clorofila-a estimada

Los valores estimados de Chl-a para el periodo de mayo 2013 a octubre de 2017 dentro de los seis polígonos definidos de manera arbitraria en este estudio se muestran en la figura 6. Los valores estimados de Chl-a variaron de 0.11 a 1.58 $\mu\text{g}\cdot\text{L}^{-1}$ y se observa una alta variabilidad estacional con picos de Chl-a máxima durante mayo y junio, mientras que los valores más bajos de Chl-a fueron predichos para diciembre y enero. Los valores estimados de Chl-a más altos, están asociados a un evento de proliferación algal de *G. catenatum*, observado el 08/06/2017, sin embargo, es importante observar a partir de las predicciones del modelo, que este evento no estuvo presente en el área 1 (Ensenada de La Paz).

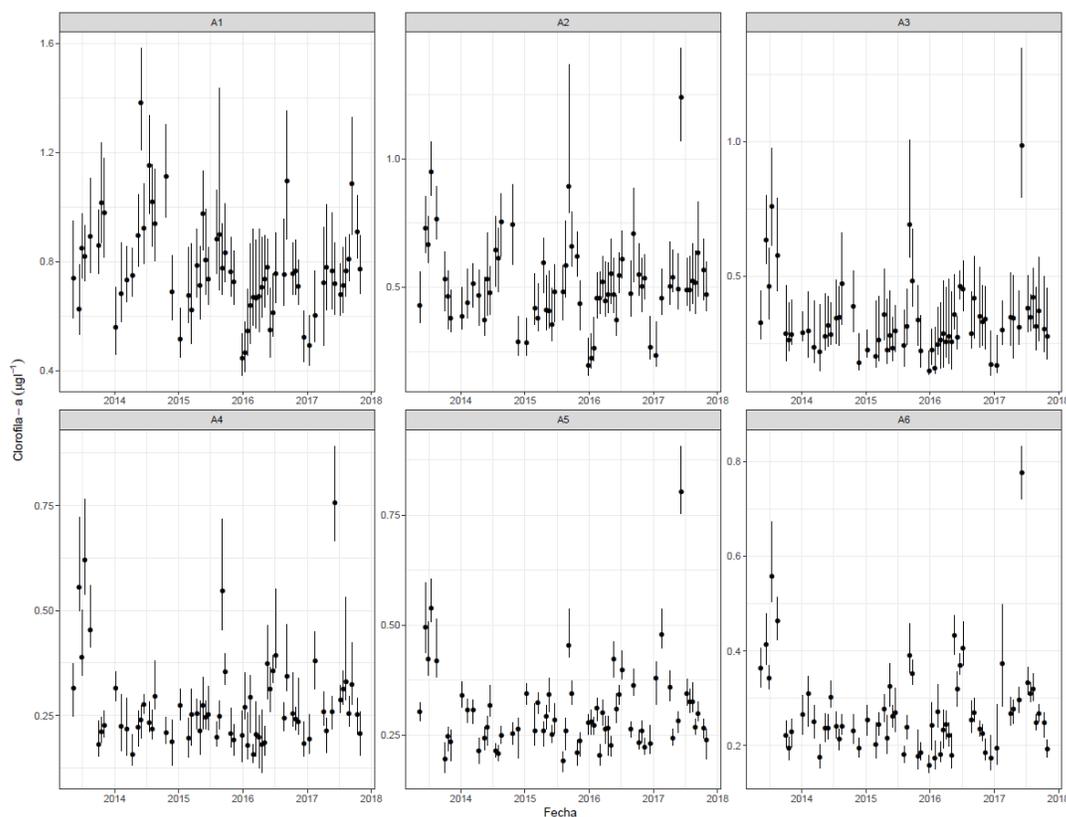


Figura 6. Predicciones de Chl-a obtenidas a partir del modelo mejor ajustado y las imágenes Landsat del período 2013 a 2017. Los puntos representan la mediana; las líneas verticales representan el primer y tercer cuartil. A1-A6 representan los polígonos del área de estudio (ver la Fig. 1A para más detalles).

7.4.5 Variabilidad espacial de la clorofila-a estimada

La figura 7 representa la concentración de Chl-a estimada para el área de estudio, correspondiente al mes de junio de los años 2013 a 2017, donde se comparan los valores obtenidos en cada una de las fechas. Valores altos de Chl-a se observan el 08/06/2017, debido a que en ésta se presentó un evento de proliferación. De igual manera se observaron valores altos en la imagen correspondiente al 13/06/2013 en comparación con el resto de las imágenes, esto se debe a un evento de proliferación reportado en la literatura del 18 al 20 de junio de 2013.

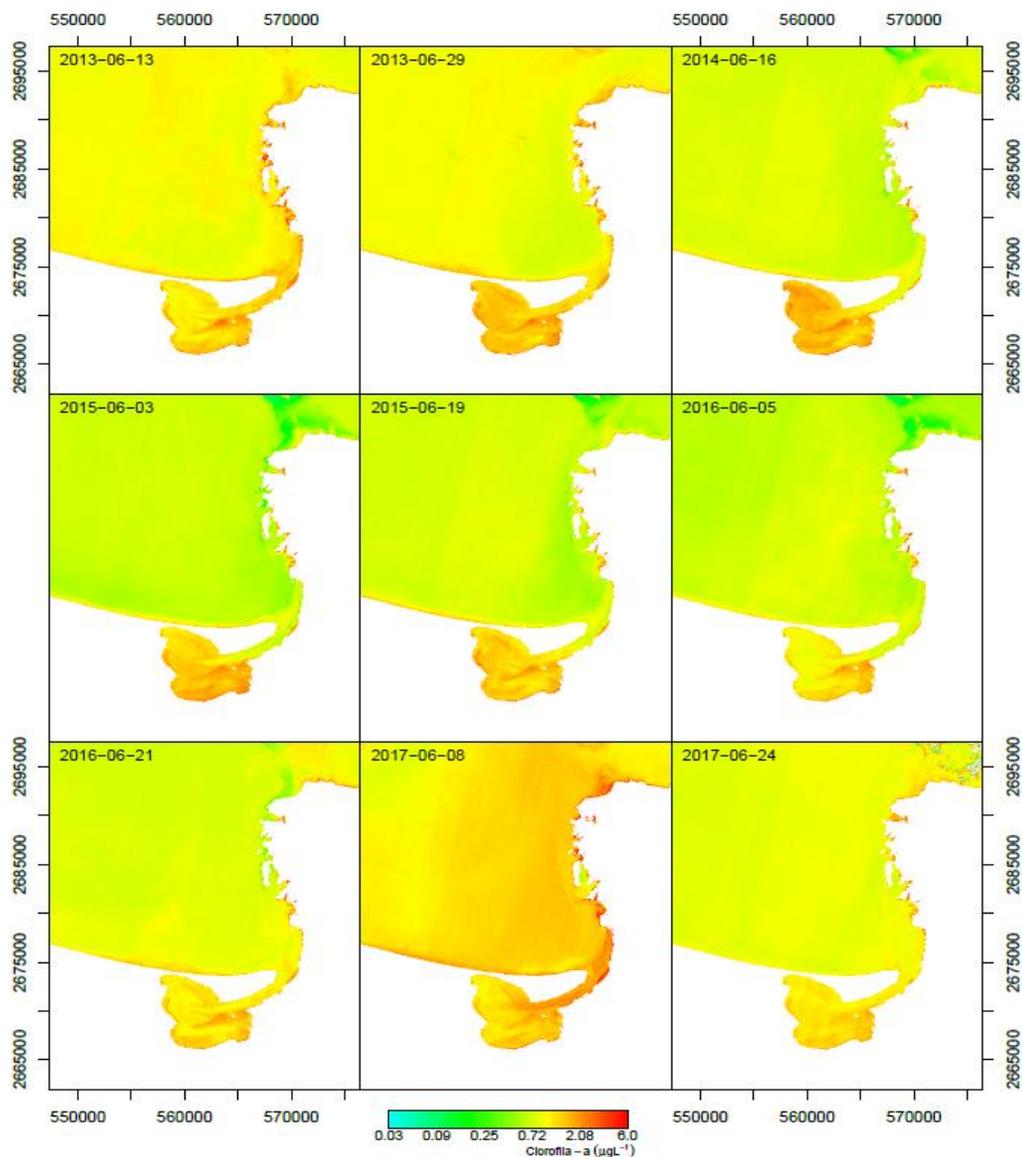


Figura 7. Predicción espacial de Chl-a ($\mu\text{g}\cdot\text{L}^{-1}$) en el área de estudio, correspondiente al mes de junio del 2013 al 2017.

7.5 Detección de proliferaciones algales

A partir de los valores de Chl-a obtenidos a lo largo de un ciclo anual de monitoreo en la Bahía de La Paz, se establecieron valores de referencia basados en los cuartiles de los datos. Aplicando los valores de referencia se clasificó en cuál es la probabilidad de ocurrencia de un evento de proliferación (Fig. 8A). En donde los valores dentro del cuartil 0 (Q0) y 1 (Q1) fueron clasificados como

valores con probabilidad baja de proliferación, mientras que los valores que se encuentran entre el primer y tercer (Q3) cuartil se le asignó un valor medio y finalmente los valores que se encuentran entre el tercer y cuarto (Q4) cuartil representan una alta probabilidad de ocurrencia de un evento de proliferación, tomándose como referencia valores de Chl-a medidos en campo durante un evento de proliferación de *G. catenatum* en el área de estudio.

En la figura 8 se muestra de manera gráfica la representación espacial de los valores de referencia, como una propuesta de clasificación de eventos de proliferación y su posible implementación como un sistema de monitoreo en el área de estudio. La figura 8B representa los valores promedio de Chl-a estimados durante un año de monitoreo y la figura 8C representa los valores estimados para el día 08/06/2017, fecha en que se estimaron valores altos de Chl-a, correspondientes a un evento de proliferación observado en campo.

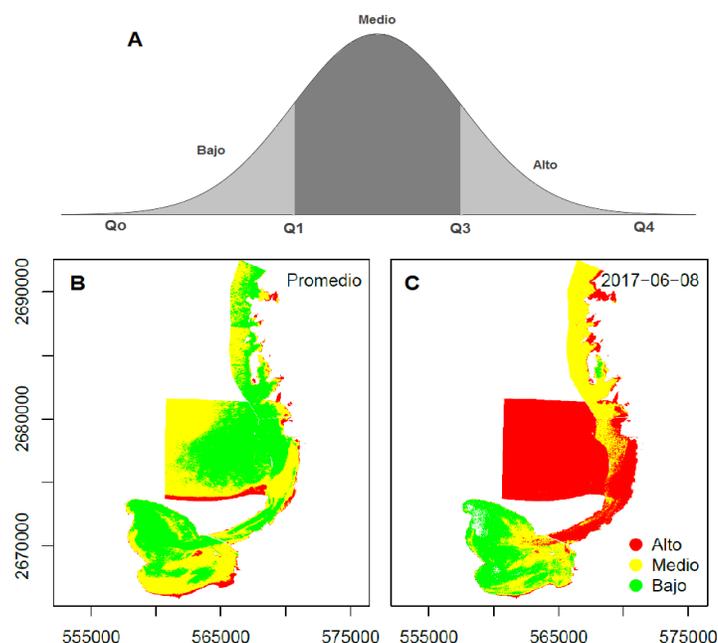


Figura 8. Propuesta de un sistema de monitoreo basado en valores de referencia establecidos a partir de un ciclo anual de monitoreo. A) Representación gráfica de los valores de referencia. B) Valores promedio de Chl-a. C) Valores estimados durante un evento de proliferación algal.

7.6 Modelación estadística de la comunidad de fitoplancton

7.6.1 Selección del mejor modelo ajustado

El mejor modelo ajustado para cada uno de los géneros de fitoplancton analizados, se muestran en la tabla VII. El orden de las variables predictoras fue definido considerando la contribución de cada variable sola, por lo tanto, la variable predictora que contribuye más fue adicionada al modelo nulo en el primer paso. Los resultados indican que el mejor modelo MAG ajustado es aquel que incluye todos los parámetros ambientales. Los valores más altos de R^2 ajustada fueron obtenidos para los géneros *Gymnodinium* (0.99) y *Pseudo-Nitzschia* (0.96), así también valores de devianza mayores al 80%. Por el contrario los modelos construidos para los géneros *Protoperdinium* y *Tripos* mostraron los valores de R^2 ajustada y la devianza explicada de los datos más baja 60.5 and 63.8% respectivamente.

Tabla VII. Estadísticos de evaluación del desempeño predictivo de los modelos MAG. R^2_{ajust} (coeficiente de determinación ajustado); AIC (criterio de información de Akaike); R (coeficiente de correlación de Pearson); RMSE (raíz del error cuadrático medio). En negrita, el MAG con la mayor capacidad predictiva de cada uno de los géneros analizados.

| Género | Variable | Res. Dev | Devianza | P(X_2) | Dev expl (%) | R^2_{ajust} | AIC | R | RSME |
|-------------------------|-----------|----------|----------|------------|--------------|---------------|---------------|-------------|-------------|
| <i>Tripos</i> | Nulo | 190.01 | | | | | 307.59 | | 3.18 |
| | +f(TSM) | 142.95 | 47.06 | < 0.05 | 24.8 | 0.22 | 265.22 | 0.49 | 2.78 |
| | +f(Chl-a) | 93.79 | 49.16 | < 0.05 | 50.6 | 0.49 | 221.37 | 0.73 | 2.21 |
| | +f(Sal) | 88.51 | 5.28 | < 0.05 | 53.4 | 0.50 | 220.04 | 0.74 | 2.16 |
| | +f(pH) | 79.56 | 8.95 | < 0.05 | 58.1 | 0.55 | 216.76 | 0.78 | 2.02 |
| | +f(OD) | 68.70 | 10.86 | < 0.05 | 63.8 | 0.61 | 212.72 | 0.83 | 1.82 |
| <i>Prorocentrum</i> | Nulo | 184.35 | | | | | 292.32 | | 2.87 |
| | +f(TSM) | 127.16 | 57.18 | | 31 | 0.29 | 238.41 | 0.57 | 2.38 |
| | +f(pH) | 107.54 | 19.62 | < 0.05 | 41.7 | 0.38 | 226.96 | 0.67 | 2.15 |
| | +f(Sal) | 92.30 | 15.24 | < 0.05 | 49.9 | 0.51 | 216.09 | 0.78 | 1.85 |
| | +f(OD) | 73.34 | 18.96 | < 0.05 | 60.2 | 0.63 | 203.09 | 0.84 | 1.61 |
| | +f(Chl-a) | 72.88 | 0.46 | < 0.05 | 60.5 | 0.61 | 204.62 | 0.84 | 1.63 |
| <i>Pseudo-nitzschia</i> | Nulo | 453.23 | | | | | 540.58 | | 6.54 |
| | +f(pH) | 316.99 | 136.24 | < 0.05 | 30.1 | 0.28 | 410.03 | 0.56 | 5.42 |
| | +f(Sal) | 194.08 | 122.91 | < 0.05 | 57.2 | 0.51 | 293.14 | 0.76 | 4.28 |
| | +f(Chl-a) | 100.81 | 93.27 | < 0.05 | 77.8 | 0.77 | 205.72 | 0.90 | 2.93 |
| | +f(OD) | 77.87 | 22.94 | < 0.05 | 82.8 | 0.87 | 188.11 | 0.95 | 2.13 |
| | +f(TSM) | 61.97 | 15.90 | < 0.05 | 86.3 | 0.89 | 174.17 | 0.96 | 1.92 |
| <i>Gymnodinium</i> | Nulo | 2468.49 | | | | | 2526.03 | | 31.57 |
| | +f(Chl-a) | 884.65 | 1583.85 | < 0.05 | 64.2 | 0.67 | 948.08 | 0.83 | 17.65 |
| | +f(TSM) | 614.07 | 270.58 | < 0.05 | 75.1 | 0.83 | 682.32 | 0.91 | 13.33 |
| | +f(Sal) | 419.78 | 194.29 | < 0.05 | 83 | 0.87 | 494.53 | 0.95 | 10.14 |
| | +f(pH) | 275.91 | 143.87 | < 0.05 | 88.8 | 0.92 | 357.07 | 0.97 | 7.63 |
| | +f(OD) | 152.12 | 123.79 | < 0.05 | 93.8 | 0.97 | 239.09 | 0.99 | 4.42 |

7.7 Preferencias ambientales del fitoplancton

Los gráficos de efectos parciales de los modelos (Fig. 9), fueron usados para describir la relación entre las variables de respuesta (abundancia de fitoplancton) y variables predictoras (factores ambientales). De acuerdo a estos gráficos, altas abundancias de *Tripes* se espera que ocurran en ambientes con TSM de 22 a 28 °C, bajos valores de Chl-a ($< 1 \mu\text{g}\cdot\text{L}^{-1}$), salinidad (< 35.5 UPS) y OD ($< 4.5 \mu\text{g}\cdot\text{L}^{-1}$), pH de 7.5 a 8.1 (Fig. 9A). Para *Prorocentrum*, se espera que ocurran altas abundancias en aguas con TSM de 24 a 29 °C, pH de 7.7 a 8.1, Salinidad de 35.5 a 37 UPS, valores altos de OD ($> 4.5 \text{mg}\cdot\text{L}^{-1}$), y valores bajos de Chl-a ($< 0.5 \mu\text{g}\cdot\text{L}^{-1}$) (Fig. 9B). Valores altos de abundancia de *Pseudo-nitzschia* son esperados que ocurran en aguas con valores bajos de pH (< 7.7), baja salinidad (< 36.5 UPS), Chl-a de 0.5 a $2 \mu\text{g}\cdot\text{L}^{-1}$, OD de 4.5 a $5.5 \text{mg}\cdot\text{L}^{-1}$, y bajos valores de TSM (< 24 °C) (Fig. 9C). Finalmente, valores de abundancia altos de *Gymnodinium* se espera que ocurran en aguas con valores altos de Chl-a ($> 1 \mu\text{g}\cdot\text{L}^{-1}$), TSM de 22 a 26 °C, salinidad de 35 a 36.5 UPS, altos valores de pH (> 7.8), y OD más bajo que $5.5 \text{mg}\cdot\text{L}^{-1}$ (Fig. 9D).

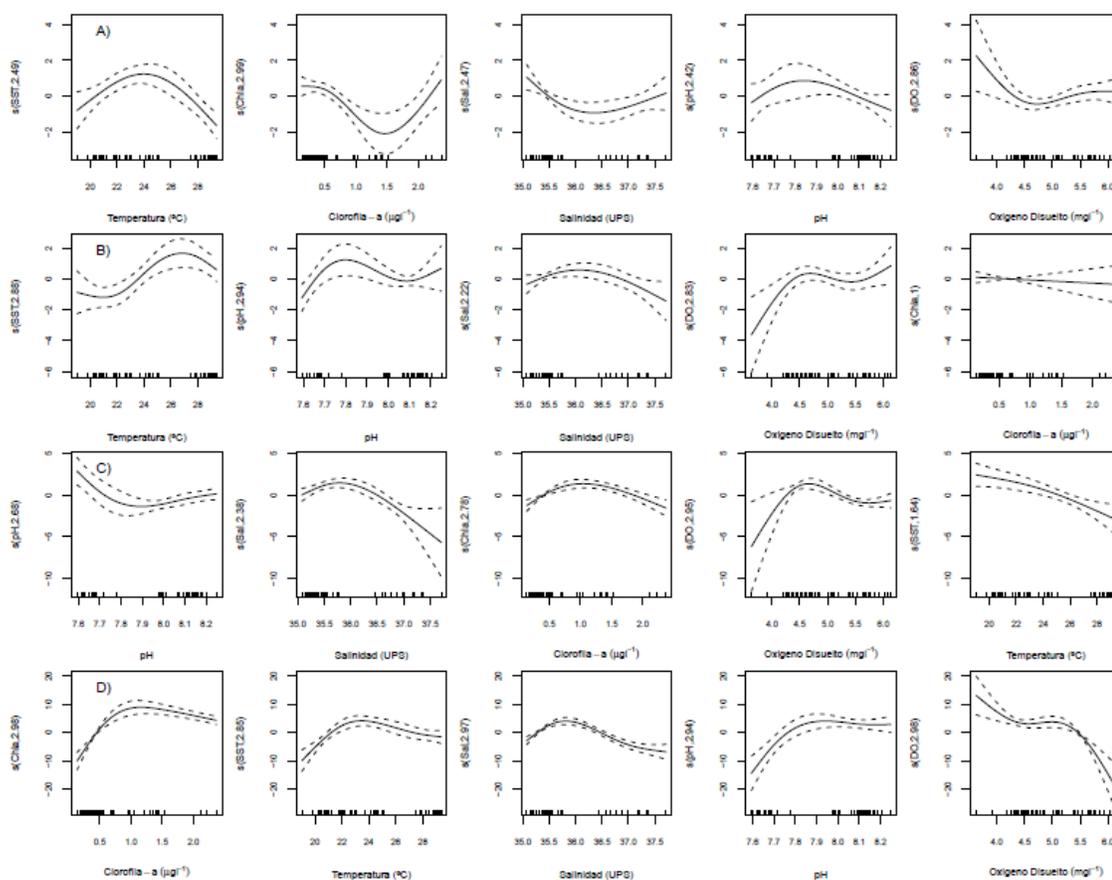


Figura 9. Gráficos de efectos parciales de MAG. A) *Triplos*, B) *Procoentrum*, C) *Pseudo-nitzschia*, D) *Gymnodinium*. La línea sólida representa la línea ajustada, el área punteada indica el intervalo de confianza al 95%. Las líneas en la parte inferior del eje x indican los valores observados de la variable predictiva y los números en el eje y indican los grados efectivos de libertad.

7.8 Predicción espacial de la abundancia de fitoplancton

Los patrones de distribución mensual estimados para el género *Triplos* a una distribución espacial de 30 m, son representados en la figura 10. Los resultados indican que la abundancia de *Triplos* es constante a través del año, presentando las mayores abundancias de noviembre a junio principalmente en la región oceánica, donde las condiciones ambientales medidas *in situ* (Fig. 2) son similares a las observadas en los gráficos de efectos parciales, principalmente en la región oceánica de la Bahía de La Paz, donde fueron registrados los valores más altos.

También se observa que durante los meses de agosto a octubre (verano) la abundancia de este género disminuye.

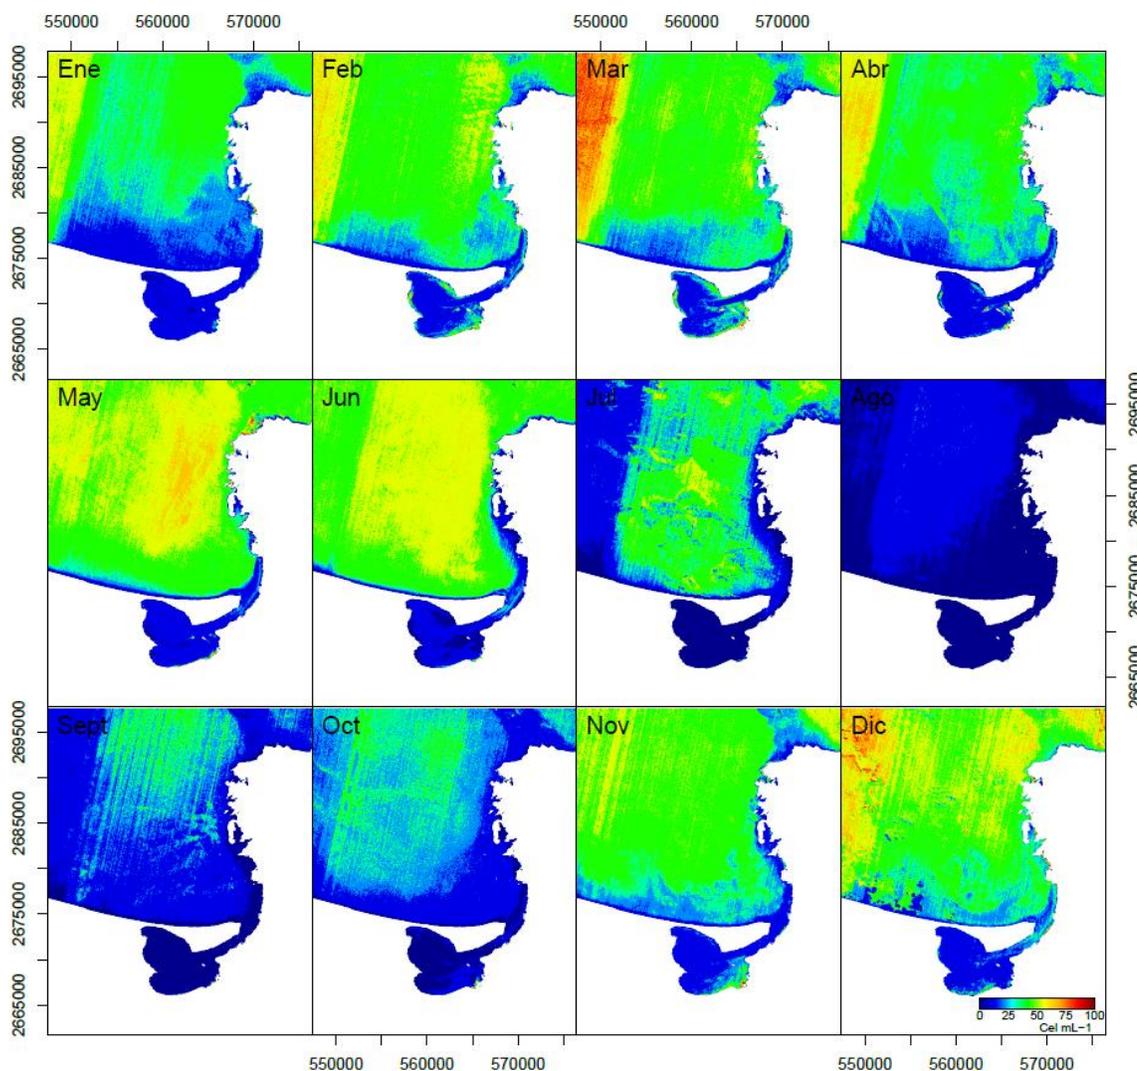


Figura 10. Predicción espacial estimada mediante MAG para el género *Tripos* en la Bahía de La Paz.

Los patrones de distribución la abundancia de *Prorocentrum*, sugieren que las condiciones ambientales idóneas para la presencia de este género, ocurre durante los meses de junio a noviembre, particularmente durante junio al interior de la ensenada y en las zonas costeras, mientras que en julio se observaría una mayor abundancia en la región oceánica del área de (Fig. 11).

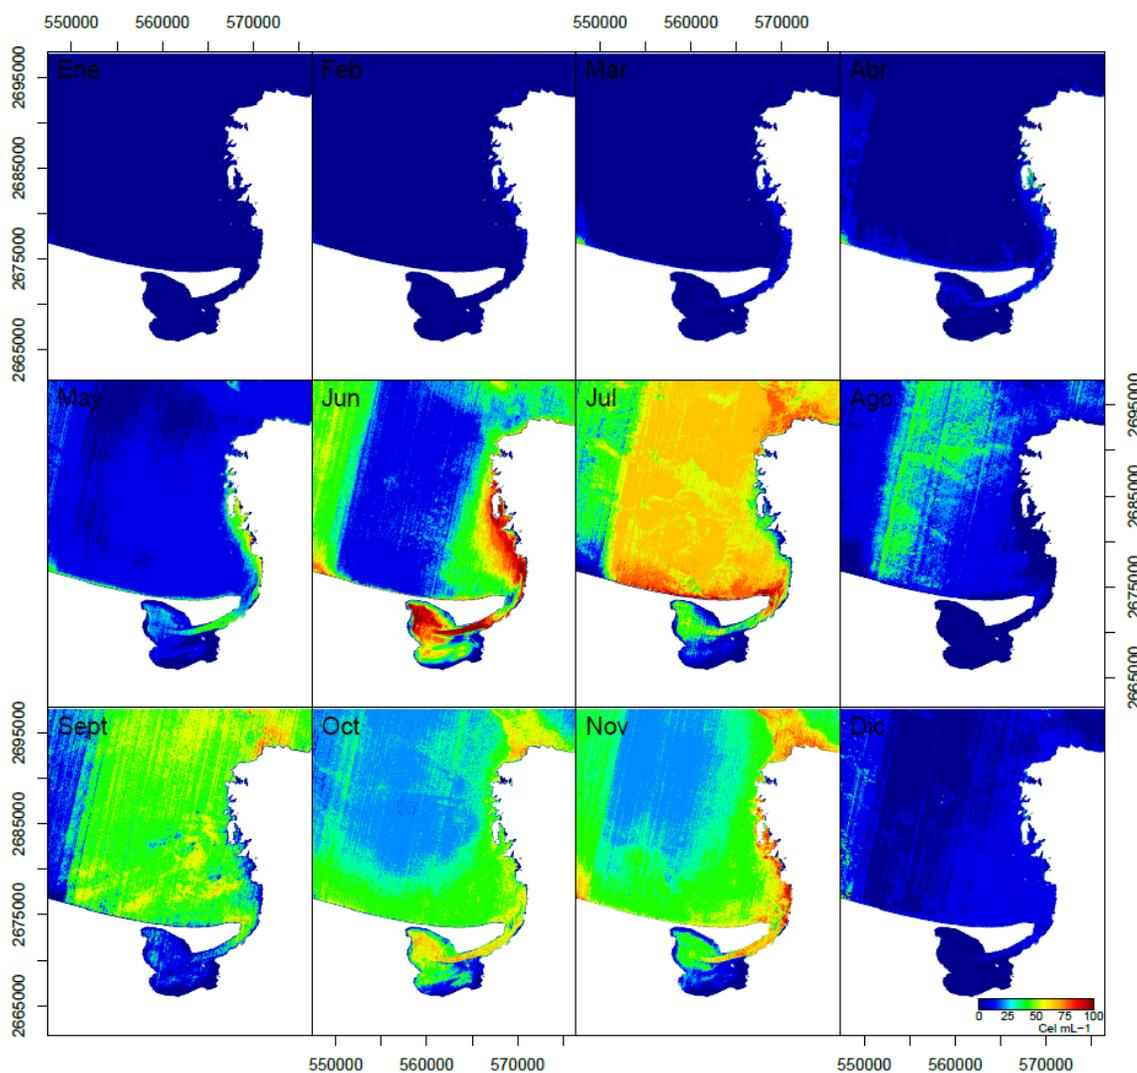


Figura 11. Predicción espacial estimada mediante MAG para el género *Prorocentrum* en la Bahía de La Paz.

Los patrones de distribución la abundancia del género *Pseudo-nitzschia* sugieren que las condiciones ambientales adecuadas este género ocurren de diciembre a agosto, con una distribución principalmente oceánica durante los meses de diciembre a junio; y durante los meses de julio a septiembre el área de con mayor abundancia disminuye, concentrándose en las zonas costeras, principalmente en el canal y la zona de transición entre el canal y la Bahía de La Paz (Fig. 12).

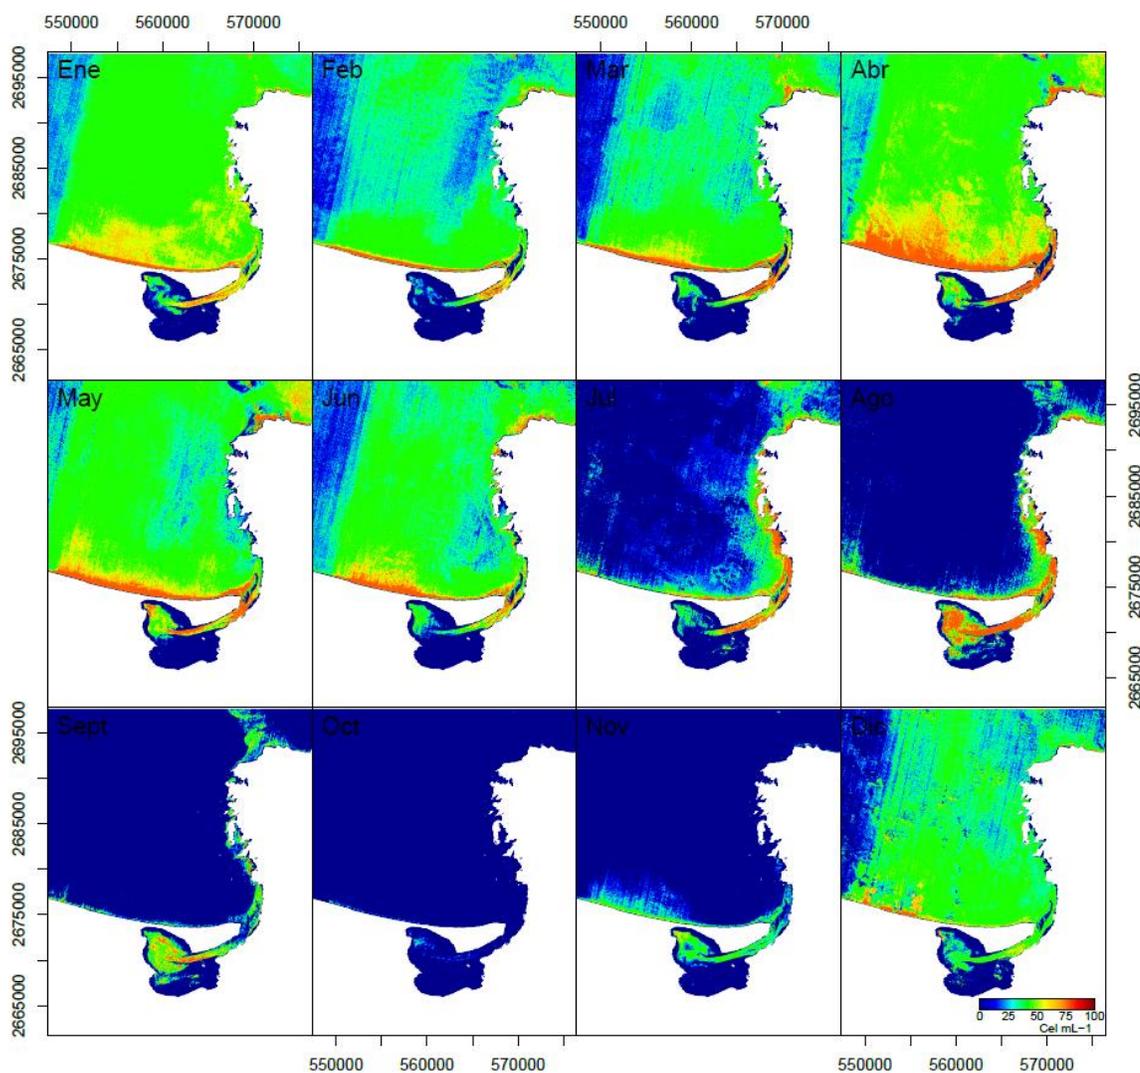


Figura 12. Predicción espacial estimada mediante MAG para el género *Pseudo-nitzschia* en la Bahía de La Paz.

La figura 13, muestra el patrón de distribución de la abundancia de *Gymnodinium*, los resultados sugieren que las condiciones ambientales adecuadas para este género se presentan durante los meses de marzo a julio y de octubre a noviembre. Durante los meses de marzo a mayo la distribución es principalmente costera y al interior de la ensenada; posteriormente durante Junio se incrementa el área de distribución en toda el área de estudio; disminuyendo su

presencia durante los meses de julio a septiembre y finalmente de octubre a noviembre se observa un incremento al interior de la ensenada.

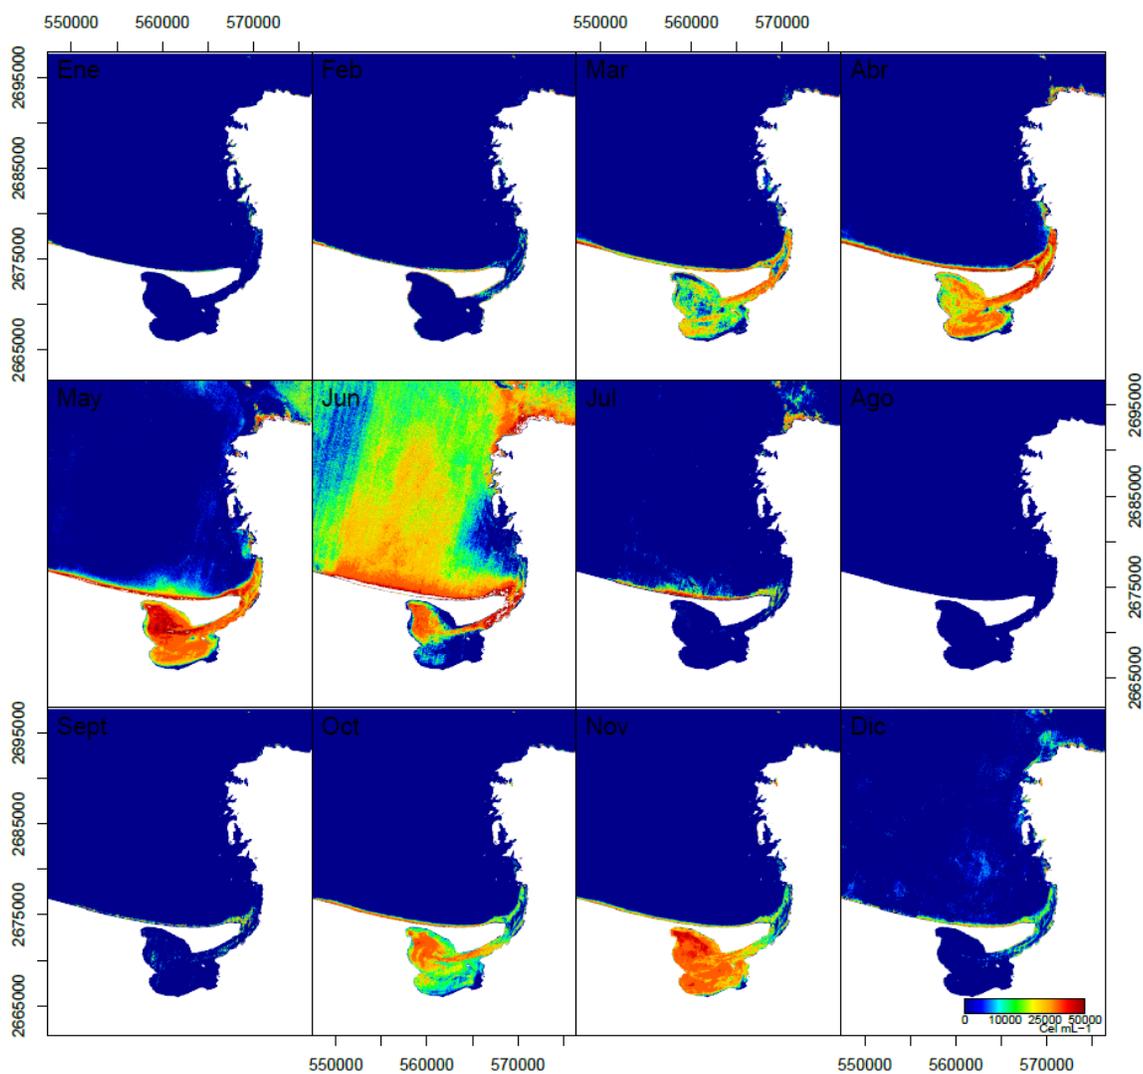


Figura 13. Predicción espacial estimada mediante MAG para el género *Gymnodinium* en la Bahía de La Paz.

8. DISCUSIÓN

8.1 Estimación de clorofila-a

Este estudio evaluó el uso de Landsat 8 para estimar la concentración de Chl-a en un cuerpo de agua costera ubicado en el noroeste de México mediante la medición de datos de campo y modelos de regresión (lineal simple, lineal múltiple y modelos aditivos generalizados), con la finalidad de describir la relación de esta variable con la reflectancia del agua en diferentes longitudes de onda, registrados por el satélite y obtener valores de Chl-a con una alta resolución espacial, lo que permitió describir la variabilidad espacio-temporal en el área de estudio desde 2013 hasta 2017. La importancia de lo anterior radica en que a partir de estas estimaciones se pueden identificar eventos de proliferaciones algales desde el espacio. Los resultados obtenidos sugieren que el uso de las bandas espectrales 1 (aerosol costero), 2 (azul), 3 (verde) y 5 (NIR), a partir de un modelo de RLM, permite estimar de forma confiable ($R^2 = 0.757$) concentraciones de Chl-a en un ambiente costero.

A la fecha, existe un gran número de publicaciones que muestran que la Chl-a puede estimarse utilizando imágenes satelitales Landsat, mediante la medición de datos *in situ* y el uso de modelos de regresión lineal simples o múltiples; sin embargo, los enfoques que se han utilizado para este propósito son muy diversos. Por ejemplo, algunos autores han utilizado modelos simples en donde la variable predictiva es solamente una de las bandas espectrales (Allan *et al.*, 2015; Kim *et al.*, 2016; Tebbs *et al.*, 2013); otros autores proponen que la relación de dos bandas espectrales podría usarse como un buen predictor de la concentración de Chl-a (Giardino *et al.*, 2001; Han y Jordan, 2005; Masocha *et al.*, 2017; Patra *et al.*, 2016; Torbick y Corbiere, 2015); mientras que otros autores sugirieron que la combinación de varias bandas espectrales en modelos de regresión lineal múltiple

permiten una mejor estimación de Chl-a en ambientes acuáticos (Brezonik *et al.*, 2005; Brivio *et al.*, 2001; Kim *et al.*, 2016; Lim y Choi, 2015; Singh *et al.*, 2014).

Estos enfoques generan incertidumbre sobre cuál es el mejor modelo para estimar Chl-a en ambientes acuáticos. Por este motivo, este estudio utilizó un enfoque estadístico y la teoría de absorción/reflexión de Chl-a para evaluar la capacidad predictiva de modelos RLS, RLM y MAG en la estimación de Chl-a; de tal manera que los modelos se construyeron utilizando bandas espectrales donde Chl-a tenía su mayor absorción/reflexión. De acuerdo con los principales resultados obtenidos por diversos investigadores, la Chl-a tiene su mayor absorción de luz en longitudes de onda de 400 a 500 nm (azul) y 680 nm (rojo) y su máxima reflexión a 550 nm (verde) y 700 nm (NIR). Por lo tanto, se esperaba una correlación negativa entre Chl-a y la reflectancia de la banda azul, es decir, cuanto mayor es la concentración de Chl-a, menor es la reflectancia en esta longitud de onda. Por otro lado, se esperaba una correlación positiva entre Chl-a y la reflectancia en las bandas verde y NIR, en otras palabras, cuanto mayor es la concentración de Chl-a, mayor es la reflectancia en estas longitudes de onda (Arenz *et al.*, 1996; Brivio *et al.*, 2001; Dalu *et al.*, 2015; Dube, 2012; Dube *et al.*, 2014).

Inicialmente, este estudio evaluó la correlación lineal entre la Chl-a transformada mediante el uso de la función logaritmo natural y la reflectancia espectral en 5 longitudes de onda (aerosol/ costero, azul, verde, rojo y NIR) utilizando coeficientes de correlación de Pearson, sin embargo, dos cosas que llamaron la atención en los resultados obtenidos fueron: (1) La baja correlación ($r < 0.2$) entre Chl-a y las bandas espectrales seleccionadas; y (2) La baja correlación entre Chl-a y las banda roja y NIR que además presentó un signo opuesto al esperado. En ese sentido, varios autores han encontrado valores altos o bajos del coeficiente de correlación de Pearson y la Chl-a; por ejemplo, Lim y Choi (2015) encontraron valores de correlación mayores que 0.6 entre las bandas

azul, verde, roja y NIR y la Chl-a; sin embargo, sus resultados sugirieron relaciones inversas porque todos los valores de correlación fueron negativos. Por otro lado, Patra *et al.* (2016) encontró correlaciones menores de 0.5 y positivas entre las bandas azules, verdes, rojas y NIR y la Chl-a. En ambos casos, la estimación de Chl-a se realizó en cuerpos de agua dulce (ríos y lagos), lo que podría haber generado estas diferencias con respecto a los resultados encontrados en este trabajo. Por lo general, en cuerpos de agua dulce como ríos y lagos, la turbidez (causada por la materia orgánica particulado) es varias veces mayor que en los cuerpos marinos (Del Castillo *et al.*, 2000; Joshi y D'Sa, 2015).

Otros autores han sugerido que la combinación de bandas espectrales en forma de proporción (por ejemplo, NIR/rojo) presenta una mayor correlación con la Chl-a (Lim y Choi, 2015; Masocha *et al.*, 2017; Patra *et al.*, 2016; Tebbs *et al.*, 2013; Watanabe *et al.*, 2015). En este sentido, nuestro estudio encontró valores de correlación más altos entre la Chl-a y la proporción de la banda roja entre la banda aerosol costera transformada al cuadrado ($B4/B1^2$). Otro punto interesante en este trabajo fue el uso de la banda de aerosol costera (B1) porque cuando se incluyó, los modelos aumentaron el valor de correlación (R) y disminuyeron el valor de RMSE. Esta banda está constituida por longitudes de onda que detectan azul profundo y violeta muy similar a la banda azul que se caracteriza por baja reflectancia en ambientes con alta concentración de Chl-a. De acuerdo con Slonecker *et al.* (2016) y Loyd (2013), esta característica hace que la banda sea potencialmente importante para la investigación de los fenómenos costeros.

Como se mencionó anteriormente, el modelo RLM seleccionado se utilizó para realizar inferencia estadística, en este caso particular, para evaluar la relación lineal entre bandas espectrales y la Chl-a mediante el uso de los coeficientes del modelo de regresión lineal múltiple. Los resultados mostraron una alta concordancia entre los resultados observados (modelo) y esperados (propiedades de absorción/reflexión de Chl-a), específicamente el coeficiente negativo de la

banda azul (B2) y los coeficientes positivos de las bandas verdes (B3) y NIR (B5). En este sentido, Brivio *et al.* (2001) y Lim y Choi (2015) utilizaron modelos de regresión lineal múltiple para estimar valores de Chl-a (entre otros) a través del uso de diferentes bandas espectrales de Landsat; sin embargo, los coeficientes del mejor modelo utilizado para estimar la Chl-a mostraron los signos esperados opuestos. Por ejemplo, valores positivos con banda azul (B2) y negativos con banda verde (B3).

A la fecha, muchos estudios han abordado la estimación de Chl-a a partir de imágenes adquiridas por satélites, tanto en cuerpos de agua dulce como en ambientes marinos, obteniendo resultados prometedores; sin embargo, al comparar métodos y resultados, han mostrado una gran discrepancia en la forma en que se ha estimado la Chl-a a partir de imágenes Landsat, que puede deberse a la longitud de onda utilizada (o proporciones entre ellas), el tipo de método estadístico o el tipo del entorno donde se realizó el estudio. Todo esto sugiere que los métodos aplicados en un lugar o entorno específico no se pueden replicar de manera similar en otro lugar y/o entorno diferente; sugiriendo la necesidad de una mayor validación de campo y cobertura espacial o temporal, así como también una comparación de la estimación de Chl-a en diferentes tipos de ambientes acuáticos con un método estandarizado.

8.2 Relaciones entre los principales grupos de fitoplancton y parámetros ambientales

El estudio de los parámetros físico-químicos y su efecto en la biodiversidad del fitoplancton, es de gran importancia debido a que en ambientes costeros y oceánicos, la dinámica del fitoplancton se encuentra definida en función de procesos ambientales, que influyen fuertemente en la estructura de la comunidad y afectan la diversidad, favoreciendo o limitando el crecimiento de los diferentes grupos de fitoplancton (Aktan *et al.*, 2005; Jensen *et al.*, 2017; Mei-Lin *et al.*,

2014). Los parámetros ambientales que se abordaron en este trabajo son representados estacionalmente en la figura 2, donde las variables muestran diferencias entre cada una de las estaciones; esto debido a que la Bahía de La Paz es una región que presenta una dinámica física y ecológica influenciada fuertemente por cambios estacionales (Lluch-Cota *et al.*, 2010). Debido a esto, en este trabajo se evaluó el efecto de la variabilidad ambiental en la abundancia de los principales grupos de fitoplancton presentes en la Bahía de La Paz, para lograrlo se utilizaron modelos de distribución de especies (Modelos Aditivos Generalizados, MAG), utilizando como variable respuesta la abundancia de los principales grupos de fitoplancton, medidos en campo, y los parámetros ambientales derivados de imágenes Landsat 8 como variables predictivas.

Estudios previos han utilizado ampliamente diversas técnicas y métodos para evaluar las relaciones existentes entre los parámetros ambientales y físico-químicos sobre la distribución espacial y temporal, así como las fluctuaciones en la abundancia de la comunidad de fitoplancton; abordándolas desde diversas perspectivas, como análisis de clúster (Tafas y Economou-Amilli, 1997), análisis de correspondencia canónica (Ghinaglia *et al.*, 2004; Liu *et al.*, 2010; Naselli-Flores y Barone, 1998), análisis de componentes principales (Ghinaglia *et al.*, 2004; Mei-Lin *et al.*, 2014). Sin embargo, las relaciones entre los parámetros ambientales y la estructura de la comunidad no siempre se presentan como del tipo lineal, es por esto, que los MAG pudieran ser una herramienta más adecuada, ya que permiten evaluar relaciones lineales y no-lineales entre la variable respuesta y las variables predictivas. En este sentido, el uso de MAG en el presente estudio permitió analizar los efectos de cinco parámetros ambientales (TSM, Chl-a, salinidad, pH y OD) sobre la distribución probable de cuatro géneros (*Triplos*, *Prorocentrum*, *Pseudo-nitzschia* y *Gymnodinium*) en la Bahía de La Paz.

En la actualidad se han llevado a cabo numerosos estudios que utilizan parámetros ambientales para describir la distribución de organismos que viven en aguas poco profundas, así como la variación estacional en la diversidad y la riqueza de especies, sugiriendo que están estrechamente relacionadas con las condiciones ambientales de la superficie del mar, como la temperatura superficial del mar y la concentración de clorofila (Bentlage *et al.*, 2013; Macpherson, 2002; Shen *et al.*, 2012).

El fitoplancton ha sido estudiado a lo largo de varias décadas en el Golfo de California (Gárate-Lizárraga, 2013; Gárate-Lizárraga *et al.*, 2006, 2007), en los cuales se ha documentado la estructura estacional de la comunidad del fitoplancton, asociados a surgencias, capas de mezcla de agua (Martínez-López *et al.*, 2001), reportando que los principales grupos presentes en el Golfo de California son Dinoflagelados, Diatomeas, Rafidofitas, Cianobacterias y coccolitoforidos; coincidiendo con los principales géneros registrados en el presente trabajo (Fig. 3). Sin embargo, a pesar de la gran cantidad de estudios sobre el fitoplancton en la Bahía de La Paz, existen pocos estudios que analizan el efecto de los parámetros ambientales en la distribución probable de cada uno de ellos.

Los resultados obtenidos de las predicciones espaciales y temporales para el género *Prorocentrum*, nos indican que la abundancia de este género se observa de junio a noviembre, siendo durante junio y julio donde se presentarán las mayores densidades celulares. Estos resultados concuerdan con los principales reportes de eventos de proliferaciones que se tienen registrados para el Golfo de California, en donde las abundancias más altas para diversas especies del género *Prorocentrum* (*P. minimum*, *P. lima*, *P. rathymum* y *P. dentatum*, *P. micans* y *P. gracile*) se presentan a partir de finales de verano y durante el otoño y han sido asociados a temperaturas de 23.5 a 33 °C y salinidades de 28 a 40 UPS (Cortés-Altamirano y Agraz, 1994; Gárate-Lizárraga *et al.*, 2015; Sierra-Beltrán *et al.*,

2005). Estos rangos de valores son similares a los observados en los gráficos de respuesta de los MAG (Fig. 9B), TSM (24 a 28 °C), Sal (35 a 37), donde fue observada una correlación negativa, la cual ha sido descrita por (Sierra-Beltrán *et al.*, 2005). De acuerdo a los resultados, el rango óptimo de pH se encuentra entre 7.6 a 8. Estudios previos han demostrado que especies de *Prorocentrum* tienden a tolerar valores altos de pH (>9), que le ayudan en la competencia con otras especies (Pedersen y Hansen, 2003; Sierra-Beltrán *et al.*, 2005).

Las predicciones espaciales y temporales del género *Pseudo-nitzschia*, indican que la abundancia de este género en la Bahía de La Paz, es mayor desde diciembre hasta junio, observándose las densidades celulares más altas durante los meses de abril a junio; estos resultados son respaldados por los reportes existentes en la literatura sobre eventos de proliferación, los cuales inician a partir de enero a julio en el Golfo de California (Gárate-Lizárraga *et al.*, 2013; López-Cortés *et al.*, 2015; Sierra-Beltrán *et al.*, 1997). De manera similar, Rivera-Vilarelle *et al.* (2013) encontraron resultados similares en el Pacífico central Mexicano, donde la máxima diversidad y abundancia fue observada durante la primavera, mientras que para el otoño tiende a disminuir. El modelo predice que las condiciones ambientales donde se observaran las mayores abundancias de este género se presentan cuando los valores de TSM son bajos (< 20 °C) y que existe una correlación negativa con esta variable (Fig. 8C); estos datos obtenidos son similares a los publicados previamente para la región del Golfo de California, donde se reportan valores de TSM en un rango de 18 a 19 °C al inicio de los eventos de proliferación y cuando TSM incrementa (27 a 28 °C) la abundancia tiende a disminuir (Gárate-Lizárraga *et al.*, 2007; López-Cortés *et al.*, 2015; Rivera-Vilarelle *et al.*, 2013); Además, estos resultados también concuerdan con trabajos reportados en diversas partes del mundo, quienes registran abundancias de *Pseudo-nitzschia* asociadas con bajas temperaturas, altas salinidades (Trainer *et al.*, 2000, 2012) y bajos valores de pH (Lundholm *et al.*, 2004).

Basado en los resultados de los MAG para el género *Gymnodinium*, las cinco variables son importantes predictoras para modelar la distribución espacial y temporal de este género (Fig. 9D). Los resultados predicen que las condiciones ambientales adecuadas para este género se presentan cuando TSM se encuentra dentro de un rango de 20 a 26 °C. Patrones similares fueron observados durante diversos eventos de proliferaciones en el Golfo de California, donde la temperatura se ha registrado en un rango de 19 a 26 °C (Band-Schmidt *et al.*, 2010; García-Hernández *et al.*, 2005; Hernández-Sandoval *et al.*, 2009; López-Cortés *et al.*, 2011). Este rango de valores ha sido reportado en diversas áreas del Pacífico Mexicano (Mee *et al.*, 1986). Así también, algunas discrepancias fueron observadas entre nuestros resultados y algunas variables registradas en la literatura; por ejemplo, algunos trabajos reportan un rango de salinidad de 34 a 38 UPS (García-Hernández *et al.*, 2005; Graham, 1943); altas concentraciones de OD (2 a 10 mg/L) (García-Hernández *et al.*, 2005; Hernández-Sandoval *et al.*, 2009; Morquecho y Lechuga-Devéze, 2004) y Chl-a de 2 a 7 mgm⁻³ (Gárate-Lizárraga *et al.*, 2009; López-Cortés *et al.*, 2011).

Los resultados obtenidos en el presente trabajo sobre las predicciones espacial y temporal de *Gymnodinium* para la Bahía de La Paz, nos indican la presencia de este género principalmente durante los meses de marzo a julio y de octubre a noviembre, siendo de abril a junio cuando se presentarán las mayores densidades celulares. Estos resultados son consistentes con los principales reportes de eventos de proliferaciones para el área de estudio, particularmente con lo reportado por Gárate-Lizárraga *et al.* (2004), quien durante un año de monitoreo en la Bahía de La Paz registró *G. catenatum* en cinco meses, octubre, diciembre, marzo, abril y junio

9. CONCLUSIONES

Este estudio ha evaluado la capacidad predictiva de modelos de regresión (lineal simples y múltiples y modelos aditivos generalizados) para estimar la concentración de Chl-a, utilizando las primeras cinco bandas de imágenes Landsat 8 en la Bahía de La Paz, Baja California Sur. Los resultados obtenidos indicaron que este método proporcionó una estimación confiable de Chl-a en pequeñas masas de agua costeras debido a la alta coherencia encontrada en los coeficientes del modelo con las propiedades de absorción/reflexión de Chl-a evaluadas en laboratorio bajo condiciones controladas. Por lo tanto, la detección remota ha demostrado representar una oportunidad ideal para desarrollar investigaciones a escala regional sobre diversos parámetros en entornos estimados en pequeñas masas de agua costeras para permitir un monitoreo constante a bajo costo y en una escala espacial de alta calidad.

Los MAG aplicados a los modelos de distribución de los principales géneros de fitoplancton en el área de estudio, sugieren que la estructura de las poblaciones de fitoplancton en la Bahía de La Paz se encuentra definida por cambios estacionales predecibles, y las variaciones se pueden explicar de manera significativa por los parámetros ambientales en diferente orden de importancia para cada uno de los géneros analizados. En la mayoría de los modelos, por orden de importancia las variables que aportan mayor información y que rigen su distribución espacial y temporal son: la temperatura, clorofila-a, pH, salinidad y el oxígeno disuelto. Los resultados sugieren que los modelos MAG son adecuados para predecir la abundancia de especies oportunistas que comienzan a proliferar dominando sobre otras. Estos modelos resumen de manera adecuada las condiciones ambientales óptimas para cada uno de los géneros analizados, así como también las condiciones adversas que generan una disminución en la abundancia de las mismas. El estudio demostró que el modelado espacial basado

en MAG podría utilizarse para crear mapas confiables de la distribución de especies de fitoplancton.

Este trabajo representa uno de los primeros esfuerzos para utilizar modelos de distribución de especies en comunidades de fitoplancton usando parámetros ambientales de alta resolución espacial derivadas de imágenes Landsat. Por lo tanto, esta técnica podría ser una herramienta útil para describir las preferencias de hábitat de las comunidades de fitoplancton con una alta resolución espacial, mismas que se puede implementar en programas de monitoreo.

10. LITERATURA CITADA

- Aktan, Y., V. Tüfekçi, H. Tüfekçi, G. Aykulu. 2005. Distribution patterns, biomass estimates and diversity of phytoplankton in Izmit Bay (Turkey). *Estuar. Coast. Shelf Sci.* 64(2):372–384.
- Allan., D. P. Hamilton, B. J. Hicks, L. Brabyn. 2011. Landsat remote sensing of chlorophyll a concentrations in central North Island lakes of New Zealand. *Int. J. Remote Sens.* 32(7):2037–2055.
- Allan, M., P. D. Hamilton, B. Hicks, L. Brabyn. 2015. Empirical and semi-analytical chlorophyll a algorithms for multi-temporal monitoring of New Zealand lakes using Landsat. *Environ. Monit. Assess.* 187(6):364–388.
- Álvarez–Arellano, A. D., H. Rojas–Soriano, J. J. Prieto–Mendoza. 1997. Geología de la Bahía de La Paz y áreas adyacentes. En: Urbán Ramírez, J., Ramírez Rodríguez, M. (Eds.). *La Bahía de La Paz, investigación y conservación.* Mexico, pp. 13–29.
- Anderson, C. R., D. A. Siegel, R. M. Kudela, M. A. Brzezinski. 2009. Empirical models of toxigenic *Pseudo-nitzschia* blooms: Potential use as a remote detection tool in the Santa Barbara Channel. *Harmful Algae* 8(3):478–492.
- Antoine, D., J.-M. André, A. Morel. 1996. Oceanic primary production 2. Estimation at global scale from satellite (Coastal Zone Color Scanner) chlorophyll. *Global Biogeochem. Cycles* 10(1):57–69.
- Arenz, R. F. J., W. M. J. Lewis, J. F. Saunders. 1996. Determination of chlorophyll and dissolved organic carbon from reflectance data for Colorado reservoirs. *Int. J. Remote Sens.* 17(8):1547–1566.
- Austin, M. 2007. Species distribution models and ecological theory: A critical

- assessment and some possible new approaches. *Ecol. Modell.* 200(2):1–19.
- Aviña-Hernández, R. J. 2018. Estimación de parámetros ambientales a partir de imágenes Landsat 8 y mediciones in situ, en Bahía de La Paz, BCS. La Paz, B.C.S. Centro de Investigaciones Biológicas del Noroeste. 97 p.
- Babin, M., C. S. Roesler, J. J. Cullen. 2008. Real-time coastal observing systems for marine ecosystem dynamics and harmful algal blooms: theory, instrumentation and modelling, Oceanographic methodology series. UNESCO, España.
- Balech, E. 1988. Los dinoflagelados del Atlántico sudoccidental, 1a ed. Ministerio de Agricultura, Pesca y Alimentación, Secretaría General Técnica.
- Band-Schmidt, C. J., J. J. Bustillos-Guzmán, D. J. López-Cortés, I. Gárate-Lizárraga, E. J. Núñez-Vázquez, F. E. Hernández-Sandoval. 2010. Ecological and physiological studies of *Gymnodinium catenatum* in the Mexican Pacific: A review. *Mar. Drugs* 8(6):1935–1961.
- Barton, A. D., A. J. Irwin, Z. V Finkel, C. A. Stock. 2016. Anthropogenic climate change drives shift and shuffle in North Atlantic phytoplankton communities. *Proc. Natl. Acad. Sci. U. S. A.* 113(11):2964–9.
- Bentlage, B., A. T. Peterson, N. Barve, P. Cartwright. 2013. Plumbing the depths: extending ecological niche modelling and species distribution modelling in three dimensions. *Glob. Ecol. Biogeogr.* 22(8):952–961.
- Bonanse, M., M. Ledesma, C. Rodriguez, L. Pinotti. 2018. Using new remote sensing satellites for assessing water quality in a reservoir. *Hydrol. Sci. J.* 1–11.
- Boucher, J., K. C. Weathers, H. Norouzi, B. Steele. 2018. Assessing the effectiveness of Landsat 8 chlorophyll *a* retrieval algorithms for regional freshwater monitoring. *Ecol. Appl.* 28(4):1044–1054.
- Brezonik, P., K. D. Menken, M. Bauer. 2005. Landsat-based remote sensing of lake water quality characteristics, including chlorophyll and colored dissolved organic matter (CDOM). *Lake Reserv. Manag.* 21(4):373–382.
- Brivio, P. A., C. Giardino, E. Zilioli. 2001. Determination of chlorophyll concentration changes in Lake Garda using an image-based radiative transfer code for Landsat TM images. *Int. J. Remote Sens.* 22(2–3):487–502.
- Brown, C. W., J. A. Yoder. 1994. Coccolithophorid blooms in the global ocean. *J. Geophys. Res.* 99(C4):7467–7482.
- Caballero, I., F. Steinmetz, G. Navarro, I. Caballero, F. Steinmetz, G. Navarro. 2018. Evaluation of the first year of operational sentinel-2A data for retrieval of

- suspended solids in medium- to high-turbidity waters. *Remote Sens.* 10(7):23.
- Cannizzaro, J. P., K. L. Carder, F. R. Chen, C. A. Heil, G. A. Vargo. 2008. A novel technique for detection of the toxic dinoflagellate, *Karenia brevis*, in the Gulf of Mexico from remotely sensed ocean color data. *Cont. Shelf Res.* 28(1):137–158.
- Carvalho, G. A., P. J. Minnett, L. E. Fleming, V. F. Banzon, W. Baringer. 2010. Satellite remote sensing of harmful algal blooms: A new multi-algorithm method for detecting the Florida Red Tide (*Karenia brevis*). *Harmful Algae* 9(5):440–448.
- Cervantes-Duarte, R., R. Guerrero-Godínez. 1987. Variación espacio-temporal de nutrientes de la Ensenada de La Paz, B.C.S. *An. del Inst. Ciencias del Mar y Limnol.* 15(2):129–142.
- Chang, K.-W., Y. Shen, P.-C. Chen. 2004. Predicting algal bloom in the Techi reservoir using Landsat TM data. *Int. J. Remote Sens.* 25:3411–3422.
- Charlie Loyd. 2013. Putting Landsat 8's Bands to Work | Mapbox [WWW Document]. URL <https://www.mapbox.com/blog/putting-landsat-8-bands-to-work/> (consultado 5.29.17).
- Chen, Q., T. Kutser, A. Collin, T. A. Warner. 2018. Fine resolution remote sensing of species in terrestrial and coastal ecosystems. *Int. J. Remote Sens.* 39(17):5597–5599.
- Clark, P. E., M. L. Rilee. 2010. Principles of remote sensing. En: *Remote sensing tools for exploration*. Springer New York, New York, NY, pp. 29–52.
- Cortés-Altamirano, R., C. M. Agraz. 1994. Presencia de *Prorocentrum minimum* (Pav.) Schiller en estanques para cultivo de camarón. *Cienc Mar UAS.* 13:11–16.
- Cullen, J. J., Á. M. Ciotti, R. F. Davis, M. R. Lewis. 1997. Optical detection and assessment of algal blooms. *Limnol. Oceanogr.* 42(5part2):1223–1239.
- Dalu, T., T. Dube, P. W. Froneman, M. T. B. Sachikonye, B. W. Clegg, T. Nhiwatiwa. 2015. An assessment of chlorophyll- *a* concentration spatio-temporal variation using Landsat satellite data, in a small tropical reservoir. *Geocarto Int.* 30(10):1130–1143.
- Dekker, A. G., S. W. M. Peters. 1993. The use of the Thematic Mapper for the analysis of eutrophic lakes: a case study in the Netherlands. *Int. J. Remote Sens.* 14(5):799–821.
- Del Castillo, C. E., F. Gilbes, P. G. Coble, F. E. Müller-Karger. 2000. On the dispersal of riverine colored dissolved organic matter over the West Florida

- Shelf. *Limnol. Oceanogr.* 45(6):1425–1432.
- Dorji, P., P. Fearn. 2017. Impact of the spatial resolution of satellite remote sensing sensors in the quantification of total suspended sediment concentration: A case study in turbid waters of Northern Western Australia. *PLoS One* 12(4):e0175042.
- Duarte, P., M. F. Macedo, L. C. da Fonseca. 2006. The relationship between phytoplankton diversity and community function in a coastal lagoon. En: *Marine Biodiversity*. Springer Netherlands, Dordrecht, pp. 3–18.
- Dube, T. 2012. Primary Productivity of intertidal mudflats in the Wadden Sea: A remote sensing method. University Twente-ITC.
- Dube, T., W. Gumindoga, M. Chawira. 2014. Detection of land cover changes around Lake Mutirikwi, Zimbabwe, based on traditional remote sensing image classification techniques. *African J. Aquat. Sci.* 39(1):89–95.
- Dwivedi, R., M. Rafeeq, B. R. Smitha, K. B. Padmakumar, L. C. Thomas, V. N. Sanjeevan, P. Prakash, M. Raman. 2015. Species identification of mixed algal bloom in the Northern Arabian Sea using remote sensing techniques. *Environ. Monit. Assess.*
- Eaton, S., C. Ellis, D. Genney, R. Thompson, R. Yahr, D. T. Haydon. 2018. Adding small species to the big picture: Species distribution modelling in an age of landscape scale conservation. *Biol. Conserv.* 217:251–258.
- Ekerchin, S. 2007. Water Quality Retrievals from High Resolution Ikonos Multispectral Imagery: A Case Study in Istanbul, Turkey. *Water. Air. Soil Pollut.* 183(1–4):239–251.
- Elith, J., J. R. Leathwick. 2009. Species Distribution Models: Ecological Explanation and Prediction Across Space and Time. *Annu. Rev. Ecol. Evol. Syst.* 40(1):677–697.
- Flombaum, P., J. L. Gallegos, R. A. Gordillo, J. Rincon, L. L. Zabala, N. Jiao, D. M. Karl, W. K. W. Li, et al. 2013. Present and future global distributions of the marine Cyanobacteria *Prochlorococcus* and *Synechococcus*. *Proc. Natl. Acad. Sci.* 110(24):9824–9829.
- Fois, M., A. Cuena-Lombraña, G. Fenu, G. Bacchetta. 2018. Using species distribution models at local scale to guide the search of poorly known species: Review, methodological issues and future directions. *Ecol. Modell.* 385:124–132.
- Gárate-Lizárraga, I. 2013. Bloom of *Cochlodinium polykrikoides* (Dinophyceae: Gymnodiniales) in Bahía de La Paz, Gulf of California. *Mar. Pollut. Bull.* 67(1–2):217–222.

- Gárate-Lizárraga, I., C. J. Band-Schmidt, F. Aguirre-Bahena, T. G. del Alamo. 2009. A multi-species microalgae bloom in Bahía de La Paz, Gulf of California, Mexico (June 2008). *CICIMAR Océánides* 24(1):15–29.
- Gárate-Lizárraga, I., C. J. Band-Schmidt, D. López-Cortés, J. J. Bustillos-Guzmán, K. Erler. 2007. Bloom of *Pseudo-nitzschia fraudulenta* in Bahía de La Paz, Gulf of California (June-July 2006). *Harmful Algae News* 33(July 2006):6–7.
- Gárate-Lizárraga, I., J. J. Bustillos-Guzmán, K. Erler, M. S. Muñetón-Gómez, B. Luckas, A. Tripp-Quezada. 2004. Paralytic shellfish toxins in the chocolata clam, *Megapitaria squalida* (Bivalvia: Veneridae), in Bahía de La Paz, Gulf of California. *Rev. Biol. Trop.* 52(1):133–140.
- Gárate-Lizárraga, I., A. Martínez-López, I. G. Izárraga, A. Martínez-López. 2015. Primer registro de una marea roja de *Prorocentrum mexicanum* (Prorocentraceae) en el Golfo de California. *Rev. Biol. Trop.* 45(3):1263–1271.
- Gárate-Lizárraga, I., M. del S. Muñetón Gómez, V. Maldonado López. 2006. Florecimiento del dinoflagelado *Gonyaulax polygramma* frente a la isla Espiritu Santo, Golfo de California, México. *Rev. Invest. Mar* 27(1):31–39.
- Gárate-Lizárraga, I., C. A. Poot-Delgado, E. R. Ramírez-Castillo, M. H. Páez-Hernández. 2013. Proliferation of *Pseudo-nitzschia brasiliensis* and *P. cf. pseudodelicatissima* (Bacillariophyceae) in the Estero Santa Cruz, northern Gulf of California, Mexico. *Rev. Biol. Mar. Oceanogr.* 48(2):393–399.
- García-Hernández, J., L. García-Rico, M. E. Jara-Marini, R. Barraza-Guardado, A. Hudson Weaver. 2005. Concentrations of heavy metals in sediment and organisms during a harmful algal bloom (HAB) at Kun Kaak Bay, Sonora, Mexico. *Mar. Pollut. Bull.* 50(7):733–739.
- Gens, R. 2010. Remote sensing of coastlines: detection, extraction and monitoring. *Int. J. Remote Sens.* 31(7):1819–1836.
- Gernez, P., V. Lafon, A. Lerouxel, C. Curti, B. Lubac, S. Cerisier, L. Barillé. 2015. Toward sentinel-2 high resolution remote sensing of suspended particulate matter in very turbid waters: SPOT4 (take5) experiment in the Loire and Gironde estuaries. *Remote Sens.* 7(8):9507–9528.
- Ghinaglia, L. T., J. A. Herrera-Silveira, F. A. Comín. 2004. Structural variations of phytoplankton in the coastal seas of Yucatan, Mexico. *Hydrobiologia* 519:85–102.
- Gholizadeh, M. H., A. M. Melesse, L. A. Reddi. 2016. A comprehensive review on water quality parameters estimation using remote sensing techniques. *Sensors* 16:1298.
- Giardino, C., M. Pepe, P. A. Brivio, P. Ghezzi, E. Zilioli. 2001. Detecting

chlorophyll, Secchi disk depth and surface temperature in a sub-alpine lake using Landsat imagery. *Sci. Total Environ.* 268(1–3):19–29.

- Gitelson, A. A. 1992. The peak near 700 nm on radiance spectra of algae and water: relationships of its magnitude and position with chlorophyll concentration. *Int. J. Remote Sens.* 13:3367–3373.
- Gitelson, A. A., G. Dall’Olmo, W. M. Moses, D. C. Rundquist, T. Barrow, T. R. Fisher, D. Gurlin, H. Holz. 2008. A simple semi-analytical model for remote estimation of chlorophyll-a in turbid waters: Validation. *Remote Sens. Environment* 112:3582–3593.
- González, L. V., E. Spyarakos, Torres P.J.M., L. González Vilas, E. Spyarakos, J. M. Torres Palenzuela. 2011. Neural network estimation of chlorophyll a from MERIS full resolution data for the coastal waters of Galician rias (NW Spain). *Remote Sens. Environ.* 115(2):524–535.
- Gower, J., S. King, G. Borstad, L. Brown. 2005. Detection of intense plankton blooms using the 709nm band of the MERIS imaging spectrometer. *J. Int. J. Remote Sens.* 26:2005–2012.
- Graham, H. W. 1943. *Gymnodinium catenatum*, a new dinoflagellate from the Gulf of California. *Trans. Am. Microsc. Soc.* 62(3):259.
- Grenouillet, G., L. Buisson, N. Casajus, S. Lek. 2011. Ensemble modelling of species distribution: the effects of geographical and environmental ranges. *Ecography (Cop.)*. 34(1):9–17.
- Griffin, C. G., K. E. Frey, J. Rogan, R. M. Holmes. 2011. Spatial and interannual variability of dissolved organic matter in the Kolyma River, East Siberia, observed using satellite imagery. *J. Geophys. Res.* 116(G3):G03018.
- Han, L., K. J. Jordan. 2005. Estimating and mapping chlorophyll- a concentration in Pensacola Bay, Florida using Landsat ETM+ data. *Int. J. Remote Sens.* 26(23):5245–5254.
- Hastie, T. J., R. J. Tibshirani. 1990. *Generalized additive models*. Chapman & Hall/CRC Monographs on Statistics & Applied Probability.
- He, R., D. J. McGillicuddy, B. A. Keafer, D. M. Anderson. 2008. Historic 2005 toxic bloom of *Alexandrium fundyense* in the western Gulf of Maine: 2. Coupled biophysical numerical modeling. *J. Geophys. Res. Ocean.* 113(7):1–12.
- Hellweger, F. L., P. Schlosser, U. Lall, J. K. Weissel. 2004. Use of satellite imagery for water quality studies in New York Harbor. *Estuar. Coast. Shelf Sci.* 61(3):437–448.
- Hernández-Sandoval, F. E., D. J. López-Sortés, C. J. Band-Schmidt, I. Gárate-

- Lizárraga. 2009. Toxinas paralizantes en moluscos bivalvos durante una proliferación de *Gymnodinium catenatum* Graham en la Bahía de La Paz , México. *Hidrobiológica* 19(March 2007):245–256.
- Hijmans, R. J. 2016. *Raster: Geographic Data Analysis and Modeling*.
- Hu, C., F. E. Muller-Karger, C. Taylor, K. L. Carder, C. Kelble, E. Johns, C. A. Heil. 2005. Red tide detection and tracing using MODIS fluorescence data: A regional example in SW Florida coastal waters. *Remote Sens. Environ.*
- Irwin, A. J., A. M. Nelles, Z. V. Finkel. 2012. Phytoplankton niches estimated from field data. *Limnol. Oceanogr.* 57(3):787–797.
- James, G., D. Witten, T. Hastie, R. Tibshirani. 2013. Linear model selection and regularization. pp. 203–264.
- Jensen, J. R. 2007. *Remote sensing of the environment: an earth resource perspective*, 2nd ed. ed. Pearson Prentice Hall, Upper Saddle River.
- Jensen, E. A. Mousing, K. Richardson. 2017. Using species distribution modelling to predict future distributions of phytoplankton: Case study using species important for the biological pump. *Mar. Ecol.* 38(3):1–12.
- Jiménez-Illescas, A. R., M. A. Alatorre-Mendieta, M. Obeso-Nieblas, B. Hirasago-Germán, H. García-Escobar. 2008. Efectos de la construcción de un canal artificial entre la ensenada y la Bahía de la Paz. *Ing. Hidraul. en México* 23(2):45–57.
- Jiménez-Illescas, A. R., M. Obeso-Nieblas, D. A. Salas de L. 1997. Oceanografía física de La Bahía de La Paz, B.C.S. En: Urbán Ramírez, J., Ramírez Rodríguez, M. (Eds.). *La Bahía de La Paz, Investigaciones y conservación*. Mexico, pp. 31–51.
- Jiménez-Muñoz, J. C., J. A. Sobrino, D. Skoković, C. Mattar, J. Cristóbal. 2014. Land surface temperature retrieval methods from Landsat-8 thermal infrared sensor data. *Geosci. Remote Sens. Lett. IEEE* 11(10):1840–1843.
- Joshi, I., E. J. D'Sa. 2015. Seasonal variation of colored dissolved organic matter in barataria bay, Louisiana, using combined landsat and field data. *Remote Sens.* 7(9):12478–12502.
- Kaliraj, S., N. Chandrasekar, K. K. Ramachandran. 2019. Phytoplankton (chl-a) biomass seasonal variability in the Gulf of Mannar, South India: A remote sensing perspective. En: *Applications and Challenges of Geospatial Technology*. Springer International Publishing, Cham, pp. 57–74.
- Khorram, S., C. F. van der Wiele, F. H. Koch, S. A. C. Nelson, M. D. Potts. 2016. Remote sensing: past and present. En: *Principles of applied remote sensing*.

Springer, Cham, pp. 1–20.

- Kim, K. B. Chul, J. Y. Nam. 2016. Predicting chlorophyll- a using Landsat 8 OLI sensor data and the non-linear RANSAC method – a case study of Nakdong River, South Korea. *Int. J. Remote Sens.* 37(14):3255–3271.
- Kim, Y., Y. Byun, Y. Kim, Y. Eo. 2009. Detection of *Cochlodinium polykrikoides* red tide based on two-stage filtering using MODIS data. *Desalination* 249(3):1171–1179.
- Kirk, J. T. O. 1994. Remote sensing of the aquatic environment. En: Light and photosynthesis in aquatic ecosystems. Cambridge University Press, Cambridge, pp. 199–262.
- Klemas, V. 2012. Remote sensing of algal blooms: an overview with case studies. *J. Coast. Res.* 34–43.
- Kloiber, S. M., P. L. Brezonik, L. G. Olmanson, M. E. Bauer. 2002. A procedure for regional lake water clarity assessment using Landsat multispectral data. *Remote Sens. Environ.* 82(1):38–47.
- Kofoed, C. A., O. Swezy. 1921. The free-living unarmored dinoflagellata, 1a ed. Calif. University of California, Berkeley, California, USA. 562 P.
- Kong, J.-L., X.-M. Sun, D. Wong, Y. Chen, J. Yang, Y. Yan, L.-X. Wang. 2015. A semi-analytical model for remote sensing retrieval of suspended sediment concentration in the Gulf of Bohai, China. *Remote Sens.* 7(5):5373–5397.
- Krug, L. A., T. Platt, S. Sathyendranath, A. B. Barbosa. 2018. Patterns and drivers of phytoplankton phenology off SW Iberia: A phenoregion based perspective. *Prog. Oceanogr.* 165:233–256.
- Licea, S., J. L. Moreno, H. Santoyo, G. Figueroa. 1995. Dinoflageladas del Golfo de California, 1a ed. Universidad Autónoma de Baja California Sur, Mexico. 165 p.
- Ligi, M., T. Kutser, K. Kallio, J. Attila, S. Koponen, B. Paavel, T. Soomets, A. Reinart. 2017. Testing the performance of empirical remote sensing algorithms in the Baltic Sea waters with modelled and in situ reflectance data. *Oceanologia* 59(1):57–68.
- Lim, J., M. Choi. 2015. Assessment of water quality based on Landsat 8 operational land imager associated with human activities in Korea. *Environ. Monit. Assess.* 187(6):1–17.
- Liu, D., Y. Wang. 2013. Trends of satellite derived chlorophyll-a (1997-2011) in the Bohai and Yellow Seas, China: Effects of bathymetry on seasonal and inter-annual patterns. *Prog. Oceanogr.* 116:154–166.

- Liu, Y., M. A. Islam, J. Gao. 2003. Quantification of shallow water quality parameters by means of remote sensing. *Prog. Phys. Geogr. Earth Environ.* 27(1):24–43.
- Liu, Y., L. Liu, H. Shen. 2010. Seasonal variations of phytoplankton community structure in relation to physico-chemical factors in Lake Baiyangdian, China. *Procedia Environ. Sci.* 2(5):1622–1631.
- Lluch-Cota, S. E., A. Parés-Sierra, V. O. Magaña-Rueda, F. Arreguín-Sánchez, G. Bazzino, H. Herrera-Cervantes, D. Lluch-Belda. 2010. Changing climate in the Gulf of California. *Prog. Oceanogr.* 87(1–4):114–126.
- López-Cortés, D. J., C. J. Band-Schmidt, I. Gárate-Lizárraga, J. J. Bustillos-Guzmán, F. E. Hernández-Sandoval, E. J. Núñez-Vázquez. 2011. Co-ocurrencia de *Chattonella marina* y *Gymnodinium catenatum* en la Bahía de La Paz, Golfo de California (primavera 2009). *Hidrobiologica* 21(2):185–196.
- López-Cortés, D. J., E. J. Núñez-Vázquez, C. J. Band-Schmidt, I. Gárate-Lizárraga, F. Hernández-Sandoval, J. J. Bustillos-Guzmán. 2015. Mass fish die-off during a diatom bloom in the Bahía de La Paz, Gulf of California. *Hidrobiológica* 25(1):39–48.
- Lou, X., C. Hu. 2014. Diurnal changes of a harmful algal bloom in the East China Sea: Observations from GOCI. *Remote Sens. Environ.* 140:562–572.
- Lubac, B., H. Loisel, N. Guiselin, R. Astoreca, L. F. Artigas, X. Mériaux. 2008. Hyperspectral and multispectral ocean color inversions to detect *Phaeocystis globosa* blooms in coastal waters. *J. Geophys. Res. Ocean.* 113(6):1–17.
- Lundholm, N., P. Hansen, Y. Kotaki. 2004. Effect of pH on growth and domoic acid production by potentially toxic diatoms of the genera *Pseudo-nitzschia* and *Nitzschia*. *Mar. Ecol. Prog. Ser.* 273:1–15.
- Macpherson, E. 2002. Large-scale species-richness gradients in the Atlantic Ocean. *Proceedings. Biol. Sci.* 269(1501):1715–20.
- Madhu, N. V., R. Jyothibabu, K. K. Balachandran, U. K. Honey, G. D. Martin, J. G. Vijay, C. A. Shiyas, G. V. M. Gupta, et al. 2007. Monsoonal impact on planktonic standing stock and abundance in a tropical estuary (Cochin backwaters – India). *Estuar. Coast. Shelf Sci.* 73(1–2):54–64.
- Maguire, K. C., D. Nieto-Lugilde, M. C. Fitzpatrick, J. W. Williams, J. L. Blois. 2015. Modeling species and community responses to past, present, and future episodes of climatic and ecological change. *Annu. Rev. Ecol. Evol. Syst.* 46(1):343–368.
- Martínez-López, A., R. Cervantes-Duarte, Reyes-Salinas, A, J. E. Valdez-Holguín. 2001. Cambio estacional de clorofila a en la Bahía de La Paz, B. C. S.,

- México. *Hidrobiológica* 11(1):45–52.
- Masocha, M., T. Dube, T. Nhiwatiwa, D. Choruma. 2017. Testing utility of Landsat 8 for remote assessment of water quality in two subtropical African reservoirs with contrasting trophic states. *Geocarto Int.* 6049(March):1–14.
- McCarthy, M. J., K. E. Colna, M. M. El-Mezayen, A. E. Laureano-Rosario, P. Méndez-Lázaro, D. B. Otis, G. Toro-Farmer, M. Vega-Rodriguez, et al. 2017. Satellite remote sensing for coastal management: A review of successful applications. *Environ. Manage.* 60(2):323–339.
- McClain, C. R. 2009. A decade of satellite ocean color observations. *Ann. Rev. Mar. Sci.* 1:19–42.
- McGillicuddy, D. J. J., D. W. Townsend, R. He, B. A. Keafer, J. L. Kleindinst, Y. Li, J. P. Manning, D. G. Mountain, et al. 2011. Suppression of the 2010 *Alexandrium fundyense* bloom by changes in physical, biological, and chemical properties of the Gulf of Maine. *Limnol. Oceanogr.* 56(6):2411–2426.
- Mee, L. D., M. Espinosa, G. Diaz. 1986. Paralytic shellfish poisoning with a *Gymnodinium catenatum* red tide on the Pacific Coast of Mexico. *Mar. Environ. Res.* 19(1):77–92.
- Mei-Lin, W., W. You-Shao, W. Yu-Tu, S. Fu-Lin, S. Cui-Ci, J. Zhao-Yu, C. Hao. 2014. Influence of environmental changes on phytoplankton pattern in Daya Bay, South China Sea. *Rev. Biol. Mar. Oceanogr.* 49(2):323–337.
- Miller, R. L., C. E. del Castillo, B. A. Mckee. 2007. Remote sensing of coastal aquatic environments technologies, techniques and applications. Springer.
- Mishra, D., R. Gould. 2016. Preface: remote sensing in coastal environments. *Remote Sens.* 8(8):665.
- Morel, A., L. Prieur. 1977. Analysis of variations in ocean color1. *Limnol. Oceanogr.* 22(4):709–722.
- Moreno, J. L., S. Licea, H. Santoyo. 1996. Diatomeas del Golfo de California. México. 272 p.
- Morquecho, L., C. H. Lechuga-Devéze. 2004. Seasonal occurrence of planktonic dinoflagellates and cyst production in relationship to environmental variables in subtropical Bahía Concepción, Gulf of California. *Bot. Mar.* 47(4):313–322.
- Naselli-Flores, L., R. Barone. 1998. Phytoplankton dynamics in two reservoirs with different trophic state (Lake Rosamarina and Lake Arancio, Sicily, Italy). *Hydrobiologia* 369/370(0):163–178.
- Nazeer, M., J. E. Nichol. 2016. Development and application of a remote sensing-

- based Chlorophyll-a concentration prediction model for complex coastal waters of Hong Kong. *J. Hydrol.* 532:80–89.
- O'Reilly, J. E., S. Maritorena, B. G. Mitchell, D. A. Siegel, K. L. Carder, S. A. Garver, K. M., C. McClain., et al. 1998. Ocean color chlorophyll algorithms for SeaWiFS. *J. Geophys. Res.* 103(C11):24937–24953.
- O'Reilly, J. E., S. Maritorena, M. O'Brien, D. a. Siegel, D. Toole, D. Menzies, R. Smith, J. L. Mueller, et al. 2000. SeaWiFS postlaunch calibration and validation analyses, Part 3. En: Hooker, S.B. (Ed.). SeaWiFS postlaunch technical report series. pp. 1–49.
- Olascoaga, M. J., F. J. Beron-Vera, L. E. Brand, H. Koçak. 2008. Tracing the early development of harmful algal blooms on the West Florida Shelf with the aid of Lagrangian coherent structures. *J. Geophys. Res. Ocean.* 113(12):1–10.
- Olmanson, L. G., M. E. Bauer, P. L. Brezonik. 2008. A 20-year Landsat water clarity census of Minnesota's 10,000 lakes. *Remote Sens. Environ. J.* 112:4086–4097.
- Ouillon, S., P. Douillet, A. Petrenko, J. Neveux, C. Dupouy, J.-M. Froidefond, S. Andréfouët, A. Muñoz-Caravaca. 2008. Optical algorithms at satellite wavelengths for total suspended matter in tropical coastal waters. *Sensors (Basel)*. 8(7):4165–4185.
- Patra, P. P., S. K. Dubey, R. K. Trivedi, S. K. Suhu, S. K. Rout. 2016. Estimation of chlorophyll-a concentration and trophic states for an inland lake from Landsat-8 OLI data: A case Nalban Lake of East Kalkota Wetland, India. *Preprints (August)*:18.
- Pedersen, M. F., P. J. Hansen. 2003. Effects of high pH on a natural marine planktonic community. *Mar. Ecol. Prog. Ser.* 260(September):19–31.
- R Core Team. 2016. R: A language and environment for statistical computing. R Foundation for Statistical Computing.
- Reddy, G. P. O. 2018. Satellite remote sensing sensors: Principles and applications. En: *Geospatial Technologies in Land Resources Mapping, Monitoring and Management*. Springer, Cham, pp. 21–43.
- Reiss, H., S. Cunze, K. König, H. Neumann, I. Kröncke. 2011. Species distribution modelling of marine benthos: a North Sea case study. *Mar. Ecol. Prog. Ser.* 442(December):71–86.
- Rivera-Vilarelle, M., S. Quijano-Scheggia, A. Olivos-Ortiz, J. H. Gavino-Rodríguez, F. Castro-Ochoa, A. Reyes-Herrera. 2013. The genus *Pseudo-nitzschia* (Bacillariophyceae) in Manzanillo and Santiago Bays, Colima, Mexico. *Bot. Mar.* 56(4):357–373.

- Robinson, N. M., W. A. Nelson, M. J. Costello, J. E. Sutherland, C. J. Lundquist. 2017. A systematic review of marine-based species distribution models (SDMs) with recommendations for best practice. *Front. Mar. Sci.* 4:421.
- Rodríguez, J. P., L. Brotons, J. Bustamante, J. Seoane. 2007. The application of predictive modelling of species distribution to biodiversity conservation. *Divers. Distrib.* 13(3):243–251.
- Round, F. E., R. M. Crawford, D. G. Mann. 1990. *The diatoms biology and morphology of the genera.* Cambridge University Press.
- Roy, D. P. P., M. A. A. Wulder, T. R. R. Loveland, W. C.E., R. G. G. Allen, M. C. C. Anderson, D. Helder, J. R. R. Irons, et al. 2014. Landsat-8: Science and product vision for terrestrial global change research. *Remote Sens. Environ.* 145:154–172.
- Sathyendranath, S. 2000. General introduction. En: *Remote sensing of ocean colour in coastal and other optically complex waters.* International Ocean Colour Coordinating Group (IOCCG), Dartmouth, NS, Canada, pp. 5–21.
- Sathyendranath, S., R. P. Bukata, R. Arnone, M. D. Dowell, C. O. Davis, M. Babin, J.-F. Berthon, O. V. Kopelevich, et al. 2000. Colour of case 2 waters. En: *Remote sensing of ocean colour in coastal and other optically complex waters.* International Ocean Colour Coordinating Group (IOCCG), Dartmouth, NS, Canada, pp. 23–46.
- Schiebe, F. R., J. A. Harrington, J. C. Ritchie. 1992. Remote sensing of suspended sediments: the Lake Chicot, Arkansas project. *Int. J. Remote Sens.* 13(8):1487–1509.
- Schofield, O., J. Grzymiski, W. P. Bissett, G. J. Kirkpatrick, D. F. Millie, M. Moline, C. S. Roesler. 1999. Optical monitoring and forecasting systems for harmful algal blooms: Possibility or pipe dream? *J. Phycol.* 35(6 SUPPL.):1477–1496.
- Shekhar, T. R. S., B. R. Kiran, E. T. Puttaiah, Y. Shivaraj, K. M. Mahadevan. 2008. Phytoplankton as index of water quality with reference to industrial pollution. *J. Environ. Biol.* 29(2):233–6.
- Shen, L., H. Xu, X. Guo. 2012. Satellite remote sensing of harmful algal blooms (HABs) and a potential synthesized framework. *Sensors* 12(6):7778–7803.
- Shin, J., K. Kim, Y. Son, J.-H. Ryu, J. Shin, K. Kim, Y. B. Son, J.-H. Ryu. 2018. Synergistic effect of multi-sensor Data on the detection of *Margalefidinium polykrikoides* in the South Sea of Korea. *Remote Sens.* 11(1):36.
- Sierra-Beltrán, A. P. P., R. Cortés-Altamirano, M. C. C. Cortés-Lara. 2005. Occurrences of *Prorocentrum minimum* (Pavillard) in México. *Harmful Algae* 4(3):507–517.

- Sierra-Beltrán, A. P., M. Palafox-Urbe, J. Grajales-Montiel, A. Cruz-Villacorta, J. L. L. Ochoa, A. Sierra-Beltrán, M. Palafox-Urbe, J. Grajales-Montiel, et al. 1997. Sea bird mortality at Cabo San Lucas, Mexico: evidence that toxic diatom blooms are spreading. *Toxicon* 35(3):447–53.
- Sin, Y., R. L. Wetzel, I. C. Anderson. 1999. Spatial and temporal characteristics of nutrient and phytoplankton dynamics in the York River Estuary, Virginia: analyses of long-term data. *Estuaries* 22(2):260.
- Singh, K., M. Ghosh, S. S.R., P. Kumar. 2014. Blue–Red–NIR model for chlorophyll-a retrieval in hypersaline-Alkaline water using Landsat ETM+ sensor. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 7(8):3553–3559.
- Slonecker, E. T., D. K. Jones, B. A. Pellerin. 2016. The new Landsat 8 potential for remote sensing of colored dissolved organic matter (CDOM). *Mar. Pollut. Bull.* 107(2):518–527.
- Smayda, T. J., C. S. Reynolds. 2001. Community assembly in marine phytoplankton: Application of recent models to harmful dinoflagellate blooms. *J. Plankton Res.* 23(5):447–461.
- Sournia, A. 1978. *Phytoplankton manual*. UNESCO, Paris. 337 p.
- Steidinger, K. A., K. Haddad. 1981. Biologic and hydrographic aspects of red tides. *Bioscience* 31(11):814–819.
- Stumpf, R. P. 2001. Applications of satellite ocean color sensors for monitoring and predicting harmful algal blooms. *Hum. Ecol. Risk Assess. An Int. J.* 7(5):1363–1368.
- Stumpf, R. P., M. E. Culver, P. A. Tester, M. Tomlinson, G. J. Kirkpatrick, B. A. Pederson, E. Truby, V. Ransibrahmanakul, et al. 2003. Monitoring *Karenia brevis* blooms in the Gulf of Mexico using satellite ocean color imagery and other data. *Harmful Algae* 2(2):147–160.
- Subramaniam, A., C. W. Brown, R. R. Hood, E. J. Carpenter, D. G. Capone. 2002. Detecting *Trichodesmium* blooms in SeaWiFS imagery. *Deep Sea Res. Part II Top. Stud. Oceanogr.* 49(1–3):107–121.
- Tafas, T., A. Economou-Amilli. 1997. Limnological survey of the warm monomictic lake Trichonis (central western Greece); II. Seasonal phytoplankton periodicity-a community approach. *Hydrobiologia* 344:141–153.
- Tebbs, E. J., J. J. Remedios, D. M. Harper. 2013. Remote sensing of chlorophyll-a as a measure of cyanobacterial biomass in Lake Bogoria, a hypertrophic, saline-alkaline, flamingo lake, using Landsat ETM+. *Remote Sens. Environ.* 135:92–106.

- Teodoro, A. C. 2016. Optical satellite remote sensing of the coastal zone environment-an overview. En: Marghany, M. (Ed.). Environmental Applications of Remote Sensing. InTech, pp. 165–196.
- Tomas, C. R. 1996. Identifying marine diatoms and dinoflagellates. Academic Press.
- Tomlinson, M. C., R. P. Stumpf, V. Ransibrahmanakul, E. W. Truby, G. J. Kirkpatrick, B. A. Pederson, G. A. Vargo, C. A. Heil. 2004. Evaluation of the use of SeaWiFS imagery for detecting *Karenia brevis* harmful algal blooms in the eastern Gulf of Mexico. *Remote Sens. Environ.* 91(3–4):293–303.
- Torbick, N., M. Corbiere. 2015. A multiscale mapping assessment of lake champlain cyanobacterial harmful algal blooms. *Int. J. Environ. Res. Public Health* 12(9):11560–11578.
- Townhill, B. L., J. Tinker, M. Jones, S. Pitois, V. Creach, S. D. Simpson, S. Dye, E. Bear, et al. 2019. Harmful algal blooms and climate change: exploring future distribution changes. *ICES J. Mar. Sci.* 76(1):353–353.
- Trainer, V. L., N. G. Adams, B. D. Bill, C. M. Stehr, J. C. Wekell, P. Moeller, M. Busman, D. Woodruff. 2000. Domoic acid production near California coastal upwelling zones, June 1998. *Limnol. Oceanogr.* 45(8):1818–1833.
- Trainer, V. L., S. S. Bates, N. Lundholm, A. E. Thessen, W. P. Cochlan, N. G. Adams, C. G. Trick. 2012. Pseudo-nitzschia physiological ecology, phylogeny, toxicity, monitoring and impacts on ecosystem health. *Harmful Algae* 14(December):271–300.
- Tyler, M. A., R. P. Stumpf. 1989. Feasibility of using satellites for detection of kinetics of small phytoplankton blooms in estuaries: Tidal and migrational effects. *Remote Sens. Environ.* 27(3):233–249.
- Vajravelu, M., Y. Martin, S. Ayyappan, M. Mayakrishnan. 2018. Seasonal influence of physico-chemical parameters on phytoplankton diversity, community structure and abundance at Parangipettai coastal waters, Bay of Bengal, South East Coast of India. *Oceanologia* 60(2):114–127.
- Watanabe, F. S. Y., E. Alcântara, T. W. P. Rodrigues, N. N. Imai, C. C. F. Barbosa, L. H. da S. Rotta. 2015. Estimation of chlorophyll-a concentration and the trophic state of the barra bonita hydroelectric reservoir using OLI/landsat-8 images. *Int. J. Environ. Res. Public Health* 12(9):10391–10417.
- Wiens, J. A., D. Stralberg, D. Jongsomjit, C. A. Howell, M. A. Snyder. 2009. Niches, models, and climate change: Assessing the assumptions and uncertainties. *Proc. Natl. Acad. Sci.* 106(Supplement_2):19729–19736.
- Wood, S. N. 2006. Generalized Additive Models: an introduction with R, 1 edition.

- ed. Chapman and Hall/CRC, Florida, USA. 410 p.
- Wood, S. N. 2003. Thin plate regression splines. *J. R. Stat. Soc. B* 65:95–114.
- Xing, Q., C. Hu. 2016. Mapping macroalgal blooms in the Yellow Sea and East China Sea using HJ-1 and Landsat data: Application of a virtual baseline reflectance height technique. *Remote Sens. Environ.* 178:113–126.
- Yoder, J. A., J. E. O'Reilly, A. H. Barnard, T. S. Moore, C. M. Ruhsam. 2001. Variability in coastal zone color scanner (CZCS) Chlorophyll imagery of ocean margin waters off the US East Coast. *Cont. Shelf Res.* 21(11–12):1191–1218.
- Zanter, K. 2018. *Landsat 8 Data Users Handbook*, 3.0. ed. Sioux Falls, South Dakota.
- Zhao, D., X. Xing, Y. Liu, Y. Jianhong, L. Wang. 2010. The relation of chlorophyll-*a* concentration with the reflectance peak near 700 nm in algae-dominated waters and sensitivity of fluorescence algorithms for detecting algal bloom. *Int. J. Remote Sens.* 31(1):39–48.
- Zhao, J., M. Temimi, H. Ghedira. 2015. Characterization of harmful algal blooms (HABs) in the Arabian Gulf and the Sea of Oman using MERIS fluorescence data. *ISPRS J. Photogramm. Remote Sens.* 101:125–136.
- Zuur, A. F., E. N. Ieno, G. M. Smith. 2007. *Analysing ecological data, Statistics for biology and health, Statistics for Biology and Health.* Springer New York, New York, NY. 686 p.
- Zuur, A. F., E. N. Ieno, N. Walker, A. A. Saveliev, G. M. Smith. 2009. *Mixed effects models and extensions in ecology with R, Statistics for Biology and Health.* Springer New York, New York, NY. 549 p.

11. ANEXOS

Tabla A1. Bondad de ajuste de los modelos RLS

| Modelo | R2 | R ² _{ajust} | AIC |
|-----------------------------------|-------|---------------------------------|---------|
| $y = -2.48 + 11.72*(B01)$ | 0.047 | 0.039 | 246.805 |
| $y = -1.76 + 7.35*(B02)$ | 0.033 | 0.025 | 248.46 |
| $y = -1.71 + 9.89*(B03)$ | 0.115 | 0.108 | 238.265 |
| $y = -2.08 + 26.69*(B04)$ | 0.308 | 0.302 | 210.009 |
| $y = -1.54 + 25.69*(B05)$ | 0.222 | 0.215 | 223.518 |
| $y = -2.48 + 11.72*(B01^2)$ | 0.047 | 0.039 | 246.805 |
| $y = -1.76 + 7.35*(B02^2)$ | 0.033 | 0.025 | 248.46 |
| $y = -1.71 + 9.89*(B03^2)$ | 0.115 | 0.108 | 238.265 |
| $y = -2.08 + 26.69*(B04^2)$ | 0.308 | 0.302 | 210.009 |
| $y = -1.54 + 25.69*(B05^2)$ | 0.222 | 0.215 | 223.518 |
| $y = -2.06 + 4.62*(B01+B02)$ | 0.04 | 0.031 | 247.722 |
| $y = -2.1 + 8.03*(B01+B02^2)$ | 0.04 | 0.031 | 247.716 |
| $y = -2.16 + 5.82*(B01+B03)$ | 0.091 | 0.083 | 241.346 |
| $y = -2.19 + 9.04*(B01+B03^2)$ | 0.051 | 0.043 | 246.294 |
| $y = -2.84 + 10.95*(B01+B04)$ | 0.171 | 0.163 | 230.862 |
| $y = -2.59 + 12.37*(B01+B04^2)$ | 0.064 | 0.055 | 244.811 |
| $y = -2.81 + 12.14*(B01+B05)$ | 0.154 | 0.146 | 233.164 |
| $y = -2.58 + 12.44*(B01+B05^2)$ | 0.057 | 0.049 | 245.59 |
| $y = -1.73 + 6.17*(B01^2+B02)$ | 0.034 | 0.026 | 248.353 |
| $y = -1.37 + 14.18*(B01^2+B02^2)$ | 0.027 | 0.019 | 249.189 |
| $y = -1.72 + 8.22*(B01^2+B03)$ | 0.104 | 0.096 | 239.699 |
| $y = -1.38 + 18.33*(B01^2+B03^2)$ | 0.049 | 0.041 | 246.568 |
| $y = -2.12 + 19.58*(B01^2+B04)$ | 0.246 | 0.239 | 219.893 |
| $y = -1.74 + 41.23*(B01^2+B04^2)$ | 0.088 | 0.08 | 241.798 |
| $y = -1.79 + 20.95*(B01^2+B05)$ | 0.202 | 0.195 | 226.376 |
| $y = -1.73 + 43.79*(B01^2+B05^2)$ | 0.07 | 0.061 | 244.074 |
| $y = -2.06 + 4.62*(B02+B01)$ | 0.04 | 0.031 | 247.722 |
| $y = -1.73 + 6.17*(B02+B01^2)$ | 0.034 | 0.026 | 248.353 |
| $y = -1.83 + 4.69*(B02+B03)$ | 0.076 | 0.068 | 243.274 |
| $y = -1.67 + 6.18*(B02+B03^2)$ | 0.038 | 0.03 | 247.871 |
| $y = -2.27 + 8.67*(B02+B04)$ | 0.14 | 0.132 | 235.085 |
| $y = -1.84 + 8.01*(B02+B04^2)$ | 0.045 | 0.037 | 247.041 |
| $y = -2.27 + 9.89*(B02+B05)$ | 0.13 | 0.123 | 236.309 |
| $y = -1.83 + 7.94*(B02+B05^2)$ | 0.041 | 0.032 | 247.601 |
| $y = -2.1 + 8.03*(B02^2+B01)$ | 0.04 | 0.031 | 247.716 |
| $y = -1.37 + 14.18*(B02^2+B01^2)$ | 0.027 | 0.019 | 249.189 |
| $y = -1.63 + 7.63*(B02^2+B03)$ | 0.096 | 0.088 | 240.766 |

| Modelo | R2 | R ² _{ajust} | AIC |
|-----------------------------------|-------|---------------------------------|---------|
| $y = -1.22 + 14.26*(B02^2+B03^2)$ | 0.037 | 0.028 | 248.073 |
| $y = -1.96 + 18.48*(B02^2+B04)$ | 0.23 | 0.223 | 222.304 |
| $y = -1.38 + 29.9*(B02^2+B04^2)$ | 0.06 | 0.052 | 245.219 |
| $y = -1.68 + 20.72*(B02^2+B05)$ | 0.198 | 0.191 | 227.038 |
| $y = -1.34 + 30.24*(B02^2+B05^2)$ | 0.045 | 0.036 | 247.12 |
| $y = -2.16 + 5.82*(B03+B01)$ | 0.091 | 0.083 | 241.346 |
| $y = -1.72 + 8.22*(B03+B01^2)$ | 0.104 | 0.096 | 239.699 |
| $y = -1.83 + 4.69*(B03+B02)$ | 0.076 | 0.068 | 243.274 |
| $y = -1.63 + 7.63*(B03+B02^2)$ | 0.096 | 0.088 | 240.766 |
| $y = -1.95 + 8.37*(B03+B04)$ | 0.194 | 0.187 | 227.53 |
| $y = -1.72 + 9.79*(B03+B04^2)$ | 0.125 | 0.117 | 236.986 |
| $y = -1.96 + 10.02*(B03+B05)$ | 0.204 | 0.196 | 226.197 |
| $y = -1.73 + 10.08*(B03+B05^2)$ | 0.123 | 0.116 | 237.224 |
| $y = -2.19 + 9.04*(B03^2+B01)$ | 0.051 | 0.043 | 246.294 |
| $y = -1.38 + 18.33*(B03^2+B01^2)$ | 0.049 | 0.041 | 246.568 |
| $y = -1.67 + 6.18*(B03^2+B02)$ | 0.038 | 0.03 | 247.871 |
| $y = -1.22 + 14.26*(B03^2+B02^2)$ | 0.037 | 0.028 | 248.073 |
| $y = -1.87 + 18.79*(B03^2+B04)$ | 0.248 | 0.242 | 219.548 |
| $y = -1.25 + 35.68*(B03^2+B04^2)$ | 0.099 | 0.091 | 240.376 |
| $y = -1.61 + 22.31*(B03^2+B05)$ | 0.23 | 0.223 | 222.336 |
| $y = -1.24 + 39.71*(B03^2+B05^2)$ | 0.089 | 0.081 | 241.679 |
| $y = -2.84 + 10.95*(B04+B01)$ | 0.171 | 0.163 | 230.862 |
| $y = -2.12 + 19.58*(B04+B01^2)$ | 0.246 | 0.239 | 219.893 |
| $y = -2.27 + 8.67*(B04+B02)$ | 0.14 | 0.132 | 235.085 |
| $y = -1.96 + 18.48*(B04+B02^2)$ | 0.23 | 0.223 | 222.304 |
| $y = -1.95 + 8.37*(B04+B03)$ | 0.194 | 0.187 | 227.53 |
| $y = -1.87 + 18.79*(B04+B03^2)$ | 0.248 | 0.242 | 219.548 |
| $y = -1.92 + 14.77*(B04+B05)$ | 0.298 | 0.292 | 211.663 |
| $y = -2.05 + 25.52*(B04+B05^2)$ | 0.309 | 0.303 | 209.825 |
| $y = -2.59 + 12.37*(B04^2+B01)$ | 0.064 | 0.055 | 244.811 |
| $y = -1.74 + 41.23*(B04^2+B01^2)$ | 0.088 | 0.08 | 241.798 |
| $y = -1.84 + 8.01*(B04^2+B02)$ | 0.045 | 0.037 | 247.041 |
| $y = -1.38 + 29.9*(B04^2+B02^2)$ | 0.06 | 0.052 | 245.219 |
| $y = -1.72 + 9.79*(B04^2+B03)$ | 0.125 | 0.117 | 236.986 |
| $y = -1.25 + 35.68*(B04^2+B03^2)$ | 0.099 | 0.091 | 240.376 |
| $y = -1.56 + 24.36*(B04^2+B05)$ | 0.237 | 0.231 | 221.195 |
| $y = -1.38 + 158.4*(B04^2+B05^2)$ | 0.266 | 0.26 | 216.753 |
| $y = -2.81 + 12.14*(B05+B01)$ | 0.154 | 0.146 | 233.164 |
| $y = -1.79 + 20.95*(B05+B01^2)$ | 0.202 | 0.195 | 226.376 |
| $y = -2.27 + 9.89*(B05+B02)$ | 0.13 | 0.123 | 236.309 |

| Modelo | R2 | R ² _{ajust} | AIC |
|--------------------------------------|-------|---------------------------------|---------|
| $y = -1.68 + 20.72*(B05+B02^2)$ | 0.198 | 0.191 | 227.038 |
| $y = -1.96 + 10.02*(B05+B03)$ | 0.204 | 0.196 | 226.197 |
| $y = -1.61 + 22.31*(B05+B03^2)$ | 0.23 | 0.223 | 222.336 |
| $y = -1.92 + 14.77*(B05+B04)$ | 0.298 | 0.292 | 211.663 |
| $y = -1.56 + 24.36*(B05+B04^2)$ | 0.237 | 0.231 | 221.195 |
| $y = -2.58 + 12.44*(B05^2+B01)$ | 0.057 | 0.049 | 245.59 |
| $y = -1.73 + 43.79*(B05^2+B01^2)$ | 0.07 | 0.061 | 244.074 |
| $y = -1.83 + 7.94*(B05^2+B02)$ | 0.041 | 0.032 | 247.601 |
| $y = -1.34 + 30.24*(B05^2+B02^2)$ | 0.045 | 0.036 | 247.12 |
| $y = -1.73 + 10.08*(B05^2+B03)$ | 0.123 | 0.116 | 237.224 |
| $y = -1.24 + 39.71*(B05^2+B03^2)$ | 0.089 | 0.081 | 241.679 |
| $y = -2.05 + 25.52*(B05^2+B04)$ | 0.309 | 0.303 | 209.825 |
| $y = -1.38 + 158.4*(B05^2+B04^2)$ | 0.266 | 0.26 | 216.753 |
| $y = -1.36 + 28.13*(B01*B02)$ | 0.028 | 0.019 | 249.147 |
| $y = -1.1 + 94.29*(B01*B02^2)$ | 0.014 | 0.006 | 250.708 |
| $y = -1.36 + 39.62*(B01*B03)$ | 0.07 | 0.062 | 243.987 |
| $y = -1.08 + 143.37*(B01*B03^2)$ | 0.033 | 0.024 | 248.507 |
| $y = -1.65 + 122.39*(B01*B04)$ | 0.209 | 0.202 | 225.445 |
| $y = -1.29 + 1219.67*(B01*B04^2)$ | 0.192 | 0.185 | 227.888 |
| $y = -1.43 + 155.11*(B01*B05)$ | 0.195 | 0.188 | 227.375 |
| $y = -1.13 + 1888.99*(B01*B05^2)$ | 0.152 | 0.145 | 233.401 |
| $y = -1.18 + 117.45*(B01^2*B02)$ | 0.02 | 0.012 | 250.001 |
| $y = -1.04 + 402.94*(B01^2*B02^2)$ | 0.009 | 0.001 | 251.285 |
| $y = -1.18 + 164.03*(B01^2*B03)$ | 0.043 | 0.034 | 247.351 |
| $y = -1.02 + 595.98*(B01^2*B03^2)$ | 0.019 | 0.01 | 250.217 |
| $y = -1.38 + 556.16*(B01^2*B04)$ | 0.138 | 0.13 | 235.306 |
| $y = -1.18 + 5962.52*(B01^2*B04^2)$ | 0.132 | 0.124 | 236.092 |
| $y = -1.33 + 902.94*(B01^2*B05)$ | 0.164 | 0.157 | 231.762 |
| $y = -1.09 + 10789.19*(B01^2*B05^2)$ | 0.122 | 0.114 | 237.377 |
| $y = -1.36 + 28.13*(B02*B01)$ | 0.028 | 0.019 | 249.147 |
| $y = -1.18 + 117.45*(B02*B01^2)$ | 0.02 | 0.012 | 250.001 |
| $y = -1.23 + 31.42*(B02*B03)$ | 0.048 | 0.039 | 246.745 |
| $y = -1.04 + 115.23*(B02*B03^2)$ | 0.022 | 0.013 | 249.835 |
| $y = -1.49 + 112.13*(B02*B04)$ | 0.166 | 0.159 | 231.458 |
| $y = -1.23 + 1170.52*(B02*B04^2)$ | 0.158 | 0.15 | 232.609 |
| $y = -1.41 + 174.83*(B02*B05)$ | 0.19 | 0.183 | 228.092 |
| $y = -1.13 + 2178.52*(B02*B05^2)$ | 0.15 | 0.142 | 233.688 |
| $y = -1.1 + 94.29*(B02^2*B01)$ | 0.014 | 0.006 | 250.708 |
| $y = -1.04 + 402.94*(B02^2*B01^2)$ | 0.009 | 0.001 | 251.285 |
| $y = -1.06 + 105.17*(B02^2*B03)$ | 0.019 | 0.01 | 250.153 |

| Modelo | R2 | R ² _{ajust} | AIC |
|--------------------------------------|-------|---------------------------------|---------|
| $y = -0.98 + 364.15*(B02^2*B03^2)$ | 0.007 | -0.002 | 251.54 |
| $y = -1.2 + 442.79*(B02^2*B04)$ | 0.081 | 0.073 | 242.636 |
| $y = -1.1 + 5067.18*(B02^2*B04^2)$ | 0.082 | 0.074 | 242.558 |
| $y = -1.28 + 1093.66*(B02^2*B05)$ | 0.146 | 0.139 | 234.189 |
| $y = -1.09 + 14182.23*(B02^2*B05^2)$ | 0.117 | 0.109 | 238.071 |
| $y = -1.36 + 39.62*(B03*B01)$ | 0.07 | 0.062 | 243.987 |
| $y = -1.18 + 164.03*(B03*B01^2)$ | 0.043 | 0.034 | 247.351 |
| $y = -1.23 + 31.42*(B03*B02)$ | 0.048 | 0.039 | 246.745 |
| $y = -1.06 + 105.17*(B03*B02^2)$ | 0.019 | 0.01 | 250.153 |
| $y = -1.35 + 112.75*(B03*B04)$ | 0.162 | 0.155 | 232.019 |
| $y = -1.17 + 1182.74*(B03*B04^2)$ | 0.138 | 0.13 | 235.321 |
| $y = -1.39 + 230.35*(B03*B05)$ | 0.231 | 0.224 | 222.205 |
| $y = -1.13 + 2921.91*(B03*B05^2)$ | 0.168 | 0.16 | 231.249 |
| $y = -1.08 + 143.37*(B03^2*B01)$ | 0.033 | 0.024 | 248.507 |
| $y = -1.02 + 595.98*(B03^2*B01^2)$ | 0.019 | 0.01 | 250.217 |
| $y = -1.04 + 115.23*(B03^2*B02)$ | 0.022 | 0.013 | 249.835 |
| $y = -0.98 + 364.15*(B03^2*B02^2)$ | 0.007 | -0.002 | 251.54 |
| $y = -1.09 + 431.08*(B03^2*B04)$ | 0.066 | 0.057 | 244.56 |
| $y = -1.03 + 4629.09*(B03^2*B04^2)$ | 0.054 | 0.045 | 246.005 |
| $y = -1.24 + 1685.02*(B03^2*B05)$ | 0.174 | 0.167 | 230.401 |
| $y = -1.09 + 24842.88*(B03^2*B05^2)$ | 0.139 | 0.131 | 235.161 |
| $y = -1.65 + 122.39*(B04*B01)$ | 0.209 | 0.202 | 225.445 |
| $y = -1.38 + 556.16*(B04*B01^2)$ | 0.138 | 0.13 | 235.306 |
| $y = -1.49 + 112.13*(B04*B02)$ | 0.166 | 0.159 | 231.458 |
| $y = -1.2 + 442.79*(B04*B02^2)$ | 0.081 | 0.073 | 242.636 |
| $y = -1.35 + 112.75*(B04*B03)$ | 0.162 | 0.155 | 232.019 |
| $y = -1.09 + 431.08*(B04*B03^2)$ | 0.066 | 0.057 | 244.56 |
| $y = -1.32 + 326.22*(B04*B05)$ | 0.252 | 0.245 | 219.01 |
| $y = -1.1 + 3879.19*(B04*B05^2)$ | 0.164 | 0.157 | 231.719 |
| $y = -1.29 + 1219.67*(B04^2*B01)$ | 0.192 | 0.185 | 227.888 |
| $y = -1.18 + 5962.52*(B04^2*B01^2)$ | 0.132 | 0.124 | 236.092 |
| $y = -1.23 + 1170.52*(B04^2*B02)$ | 0.158 | 0.15 | 232.609 |
| $y = -1.1 + 5067.18*(B04^2*B02^2)$ | 0.082 | 0.074 | 242.558 |
| $y = -1.17 + 1182.74*(B04^2*B03)$ | 0.138 | 0.13 | 235.321 |
| $y = -1.03 + 4629.09*(B04^2*B03^2)$ | 0.054 | 0.045 | 246.005 |
| $y = -1.19 + 3950.63*(B04^2*B05)$ | 0.23 | 0.223 | 222.277 |
| $y = -1.05 + 43747.58*(B04^2*B05^2)$ | 0.132 | 0.124 | 236.132 |
| $y = -1.43 + 155.11*(B05*B01)$ | 0.195 | 0.188 | 227.375 |
| $y = -1.33 + 902.94*(B05*B01^2)$ | 0.164 | 0.157 | 231.762 |
| $y = -1.41 + 174.83*(B05*B02)$ | 0.19 | 0.183 | 228.092 |

| Modelo | R2 | R ² _{ajust} | AIC |
|--------------------------------------|-------|---------------------------------|---------|
| $y = -1.28 + 1093.66*(B05*B02^2)$ | 0.146 | 0.139 | 234.189 |
| $y = -1.39 + 230.35*(B05*B03)$ | 0.231 | 0.224 | 222.205 |
| $y = -1.24 + 1685.02*(B05*B03^2)$ | 0.174 | 0.167 | 230.401 |
| $y = -1.32 + 326.22*(B05*B04)$ | 0.252 | 0.245 | 219.01 |
| $y = -1.19 + 3950.63*(B05*B04^2)$ | 0.23 | 0.223 | 222.277 |
| $y = -1.13 + 1888.99*(B05^2*B01)$ | 0.152 | 0.145 | 233.401 |
| $y = -1.09 + 10789.19*(B05^2*B01^2)$ | 0.122 | 0.114 | 237.377 |
| $y = -1.13 + 2178.52*(B05^2*B02)$ | 0.15 | 0.142 | 233.688 |
| $y = -1.09 + 14182.23*(B05^2*B02^2)$ | 0.117 | 0.109 | 238.071 |
| $y = -1.13 + 2921.91*(B05^2*B03)$ | 0.168 | 0.16 | 231.249 |
| $y = -1.09 + 24842.88*(B05^2*B03^2)$ | 0.139 | 0.131 | 235.161 |
| $y = -1.1 + 3879.19*(B05^2*B04)$ | 0.164 | 0.157 | 231.719 |
| $y = -1.05 + 43747.58*(B05^2*B04^2)$ | 0.132 | 0.124 | 236.132 |
| $y = 1.4 - 1.96*(B01/B02)$ | 0.032 | 0.023 | 248.659 |
| $y = 0.11 - 0.09*(B01/B02^2)$ | 0.065 | 0.057 | 244.613 |
| $y = 1.06 - 1.13*(B01/B03)$ | 0.275 | 0.269 | 215.306 |
| $y = -0.03 - 0.04*(B01/B03^2)$ | 0.282 | 0.276 | 214.275 |
| $y = 1.08 - 0.61*(B01/B04)$ | 0.423 | 0.417 | 189.224 |
| $y = -0.07 - 0.01*(B01/B04^2)$ | 0.359 | 0.353 | 201.274 |
| $y = -0.1 - 0.12*(B01/B05)$ | 0.186 | 0.179 | 228.74 |
| $y = -0.53 - 0*(B01/B05^2)$ | 0.165 | 0.158 | 231.643 |
| $y = -3.39 + 15.69*(B01^2/B02)$ | 0.045 | 0.037 | 247.029 |
| $y = 0.37 - 0.92*(B01^2/B02^2)$ | 0.037 | 0.029 | 247.989 |
| $y = 2 - 12.85*(B01^2/B03)$ | 0.306 | 0.3 | 210.33 |
| $y = 0.14 - 0.33*(B01^2/B03^2)$ | 0.3 | 0.294 | 211.314 |
| $y = 1.84 - 6.54*(B01^2/B04)$ | 0.506 | 0.502 | 171.189 |
| $y = 0.09 - 0.09*(B01^2/B04^2)$ | 0.401 | 0.396 | 193.462 |
| $y = -0.22 - 0.82*(B01^2/B05)$ | 0.14 | 0.132 | 235.089 |
| $y = -0.53 - 0.01*(B01^2/B05^2)$ | 0.151 | 0.143 | 233.602 |
| $y = -2.72 + 2.12*(B02/B01)$ | 0.021 | 0.013 | 249.881 |
| $y = 1.83 - 0.43*(B02/B01^2)$ | 0.053 | 0.045 | 246.067 |
| $y = 2.11 - 2.07*(B02/B03)$ | 0.372 | 0.366 | 198.86 |
| $y = 0.1 - 0.05*(B02/B03^2)$ | 0.306 | 0.3 | 210.38 |
| $y = 1.27 - 0.8*(B02/B04)$ | 0.44 | 0.435 | 185.79 |
| $y = -0.03 - 0.01*(B02/B04^2)$ | 0.367 | 0.362 | 199.76 |
| $y = -0.19 - 0.13*(B02/B05)$ | 0.157 | 0.149 | 232.772 |
| $y = -0.55 - 0*(B02/B05^2)$ | 0.153 | 0.145 | 233.291 |
| $y = -1.42 + 5.04*(B02^2/B01)$ | 0.023 | 0.015 | 249.66 |
| $y = -1.7 + 1.07*(B02^2/B01^2)$ | 0.017 | 0.008 | 250.411 |
| $y = 4.33 - 32.94*(B02^2/B03)$ | 0.398 | 0.393 | 193.982 |

| Modelo | R2 | R ² _{ajust} | AIC |
|----------------------------------|-------|---------------------------------|---------|
| $y = 0.64 - 0.71*(B02^2/B03^2)$ | 0.385 | 0.38 | 196.454 |
| $y = 0.84 - 5.95*(B02^2/B04)$ | 0.293 | 0.286 | 212.536 |
| $y = 0.11 - 0.13*(B02^2/B04^2)$ | 0.393 | 0.388 | 194.865 |
| $y = -0.56 - 0.61*(B02^2/B05)$ | 0.066 | 0.058 | 244.482 |
| $y = -0.63 - 0.01*(B02^2/B05^2)$ | 0.107 | 0.099 | 239.345 |
| $y = -2.47 + 2.61*(B03/B01)$ | 0.192 | 0.185 | 227.899 |
| $y = -3.77 + 0.64*(B03/B01^2)$ | 0.276 | 0.27 | 215.204 |
| $y = -3.72 + 4.02*(B03/B02)$ | 0.327 | 0.321 | 206.895 |
| $y = -6.38 + 0.86*(B03/B02^2)$ | 0.412 | 0.407 | 191.247 |
| $y = 0.41 - 0.72*(B03/B04)$ | 0.123 | 0.116 | 237.216 |
| $y = -0.01 - 0.02*(B03/B04^2)$ | 0.285 | 0.279 | 213.709 |
| $y = -0.67 - 0.07*(B03/B05)$ | 0.028 | 0.019 | 249.141 |
| $y = -0.67 - 0*(B03/B05^2)$ | 0.075 | 0.067 | 243.398 |
| $y = -1.31 + 7.68*(B03^2/B01)$ | 0.091 | 0.083 | 241.447 |
| $y = -1.55 + 1.71*(B03^2/B01^2)$ | 0.141 | 0.133 | 234.941 |
| $y = -1.47 + 9.46*(B03^2/B02)$ | 0.131 | 0.124 | 236.184 |
| $y = -2.24 + 2.66*(B03^2/B02^2)$ | 0.295 | 0.288 | 212.233 |
| $y = -1.02 + 0.54*(B03^2/B04)$ | 0.002 | -0.006 | 252.098 |
| $y = -0.42 - 0.15*(B03^2/B04^2)$ | 0.099 | 0.091 | 240.441 |
| $y = -0.96 + 0.03*(B03^2/B05)$ | 0 | -0.009 | 252.347 |
| $y = -0.89 - 0*(B03^2/B05^2)$ | 0.008 | -0.001 | 251.481 |
| $y = -2.77 + 5.68*(B04/B01)$ | 0.436 | 0.431 | 186.534 |
| $y = -3.6 + 1.09*(B04/B01^2)$ | 0.542 | 0.538 | 162.49 |
| $y = -3.06 + 5.55*(B04/B02)$ | 0.477 | 0.473 | 177.742 |
| $y = -3.45 + 0.72*(B04/B02^2)$ | 0.434 | 0.429 | 186.916 |
| $y = -2.72 + 3.23*(B04/B03)$ | 0.168 | 0.16 | 231.239 |
| $y = -0.26 - 0.09*(B04/B03^2)$ | 0.068 | 0.06 | 244.26 |
| $y = -0.84 - 0.05*(B04/B05)$ | 0.003 | -0.006 | 252.064 |
| $y = -0.65 - 0*(B04/B05^2)$ | 0.063 | 0.054 | 244.931 |
| $y = -1.6 + 44.39*(B04^2/B01)$ | 0.347 | 0.341 | 203.378 |
| $y = -1.8 + 7.84*(B04^2/B01^2)$ | 0.429 | 0.424 | 187.907 |
| $y = -1.68 + 42.26*(B04^2/B02)$ | 0.382 | 0.377 | 197.018 |
| $y = -1.94 + 6.54*(B04^2/B02^2)$ | 0.475 | 0.47 | 178.247 |
| $y = -1.81 + 35.85*(B04^2/B03)$ | 0.343 | 0.337 | 204.14 |
| $y = -1.88 + 3.01*(B04^2/B03^2)$ | 0.184 | 0.177 | 228.949 |
| $y = -1.16 + 2.49*(B04^2/B05)$ | 0.047 | 0.039 | 246.797 |
| $y = -0.95 - 0*(B04^2/B05^2)$ | 0 | -0.009 | 252.359 |
| $y = -1.66 + 4.09*(B05/B01)$ | 0.239 | 0.233 | 220.883 |
| $y = -1.77 + 0.62*(B05/B01^2)$ | 0.243 | 0.237 | 220.312 |
| $y = -1.67 + 3.48*(B05/B02)$ | 0.231 | 0.225 | 222.092 |

| Modelo | R2 | R ² _{ajust} | AIC |
|----------------------------------|-------|---------------------------------|---------|
| $y = -1.74 + 0.42*(B05/B02^2)$ | 0.209 | 0.202 | 225.385 |
| $y = -1.5 + 1.84*(B05/B03)$ | 0.1 | 0.092 | 240.262 |
| $y = -0.86 - 0.02*(B05/B03^2)$ | 0.002 | -0.007 | 252.129 |
| $y = -1.48 + 1.01*(B05/B04)$ | 0.037 | 0.028 | 248.047 |
| $y = 0.53 - 0.11*(B05/B04^2)$ | 0.284 | 0.277 | 213.999 |
| $y = -1.21 + 52.27*(B05^2/B01)$ | 0.211 | 0.204 | 225.151 |
| $y = -1.26 + 8.27*(B05^2/B01^2)$ | 0.235 | 0.228 | 221.563 |
| $y = -1.22 + 44.87*(B05^2/B02)$ | 0.211 | 0.204 | 225.143 |
| $y = -1.26 + 6.04*(B05^2/B02^2)$ | 0.232 | 0.225 | 222.002 |
| $y = -1.21 + 31.85*(B05^2/B03)$ | 0.171 | 0.164 | 230.803 |
| $y = -1.22 + 2.67*(B05^2/B03^2)$ | 0.121 | 0.113 | 237.587 |
| $y = -1.27 + 23.38*(B05^2/B04)$ | 0.159 | 0.152 | 232.416 |
| $y = -1.27 + 1.09*(B05^2/B04^2)$ | 0.055 | 0.047 | 245.837 |

Tabla A2. Bondad de ajuste de los modelos RLM.

| Modelo | R2 | R ² _{ajust} | AIC |
|--|-------|---------------------------------|---------|
| $y = -3.64 + 36.92*B01 - 19.37*B02$ | 0.061 | 0.044 | 247.161 |
| $y = 1.42 - 33.97*B01 + 26.77*B03$ | 0.176 | 0.161 | 232.162 |
| $y = 2.34 - 44.69*B01 + 60.04*B04$ | 0.513 | 0.504 | 171.584 |
| $y = -1.24 - 2.59*B01 + 27.09*B05$ | 0.224 | 0.21 | 225.274 |
| $y = 4.25 - 107.06*B02 + 85.15*B03$ | 0.508 | 0.499 | 172.89 |
| $y = -0.29 - 25.43*B02 + 50.34*B04$ | 0.466 | 0.456 | 182.294 |
| $y = -1.48 - 0.63*B02 + 26.05*B05$ | 0.222 | 0.208 | 225.488 |
| $y = -1.89 - 9.58*B03 + 39.54*B04$ | 0.345 | 0.333 | 205.74 |
| $y = -1.85 + 5.19*B03 + 21.76*B05$ | 0.248 | 0.235 | 221.516 |
| $y = -2.05 + 23.16*B04 + 5.1*B05$ | 0.311 | 0.299 | 211.446 |
| $y = 0.18 + 114.07*B01 - 222.66*B02 + 109.74*B03$ | 0.729 | 0.722 | 106.21 |
| $y = 3.11 - 60.3*B01 + 10.92*B02 + 61.54*B04$ | 0.517 | 0.504 | 172.633 |
| $y = 0.22 - 32.34*B01 + 21.19*B02 + 31.22*B05$ | 0.236 | 0.215 | 225.47 |
| $y = 4.55 - 70.67*B01 + 17.44*B03 + 56.01*B04$ | 0.566 | 0.554 | 160.488 |
| $y = 4.65 - 71.61*B01 + 37.75*B03 + 35.75*B05$ | 0.461 | 0.446 | 185.309 |
| $y = 2.69 - 48.94*B01 + 70.49*B04 - 10.54*B05$ | 0.526 | 0.513 | 170.58 |
| $y = 3.74 - 100.72*B02 + 63.31*B03 + 35.33*B04$ | 0.689 | 0.681 | 121.911 |
| $y = 4.51 - 114.8*B02 + 84.99*B03 + 25.93*B05$ | 0.695 | 0.686 | 119.983 |
| $y = 0.03 - 31.35*B02 + 67.09*B04 - 16.28*B05$ | 0.492 | 0.478 | 178.585 |
| $y = -1.88 - 13.13*B03 + 51.03*B04 - 9.72*B05$ | 0.352 | 0.335 | 206.47 |
| $y = 0.94 + 88.45*B01 - 194.77*B02 + 97.55*B03 + 10.79*B04$ | 0.735 | 0.725 | 105.73 |
| $y = 1.54 + 79.56*B01 - 191.62*B02 + 102.22*B03 + 13.17*B05$ | 0.757 | 0.748 | 95.668 |
| $y = 2.83 - 51.95*B01 + 2.27*B02 + 70.22*B04 - 9.95*B05$ | 0.526 | 0.509 | 172.548 |

| Modelo | R2 | R ² _{ajust} | AIC |
|--|-------|---------------------------------|---------|
| $y = 4.67 - 71.99*B01 + 19.4*B03 + 51.59*B04 + 4*B05$ | 0.567 | 0.551 | 162.185 |
| $y = 4.16 - 108.52*B02 + 74.49*B03 + 17.09*B04 + 15.16*B05$ | 0.705 | 0.694 | 118.048 |
| $y = 1.05 + 103.37*B01 - 221.63*B02 + 119.1*B03 - 19.09*B04 + 21.39*B05$ | 0.764 | 0.753 | 94.197 |

Tabla A3. Bondad de ajuste de los modelos RLM

| Modelo | R2 | R ² _{ajust} | AIC |
|--|----|---------------------------------|---------|
| $y = f(B01)$ | NA | 0.225 | 227.042 |
| $y = f(B02)$ | NA | 0.216 | 228.198 |
| $y = f(B03)$ | NA | 0.41 | 195.293 |
| $y = f(B04)$ | NA | 0.403 | 197.197 |
| $y = f(B05)$ | NA | 0.431 | 193.247 |
| $y = f(B01) + f(B02)$ | NA | 0.227 | 228.147 |
| $y = f(B01) + f(B03)$ | NA | 0.497 | 181.159 |
| $y = f(B01) + f(B04)$ | NA | 0.6 | 156.435 |
| $y = f(B01) + f(B05)$ | NA | 0.44 | 194.196 |
| $y = f(B02) + f(B03)$ | NA | 0.674 | 136.215 |
| $y = f(B02) + f(B04)$ | NA | 0.502 | 177.489 |
| $y = f(B02) + f(B05)$ | NA | 0.52 | 180.624 |
| $y = f(B03) + f(B04)$ | NA | 0.554 | 169.094 |
| $y = f(B03) + f(B05)$ | NA | 0.582 | 160.446 |
| $y = f(B04) + f(B05)$ | NA | 0.555 | 165.684 |
| $y = f(B01) + f(B02) + f(B03)$ | NA | 0.78 | 87.97 |
| $y = f(B01) + f(B02) + f(B04)$ | NA | 0.61 | 153.976 |
| $y = f(B01) + f(B02) + f(B05)$ | NA | 0.584 | 166.312 |
| $y = f(B01) + f(B03) + f(B04)$ | NA | 0.709 | 123.493 |
| $y = f(B01) + f(B03) + f(B05)$ | NA | 0.709 | 124.955 |
| $y = f(B01) + f(B04) + f(B05)$ | NA | 0.699 | 126.568 |
| $y = f(B02) + f(B03) + f(B04)$ | NA | 0.816 | 75.917 |
| $y = f(B02) + f(B03) + f(B05)$ | NA | 0.822 | 71.161 |
| $y = f(B02) + f(B04) + f(B05)$ | NA | 0.676 | 136.092 |
| $y = f(B03) + f(B04) + f(B05)$ | NA | 0.656 | 138.877 |
| $y = f(B01) + f(B02) + f(B03) + f(B04)$ | NA | 0.854 | 51.142 |
| $y = f(B01) + f(B02) + f(B03) + f(B05)$ | NA | 0.848 | 53.33 |
| $y = f(B01) + f(B02) + f(B04) + f(B05)$ | NA | 0.704 | 127.281 |
| $y = f(B01) + f(B03) + f(B04) + f(B05)$ | NA | 0.75 | 106.847 |
| $y = f(B02) + f(B03) + f(B04) + f(B05)$ | NA | 0.829 | 66.927 |
| $y = f(B01) + f(B02) + f(B03) + f(B04) + f(B05)$ | NA | 0.847 | 54.299 |

Tabla A4. Desempeño predictivo de los modelos RLS

| Modelo | R | MSRE |
|-----------------------------------|-------|-------|
| $y = -2.48 + 11.72*(B01)$ | 0.394 | 0.674 |
| $y = -1.76 + 7.35*(B02)$ | 0.251 | 0.668 |
| $y = -1.71 + 9.89*(B03)$ | 0.386 | 0.613 |
| $y = -2.08 + 26.69*(B04)$ | 0.777 | 0.481 |
| $y = -1.54 + 25.69*(B05)$ | 0.749 | 0.635 |
| $y = -2.48 + 11.72*(B01^2)$ | 0.394 | 0.674 |
| $y = -1.76 + 7.35*(B02^2)$ | 0.251 | 0.668 |
| $y = -1.71 + 9.89*(B03^2)$ | 0.386 | 0.613 |
| $y = -2.08 + 26.69*(B04^2)$ | 0.777 | 0.481 |
| $y = -1.54 + 25.69*(B05^2)$ | 0.749 | 0.635 |
| $y = -2.06 + 4.62*(B01+B02)$ | 0.314 | 0.668 |
| $y = -2.1 + 8.03*(B01+B02^2)$ | 0.34 | 0.672 |
| $y = -2.16 + 5.82*(B01+B03)$ | 0.393 | 0.627 |
| $y = -2.19 + 9.04*(B01+B03^2)$ | 0.358 | 0.661 |
| $y = -2.84 + 10.95*(B01+B04)$ | 0.639 | 0.59 |
| $y = -2.59 + 12.37*(B01+B04^2)$ | 0.443 | 0.663 |
| $y = -2.81 + 12.14*(B01+B05)$ | 0.661 | 0.647 |
| $y = -2.58 + 12.44*(B01+B05^2)$ | 0.436 | 0.671 |
| $y = -1.73 + 6.17*(B01^2+B02)$ | 0.268 | 0.668 |
| $y = -1.37 + 14.18*(B01^2+B02^2)$ | 0.252 | 0.674 |
| $y = -1.72 + 8.22*(B01^2+B03)$ | 0.383 | 0.619 |
| $y = -1.38 + 18.33*(B01^2+B03^2)$ | 0.293 | 0.657 |
| $y = -2.12 + 19.58*(B01^2+B04)$ | 0.724 | 0.532 |
| $y = -1.74 + 41.23*(B01^2+B04^2)$ | 0.498 | 0.644 |
| $y = -1.79 + 20.95*(B01^2+B05)$ | 0.726 | 0.635 |
| $y = -1.73 + 43.79*(B01^2+B05^2)$ | 0.484 | 0.667 |
| $y = -2.06 + 4.62*(B02+B01)$ | 0.314 | 0.668 |
| $y = -1.73 + 6.17*(B02+B01^2)$ | 0.268 | 0.668 |
| $y = -1.83 + 4.69*(B02+B03)$ | 0.331 | 0.638 |
| $y = -1.67 + 6.18*(B02+B03^2)$ | 0.251 | 0.664 |
| $y = -2.27 + 8.67*(B02+B04)$ | 0.551 | 0.6 |
| $y = -1.84 + 8.01*(B02+B04^2)$ | 0.3 | 0.661 |
| $y = -2.27 + 9.89*(B02+B05)$ | 0.58 | 0.629 |
| $y = -1.83 + 7.94*(B02+B05^2)$ | 0.289 | 0.664 |
| $y = -2.1 + 8.03*(B02^2+B01)$ | 0.34 | 0.672 |
| $y = -1.37 + 14.18*(B02^2+B01^2)$ | 0.252 | 0.674 |
| $y = -1.63 + 7.63*(B02^2+B03)$ | 0.355 | 0.626 |
| $y = -1.22 + 14.26*(B02^2+B03^2)$ | 0.213 | 0.667 |
| $y = -1.96 + 18.48*(B02^2+B04)$ | 0.695 | 0.539 |

| Modelo | R | MSRE |
|-----------------------------------|-------|-------|
| $y = -1.38 + 29.9*(B02^2+B04^2)$ | 0.352 | 0.651 |
| $y = -1.68 + 20.72*(B02^2+B05)$ | 0.708 | 0.62 |
| $y = -1.34 + 30.24*(B02^2+B05^2)$ | 0.319 | 0.663 |
| $y = -2.16 + 5.82*(B03+B01)$ | 0.393 | 0.627 |
| $y = -1.72 + 8.22*(B03+B01^2)$ | 0.383 | 0.619 |
| $y = -1.83 + 4.69*(B03+B02)$ | 0.331 | 0.638 |
| $y = -1.63 + 7.63*(B03+B02^2)$ | 0.355 | 0.626 |
| $y = -1.95 + 8.37*(B03+B04)$ | 0.584 | 0.555 |
| $y = -1.72 + 9.79*(B03+B04^2)$ | 0.416 | 0.605 |
| $y = -1.96 + 10.02*(B03+B05)$ | 0.618 | 0.548 |
| $y = -1.73 + 10.08*(B03+B05^2)$ | 0.411 | 0.606 |
| $y = -2.19 + 9.04*(B03^2+B01)$ | 0.358 | 0.661 |
| $y = -1.38 + 18.33*(B03^2+B01^2)$ | 0.293 | 0.657 |
| $y = -1.67 + 6.18*(B03^2+B02)$ | 0.251 | 0.664 |
| $y = -1.22 + 14.26*(B03^2+B02^2)$ | 0.213 | 0.667 |
| $y = -1.87 + 18.79*(B03^2+B04)$ | 0.706 | 0.523 |
| $y = -1.25 + 35.68*(B03^2+B04^2)$ | 0.405 | 0.624 |
| $y = -1.61 + 22.31*(B03^2+B05)$ | 0.725 | 0.574 |
| $y = -1.24 + 39.71*(B03^2+B05^2)$ | 0.381 | 0.63 |
| $y = -2.84 + 10.95*(B04+B01)$ | 0.639 | 0.59 |
| $y = -2.12 + 19.58*(B04+B01^2)$ | 0.724 | 0.532 |
| $y = -2.27 + 8.67*(B04+B02)$ | 0.551 | 0.6 |
| $y = -1.96 + 18.48*(B04+B02^2)$ | 0.695 | 0.539 |
| $y = -1.95 + 8.37*(B04+B03)$ | 0.584 | 0.555 |
| $y = -1.87 + 18.79*(B04+B03^2)$ | 0.706 | 0.523 |
| $y = -1.92 + 14.77*(B04+B05)$ | 0.779 | 0.503 |
| $y = -2.05 + 25.52*(B04+B05^2)$ | 0.782 | 0.482 |
| $y = -2.59 + 12.37*(B04^2+B01)$ | 0.443 | 0.663 |
| $y = -1.74 + 41.23*(B04^2+B01^2)$ | 0.498 | 0.644 |
| $y = -1.84 + 8.01*(B04^2+B02)$ | 0.3 | 0.661 |
| $y = -1.38 + 29.9*(B04^2+B02^2)$ | 0.352 | 0.651 |
| $y = -1.72 + 9.79*(B04^2+B03)$ | 0.416 | 0.605 |
| $y = -1.25 + 35.68*(B04^2+B03^2)$ | 0.405 | 0.624 |
| $y = -1.56 + 24.36*(B04^2+B05)$ | 0.756 | 0.605 |
| $y = -1.38 + 158.4*(B04^2+B05^2)$ | 0.794 | 0.536 |
| $y = -2.81 + 12.14*(B05+B01)$ | 0.661 | 0.647 |
| $y = -1.79 + 20.95*(B05+B01^2)$ | 0.726 | 0.635 |
| $y = -2.27 + 9.89*(B05+B02)$ | 0.58 | 0.629 |
| $y = -1.68 + 20.72*(B05+B02^2)$ | 0.708 | 0.62 |
| $y = -1.96 + 10.02*(B05+B03)$ | 0.618 | 0.548 |

| Modelo | R | MSRE |
|--------------------------------------|-------|-------|
| $y = -1.61 + 22.31*(B05+B03^2)$ | 0.725 | 0.574 |
| $y = -1.92 + 14.77*(B05+B04)$ | 0.779 | 0.503 |
| $y = -1.56 + 24.36*(B05+B04^2)$ | 0.756 | 0.605 |
| $y = -2.58 + 12.44*(B05^2+B01)$ | 0.436 | 0.671 |
| $y = -1.73 + 43.79*(B05^2+B01^2)$ | 0.484 | 0.667 |
| $y = -1.83 + 7.94*(B05^2+B02)$ | 0.289 | 0.664 |
| $y = -1.34 + 30.24*(B05^2+B02^2)$ | 0.319 | 0.663 |
| $y = -1.73 + 10.08*(B05^2+B03)$ | 0.411 | 0.606 |
| $y = -1.24 + 39.71*(B05^2+B03^2)$ | 0.381 | 0.63 |
| $y = -2.05 + 25.52*(B05^2+B04)$ | 0.782 | 0.482 |
| $y = -1.38 + 158.4*(B05^2+B04^2)$ | 0.794 | 0.536 |
| $y = -1.36 + 28.13*(B01*B02)$ | 0.248 | 0.673 |
| $y = -1.1 + 94.29*(B01*B02^2)$ | 0.151 | 0.681 |
| $y = -1.36 + 39.62*(B01*B03)$ | 0.319 | 0.643 |
| $y = -1.08 + 143.37*(B01*B03^2)$ | 0.185 | 0.671 |
| $y = -1.65 + 122.39*(B01*B04)$ | 0.695 | 0.56 |
| $y = -1.29 + 1219.67*(B01*B04^2)$ | 0.713 | 0.575 |
| $y = -1.43 + 155.11*(B01*B05)$ | 0.74 | 0.64 |
| $y = -1.13 + 1888.99*(B01*B05^2)$ | 0.777 | 0.662 |
| $y = -1.18 + 117.45*(B01^2*B02)$ | 0.214 | 0.678 |
| $y = -1.04 + 402.94*(B01^2*B02^2)$ | 0.117 | 0.685 |
| $y = -1.18 + 164.03*(B01^2*B03)$ | 0.252 | 0.662 |
| $y = -1.02 + 595.98*(B01^2*B03^2)$ | 0.126 | 0.681 |
| $y = -1.38 + 556.16*(B01^2*B04)$ | 0.599 | 0.608 |
| $y = -1.18 + 5962.52*(B01^2*B04^2)$ | 0.631 | 0.613 |
| $y = -1.33 + 902.94*(B01^2*B05)$ | 0.72 | 0.647 |
| $y = -1.09 + 10789.19*(B01^2*B05^2)$ | 0.771 | 0.667 |
| $y = -1.36 + 28.13*(B02*B01)$ | 0.248 | 0.673 |
| $y = -1.18 + 117.45*(B02*B01^2)$ | 0.214 | 0.678 |
| $y = -1.23 + 31.42*(B02*B03)$ | 0.239 | 0.66 |
| $y = -1.04 + 115.23*(B02*B03^2)$ | 0.129 | 0.68 |
| $y = -1.49 + 112.13*(B02*B04)$ | 0.62 | 0.585 |
| $y = -1.23 + 1170.52*(B02*B04^2)$ | 0.657 | 0.595 |
| $y = -1.41 + 174.83*(B02*B05)$ | 0.723 | 0.627 |
| $y = -1.13 + 2178.52*(B02*B05^2)$ | 0.771 | 0.657 |
| $y = -1.1 + 94.29*(B02^2*B01)$ | 0.151 | 0.681 |
| $y = -1.04 + 402.94*(B02^2*B01^2)$ | 0.117 | 0.685 |
| $y = -1.06 + 105.17*(B02^2*B03)$ | 0.129 | 0.681 |
| $y = -0.98 + 364.15*(B02^2*B03^2)$ | 0.042 | 0.691 |
| $y = -1.2 + 442.79*(B02^2*B04)$ | 0.434 | 0.639 |

| Modelo | R | MSRE |
|--------------------------------------|-------|-------|
| $y = -1.1 + 5067.18*(B02^2*B04^2)$ | 0.488 | 0.641 |
| $y = -1.28 + 1093.66*(B02^2*B05)$ | 0.656 | 0.633 |
| $y = -1.09 + 14182.23*(B02^2*B05^2)$ | 0.751 | 0.662 |
| $y = -1.36 + 39.62*(B03*B01)$ | 0.319 | 0.643 |
| $y = -1.18 + 164.03*(B03*B01^2)$ | 0.252 | 0.662 |
| $y = -1.23 + 31.42*(B03*B02)$ | 0.239 | 0.66 |
| $y = -1.06 + 105.17*(B03*B02^2)$ | 0.129 | 0.681 |
| $y = -1.35 + 112.75*(B03*B04)$ | 0.587 | 0.584 |
| $y = -1.17 + 1182.74*(B03*B04^2)$ | 0.617 | 0.606 |
| $y = -1.39 + 230.35*(B03*B05)$ | 0.731 | 0.561 |
| $y = -1.13 + 2921.91*(B03*B05^2)$ | 0.775 | 0.635 |
| $y = -1.08 + 143.37*(B03^2*B01)$ | 0.185 | 0.671 |
| $y = -1.02 + 595.98*(B03^2*B01^2)$ | 0.126 | 0.681 |
| $y = -1.04 + 115.23*(B03^2*B02)$ | 0.129 | 0.68 |
| $y = -0.98 + 364.15*(B03^2*B02^2)$ | 0.042 | 0.691 |
| $y = -1.09 + 431.08*(B03^2*B04)$ | 0.358 | 0.649 |
| $y = -1.03 + 4629.09*(B03^2*B04^2)$ | 0.388 | 0.658 |
| $y = -1.24 + 1685.02*(B03^2*B05)$ | 0.612 | 0.578 |
| $y = -1.09 + 24842.88*(B03^2*B05^2)$ | 0.739 | 0.635 |
| $y = -1.65 + 122.39*(B04*B01)$ | 0.695 | 0.56 |
| $y = -1.38 + 556.16*(B04*B01^2)$ | 0.599 | 0.608 |
| $y = -1.49 + 112.13*(B04*B02)$ | 0.62 | 0.585 |
| $y = -1.2 + 442.79*(B04*B02^2)$ | 0.434 | 0.639 |
| $y = -1.35 + 112.75*(B04*B03)$ | 0.587 | 0.584 |
| $y = -1.09 + 431.08*(B04*B03^2)$ | 0.358 | 0.649 |
| $y = -1.32 + 326.22*(B04*B05)$ | 0.788 | 0.569 |
| $y = -1.1 + 3879.19*(B04*B05^2)$ | 0.797 | 0.644 |
| $y = -1.29 + 1219.67*(B04^2*B01)$ | 0.713 | 0.575 |
| $y = -1.18 + 5962.52*(B04^2*B01^2)$ | 0.631 | 0.613 |
| $y = -1.23 + 1170.52*(B04^2*B02)$ | 0.657 | 0.595 |
| $y = -1.1 + 5067.18*(B04^2*B02^2)$ | 0.488 | 0.641 |
| $y = -1.17 + 1182.74*(B04^2*B03)$ | 0.617 | 0.606 |
| $y = -1.03 + 4629.09*(B04^2*B03^2)$ | 0.388 | 0.658 |
| $y = -1.19 + 3950.63*(B04^2*B05)$ | 0.797 | 0.577 |
| $y = -1.05 + 43747.58*(B04^2*B05^2)$ | 0.803 | 0.651 |
| $y = -1.43 + 155.11*(B05*B01)$ | 0.74 | 0.64 |
| $y = -1.33 + 902.94*(B05*B01^2)$ | 0.72 | 0.647 |
| $y = -1.41 + 174.83*(B05*B02)$ | 0.723 | 0.627 |
| $y = -1.28 + 1093.66*(B05*B02^2)$ | 0.656 | 0.633 |
| $y = -1.39 + 230.35*(B05*B03)$ | 0.731 | 0.561 |

| Modelo | R | MSRE |
|--------------------------------------|--------|-------|
| $y = -1.24 + 1685.02*(B05*B03^2)$ | 0.612 | 0.578 |
| $y = -1.32 + 326.22*(B05*B04)$ | 0.788 | 0.569 |
| $y = -1.19 + 3950.63*(B05*B04^2)$ | 0.797 | 0.577 |
| $y = -1.13 + 1888.99*(B05^2*B01)$ | 0.777 | 0.662 |
| $y = -1.09 + 10789.19*(B05^2*B01^2)$ | 0.771 | 0.667 |
| $y = -1.13 + 2178.52*(B05^2*B02)$ | 0.771 | 0.657 |
| $y = -1.09 + 14182.23*(B05^2*B02^2)$ | 0.751 | 0.662 |
| $y = -1.13 + 2921.91*(B05^2*B03)$ | 0.775 | 0.635 |
| $y = -1.09 + 24842.88*(B05^2*B03^2)$ | 0.739 | 0.635 |
| $y = -1.1 + 3879.19*(B05^2*B04)$ | 0.797 | 0.644 |
| $y = -1.05 + 43747.58*(B05^2*B04^2)$ | 0.803 | 0.651 |
| $y = 1.4 - 1.96*(B01/B02)$ | 0.119 | 0.692 |
| $y = 0.11 - 0.09*(B01/B02^2)$ | 0.346 | 0.645 |
| $y = 1.06 - 1.13*(B01/B03)$ | 0.55 | 0.517 |
| $y = -0.03 - 0.04*(B01/B03^2)$ | 0.589 | 0.491 |
| $y = 1.08 - 0.61*(B01/B04)$ | 0.779 | 0.347 |
| $y = -0.07 - 0.01*(B01/B04^2)$ | 0.724 | 0.391 |
| $y = -0.1 - 0.12*(B01/B05)$ | 0.646 | 0.669 |
| $y = -0.53 - 0*(B01/B05^2)$ | 0.591 | 0.69 |
| $y = -3.39 + 15.69*(B01^2/B02)$ | -0.594 | 0.776 |
| $y = 0.37 - 0.92*(B01^2/B02^2)$ | 0.141 | 0.687 |
| $y = 2 - 12.85*(B01^2/B03)$ | 0.501 | 0.587 |
| $y = 0.14 - 0.33*(B01^2/B03^2)$ | 0.577 | 0.499 |
| $y = 1.84 - 6.54*(B01^2/B04)$ | 0.791 | 0.288 |
| $y = 0.09 - 0.09*(B01^2/B04^2)$ | 0.739 | 0.353 |
| $y = -0.22 - 0.82*(B01^2/B05)$ | 0.632 | 0.687 |
| $y = -0.53 - 0.01*(B01^2/B05^2)$ | -0.592 | 0.692 |
| $y = -2.72 + 2.12*(B02/B01)$ | 0.076 | 0.7 |
| $y = 1.83 - 0.43*(B02/B01^2)$ | -0.606 | 0.802 |
| $y = 2.11 - 2.07*(B02/B03)$ | 0.645 | 0.444 |
| $y = 0.1 - 0.05*(B02/B03^2)$ | 0.613 | 0.471 |
| $y = 1.27 - 0.8*(B02/B04)$ | 0.772 | 0.31 |
| $y = -0.03 - 0.01*(B02/B04^2)$ | 0.725 | 0.375 |
| $y = -0.19 - 0.13*(B02/B05)$ | -0.632 | 0.717 |
| $y = -0.55 - 0*(B02/B05^2)$ | -0.585 | 0.719 |
| $y = -1.42 + 5.04*(B02^2/B01)$ | 0.167 | 0.675 |
| $y = -1.7 + 1.07*(B02^2/B01^2)$ | 0.055 | 0.703 |
| $y = 4.33 - 32.94*(B02^2/B03)$ | 0.63 | 0.471 |
| $y = 0.64 - 0.71*(B02^2/B03^2)$ | 0.653 | 0.435 |
| $y = 0.84 - 5.95*(B02^2/B04)$ | 0.608 | 0.436 |

| Modelo | R | MSRE |
|----------------------------------|----------|-------------|
| $y = 0.11 - 0.13*(B02^2/B04^2)$ | 0.712 | 0.344 |
| $y = -0.56 - 0.61*(B02^2/B05)$ | -0.545 | 0.721 |
| $y = -0.63 - 0.01*(B02^2/B05^2)$ | -0.566 | 0.724 |
| $y = -2.47 + 2.61*(B03/B01)$ | 0.445 | 0.574 |
| $y = -3.77 + 0.64*(B03/B01^2)$ | 0.448 | 0.623 |
| $y = -3.72 + 4.02*(B03/B02)$ | 0.611 | 0.476 |
| $y = -6.38 + 0.86*(B03/B02^2)$ | 0.642 | 0.461 |
| $y = 0.41 - 0.72*(B03/B04)$ | -0.518 | 0.718 |
| $y = -0.01 - 0.02*(B03/B04^2)$ | 0.676 | 0.456 |
| $y = -0.67 - 0.07*(B03/B05)$ | -0.469 | 0.811 |
| $y = -0.67 - 0*(B03/B05^2)$ | -0.522 | 0.821 |
| $y = -1.31 + 7.68*(B03^2/B01)$ | 0.311 | 0.635 |
| $y = -1.55 + 1.71*(B03^2/B01^2)$ | 0.369 | 0.609 |
| $y = -1.47 + 9.46*(B03^2/B02)$ | 0.399 | 0.605 |
| $y = -2.24 + 2.66*(B03^2/B02^2)$ | 0.583 | 0.498 |
| $y = -1.02 + 0.54*(B03^2/B04)$ | -0.073 | 0.749 |
| $y = -0.42 - 0.15*(B03^2/B04^2)$ | -0.443 | 0.692 |
| $y = -0.96 + 0.03*(B03^2/B05)$ | -0.202 | 0.718 |
| $y = -0.89 - 0*(B03^2/B05^2)$ | -0.38 | 0.731 |
| $y = -2.77 + 5.68*(B04/B01)$ | 0.838 | 0.357 |
| $y = -3.6 + 1.09*(B04/B01^2)$ | 0.858 | 0.255 |
| $y = -3.06 + 5.55*(B04/B02)$ | 0.849 | 0.303 |
| $y = -3.45 + 0.72*(B04/B02^2)$ | 0.773 | 0.313 |
| $y = -2.72 + 3.23*(B04/B03)$ | -0.647 | 0.745 |
| $y = -0.26 - 0.09*(B04/B03^2)$ | 0.129 | 0.707 |
| $y = -0.84 - 0.05*(B04/B05)$ | -0.407 | 0.772 |
| $y = -0.65 - 0*(B04/B05^2)$ | -0.538 | 0.804 |
| $y = -1.6 + 44.39*(B04^2/B01)$ | 0.821 | 0.453 |
| $y = -1.8 + 7.84*(B04^2/B01^2)$ | 0.852 | 0.37 |
| $y = -1.68 + 42.26*(B04^2/B02)$ | 0.84 | 0.421 |
| $y = -1.94 + 6.54*(B04^2/B02^2)$ | 0.865 | 0.312 |
| $y = -1.81 + 35.85*(B04^2/B03)$ | 0.819 | 0.467 |
| $y = -1.88 + 3.01*(B04^2/B03^2)$ | -0.693 | 0.745 |
| $y = -1.16 + 2.49*(B04^2/B05)$ | 0.35 | 0.667 |
| $y = -0.95 - 0*(B04^2/B05^2)$ | -0.329 | 0.717 |
| $y = -1.66 + 4.09*(B05/B01)$ | 0.746 | 0.634 |
| $y = -1.77 + 0.62*(B05/B01^2)$ | 0.731 | 0.64 |
| $y = -1.67 + 3.48*(B05/B02)$ | 0.743 | 0.677 |
| $y = -1.74 + 0.42*(B05/B02^2)$ | -0.71 | 0.777 |
| $y = -1.5 + 1.84*(B05/B03)$ | -0.642 | 0.978 |

| Modelo | R | MSRE |
|----------------------------------|----------|-------------|
| $y = -0.86 - 0.02*(B05/B03^2)$ | -0.312 | 1.021 |
| $y = -1.48 + 1.01*(B05/B04)$ | -0.539 | 0.974 |
| $y = 0.53 - 0.11*(B05/B04^2)$ | 0.571 | 0.511 |
| $y = -1.21 + 52.27*(B05^2/B01)$ | 0.779 | 0.649 |
| $y = -1.26 + 8.27*(B05^2/B01^2)$ | 0.777 | 0.642 |
| $y = -1.22 + 44.87*(B05^2/B02)$ | 0.781 | 0.659 |
| $y = -1.26 + 6.04*(B05^2/B02^2)$ | 0.778 | 0.673 |
| $y = -1.21 + 31.85*(B05^2/B03)$ | -0.758 | 0.724 |
| $y = -1.22 + 2.67*(B05^2/B03^2)$ | -0.702 | 0.895 |
| $y = -1.27 + 23.38*(B05^2/B04)$ | -0.732 | 0.731 |
| $y = -1.27 + 1.09*(B05^2/B04^2)$ | -0.589 | 0.965 |

Tabla A5. Desempeño predictivo de los modelos RLM

| Modelo | R | MSRE |
|--|----------|-------------|
| $y = 2.24 - 72.28*B01 + 57.64*B02$ | -0.423 | 0.967 |
| $y = 4.32 - 62.4*B01 + 38.8*B03$ | 0.164 | 0.767 |
| $y = 3.14 - 48.09*B01 + 53.83*B04$ | 0.793 | 0.325 |
| $y = -1.17 + 1.34*B01 + 2.23*B05$ | 0.699 | 0.641 |
| $y = 3.87 - 95.23*B02 + 74.27*B03$ | 0.718 | 0.419 |
| $y = 0.05 - 24.2*B02 + 39.88*B04$ | 0.785 | 0.306 |
| $y = -1.37 + 3.83*B02 + 0.3*B05$ | 0.294 | 0.663 |
| $y = -1.51 + 3.34*B03 + 7.61*B04$ | 0.67 | 0.527 |
| $y = -1.46 + 7.9*B03 - 3.66*B05$ | 0.179 | 0.67 |
| $y = -1.46 + 19.46*B04 - 13.57*B05$ | 0.564 | 0.584 |
| $y = 1.48 + 81.53*B01 - 187.8*B02 + 98.22*B03$ | 0.856 | 0.209 |
| $y = 5.65 - 104.34*B01 + 45.79*B02 + 50.64*B04$ | 0.845 | 0.466 |
| $y = 4.75 - 119.24*B01 + 86.97*B02 + 20.82*B05$ | 0.105 | 0.882 |
| $y = 5.59 - 76.77*B01 + 28.7*B03 + 33.35*B04$ | 0.854 | 0.446 |
| $y = 6.19 - 84.54*B01 + 46.44*B03 + 21.75*B05$ | 0.719 | 0.578 |
| $y = 3.35 - 50.11*B01 + 63.8*B04 - 16.9*B05$ | 0.767 | 0.365 |
| $y = 3.98 - 97.88*B02 + 67.76*B03 + 16.1*B04$ | 0.859 | 0.288 |
| $y = 4.39 - 106.71*B02 + 80.08*B03 + 13.91*B05$ | 0.878 | 0.278 |
| $y = 0.66 - 33.39*B02 + 62.69*B04 - 25.74*B05$ | 0.707 | 0.373 |
| $y = -1.4 - 5.64*B03 + 30.57*B04 - 18.25*B05$ | 0.721 | 0.543 |
| $y = 0.87 + 100.28*B01 - 207.77*B02 + 106.96*B03 - 8*B04$ | 0.842 | 0.224 |
| $y = 2.13 + 66.02*B01 - 174.51*B02 + 95.85*B03 + 5.23*B05$ | 0.875 | 0.191 |
| $y = 5.13 - 91.69*B01 + 34.8*B02 + 55.52*B04 - 6.98*B05$ | 0.831 | 0.439 |
| $y = 6.08 - 82.82*B01 + 36.05*B03 + 21.69*B04 + 10.88*B05$ | 0.85 | 0.469 |
| $y = 4.41 - 107.18*B02 + 81.16*B03 - 1.74*B04 + 14.82*B05$ | 0.876 | 0.282 |

Tabla A6. Desempeño predictivo de los modelos MAG

| Modelo | R | MSRE |
|--|----------|-------------|
| $y = f(B01)$ | -0.145 | 0.872 |
| $y = f(B02)$ | 0.26 | 0.65 |
| $y = f(B03)$ | 0.687 | 0.425 |
| $y = f(B04)$ | 0.759 | 0.449 |
| $y = f(B05)$ | 0.749 | 0.635 |
| $y = f(B01) + f(B02)$ | -0.281 | 1.261 |
| $y = f(B01) + f(B03)$ | 0.56 | 0.66 |
| $y = f(B01) + f(B04)$ | 0.656 | 0.56 |
| $y = f(B01) + f(B05)$ | -0.152 | 0.876 |
| $y = f(B02) + f(B03)$ | 0.77 | 0.335 |
| $y = f(B02) + f(B04)$ | 0.697 | 0.364 |
| $y = f(B02) + f(B05)$ | -0.159 | 0.834 |
| $y = f(B03) + f(B04)$ | 0.601 | 0.586 |
| $y = f(B03) + f(B05)$ | 0.465 | 0.645 |
| $y = f(B04) + f(B05)$ | 0.427 | 0.596 |
| $y = f(B01) + f(B02) + f(B03)$ | 0.835 | 0.239 |
| $y = f(B01) + f(B02) + f(B04)$ | 0.646 | 0.695 |
| $y = f(B01) + f(B02) + f(B05)$ | -0.338 | 1.372 |
| $y = f(B01) + f(B03) + f(B04)$ | 0.755 | 0.527 |
| $y = f(B01) + f(B03) + f(B05)$ | 0.537 | 0.745 |
| $y = f(B01) + f(B04) + f(B05)$ | 0.434 | 0.586 |
| $y = f(B02) + f(B03) + f(B04)$ | 0.821 | 0.286 |
| $y = f(B02) + f(B03) + f(B05)$ | 0.757 | 0.379 |
| $y = f(B02) + f(B04) + f(B05)$ | 0.364 | 0.652 |
| $y = f(B03) + f(B04) + f(B05)$ | 0.306 | 0.693 |
| $y = f(B01) + f(B02) + f(B03) + f(B04)$ | 0.798 | 0.274 |
| $y = f(B01) + f(B02) + f(B03) + f(B05)$ | 0.748 | 0.319 |
| $y = f(B01) + f(B02) + f(B04) + f(B05)$ | 0.363 | 0.708 |
| $y = f(B01) + f(B03) + f(B04) + f(B05)$ | 0.562 | 0.607 |
| $y = f(B02) + f(B03) + f(B04) + f(B05)$ | 0.752 | 0.373 |
| $y = f(B01) + f(B02) + f(B03) + f(B04) + f(B05)$ | 0.749 | 0.317 |