



Estudio de la Clorofila-a Satelital en el Golfo San Jorge: Validación con Datos de Campo y Comparación Intersatelital

Por ***Lic. Maria Ayelen Sánchez Valdivia***

Presentado ante la Facultad de Matemática, Astronomía y Física y el Instituto de Altos Estudios Espaciales Mario Gulich como parte de los requerimientos para la obtención del grado de

MAGISTER EN APLICACIONES DE INFORMACION ESPACIAL

UNIVERSIDAD NACIONAL DEL CÓRDOBA

2023

©IG-CONAE 2023
©FaMAF-UNC 2023

DIRECTORA

Dra. Carolina Tauro

CONAE, Córdoba, Argentina

CO-DIRECTORA

Dra. Mónica Rabolli

Instituto Colomb, UNSAM, Buenos Aires, Argentina



Esta obra está bajo Licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional

Agradecimientos

En primer lugar, quiero agradecer a mi familia cuyo apoyo incondicional y constante fue el sostén de mi carrera académica y crecimiento personal. ¡Gracias por alentarme a perseguir mis sueños!

Gracias infinitas a mi directora Caro Tauro, quien fue mi guía y mentora desde que comencé la maestría. Su paciencia, dedicación y experiencia fueron fundamentales en la realización de esta tesis. No sólo fue mi directora, sino también la persona que más me motivó a seguir adelante en los momentos difíciles de este proceso.

Gracias a Mónica Rabolli, por haber sido el puente hacia este mundo de la teledetección. Cada paso que doy en mi carrera profesional, sus enseñanzas están presentes. ¡Son los cimientos de mi formación!

Gracias a CONAE por otorgarme la beca para realizar esta maestría. Al Instituto Gulich y sus profesores por brindarme el espacio y los contenidos tan valiosos para mi carrera académica. También por darme la oportunidad de realizar la pasantía en ISMAR (Italia) donde pude perfeccionarme en la temática de esta tesis. Gracias a la Dra. Federica Braga por ser mi tutora italiana. Agradezco especialmente a Anabella y a Santi, directores de la maestría desde que comencé la carrera hasta que entregué la tesis. ¡Gracias por tanto apoyo!

Gracias a Gabriela Williams, Juan Pisoni y Cecilia Gimenez, sus valiosos y constructivos aportes enriquecieron este trabajo y contribuyeron significativamente a su mejora.

Gracias a todos mis compañeros del Gulich, tuve la suerte de conocerlos y compartir momentos inolvidables con ellos. En especial a Almen, Nati, Nacho y Cris. Gracias por acompañarme y ser la familia de corazón.

Dedico este logro a Leo y a Fausto.

Resumen

En la presente tesis se estudió la estimación de Cl-a de origen satelital generada por distintos sensores y se la comparó con mediciones *in situ* en el Golfo San Jorge (Argentina). Se desarrollaron metodologías y se calcularon diferentes estadísticos para comparar dichos datos. En primera instancia se compararon mediciones *in situ* de Cl-a de campañas realizadas durante los años 2014 y 2016 con la Cl-a satelital estimada por el algoritmo OC3 usando imágenes MODIS/Aqua y VIIRS/Suomi-NPP. Los resultados obtenidos mostraron una correspondencia aceptable entre las mediciones de ambas campañas con los valores estimados por MODIS/Aqua ($r^2 = 0.59-0.67$ respectivamente) y VIIRS/Suomi-NPP ($r^2 = 0.54-0.82$ respectivamente). Por otro lado, se compararon estimaciones de Cl-a satelital usando Landsat 8 y Sentinel-2 con Cl-a de MODIS/Aqua (sensor de referencia para las comparaciones *in situ*/satelital) en escenas coincidentes durante los años 2017, 2018 y 2019. Aquí, se obtuvieron casos con buenas correspondencias así como también casos con bajas correlaciones. Según los resultados alcanzados en esta tesis, es clara la necesidad de contar con más datos empíricos para generar o ajustar algoritmos regionales. Como aporte concreto a la misión SABIA-Mar, tanto los protocolos de comparación como los estadísticos para establecer medidas de errores serán incluidos en los planes de calibración y validación de los productos de la misión.

Palabras clave: clorofila-a, Golfo San Jorge, algoritmo OC3, MODIS, VIIRS, Landsat 8, Sentinel-2, SABIA-Mar.

Abstract

In this thesis, Chl-a derived from different sensors was studied and compared with in situ measurements in San Jorge Gulf (Argentina). Methodologies were developed and different statistics were calculated to compare these data. Initially, Chl-a in situ measurements obtained during campaigns in 2014 and 2016 were compared to Chl-a estimated by the OC3 algorithm using MODIS/Aqua and VIIRS/Suomi-NPP. The results showed an acceptable correspondence between field measurements from both campaigns with the values estimated by MODIS/Aqua ($r^2 = 0.59-0.67$ respectively) and VIIRS/Suomi-NPP ($r^2 = 0.54-0.82$ respectively). On the other hand, Chl-a derived from Landsat 8 and Sentinel-2, was compared with Chl-a from MODIS/Aqua (used as reference for satellite/in situ comparisons) in coinciding scenes during 2017, 2018 and 2019. Correlations varied, with some cases showing good correspondences and others weak. Based on the results obtained in this thesis, it is evident the requirement for more empirical data to develop or modify regional algorithms. As a specific contribution to SABIA-Mar mission, both the comparison protocols and the statistics to determine error measurements, will be included in the calibration and validation plans for the mission products.

Keywords: *chlorophyll-a, San Jorge Gulf, OC3 algorithm, MODIS, VIIRS, Landsat 8, Sentinel-2, SABIA-Mar.*

Tabla de Contenidos

1. Introducción	1
1.1. Motivación del trabajo	4
1.2. Hipótesis y Objetivos	5
1.2.1. Objetivos Específicos	6
2. Marco Teórico	7
2.1. Teleobservación del color del mar	7
2.1.1. Aspectos generales	7
2.1.2. Corrección Atmosférica	10
2.2. Propiedades y componentes bio-ópticos de aguas marinas y costeras.	16
2.2.1. Propiedades ópticas aparentes e inherentes	16
2.2.2. Principales componentes ópticamente activos.	17
2.3. Algoritmos bio-ópticos para la estimación de la $Cl-a$	20
2.4. Disponibilidad de datos	21
3. Área de estudio	23
3.1. Golfo San Jorge, Patagonia Argentina	23
4. Satélites para el estudio del color del mar	30
4.1. Satélites que miden el color del mar	30
4.2. Satélites diseñados para ambientes terrestres: Landsat 8 y Sentinel-2	36
4.3. La misión satelital SABIA-Mar	39
5. Validación con datos de campo	42
5.1. Introducción	42
5.1.1. Objetivos del capítulo	43
5.2. Descripción del protocolo de validación de Bailey y Werdell	43

5.3. Datos <i>in situ</i>	45
5.3.1. Campañas oceanográficas en el marco de la iniciativa Pampa Azul	45
5.4. Datos satelitales	47
5.4.1. Algoritmo bio-óptico para los sensores	47
5.5. Metodología de comparación	48
5.5.1. Definición del protocolo	48
5.5.2. Análisis estadístico	50
5.6. Resultados	53
5.7. Conclusiones y Discusiones	62
6. Comparación Intersatelital	64
6.1. Introducción	64
6.1.1. Objetivos del capítulo	65
6.2. Metodología	65
6.2.1. Obtención de imágenes	65
6.2.2. Procesamiento de imágenes L8 y S2: Algoritmos de corrección atmosférica . . .	66
6.2.3. Algoritmo OC3	68
6.2.4. Grillado	68
6.2.5. Análisis estadístico	72
6.3. Resultados	73
6.4. Resumen y Conclusiones	97
7. Discusiones y Conclusiones generales	100
Bibliografía	103

Introducción

La Tierra es un sistema complejo que se encuentra en un delicado balance establecido por una serie de fuerzas que operan entre la tierra, los océanos, la atmósfera y la criósfera. Aunque es bien sabido que los océanos tienen un rol crítico en el clima de la Tierra, sigue siendo el ambiente menos estudiado, por lo que comprender la ecología, bioquímica y amenazas que sufren los océanos bajo escenarios de constante cambio es fundamental. Los océanos contribuyen a diferentes procesos biológicos que ayudan a regular el clima de la Tierra (Bigg et al., 2003). Absorben un gran porcentaje del calor irradiado por el sol y transportan este calor alrededor del planeta a través de las corrientes marinas. Asimismo, son el principal sumidero de dióxido de carbono (CO₂) atmosférico (Herr and Galland, 2009).

Los ecosistemas marinos difieren de los terrestres en que las plantas verdes en el océano son principalmente microscópicas y constituyen una comunidad de algas unicelulares que colectivamente se conoce como *fitoplancton* (phyton=planta y plankton=errante) (IOCCG, 2008). Mediante el proceso de fotosíntesis, estos organismos convierten carbono inorgánico en carbono orgánico. Son los productores primarios, el primer eslabón de la cadena trófica marina, cumpliendo así un rol fundamental en los ciclos bioquímicos (Falkowski, 2012). La producción de materia orgánica (incluido el carbono) por el fitoplancton se denomina producción primaria (Pruter, 1987). Es por ello que el fitoplancton puede influir sobre el balance químico global a través de varios mecanismos, tales como la fijación de CO₂ y el calentamiento estacional de la capa superficial del mar a través de los procesos de absorción y dispersión de la luz (Gregg and Rousseaux, 2014). El fitoplancton interactúa con la luz solar a través de los pigmentos fotosintéticos contenidos en las células fitoplanctónicas, responsables de la absorción de luz por el fitoplancton. Todas las especies de fitoplancton contienen un pigmento que juega un papel fundamental en el color del mar, la clorofila-a (Cl-a). La Cl-a es el pigmento más importante involucrado en la fotosíntesis y su concentración se ha utilizado como un indicador de la biomasa fitoplanctónica y del potencial fotosintético durante muchas décadas (Jeffrey and Vesk, 2005). La Cl-a absorbe luz en longitudes de onda azules y rojas, y refleja en longitudes de onda verde. Esto significa que cuanto mayor es la concentración de fitoplancton, más verde se verá el agua. Por el contrario, si hay poco fitoplancton, el agua se verá azul. Es importante aclarar que la composición de los pigmentos en el fitoplancton varía y, por lo tanto, la Cl-a no siempre es el pigmento principal que absorbe la luz en la columna de agua marina. Si bien es el pigmento más común y ampliamente utilizado para estimar la biomasa del fitoplancton, existen otros

pigmentos que también pueden estar presentes en diferentes grupos de fitoplancton (Kramer and Siegel, 2019).

Por otra parte, en aguas turbias o costeras, otros componentes tales como sedimentos suspendidos, escorrentía terrestre, materia orgánica disuelta coloreada (CDOM, por sus siglas en inglés), influyen en el color.

Las sustancias ópticamente activas presentes en el agua se pueden clasificar en tres grupos, a saber:

- *Fitoplancton*, que incluye a las algas unicelulares y a otros organismos microscópicos;
- *Materia orgánica disuelta coloreada*, sustancias orgánicas disueltas de origen local por la degradación del fitoplancton u otras partículas orgánicas, o provenientes de un aporte externo tal como la descarga de ríos;
- *Material particulado en suspensión*, de origen orgánico no pigmentado o inorgánico.

Además de las determinaciones directas de estos componentes a través de mediciones de campo, también se los puede estimar utilizando sensores a bordo de satélites.

Como se mencionó previamente, las algas poseen pigmentos relacionados a la fotosíntesis, como la Cl-a que absorbe y refleja la luz del sol. Es decir que el fitoplancton es capaz de alterar las características ópticas del agua, es decir, el color del mar. Esta propiedad óptica permite estimar la concentración de la Cl-a (indicador de la cantidad de fitoplancton) mediante la medición de la radiación reflejada por la capa superficial del mar haciendo uso de un determinado instrumento montado sobre una plataforma satelital. Esta técnica se conoce como radiometría del color de mar (*Ocean Color Radiometry*) (IOCCG, 2008). El color del mar es un buen indicador del contenido de pigmentos y partículas en el agua, ya que la clorofila como las partículas disueltas poseen características espectrales particulares.




Figura 1.1: Interacción de la luz con los diferentes componentes presentes en el agua y la atmósfera. Fuente: (Dogliotti, 2007).

La Figura 1.1 muestra la luz que finalmente llega al sensor (1) luego de interactuar con los componentes de la atmósfera (2) (aerosoles y moléculas como el ozono y oxígeno), de ser reflejada especularmente en la superficie del agua (3) y atravesar la superficie e interactuar con las sustancias presentes en el agua (4) (e.g. fitoplancton, moléculas del agua, etc.) (Dogliotti, 2007).

La teleobservación dedicada al color del mar estudia la interacción entre la radiación proveniente del sol y el ambiente acuático. El objetivo es obtener información cuantitativa sobre el tipo y concentración de las sustancias presentes en el agua a partir de la variación de la forma espectral y de la magnitud de la señal que proviene del agua en la región visible e infrarrojo cercano del espectro electromagnético (IOCCG, 2000). A través de la radiancia que emerge del agua (L_w), se logra determinar la concentración y propiedades ópticas de aquellos componentes del agua que absorben y dispersan la luz, como ser la Cl-a (representativa del fitoplancton), sedimentos en suspensión y CDOM, los cuales son todos relevantes para estudios climáticos (Sarmiento et al., 2004) y de la calidad del agua (Hu et al., 2004). De esta manera, el monitoreo mediante la observación remota del color del mar resulta una herramienta complementaria a la mediciones de campo (particularmente escasas en el Atlántico Sudoccidental), ya que proveen una cobertura sinóptica en áreas más extensas, alta capacidad de revisita y un costo relativamente bajo. Las mediciones radiométricas satelitales del color del mar permiten estimar la concentración de clorofila-a (Cl-a) a una profundidad óptica definida como $1/K$, donde K es el coeficiente de atenuación de la radiancia en unidades m^{-1} (Yoder, 2010). Esta profundidad depende de la claridad del agua y puede variar desde unos 30 a 50 metros en mar abierto hasta menos de 1 metro en aguas costeras turbias (Yoder, 2010).

El fitoplancton es considerado la base de toda la producción animal en el mar, el sostén principal de las redes alimenticias sobre la cual las pesquerías mundiales se sustentan (IOCCG, 2008). Resulta importante entonces poder monitorear las poblaciones fitoplanctónicas ya que modificaciones en su abundancia y/o en el momento de su floración pueden afectar la distribución y abundancia de las poblaciones de peces y, en consecuencia, la actividad pesquera (IOCCG, 2008). Además, algunos florecimientos de algas pueden ser motivo de preocupación ya que ciertas especies pueden producir toxinas, capaces de provocar efectos biológicos graves en la vida silvestre y en la población humana (Codd et al., 2005; Zingone and Enevoldsen, 2000). Los florecimientos de algas compuestos por células que naturalmente producen biotoxinas son llamadas tradicionalmente *Mareas Rojas* por su efecto en el color del agua. No obstante, es más apropiado usar el término “Floraciones de Algas Nocivas” o *Harmful Algal Blooms* - HABs en inglés, ya que no siempre la existencia de algas tóxicas esta asociada a un cambio en la coloración del agua. Un ejemplo de la presencia de floraciones de algas nocivas y sus efectos en los ecosistemas marinos fue abordado por Wilson et al. (2015). El estudio investigó la posible implicación de la proliferación de algas nocivas en el aumento de la mortalidad de las crías de ballena franca austral en Península Valdés, desde el año 2005. La proliferación de algas nocivas tiene el potencial de dañar a los peces y la vida silvestre, incluidos los mamíferos marinos, a través de la producción de toxinas o alteraciones ecológicas como el agotamiento del oxígeno y el bloqueo de la luz solar. Otro caso de estudio ocurrió entre el 24 de septiembre y el 11 de octubre del año 2022 en el Golfo Nuevo. Según lo informado por varias instituciones, entre ellas el Instituto Nacional de Investigación y Desarrollo Pesquero (INIDEP), el Instituto de Investigación de Hidrobiología de la Universidad Nacional de la Patagonia San Juan Bosco, el Programa de Monitoreo Sanitario Ballena Franca Austral (PMSBFA); se registraron 30 ballenas francas muertas.

El análisis de biotoxinas en muestras de las ballenas muertas detectó la presencia de concentraciones de Toxina Paralizante de Moluscos en diversos tejidos y fluidos en 5 de las 6 ballenas analizadas. La investigación realizada hasta la fecha mantiene la hipótesis según la cual las ballenas murieron durante una floración algal nociva en el Golfo Nuevo (<https://www.argentina.gob.ar/noticias/confirman-hallazgo-de-toxinas-de-marea-roja-en-las-ballenas-que-murieron-en-peninsula>).

Por su parte, las aguas costeras son sistemas ecológicos vitales que apoyan múltiples niveles tróficos y actividades antropogénicas como la pesca y el turismo. Se estima que más del 50% de las poblaciones humanas viven en zonas costeras. Los ecosistemas costeros son valiosos en términos de biodiversidad, recursos y por su papel en la conectividad entre hábitats terrestres y acuáticos (Richardson and LeDrew, 2006). Son áreas activas en las que los nutrientes y el carbono se procesan y por lo tanto juegan un papel importante en el flujo y el ciclo del CO₂ atmosférico. Al vincular las zonas continentales con los sistemas oceánicos básicamente a través de las descargas de los ríos que suministran materiales disueltos y partículas de los ambientes terrestres, se convierten en un entorno complejo y dinámico. Estos hechos hacen que su estudio sea necesario para obtener una mejor comprensión de los procesos bioquímicos de la Tierra frente al cambio climático, como así también para generar una herramienta para las decisiones de manejo ambiental.

1.1. Motivación del trabajo

El Mar Argentino tiene una extensión litoral de 4000 km aproximadamente de costa y una plataforma continental de 1.782.500 km² (Comisión Nacional del Límite Exterior de la Plataforma Continental, COPLA, 2009), es uno de los espacios marítimos más extensos y fértiles del Hemisferio Sur debido a diversos factores. La Corriente de Malvinas, proveniente de la Antártida, aporta nutrientes esenciales para el crecimiento del fitoplancton, base de la cadena alimentaria (Acha et al., 2004). Además, los procesos de surgencias en la región de la Patagonia refuerzan este aporte de nutrientes, generando una alta productividad biológica. Esta combinación de factores propicia una rica diversidad biológica, convirtiendo al Mar Argentino en una zona crucial para la reproducción de varias especies marinas, así como en un hábitat diverso que sustenta una importante industria pesquera y contribuye significativamente a la economía regional. Pesquerías comerciales, cuencas hidrocarbúrficas y yacimientos minerales de gran relevancia conforman la Zona Económica Exclusiva. Además, es una importante fuente potencial de energía marina. Es por ello que fomentar la exploración desde un punto de vista sistemático y el uso sustentable de este patrimonio, constituye un objetivo nacional de carácter estratégico (Pampa Azul, 2015)

En este escenario, la Comisión Nacional de Actividades Espaciales (CONAE) está desarrollando actualmente el Satélite de Aplicaciones Basadas en la Información Ambiental del Mar (**SABIA-Mar**), en el marco del Plan Espacial Nacional. Esta misión prevé la construcción y puesta en órbita de un satélite orientado principalmente al estudio del color del mar. SABIA-Mar, cuyo lanzamiento está previsto para el año 2025, brindará información global de baja resolución (800 m) e información de las costas de Sudamérica a resolución media (200 m). El objetivo principal de la misión SABIA-Mar es proveer información y productos para el estudio de los ecosistemas marinos, el ciclo del carbono, la dinámica costera. Además de la radiancia emergente de la superficie del océano normalizada $[L_w]_N$ (Tauro and

Tropper, 2016), SABIA-Mar generará una serie de productos de interés para la comunidad científica: concentración de clorofila-a (Tropper and Tauro, 2016), radiación fotosintéticamente disponible (*PAR*) (Tauro and Compagnucci, 2016), coeficiente de atenuación difusa en 490 nm ($K_d(490)$) (Compagnucci and Tauro, 2016) y turbidez (*T*) (Solorza and Tropper, 2016). Para ello, SABIA-Mar contará con una serie de bandas espectrales en los rangos visible, infrarrojo cercano e infrarrojo de onda corta. En la sección 4.3 del capítulo 4, se brindarán más detalles sobre esta misión.

Como parte de una política de estado hacia el mar, la iniciativa nacional Pampa Azul (www.pampazul.gob.ar) promueve la investigación científica y los desarrollos tecnológicos que permitan preservar y explotar efectivamente los recursos marítimos, contribuyendo así a fortalecer la soberanía nacional sobre el mar (Pampa Azul, 2015). Dentro de esta iniciativa, el Golfo San Jorge (GSJ) es una de las cinco áreas geográficas prioritarias, determinadas en base a sus características oceanográficas, la importancia de sus ecosistemas y el impacto potencial de las actividades humanas.

El GSJ es una cuenca semiabierto cuya superficie es de aproximadamente 40.000 km², siendo el golfo más amplio de la costa Argentina extendiéndose desde el Cabo Dos Bahías (44°55'S, 60°32'O) hasta el Cabo Tres Puntas (47°06'S, 65°52'O) (Matano and Palma, 2018). La presencia de varios frentes costeros, la heterogeneidad ambiental y la elevada productividad de sus aguas, lo convierten en un sitio clave para la reproducción y crianza de peces e invertebrados, varios de ellos de importancia económica (Akselman, 1996). La alta disponibilidad de alimentos en los ambientes litorales brinda condiciones favorables para la reproducción de una comunidad diversa de aves y mamíferos marinos. Estos ambientes litorales también funcionan como área de alimentación para predadores tope provenientes de otras regiones (Pampa Azul, 2015). El GSJ forma parte de una cuenca petrolífera, donde el petróleo producido es transportado vía marítima, por lo que el golfo también es un escenario clave en el transporte de hidrocarburos. En este sentido, tanto la expansión de las actividades extractivas como la petrolera y pesquera, requieren el monitoreo permanente de las variables ambientales y biológicas (Pampa Azul, 2015).

En el marco de la misión satelital SABIA-Mar y su sinergia con la iniciativa Pampa Azul, de la cual la CONAE forma parte de manera activa, resulta de vital importancia estudiar y caracterizar las zonas prioritarias de la costa del Mar Argentino, como es el caso del Golfo San Jorge.

1.2. Hipótesis y Objetivos

Las hipótesis planteadas en este trabajo son las siguientes:

H1: El algoritmo OC3, utilizado para estimar la concentración de Cl-a a partir de datos derivados de los sensores MODIS y VIIRS, es aplicable en las aguas del Golfo San Jorge (GSJ).

H2: Las estimaciones de la concentración de Cl-a realizadas con los sensores OLI/Landsat 8 y MSI/Sentinel-2 en el GSJ, son comparables a las estimaciones con MODIS y pueden ser utilizadas para estudiar la calidad de las aguas del golfo.

El objetivo general es estudiar la concentración de Cl-a medida en campo y estimada por diferentes sensores satelitales en el GSJ, estableciendo metodologías de comparación que permitan evaluar la

precisión de las estimaciones y examinar la disponibilidad de estos datos en la región de estudio. Como objetivo secundario, se pretende contribuir a los planes de calibración y validación de algoritmos de CI-a para la misión SABIA-Mar.

1.2.1. Objetivos Específicos

1. Realizar mapas de CI-a en la región de estudio del Golfo San Jorge basados en datos de satelitales de sensores de color de mar, particularmente MODIS/Aqua y VIIRS/Suomi-NPP.
2. Realizar mapas de CI-a basados en datos de satelitales de sensores no diseñados para el color del mar, particularmente: OLI/Landsat 8, MSI/Sentinel 2.
3. Poner en práctica una metodología de validación de datos satelitales de color del mar con datos *in situ*.
4. Analizar diferentes métricas estadísticas que permitan comparar y evaluar los valores de CI-a de diversos orígenes (datos de campo y diferentes sensores satelitales).

Marco Teórico

2.1. Teleobservación del color del mar

2.1.1. Aspectos generales

La teledetección de la Tierra se define como la técnica que utiliza la radiación electromagnética para adquirir información sobre la tierra, la atmósfera y los océanos, sin estar en contacto físico con el objeto, la superficie o fenómeno que se desea investigar (Martin, 2014). Las propiedades del elemento estudiado deben ser inferidas a partir de la intensidad y frecuencia de la energía recibida por el sensor. Tales características van a depender de la fuente de esta energía y cómo luego se altera al propagarse a través de la atmósfera.

Las fuentes de energía electromagnética empleadas en teledetección son básicamente tres (Chuvieco and Salinero, 1996; Robinson, 2004):

1. El Sol, la principal fuente de energía natural. Emite energía de forma continua, siendo su máxima emisión para longitudes de onda (λ) comprendidas entre los 0,4 a 0,7 μm , región del visible en el espectro electromagnético (Figura 2.1).
2. Cualquier cuerpo con una temperatura superior al cero absoluto ($0^\circ\text{Kelvin} = -273^\circ\text{Centígrados}$) emite igualmente radiación electromagnética, con una intensidad y composición espectral muy diferente a la emitida por el sol, ya que esta directamente relacionada con la temperatura (alrededor de 6000°K para el Sol y 300°K para la Tierra). La radiación emitida (no reflejada) por los objetos de la superficie terrestre (segunda fuente natural de energía electromagnética) alcanza su máximo en las longitudes de onda del infrarrojo térmico (8 a 14 μm).

3. La tercera fuente de energía utilizada en teledetección espacial es artificial. A diferencia de los casos anteriores, donde se trabaja con sensores pasivos, aquí se trata de un sensor activo que genera y transmite una señal (radiación electromagnética de gran longitud de onda, es decir, microondas) hacia la superficie y detecta la porción retrodispersada de la señal. La intensidad de la señal retrodispersada se mide para discriminar diferentes tipos de objetos y el retraso en el tiempo entre la transmitida y la reflejada determina la distancia al objeto.

Debido al efecto de la atmósfera sobre la radiación reflejada y recibida, hay tres ventanas de longitud de onda electromagnética llamadas visibles, infrarrojas y de microondas; a través de las cuales se puede estudiar el océano.

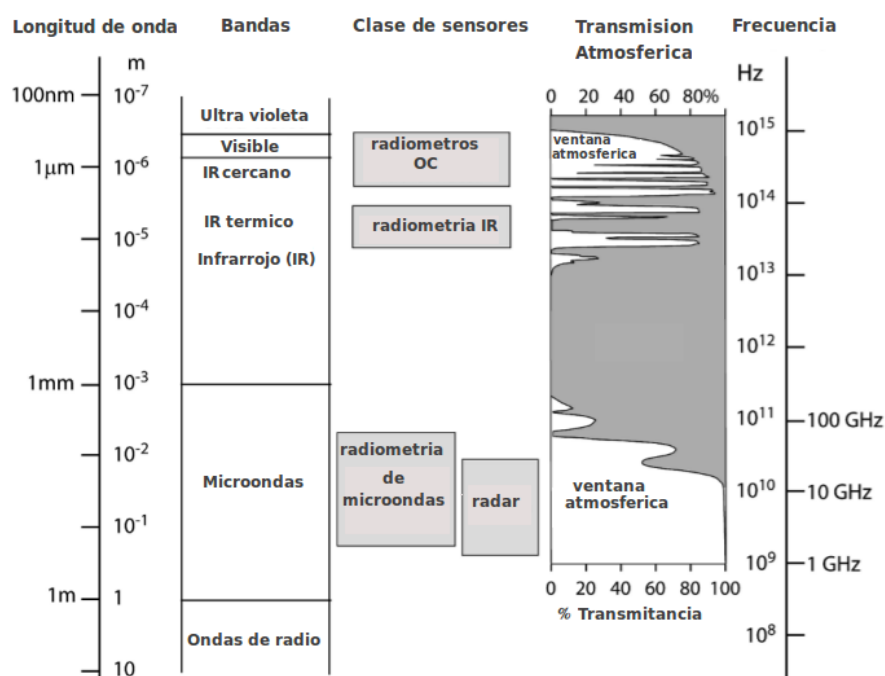


Figura 2.1: El espectro electromagnético y las regiones explotadas por instrumentos de teledetección. Fuente: adaptado de Robinson (2010).

En el visible, extendiéndose hasta el infrarrojo cercano, las observaciones dependen de la luz solar reflejada y están limitadas a los períodos diurnos sin nubes. Dado que el espectro visible contiene las únicas longitudes de onda a las cuales la luz penetra a profundidades oceánicas del orden de los 10-200 metros (Zona fótica, ver Figura 2.2 y Figura 2.3), las observaciones en esta región espectral producen la única información sobre los cambios de color en profundidad que están asociados a las concentraciones de fitoplancton, sedimentos y materia orgánica. Por otra parte, en el infrarrojo se detecta la radiación emitida desde los primeros micrómetros superiores de la superficie del mar. Aunque estas observaciones son independientes de la luz del día, el trabajo de los sensores pasivos en esta longitud de onda, esta restringido a las condiciones libres de nubes (Martin, 2014). Más adelante se profundizarán las características de los diferentes sensores que estudian el color de mar.




Figura 2.2: La penetración de la luz en el mar para cada longitud de onda que compone el espectro electromagnético. Fuente: Brooks/Cole-Thomson 2005.




Figura 2.3: Zonas en que se divide el océano según la profundidad, la distancia a la costa y la penetración de la luz solar. Fuente: adaptado de <https://coast.noaa.gov/>.

Como se mencionó en la introducción del presente trabajo, el objetivo de la teleobservación del color del mar es obtener información cuantitativa del tipo y concentración de las sustancias presentes en el agua a partir de las variación espectral de la radiación que proviene del agua. La señal que proviene del visible e infrarrojo esta compuesta principalmente por:

- * Radiación dispersada por las partículas presentes en la atmósfera.
- * Radiación reflejada de manera especular por la superficie del mar.
- * Radiación emergente de la superficie del mar, luego de ser retrodispersada al atravesar el agua.

Esta última es la que se quiere conocer dado que contiene información útil sobre el cuerpo de agua (IOCCG, 2000). El desafío de las técnicas de sensado remoto radica precisamente en este aspecto, ya que el porcentaje de radiación emergente del agua que llega al tope de la atmósfera representa aproximadamente el 10% en la longitud de onda azul (alrededor de 440 nm), el 5% en la longitud de onda verde (alrededor de 550 nm) y un porcentaje insignificante en el infrarrojo cercano (longitud de onda mayor

que 750 nm) (Gordon and Voss, 2004). Entonces, a partir de la señal recibida por el sensor, se deben llevar a cabo varios pasos para obtener finalmente el dato marino.

El primer paso es realizar la corrección atmosférica que implica obtener la radiación que emerge de la superficie del agua a partir de la señal que llega al tope de la atmósfera (TOA, por sus siglas en inglés). Este paso remueve todas las contribuciones no deseadas, incluyendo tanto la atmosférica como los efectos superficiales, y constituye un paso crucial en procesamiento de la información del color del mar. A partir de la radiación que emerge de la superficie del mar se pueden estimar componentes ópticamente activos (tales como la concentración de Cl-a) aplicando algoritmos diseñados para tal fin.

2.1.2. Corrección Atmosférica

Una tarea importante para el análisis de los datos satelitales es tener en cuenta el efecto de la atmósfera. Esto implica la estimación de la contribución atmosférica sobre la medición de la radiación electromagnética, desde la superficie del agua hasta el sensor (radiancia TOA). En muchos casos, también presupone la detección de fenómenos que inutilizan los datos como las nubes para sensores visibles e infrarrojos o lluvia intensa para radiómetros de microondas. Para todo esto, se debe conocer y entender cada uno de los componentes que conforman la radiación medida por el satélite (Figuras 2.4 y 2.5).

La forma general de expresar la radiación total L_t que llega al sensor en determinada longitud de onda (λ) a tope de atmósfera (TOA) puede describirse mediante la siguiente *Ecuación de Transferencia Radiativa* (IOCCG, 2010):

$$L_t(\lambda) = L_r(\lambda) + L_a(\lambda) + L_{ra}(\lambda) + T(\lambda)L_g(\lambda) + t(\lambda)L_{wc}(\lambda) + t(\lambda)t_0(\lambda) \cos \theta_0 [L_w(\lambda)]_N. \quad (2.1)$$

En esta ecuación:

- $L_r(\lambda)$ es la radiancia resultante de la dispersión por las moléculas (Rayleigh) en ausencia de aerosoles,
- $L_a(\lambda)$ es la radiancia derivada de la dispersión por aerosoles,
- $L_{ra}(\lambda)$ es la dispersión múltiple por moléculas y aerosoles,
- $L_g(\lambda)$ se debe a la reflectancia del haz solar desde la superficie del agua (*sun glint*)
- y la transmitancia directa $T(\lambda)$ a través de la atmósfera,
- $L_{wc}(\lambda)$ es el reflejo de la luz sobre la espuma del mar,
- $[L_w(\lambda)]_N$ es la radiancia normalizada emergente del agua.
- El ángulo cenital solar esta representado por θ_0 .
- Luego, $t(\lambda)$ y $t_0(\lambda)$ son las transmitancias difusas de la atmósfera desde el sol a la superficie y desde la superficie al sensor, respectivamente.

El proceso de eliminar los efectos atmosféricos y superficiales de la señal medida por el sensor (la radiancia total $L_t(\lambda)$) para recuperar la radiación proveniente del agua, se conoce como corrección atmosférica (IOCCG, 2010). Este proceso es fundamental para estimar con precisión cualquier propiedad bio-óptica.

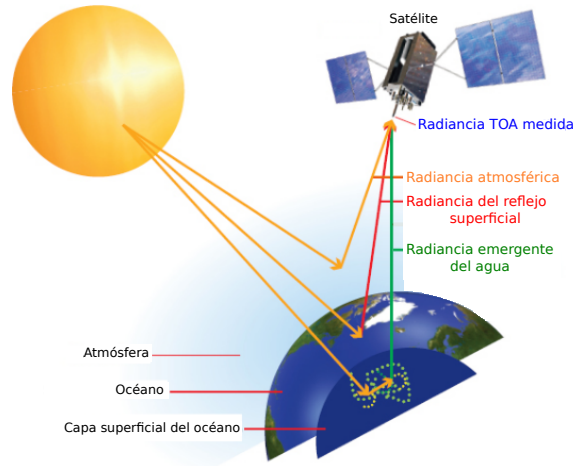


Figura 2.4: Contribución de la radiación emergente del agua (L_w), la radiación reflejada por la superficie del mar, y la dispersada por las partículas en la atmósfera a la radiación a tope de atmósfera (TOA). Fuente: adaptado de <http://www.gps.gov/multimedia/images/>.

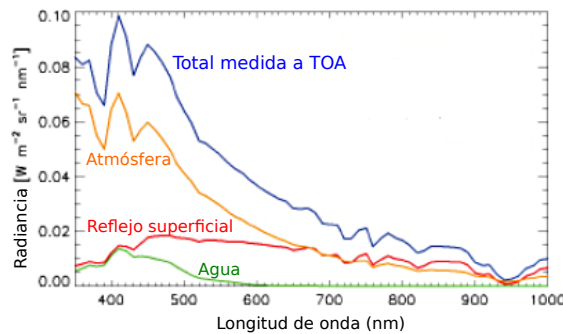


Figura 2.5: Ilustración cuantitativa de la contribución de cada una de las radiaciones representadas en la figura 2.4. Fuente: adaptado de *Assessing the Requirements for Sustained Ocean Color Research and Operations*. (Council et al., 2011).

Teniendo en cuenta la ecuación 2.1, la contribución de la atmósfera se describe por:

$$L_{path}(\lambda) = L_r(\lambda) + L_a(\lambda) + L_{ra}(\lambda). \quad (2.2)$$

En aguas del Caso 1 (típicamente aguas de mar, que se definirá en más detalle en la sección 2.2), $L_{path}(\lambda)$ contribuye aproximadamente el 90% de la radiancia TOA en el azul y el verde, y una fracción menor en el rojo (IOCCG, 2010). Respecto a los componentes que no son propiamente de la atmósfera, se pueden evitar o reducir por varias maneras más o menos complejas. Para las transmitancias difusas, la principal dificultad con su estimación es que depende de la distribución angular de la radiación justo

debajo de la superficie del mar. $L_g(\lambda)$ se puede representar tan pequeño como se desee evitando la región que rodea el borde especular del sol, y $L_{wc}(\lambda)$ se puede estimar a partir de la velocidad del viento en superficie.

En las últimas dos décadas, se han desarrollado para sensores de estudios oceánicos, varios algoritmos de corrección atmosférica para obtener productos globales de color del mar. Todos estos algoritmos utilizan métodos de transferencia radiativa estándar para calcular y eliminar $L_r(\lambda)$ de $L_t(\lambda)$. Este cálculo requiere una estimación de la presión atmosférica de la superficie y en algunos casos, también se usa la velocidad del viento en la superficie (IOCCG (2010)). La parte restante de $L_{path}(\lambda)$ se estima a partir de $L_t(\lambda)$ en las longitudes de onda NIR, donde $[L_w(\lambda)]_N$ es despreciable y de esta forma proporciona $L_a(\lambda) + L_{ra}(\lambda)$ en el NIR. A partir de $L_a(\lambda) + L_{ra}(\lambda)$ en el NIR, se estima $L_a(\lambda) + L_{ra}(\lambda)$ en el visible. Generalmente, la diferencia entre los algoritmos de corrección radica en cómo se lleva a cabo esta última estimación (IOCCG, 2010).

El presente trabajo tiene como satélites de referencia a Aqua MODIS (*Moderate Resolution Imaging Spectroradiometer*) y Suomi NPP (*National Polar-orbiting Partnership*) VIIRS (*Visible Infrared Imaging Radiometer Suite*). Por tal motivo, se focalizará en el algoritmo desarrollado para sus sensores. Gordon and Wang (1994) implementaron un algoritmo para SeaWiFS/MODIS. Su rendimiento fue luego validado a través de simulaciones, y después del lanzamiento de los satélites, a través de la aplicación directa sobre las imágenes y la comparación con datos *in situ*. En base a la ecuación 2.1, el algoritmo trabaja de la siguiente manera: la radiación $L_r(\lambda)$ se calcula a partir de las tablas de consulta (*Lookup Tables LUTs*) Rayleigh definidas por la teoría de transferencia radiativa y considerando la presión atmosférica, la velocidad del viento y la geometría solar y del sensor (junto a todos los efectos de polarización incluidos). La radiación $L_{wc}(\lambda)$ se calcula a partir de la velocidad del viento en superficie del mar. La radiancia TOA procedente del *sun glint* se enmascara (IOCCG, 2010). Los componentes $L_a(\lambda) + L_{ra}(\lambda)$ se estiman utilizando dos bandas de infrarrojo cercano (NIR) bajo el supuesto de que en aguas de mar abierto $L_w(\lambda)$ es insignificante ($L_w(NIR) = 0$ o $\rho_w(NIR) = 0$). Esta suposición se conoce como píxel negro o *black-pixel assumption*. Tras la eliminación del efecto Rayleigh, las radiancias $L_a(\lambda) + L_{ra}(\lambda)$ en las bandas NIR se emplean para seleccionar los modelos de aerosol óptimos para la extrapolación a las bandas visibles (VIS). Para el procesamiento de datos SeaWiFS/MODIS, se emplean doce modelos de aerosoles basados en modelos oceánicos, marítimos, costeros y troposféricos (IOCCG, 2010). Estos modelos representan aerosoles no absorbentes o de absorción débil. Para la extrapolación, uno de los esquemas más utilizados se basa en el epsilon de dispersión única (*single scattering epsilon SSE*) que se ha adoptado en datos SeaWiFS, MODIS, VIIRS y GOCI (*Geostationary Ocean Color Imager*). La SSE (ϵ) es la relación de la reflectancia de dispersión única de aerosol entre dos longitudes de onda para seleccionar modelos de aerosol y extrapolar esta reflectancia desde bandas NIR a bandas del visible. El concepto de dispersión única proporciona información útil relacionada con el comportamiento de las propiedades ópticas que cambian la reflectancia del aerosol de manera analítica (Ahn et al., 2016). En base a los valores de SSE (ϵ) derivados en las bandas NIR, se determinan los modelos de aerosol más apropiados (del conjunto de 12 modelos) y se aplican para la estimación de los efectos de dispersión de aerosoles en las bandas visibles (IOCCG, 2010). Por consiguiente, la radiación emergente del agua normalizada ($[L_w(\lambda)]_N$) puede derivarse a través de la ecuación 2.1.

En aguas de Caso 2 (aguas complejas típicas de las regiones costeras), la suposición del píxel negro deja de ser válida. Esto ocurre porque en aguas turbias los sedimentos presentes dispersan mucho la luz en el NIR; sucede lo mismo en aguas con alta concentración de Cl-a o en aguas muy someras donde el fondo influye en la reflectancia que emerge del agua (Dogliotti, 2007). Para estos casos es necesario implementar otro tipo de algoritmos (IOCCG, 2000). Por ejemplo, los trabajos de Ruddick et al. (2000), Wang and Shi (2007), Vanhellemont and Ruddick (2015), Pahlevan et al. (2017a), proponen el uso de la banda SWIR dentro del esquema de corrección atmosférica.

La radiancia $L(\lambda)$ se puede expresar también a través de su equivalencia con la reflectancia $\rho(\lambda)$:

$$\rho_t(\lambda) = \frac{\pi L_t(\lambda)}{F_0 \cos \theta_0}. \quad (2.3)$$

donde F_0 es la irradiancia solar extraterrestre y θ_0 es el ángulo solar cenital.

A partir de $\rho_w(\lambda)$ se puede calcular la reflectancia sensada remotamente:

$$R_{rs}(\lambda) = \frac{\rho_w(\lambda)}{\pi}. \quad (2.4)$$

La reflectancia sensada remotamente ($R_{rs}(\lambda)$) es la radiación del agua ($L_w(\lambda)$) corregida por los efectos bidireccionales de la interfaz aire-agua y el campo de luz bajo la superficie, normalizada por la irradiancia solar incidente ($Ed(\lambda)$). La R_{rs} es la medida fundamental a partir de la cual se derivan los productos del color del mar, como la concentración de clorofila-a y las propiedades ópticas marinas inherentes (Martin, 2014; Mobley et al., 2016).

Los componentes $L_a(\lambda) + L_{ra}(\lambda)$, como ya se mencionó, se estiman a partir de $[L_w(NIR)]_N$ que en aguas de Caso 1 se supone que es insignificante ($L_w(NIR)=0$). Esto se conoce como suposición del píxel negro o *black-pixel assumption*. Luego, implementando un modelo de aerosoles, se puede extrapolar $[L_w(NIR)]_N$ a $[L_w(Visible)]_N$. Para tener en cuenta el efecto de dispersión múltiple en $L_a(\lambda)$ y $L_{ra}(\lambda)$, se requieren modelos de aerosoles precisos porque ambas componentes dependen de las propiedades del aerosol y aumentan a medida que aumenta la concentración del mismo. Estos modelos representan aerosoles no absorbentes o de absorción débil. Seguidamente, usando estas tablas se estima la variación espectral de $L_a(\lambda) + L_{ra}(\lambda)$ (o sus equivalentes reflectancia $\rho_a(\lambda) + \rho_{ra}(\lambda)$) sobre dos bandas en el NIR, para luego calcular la reflectancia debida a aerosoles (ρ_{as}) en esas mismas bandas. Dado que ρ_{as} depende de las propiedades y el espesor óptico del aerosol, puede ser estimado para cada modelo.

La secuencia completa del procesamiento de datos realizada por el Grupo de Procesamiento de Biología Oceánica (OBPG) de la NASA, comienza con la medición de la radiancia TOA y finaliza con la salida de un producto geofísico. Este procesamiento se divide en varios niveles que definen el tipo de imagen disponible a los usuarios. La tabla 2.1 muestra estos niveles.

Nivel	Definición
0	Se refiere a datos de instrumentos sin procesar a resolución completa. Los datos están en "unidades de ingeniería", como voltios o números digitales.
1a	Se trata de datos de instrumentos no procesados a resolución completa, pero con información como los coeficientes de calibración radiométricos y geométricos, y los parámetros de georreferenciación agregados.
1b	Se refiere a los datos del Nivel 1a que se han procesado en unidades de sensores (por ejemplo, unidades de radiancia). La corrección atmosférica se aplica a la luminosidad del nivel 1b TOA para crear datos del nivel 2.
2	Se refiere a variables geofísicas derivadas geolocalizadas (p. ej., reflectancia emergente del agua normalizada [$\rho_w(\lambda)$] N, concentración de clorofila, K d (490 nm) y AOT (865 nm)) a la misma resolución y ubicación que los datos de Nivel 1.
3	Son variables asignadas en cuadrículas espacio-temporal uniformes, a menudo con puntos faltantes interpolados o enmascarados, y con regiones agrupadas a partir de múltiples órbitas para crear mapas a gran escala como por ejemplo de toda la Tierra.
4	Se refiere a los resultados obtenidos de una combinación de datos satelitales (<i>merge</i>) y resultados del modelo (p. ej., la salida de un modelo de ecosistema oceánico), o los resultados de análisis de datos de nivel inferior (es decir, variables que no son captadas por los instrumentos sino que se derivan de estas mediciones).

Tabla 2.1: Niveles de procesamiento de imágenes satelitales, empleado por la NASA. Fuente: adaptado de Mobley et al. (2016).

A modo de resumen, el OBPG describió el proceso de corrección atmosférica realizado en el Nivel 1b (Mobley et al., 2016), mostrado en la Figura 2.6:

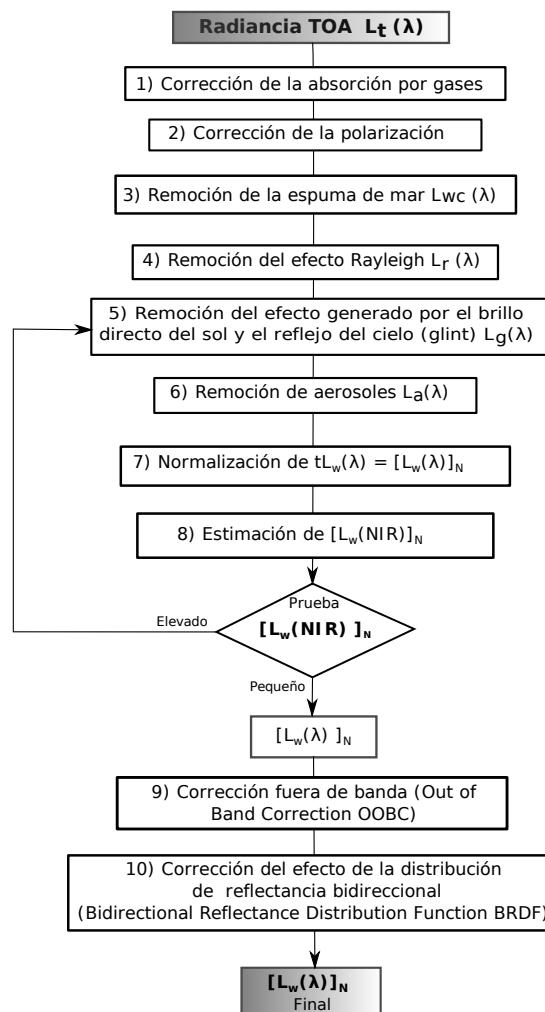


Figura 2.6: Diagrama de flujo de la corrección atmosférica implementado por el Grupo de Procesamiento de Biología Oceánica de la NASA (OBPG) para procesar datos de color del mar de sensores como MODIS y VIIRS. Fuente: adaptado de Mobley et al. (2016)

Algunas de las correcciones requieren información adicional, como la presión del nivel del mar, la velocidad del viento y la concentración de ozono, que no son recopiladas por los sensores de color del océano. Estos datos auxiliares pueden ser inexactos o faltantes, en cuyo caso deben usarse valores climatológicos. La calidad de la información auxiliar afecta la precisión de la corrección atmosférica. Por su parte, algunos gases como el CO_2 , CO , CH_4 y N_2O , tienen una absorción insignificante en las longitudes de onda visibles y NIR relevantes para la percepción remota del color del océano, no así el O_2 , O_3 , NO_2 y el H_2O (Mobley et al., 2016). Las moléculas de oxígeno y agua se pueden evitar mediante la elección juiciosa de bandas para los sensores. Sin embargo, tanto el ozono como el dióxido de nitrógeno no se pueden evitar ya que poseen bandas de absorción amplias y dependientes de la concentración. Por lo tanto, es necesario tener en cuenta la absorción por estos dos gases.

2.2. Propiedades y componentes bio-ópticos de aguas marinas y costeras.

2.2.1. Propiedades ópticas aparentes e inherentes

Una vez medida la reflectancia que emerge del agua, es posible estimar propiedades bio-ópticas de interés. Las características espectrales de $\rho_w(\lambda)$ dependen de los procesos de absorción, dispersión y atenuación que experimente la luz solar al interactuar con las sustancias ópticamente activas presentes en el agua. Esto se conoce como las propiedades ópticas inherentes (IOP) de un medio acuático. Los procesos de absorción se cuantifican mediante el coeficiente de absorción a , que es la fracción de energía absorbida cuando un haz de luz colimado (flujo de energía unidireccional) atraviesa cierto espesor de agua. Si el fotón es dispersado por la presencia de partículas, este proceso se mide por medio del coeficiente de dispersión b (*scattering*). Por otra parte, el coeficiente de atenuación c representa la fracción de energía que pierde el haz de luz cuando avanza a través del agua. Este coeficiente se debe tanto a la absorción como a la dispersión (Gómez et al., 2012):

$$c(\lambda) = a(\lambda) + b(\lambda) \quad (m^{-1}). \quad (2.5)$$

La Figura 2.7 muestra los procesos que se llevan a cabo cuando el flujo de energía incidente $\phi_i(\lambda)$ penetra en el agua. Como se observa, $\phi_i(\lambda)$ es la suma de las energías absorbida $\phi_a(\lambda)$, transmitida $\phi_t(\lambda)$ sin cambio de dirección y energía dispersada $\phi_s(\lambda)$ con un ángulo ψ (respecto a la energía $\phi_t(\lambda)$) dentro de un ángulo sólido Ω . El espesor del agua atravesado por $\phi_i(\lambda)$ se representa con Δr .

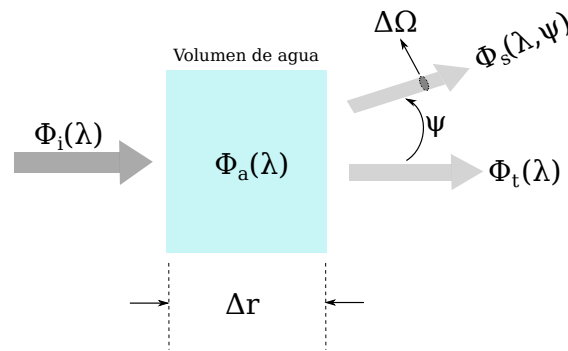


Figura 2.7: Procesos de absorción y dispersión de un haz de luz colimado al atravesar el agua. Fuente: adaptado de (Gómez et al., 2012).

Las IOPs dependen de la composición, morfología y concentración de las partículas y sustancias disueltas en el océano. La composición se refiere a qué materiales componen la partícula o sustancia disuelta, en particular al índice de refracción de ese material en relación con el del agua circundante. La morfología se refiere a los tamaños y formas de las partículas. La concentración se refiere al número de partículas en un volumen dado de agua, que se describe por la distribución del tamaño de partícula (IOCCG, 2006). Dado a que las características físicas de las sustancias disueltas y particuladas en el océano varían en órdenes de magnitud, también lo hacen las IOPs. Por ejemplo, en aguas puras o claras, tanto el coeficiente de absorción como el de dispersión son inferiores a $0,01 \text{ m}^{-1}$ a 440 nm . Pero en aguas costeras turbias con concentraciones elevadas de fitoplancton, partículas en suspensión y materia

orgánica disuelta, los coeficientes de absorción y dispersión pueden ser cuatro órdenes de magnitud mayores (IOCCG, 2006). Comprender cómo la variabilidad de las IOPs está determinada por diversos componentes del ecosistema acuático es importante para determinar las características ópticas de los principales componentes activos del océano.

Cuando la energía electromagnética atraviesa un cuerpo de agua, se cumplen las leyes de Snell y Fresnel. La primera es un indicador de cómo cambia la dirección de propagación de la luz al cambiar de medio. La segunda, de cómo cambian la dirección de polarización y el coeficiente de reflexión en función de las propiedades del medio y el ángulo de incidencia. Cuando la energía ya se encuentra en el medio acuático, se cumple la ley de Lambert-Beer:

$$E_d(\lambda, z) = E_d(\lambda, 0) \cdot e^{-k_d(\lambda)z}. \quad (2.6)$$

donde $E_d(\lambda, z)$ es la irradiancia incidente a una profundidad z y de la longitud de onda λ . $E_d(\lambda, 0)$ es la irradiancia en la superficie interior del agua (osea a una profundidad $z=0$) a cierta longitud de onda λ . Y por último, $k_d(\lambda)$ es el coeficiente de atenuación difusa a determinada λ . El coeficiente de atenuación se encarga de describir la disminución de la irradiancia en el agua (Gómez et al., 2012). Las propiedades definidas a partir de las mediciones de energía radiante en el agua se denominan propiedades ópticas aparentes (AOP). Esto quiere decir que las AOPs dependen del medio (IOP) y de la estructura geométrica direccional de la distribución de la radiancia; y muestran características lo suficientemente estables y regulables como para describir un cuerpo de agua. El coeficiente de atenuación difusa y las propiedades derivadas de él (por ej. la atenuación difusa para la radiación fotosintéticamente activa $KdPAR$ o el coeficiente de atenuación difusa en 490 nm $Kd490$) se consideran AOPs, al igual que la reflectancia y sus derivados (por ej. la reflectancia sensada remotamente).

2.2.2. Principales componentes ópticamente activos.

Las propiedades ópticas de los cuerpos naturales de agua están influenciadas por varias sustancias. Como se mencionó en la Introducción, podemos reconocer tres componentes ópticamente activos (IOCCG, 2000): **1) Fitoplancton** **2) Material en suspensión (inorgánico)** **3) Materia orgánica disuelta coloreada (CDOM o sustancia amarilla)**. El fitoplancton, del griego *phyton* que significa planta y *planktos*, es decir, errantes; es un organismo microscópico de flotación libre que se encuentra en las capas superficiales iluminadas del océano. Es el primer eslabón de la cadena trófica acuática y representa un componente importante del ciclo global del carbono. Según las estimaciones actuales, la fijación global de carbono por fitoplancton oceánico se aproxima en cantidad a la fijación de carbono terrestre sobre una escala anual (IOCCG, 2000). Miles de especies de fitoplancton, con diversos tamaños, formas y propiedades fisiológicas, existen en el medio ambiente acuático, y su concentración y composición puede cambiar en el tiempo y el espacio. La concentración de pigmentos fotosintéticos, como la clorofila-a (Cl-a), permite estimar la biomasa y la capacidad fotosintética del fitoplancton. Es importante reconocer que la clorofila-a está acompañada por una serie de pigmentos auxiliares en las células de fitoplancton (los análisis de pigmentos usando la técnica de cromatografía líquida de alto rendimiento, HPLC, muestran la presencia de quince pigmentos en una muestra típica de fitoplancton del ambiente marino). La

composición del pigmento de una muestra de agua puede variar con la estructura de la comunidad de la población de fitoplancton en la muestra, así como con el estado fisiológico de las células (por ejemplo, fotoadaptación y estado nutricional) (IOCCG, 2000).

La producción de fitoplancton asociada con la fotosíntesis generada en la capa superior del océano es la fuente dominante de material orgánico para la red alimenticia marina. El fitoplancton desempeña al menos dos funciones. Primero, como se indicó anteriormente, el fitoplancton es la base de la red alimenticia marina. El plancton animal (el zooplancton), obtiene su energía a partir del fitoplancton. A su vez, las especies más grandes de peces y mamíferos consumen el zooplancton. Segundo, el fitoplancton contribuye al ciclo global del carbono. A medida que el fitoplancton aumenta en número y masa pueden fijar el carbono, lo que significa que, en la columna de agua superior, la energía solar incidente les permite convertir el CO_2 inorgánico en carbono orgánico. Cuando el fitoplancton muere, se hunde y secuestra carbono depositándolo en las profundidades del océano. Este proceso se conoce como bomba biológica (Jeffrey and Vesk, 2005). Debido al consumo de combustibles fósiles, el ciclo del carbono está fuera de balance, con exceso de CO_2 transportado hacia el océano y la atmósfera. En la atmósfera, la presencia de CO_2 aumenta la opacidad de las ventanas de infrarrojo térmico, lo que contribuye al calentamiento global. La fijación de carbono por parte del fitoplancton transfiere parte de este exceso de carbono atmosférico desde el océano superior al profundo. Dadas las preocupaciones sobre el desequilibrio del ciclo del carbono, existe una necesidad inmediata de determinar la distribución oceánica global y regional de la clorofila y la producción primaria. Las mediciones del color del mar desde el espacio dependen de la naturaleza a pequeña escala de la fotosíntesis. La mayor parte del carbono oceánico es inorgánico; los pigmentos fotosintéticos dentro de cada célula de fitoplancton hacen posible la reducción o fijación del dióxido de carbono en carbono orgánico, por lo que la energía solar se convierte en energía química con oxígeno como un subproducto. Estos pigmentos consisten en la clorofila *a*, los pigmentos accesorios clorofila *b* y *c*, y los carotenoides fotosintéticos (Jeffrey and Vesk, 2005).




Figura 2.8: Espectro de absorción de distintos pigmentos fotosintéticos presentes en el agua. Fuente: Guidi et al. (2017)

En la Figura 2.8 se pueden observar los espectros de absorción de tres pigmentos importantes en la fotosíntesis: clorofila-a, clorofila-b y carotenoides. Las moléculas de clorofila absorben en longitudes de onda azul y roja, como se muestra en los picos de los espectros de absorción de la Figura 2.8. Tanto la Cl-a como la Cl-b absorben luz, sin embargo, la Cl-a tiene una función única y fundamental al convertir la energía solar en energía química. Por otra parte, los carotenoides son otro grupo esencial de pigmentos que absorben la luz violeta y verde azulada. Debido a que la Cl-a absorbe generalmente en dos picos ubicados en el azul y el rojo, a medida que su concentración dentro de la columna de agua aumenta, el agua se vuelve menos azul y más verde. Cuando la absorción de materia disuelta y suspendida cae exponencialmente a través del espectro visible, este material produce un color amarillo pardusco en el agua (Hoepffner and Sathyendranath, 1994).

Respecto al material inorgánico en suspensión, a diferencia del fitoplancton, su influencia se limita típicamente a ciertos cuerpos de aguas costeras y continentales. Por ejemplo, la influencia de las desembocaduras de los ríos o estuarios fangosos se hace presente por la acción de las olas y la corriente que puede llevar sedimentos del fondo a la superficie, modificando significativamente el color de los océanos. En esta categoría también se pueden incluir partículas suspendidas de otro origen, como polvo continental depositado en el agua por vientos o depósitos volcánicos (IOCCG, 2000).

La materia orgánica disuelta coloreada (CDOM, por sus siglas en inglés) es un grupo de sustancias orgánicas que consisten en ácidos húmicos y fúlvicos. Pueden tener un origen local, como por ejemplo a partir de la degradación de las células de fitoplancton y otras partículas orgánicas, o pueden presentarse en una región marina desde una fuente distante. Las sustancias amarillas se fotodegradan, por lo que es probable que aquellas de origen local se acumulen más en profundidad que en las capas superficiales de los cuerpos de agua (IOCCG, 2000).

Del estudio de los principales componentes ópticamente activos, se desprende la clasificación de las aguas que pueden caracterizar el océano, las costas o aguas continentales. Se han propuesto esquemas de clasificación para guiar cuándo aplicar algoritmos específicos de corrección óptica, bio-óptica y atmosférica. La dependencia del color en la calidad del agua llevó a Jerlov (1971) a desarrollar un esquema basado en comparaciones de muestras de agua sobre una escala de color. Luego, Morel and Prieur (1977) definieron dos amplias categorías de aguas según sus características ópticas: las aguas de tipo Caso 1 y Caso 2. En las aguas de Caso 1, los pigmentos de fitoplancton (Cl-a) y sus pigmentos detríticos covariables, dominan las propiedades ópticas del agua. Los años recientes también han observado que pequeños organismos distintos del fitoplancton, como los flagelados, las bacterias heterótrofas y los virus, que coexisten con el fitoplancton, también desempeñan un papel importante en la determinación de algunas propiedades ópticas de las aguas del Caso 1 (IOCCG, 2000). En las aguas del caso 2, predominan otras sustancias como los sedimentos suspendidos, las partículas orgánicas y el CDOM. Los componentes son independientes entre sí y no varían con la clorofila. Cada uno de ellos contribuyen al color en proporción variable. Estos pueden cambiar con el tiempo o con la ubicación geográfica, debido a una variedad de factores como la descarga de ríos o el viento (Miller et al., 2007)). También es importante señalar que, en base a la magnitud de la Cl-a, la actividad biológica oceánica define a sus aguas como: oligotróficas ($Cl-a < 0.1 \text{ mg m}^{-3}$), mesotróficas ($0.1 \text{ mg m}^{-3} < Cl-a < 1.0 \text{ mg m}^{-3}$) y eutrólicas ($Cl-a > 1.0 \text{ mg m}^{-3}$). El agua clara es oligotrófica, mientras que los términos mesotrófico y eutrófico describen una mayor actividad

biológica (Antione et al., 1996). El océano global es en gran parte oligotrófico con un valor medio de Cl-*a* que se aproxima a los 0.2 mg m³ (Dierssen, 2010).

2.3. Algoritmos bio-ópticos para la estimación de la Cl-*a*.

Los pigmentos fitoplanctónicos en el océano se estiman rutinariamente empleando técnicas de teledetección remota. Esto se logra mediante el desarrollo de algoritmos bio-ópticos que relacionan las radiancias ascendentes en el visible con la concentración del pigmento en la superficie del mar.

Existen cuatro criterios que se aplican para desarrollar un modelo en general (Oostende, 2015). El primero es el Método Empírico, el cual busca relaciones estadísticas entre los parámetros de agua medidos en campo y los valores espectrales. No existe necesariamente una relación causal entre los parámetros utilizados. Los algoritmos que utilizan bandas únicas, relaciones entre bandas, álgebra de bandas o bandas múltiples como variables independientes en diferentes análisis de regresión son un ejemplo ampliamente utilizado del enfoque empírico. Este método padece del hecho de que la extrapolación más allá del rango de componentes observado puede producir resultados erróneos. El segundo es el Método Semi-empírico, donde las características espectrales de los compuestos buscados se conocen con mayor o menor precisión. El método es útil para comprender las relaciones causales entre la reflectancia medida satelitalmente, las propiedades ópticas inherentes (IOP) y aparentes (AOP), y no es tan complejo o lento como los métodos puramente analíticos. El tercer método es el Analítico. Éste es un método más complejo en el que los espectros de reflectancia se simulan utilizando la teoría de la transferencia radiativa. Es un modelo de inversión donde se obtiene información cuantitativa de los componentes ópticamente activos a partir de la variación espectral y de la magnitud de radiancia emergente del agua (Dogliotti, 2007). Por último, el enfoque Semi-analítico, relaciona los componentes del agua con las IOP para luego modelar la reflectancia sensada remotamente (Dogliotti, 2007). En general, los algoritmos estándares utilizados por la NASA son empíricos y están basados en datos *in situ* del repositorio global SeaWiFS (*SeaWiFS Bio-optical Archive and Storage System*).

En el caso particular de la estimación de clorofila por medio de modelos empíricos, resulta válido utilizar una relación entre reflectancias azul y verde ya que a medida que la concentración de fitoplancton aumenta la reflectancia en el azul disminuye y aumenta ligeramente en el verde. A través de una regresión entre el logaritmo de la Cl-*a* observada y el logaritmo del cociente entre las reflectancias en el azul y verde, se construye el algoritmo empírico (Morel et al., 2007). En el año 1998 John O'Reilly desarrolló un algoritmo para el sensor SeaWiFS globalmente aceptado (O'Reilly et al., 1998). A partir de una gran cantidad de mediciones coincidentes de Cl-*a* *in situ* con reflectancia sensada remotamente, se logró evaluar la exactitud y precisión del algoritmo, que se expresa mediante la siguiente ecuación:

$$\log_{10}(Cl_a) = a_0 + \sum_{i=1}^4 a_i \log_{10} \left(\frac{R_{rs}(\lambda_{azul})}{R_{rs}(\lambda_{verde})} \right)^i \quad (2.7)$$

donde el cociente se realiza sobre las reflectancias sensadas remotamente en dos longitudes de onda: verde ($\lambda \sim 550-560$ nm) y la de mayor reflectancia de dos o tres longitudes de onda que se encuentran entre el azul y el verde ($\lambda \sim 443, \sim 490, \sim 510$ nm). El número de bandas y los coeficientes $a_0 - a_4$

dependen del sensor utilizado.

Aplicar un cociente entre bandas resulta ventajoso porque se puede eliminar parcialmente la influencia de la atmósfera. Por ejemplo, si se usa una banda espectral donde la variabilidad óptica es mayor debido a un parámetro dado (parámetro en estudio) y otra banda donde tal parámetro tiene un impacto despreciable, se normaliza la señal útil a las condiciones atmosféricas en el momento de adquisición de la imagen. De esta manera, se disminuyen algunos efectos que no pudieron ser eliminados en el proceso de corrección atmosférica (Dogliotti, 2007).

2.4. Disponibilidad de datos

En el presente capítulo se explicó que el porcentaje de radiancia emergente del agua (L_w) que llega al sensor es considerablemente bajo. Un patrón característico de los cuerpos de agua clara, producto de la absorción de la radiación recibida, es la poca o nula reflectividad en el infrarrojo, especialmente en el infrarrojo medio (Jensen, 2013). Este rasgo diferencia a los cuerpos de agua de los suelos y la vegetación. Dicha diferencia se puede visualizar al comparar las firmas espectrales de cada una de estas coberturas. La firma espectral del agua se caracteriza por ser una curva plana, baja (particularmente en la región del visible) y de sentido descendente hacia el infrarrojo de onda corta (SWIR). Toda la información referente a las propiedades ópticas del agua, se extraen de esa pequeña porción del visible. Por ello, se requiere el desarrollo de un trabajo más minucioso en la búsqueda de imágenes satelitales¹ si se quiere estudiar con precisión la calidad del agua; pues no todas las imágenes dispuestas en los portales son completamente útiles. Tanto la presencia de nubes como los destellos del sol (*sun glint*) y los ángulos asociados a la geometría de iluminación y observación al momento de capturar la escena², son factores condicionantes para establecer si una imagen resulta adecuada. Para la validación de productos satelitales como la clorofila-*a* o la materia orgánica disuelta (CDOM), la selección se reduce aun más. Como se verá en el Capítulo 5 correspondiente a la metodología de validación, las imágenes también deben pertenecer a un intervalo de tiempo y espacio.

En lo que respecta a datos medidos en campo, hoy en día la disponibilidad es menos amplia. La limitación se debe a varias causas. La zona de estudio es extensa y se precisan numerosas campañas para poder recolectar datos que sean representativos de toda la región. A su vez, en caso de existir campañas, se debe tener en consideración la posibilidad de errores en las mediciones como así también al momento de procesar y analizar las muestras en el laboratorio. Por otra parte, las condiciones climáticas representan de igual forma un limitante: nubosidad variable, el movimiento de la embarcación debido al viento, presencia de olas; etc. Llevar adelante una campaña no resulta una tarea simple. La investigación científica en el mar necesita de infraestructuras complejas como ser: distintos tipos de plataformas tripuladas y no tripuladas, equipamiento embarcado y de apoyo en tierra, sensores remotos e instrumental científico (Pampa Azul, 2015). Históricamente, a pesar del potencial y la envergadura de los recursos marinos de nuestro país, el mar ha sido muy poco estudiado. En el Golfo San Jorge, dentro del marco Pampa Azul, hasta el momento se han efectuado cuatro campañas, de las cuales una se llevó a cabo en verano (2014)

¹ Como imágenes satelitales, se hace referencia sólo a aquellas obtenidas por sensores pasivos.

² Ángulos cenital solar y cenital del sensor.

y las tres restantes durante la primavera (2016, 2017 y 2022) (Pampa Azul, 2015); por lo cual, no se cuenta con mucha información en otoño e invierno. Fuera de esta iniciativa, en años anteriores también se han realizado campañas en el golfo. Por ejemplo, en el 2001, Cucchi Colleoni and Carreto (2001) analizaron la variación estacional de la biomasa fitoplanctónica durante campañas llevadas a cabo en los meses de enero, mayo, agosto, septiembre y noviembre de tal año. Por otra parte, Fernández et al. (2007b) estudiaron la variabilidad estacional y espacial de los parámetros físico-químicos del sistema bentónico del GSJ durante el otoño de 2001 hasta el verano de 2002. En el 2015, Glembocki et al. (2015) estudiaron la dinámica espacial del camarón rojo patagónico en el GSJ mediante el análisis de las condiciones oceanográficas de la zona. El trabajo analizó las condiciones oceanográficas de la zona, incluidos los patrones de circulación, temperatura, salinidad y concentraciones de nutrientes. También utilizaron series de imágenes Landsat para identificar y caracterizar estructuras oceanográficas persistentes en el área. Luego, Crespi-Abril et al. (2018) analizaron por primera vez la distribución espacial de la concentración de polvo en el GSJ y plataforma adyacente, y trabajos más recientes como los de Pisoni et al. (2020) evaluaron las condiciones para el desarrollo de surgencias costeras en el GSJ.

La disponibilidad de datos, principalmente aquellos medidos en campo, suele no ser continua y representa un inconveniente para llevar a cabo las validaciones. Esto es así porque en su forma más simple, la validación se trata de un proceso de comparación entre el valor de una variable determinada a partir de los datos satelitales con el valor de esta misma variable medida en campo, coincidente en tiempo y espacio. Y cuando se trata de una validación inter-satelital, la comparación se realiza entre valores estimados por diferentes sensores con similares características. En ambos casos, para ser significativo, esto debe realizarse una gran cantidad de veces. La necesidad de contar con numerosos datos de campo también se debe a la variabilidad inherente de las propiedades biológicas oceánicas, característica que suele ser mayor en zonas costeras. Es decir que los datos de una sola campaña en una región limitada, aunque se obtengan muchos puntos coincidentes, no serán adecuados para validar un algoritmo global o regional. También porque es requisito probar un algoritmo en diversas condiciones ambientales que influyen en él o en el procesamiento de datos. Por ejemplo, si los productos geofísicos son sensibles a la corrección atmosférica, la validación debe realizarse en una variedad de condiciones atmosféricas representativas antes de calificar su desempeño (Robinson, 2010). Las tareas de validación requieren que los datos de campo sean lo más precisos posible. Desafortunadamente, el volumen de datos adecuados para tales actividades ha sido históricamente limitado debido a la escasez de observaciones integrales y simultáneas, y a las dificultades asociadas con el muestreo regional y global. Actualmente se están implementando redes de muestreo con instrumentos que miden permanentemente, como ser las estaciones AERONET en conjunto a diversas campañas oceanográficas en el marco de SeaBASS. Sin embargo, en nuestro mar Argentino aún queda mucho por hacer con respecto a la generación de redes de muestreo para desarrollar una base de datos *in situ* sólida, sistematizada y actualizada. Al momento, en la desembocadura del canal principal de navegación del Estuario de Bahía Blanca, se encuentra instalada una estación AERONET (*AERosol RObotic NETwork*) sobre la Torre del Mareógrafo. Desde el sitio <https://aeronet.gsfc.nasa.gov/> es posible descargar datos de la radiancia emergente del agua normalizada (Lwn) a partir del año 2020 (Arena et al., 2021).

Área de estudio

3.1. Golfo San Jorge, Patagonia Argentina

El Golfo San Jorge (GSJ) es una cuenca semiabierta del Mar Argentino (ver Figura 3.1) que ocupa una superficie de 39.340 km², siendo el golfo más amplio de la costa de nuestro país. Se extiende desde el Cabo Dos Bahías (44°55'S, 60°32'O) hasta el Cabo Tres Puntas (47°06'S, 65°52'O) (Matano and Palma, 2018). El origen de este engolfamiento puede haber estado asociado a una inundación marina de un antigua depresión cerrada semicircular, formación geológica muy común a lo largo de toda la Patagonia (Ponce and Rabassa, 2012). El ambiente terrestre adyacente al golfo esta caracterizado por la presencia de mesetas patagónicas divididas por diversos valles fluviales. Estas geoformas dan lugar a una costa patagónica de perfil accidentado, cuyas playas de arenas finas están acompañadas por acantilados (Akselman, 1996). Por otra parte, las bahías y caletas presentan rocas a poca profundidad del agua que se exponen cuando las mareas bajan. Cabe destacar una característica del ambiente costero relativa a la magnitud de las mareas: éstas son semidiurnas, es decir que en 24 hs se producen dos pleamares y dos bajamares de diferente magnitud que pueden medir aproximadamente entre 5-6 m durante las mareas en luna llena o nueva (sicigias) (Guerrero and Piola, 1997).

Respecto a su características climáticas, el GSJ posee un clima árido a semiárido con precipitaciones medias anuales de apenas unos 200 mm. La temperatura media anual es de 12,7 °C, las temperaturas medias son de 20 °C en verano y 6 °C en invierno (Akselman, 1996). La región se encuentra dominada por corrientes de aire que provienen del Océano Pacífico; estos vientos predominantes del oeste se caracterizan por ser persistentes durante casi todo el año, con velocidades medias de 41 km/h y ráfagas de 100 km/h promedio. Durante la primavera se registran los vientos de mayor velocidad y los mínimos durante el invierno. De los vientos provenientes de cuadrantes dominados por el mar se destacan los del noreste, que soplan con una velocidad promedio de 22 km/h (Isla et al., 2002). El viento es uno de los agentes más enérgicos en la dinámica de la costa, siendo elemental su análisis para comprender la formación y características de las olas. Éstas, a su vez, son importantes de tener en cuenta dado que pueden afectar el estudio superficial del mar con sensores remotos porque alteran la dirección de la luz incidente sobre el agua. Trabajos relacionados al movimiento de olas en el GSJ determinan que, si bien hay un predominio

del tren de olas del cuadrante este-sudeste, las de mayor magnitud provienen del sector este-noreste (Isla et al., 2002).




Figura 3.1: Ubicación geográfica de la zona de estudio

Los niveles de profundidad del GSJ aumentan desde la costa hacia el centro, alcanzando profundidades máximas de 110 m. Hacia el sector sur las profundidades oscilan entre 50-70 m y aproximadamente 90 m en el sector norte (ver Figura 3.2) (Torres et al., 2018).

En cuanto a su hidrografía, las aguas del GSJ pertenecen en parte a la denominada Agua de Plataforma (33,2 ups <salinidad <33,8 ups), pero estos valores se modifican por el aporte de Aguas Costeras, cuya salinidad se caracteriza por ser <33,2 ups. Como resultado, la salinidad de las aguas varía entre los 33.0 ups al sur del golfo y los 33,5 ups hacia el centro y norte del mismo, con baja variabilidad estacional (Fernández, 2006).

Dentro del GSJ las aguas son influenciadas por la presencia de aguas subantárticas de plataforma y también por el ingreso de aguas frías y de baja salinidad que provienen del sur transportadas por la Corriente Patagónica (Figura 3.2). Esta corriente tiene dirección NNE y se divide en dos ramas al llegar al GSJ: una ingresa por el sur del golfo y la otra continúa por la plataforma (Palma et al., 2003; Palma and Matano, 2012). La circulación del golfo se caracteriza por un giro ciclónico delimitado al oeste por una intensa corriente costera y hacia el este por la Corriente Patagónica. Las corrientes que se producen por las grandes amplitudes de marea, interactúan con el fondo marino y favorecen la mezcla vertical en sectores someros y costeros. Esto permite homogeneizar toda la columna de agua, haciendo disponible los nutrientes a los productores primarios. Los extremos norte y sur del GSJ están caracterizados por sistemas frontales (Glembocki et al., 2015). El extremo norte recibe la influencia del Sistema Frontal Norpatagónico (SFNP) que se forma en primavera y verano como resultado de la elevada disipación de energía de marea y la estratificación térmica. Este frente divide áreas costeras homogéneas de aguas en regiones más profundas. En el extremo sur se desarrolla el Sistema Frontal del Golfo San Jorge (SFGSJ),

3.1 GOLFO SAN JORGE, PATAGONIA ARGENTINA

que durante la primavera y el verano da lugar a la transición de aguas mezcladas y de baja salinidad que ingresan al GSJ con las aguas estratificadas dentro del golfo y en la plataforma.

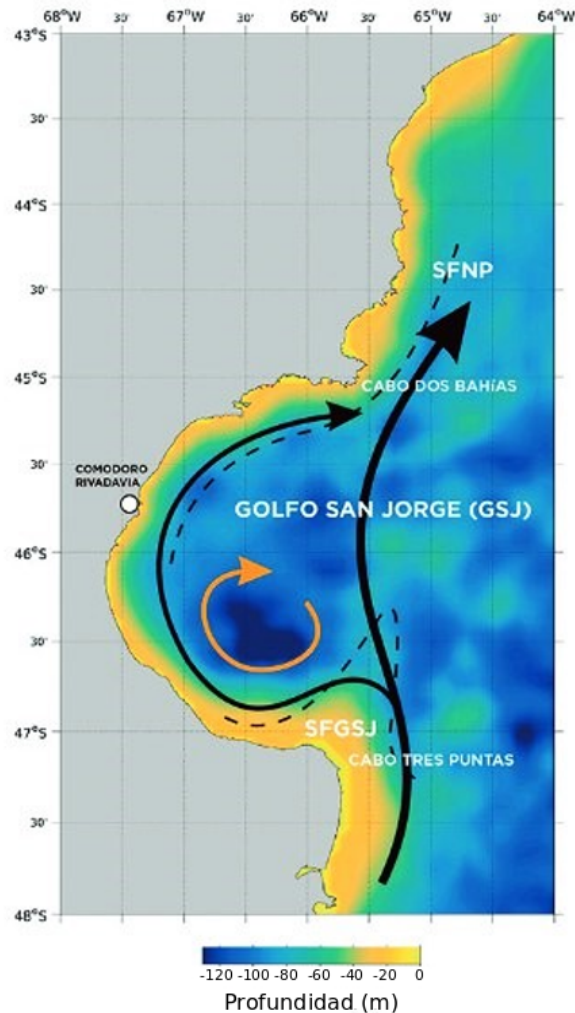


Figura 3.2: Esquema de Corrientes y Circulación en el GSJ. Se representa en líneas negras la Corriente Patagónica de dirección NNE. En línea anaranjada se muestra la circulación media anual dentro del GSJ, que se caracteriza por un giro ciclónico en sentido horario. En líneas punteadas representan los dos frentes presentes en la región: Sistema Frontal Norpatagónico (SFNP) y Sistema Frontal del Golfo San Jorge (SFGSJ). La escala de colores indica profundidad en metros. Fuente: Dans et al. (2021).

El GSJ se encuentra incluido en la Provincia biogeográfica Magallánica de aguas templado-frías (Akselman, 1996). Durante el verano, el aumento de la radiación solar y las temperaturas más altas del aire calientan la capa superficial del agua. Esto hace que el agua en la superficie sea más cálida que las capas más profundas. A medida que el agua se calienta, se vuelve menos densa y tiende a quedarse en la parte superior, dando lugar a una estratificación térmica. Como indican las Figuras 3.3 y 3.4, los registros de temperatura del agua demuestran una distribución horizontal que se presenta en el golfo y sus adyacencias en diferentes niveles de profundidad con un gradiente positivo de dirección sur-norte.

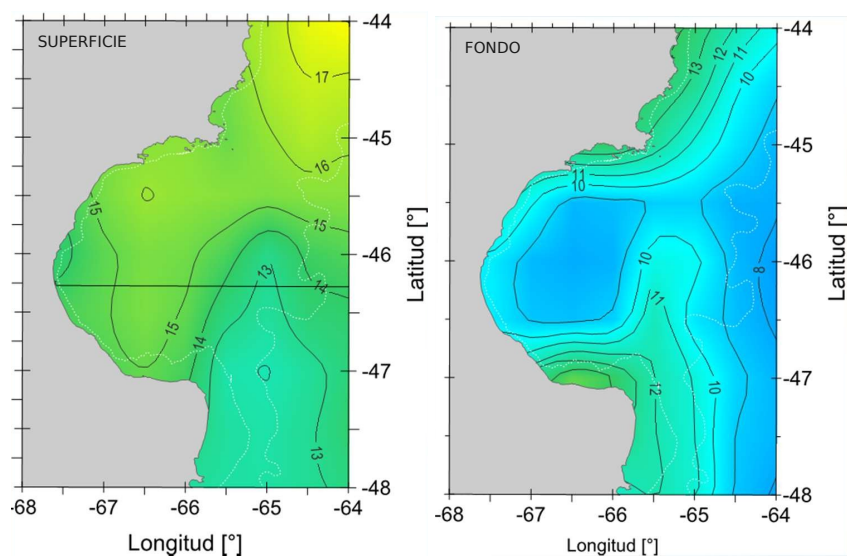


Figura 3.3: Distribución horizontal en superficie y fondo de la temperatura del GSJ durante el período cálido (enero, febrero y marzo). Fuente: Baldoni et al. (2015).




Figura 3.4: Distribución horizontal en superficie y fondo de la temperatura del GSJ durante el período frío (agosto y septiembre). Fuente: Baldoni et al. (2015).

El rango de temperatura superficial máxima y mínima registrada en el GSJ puede variar de un año a otro y de una ubicación a otra dentro del golfo. Sin embargo, como se observa en las Figuras 3.3 y 3.4, los valores de temperatura superficial en verano alcanzan los 16°C, sobre todo en los lugares cercanos a la costa expuestos al sol y al calentamiento estacional. En el fondo la temperatura oscila entre 9-11°C. En otoño-invierno, la temperatura es similar en toda la columna de agua, con valores de alrededor a 7-8 °C, especialmente en zonas alejadas de la costa (Glembocki et al., 2015; Matano and Palma, 2018; Dans et al., 2021). El patrón horizontal de la distribución de la temperatura muestra isotermas de menores valores en el sector sur del Golfo, las que se bifurcan en una rama costera y otra con dirección norte. Este patrón se manifiesta en toda la columna de agua y en el período de mayor estratificación suele ser

un poco más pronunciado en la capa superficial. Sin embargo, este patrón no se presenta de manera constante; a veces no se observa la rama costera en el otoño y ocurre una disminución latitudinal en la rama que avanza por el sector exterior del golfo (Akselman, 1996). La Figura 3.5, representa la variación estacional de la temperatura superficial del mar (SST), generada con los productos L3 de MODIS Aqua para el periodo: 2014-2018. Se puede observar el gradiente positivo de sur a norte y el cambio horizontal de temperatura en los frentes de marea presentes en el GSJ.

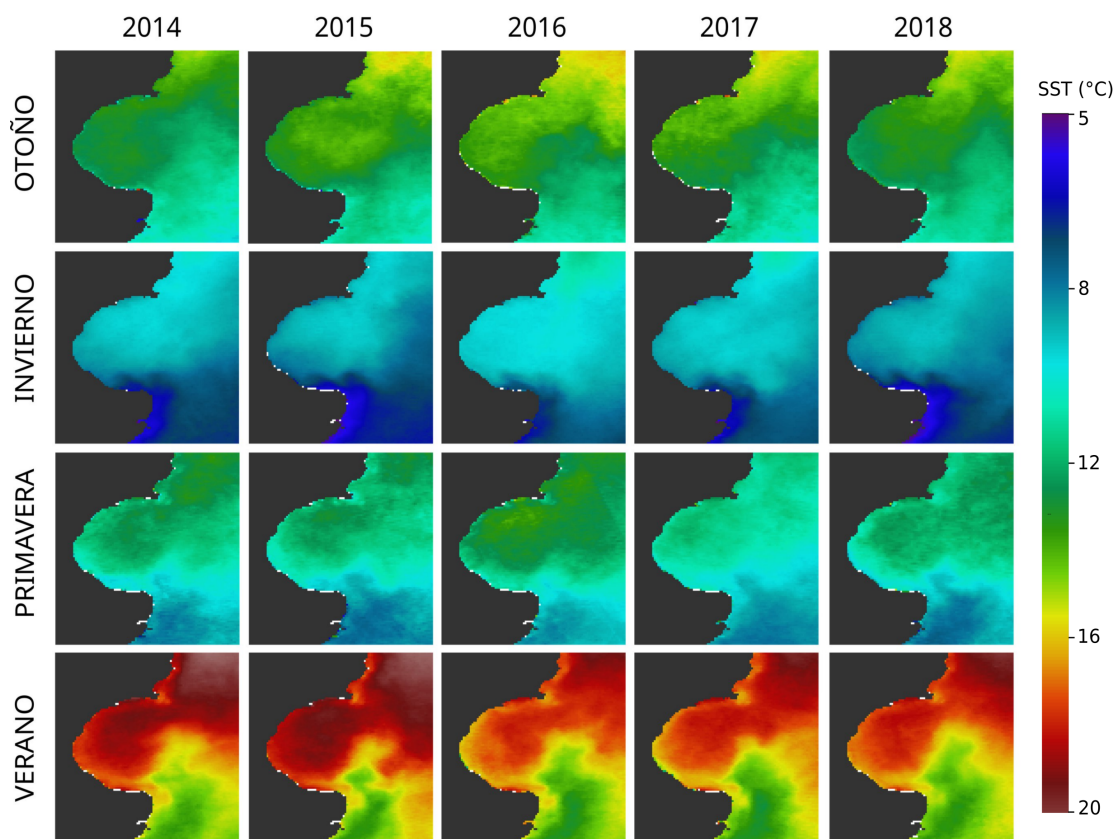


Figura 3.5: Variación estacional de la temperatura superficial del mar (SST), producto L3 de MODIS Aqua. Periodo:2014-2018.

El Mar Patagónico constituye un ambiente marino altamente productivo, con valores de abundancia de fitoplancton aproximadamente tres veces mayor a la media registrada en el resto de los océanos (Piola et al., 2010). La distribución del fitoplancton está influenciada por la presencia de frentes oceánicos y la estratificación vertical del agua. Los frentes oceánicos son zonas de transición entre masas de agua con diferentes propiedades, como temperatura, salinidad y densidad. En estas zonas, se producen gradientes abruptos de propiedades físicas y químicas del agua. Los frentes oceánicos a menudo actúan como áreas de concentración de nutrientes y, por lo tanto, son lugares propicios para el crecimiento del fitoplancton. Las diferencias en las condiciones del agua en los frentes pueden estimular la producción primaria y atraer a los organismos que se alimentan de fitoplancton. Por otra parte, en las capas estratificadas, los nutrientes tienden a estar concentrados en las capas más profundas, donde la luz no penetra. Sin embargo, en las regiones donde la estratificación es menos pronunciada, como en los frentes oceánicos, las condiciones son más propicias para que los nutrientes asciendan a las capas superficiales y se vuelvan

accesibles para el fitoplancton, lo que favorece su crecimiento. En el GSJ particularmente, Glembocki et al. (2015); Torres et al. (2018); Pisoni et al. (2020); Segura et al. (2021) observaron que los ciclos de producción primaria no son espacialmente uniformes. Estos ciclos también presentan variabilidad temporal. Durante la primavera presentan un máximo y un segundo pico de menor intensidad en el otoño (Akselman, 1996; Williams et al., 2018). Este ciclo está asociado al proceso de formación estacional de la termoclina que se inicia en la primavera, alcanza su mayor desarrollo en el verano, disminuye en el otoño y desaparece en invierno (Rivas and Piola, 2002; Torres et al., 2018). El GSJ se caracteriza por un ciclo periódico con alternancia de homogenización y estratificación de la columna de agua y un ritmo bianual de producción fitoplanctónica. Durante la primavera, el asentamiento de la termoclina entre los 30 y 50 metros es el fenómeno hidrológico más significativo, en conjunto con la existencia de los sectores frontales costeros y de plataforma (Glorioso, 1987). El desarrollo fitoplanctónico en el GSJ muestra una secuencia estacional típica de regiones templadas. Los grupos taxonómicos preponderantes corresponden a las diatomeas y los dinoflagelados. En invierno las poblaciones se reducen y el grupo de diatomeas presenta una preponderancia neta sobre el de los dinoflagelados (por ejemplo, *Paralia sulcata*, *Thalassionema nitzschioides*, *Pleurosigma normanii*, los más representantes de los géneros *Thalassiosira* y *Coscinodiscus*, las especies de mayor importancia tanto por su densidad poblacional como por la amplitud de su distribución en el golfo). Durante el florecimiento primaveral se observan los valores más elevados del ciclo asociados a la diatomea *Thalassiosira auguste-lineata* y a los dinoflagelados *Alexandrium tamarense*, *Heterocapsa triquetra* y *Prorocentrum micans*. En verano decrece de manera abrupta la concentración de fitoplancton predominado por los dinoflagelados. Durante el otoño se produce un incremento de los niveles de fitoplancton, siendo esta vez las diatomeas quienes presentan los niveles de población más elevados (Cucchi Colleoni and Carreto, 2001; Fernández et al., 2005, 2007b; Carreto et al., 2007; Segura et al., 2021).

Por todas estas características, el Golfo San Jorge (GSJ) ha sido incluido en el Programa Nacional Pampa Azul como una de sus áreas estratégicas prioritarias de investigación dentro del marco de la Política de Ciencia y Tecnología de la Nación (Figura 3.6).

3.1 GOLFO SAN JORGE, PATAGONIA ARGENTINA




Figura 3.6: Áreas prioritarias que comprende la iniciativa Pampa Azul. Fuente: Sitio Web Pampa Azul <http://www.pampazul.gob.ar/areas-prioritarias>

Satélites para el estudio del color del mar

4.1. Satélites que miden el color del mar

El primer sensor que enfocó su atención en el océano y las aguas costeras fue el *Coastal Zone Color Scanner* (CZCS) a bordo del Nimbus 7. Se puso en órbita por la NASA en el año 1978 y la misión concluyó a finales de junio de 1986, superando las expectativas de tan sólo un año de vida útil. Con un ancho de barrido de 1.556 km, resolución espacial de 80 m y seis bandas que cubrían desde los 433 nm a los 12.500 nm del rango espectral. De las seis bandas espectrales, cuatro se usaron principalmente para el color del mar. Estas cuatro bandas se centraron en 443, 520, 550 y 670 nm con un ancho de banda de 20 nm. El objetivo de la misión era comprobar si la teledetección podría utilizarse para identificar y cuantificar material suspendido y disuelto en la superficie del océano. El sensor demostró con éxito que el color del mar podría usarse para cuantificar las concentraciones de clorofila y sedimentos en el océano, es decir, logró estimar la biomasa y la productividad del fitoplancton global. Debido a la potencia limitada, podría funcionar solo unas pocas horas por día. Proporcionó la justificación para la creación de SeaWiFS y MODIS.

En 1997 la NASA lanzó el Sea-Viewing Wide Field-of-View Sensor (SeaWiFS). El SeaWiFS era un espectrorradiómetro a bordo del satélite de órbita polar OrbView-2, con un ancho de barrido de 2800 km, una resolución espacial de 1.100 m y que operaba con ocho bandas en el rango espectral del visible a infrarrojo cercano (402 a 885 nm). El instrumento se inclinó ± 20 grados para minimizar el brillo solar. El sensor contribuyó significativamente en la comprensión de El Niño-Oscilación del Sur (ENSO, por sus siglas en inglés). SeaWiFS se puso en órbita durante el evento de El Niño que comenzó en 1997 (uno de los eventos más fuertes del siglo XX), por lo tanto, los años iniciales del registro están fuertemente sesgados por los efectos de ENSO. Los datos satelitales combinados con datos *in situ* del Pacífico ecuatorial ayudaron a los científicos a entender la dinámica de la Oscilación del Sur y sus impactos en los ecosistemas. Así como también se logró demostrar que los efectos de El Niño no están restringidos a las regiones de surgencia ecuatorial y costera (IOCCG, 2008). La misión finalizó en diciembre de 2010.

El siguiente sensor, considerado como el referente de mediciones en este trabajo, es el *Moderate Resolution Imaging Spectroradiometer* (MODIS) a bordo de los satélites Terra (EOS AM) y Aqua (EOS PM). El primer satélite que lleva a bordo este sensor fue el Terra, puesto en órbita por NASA en el año 1999. Posteriormente, en el 2002, se lanza el satélite Aqua. MODIS tiene un ancho de barrido de 2.330 km, con resoluciones espaciales de 250 m, 500 m y 1 km. Es un instrumento clave diseñado para observaciones terrestres, atmosféricas y oceánicas. La órbita de Terra (708 km) esta programada para que cruce la línea ecuatorial de norte a sur a las 10:30 am (hora local), mientras que Aqua (705 km) lo hace de sur a norte a las 01:30 pm (hora local) Ambos satélites visualizan toda la superficie de la Tierra entre uno y dos días (NASA, 1999). MODIS cuenta con 36 bandas espectrales que cubren un rango de 0.405 μm a 14.385 μm . Las primeras 19 bandas abarcan la región del espectro electromagnético ubicada entre los 0.405 nm y los 2.155 nm. Las bandas 1 a la 7 se utilizan para aplicaciones terrestres; las bandas 8 a la 16 para color del mar y las bandas 17 a la 19 para los estudios atmosféricos. Finalmente, las bandas 20 a la 36 cubren la porción del infrarrojo térmico (3,660nm al 14,385 nm) (NASA, 1999). Los productos MODIS están categorizados en cinco niveles, del 0 a 4, de acuerdo al grado de procesamiento que poseen.

- ❖ Nivel L0: datos sin tratamiento y en su resolución original.
- ❖ Nivel L1: datos de geolocalización, máscara de agua y tierra, elevación del terreno, ángulo cenital y azimutal del sol y el sensor. Éstos a su vez, se subdividen en:
 - Nivel L1A: datos de geolocalización, calibración y procesamiento. Contienen las radiancias (MOD01) de las 36 bandas y datos auxiliares del sensor tales como los coeficientes de calibración radiométrica, corrección geométrica y parámetros de georreferenciación (efemérides de la plataforma).
 - Nivel L1B: bandas del nivel 1A corregidas, calibradas y geolocalizadas (MOD02).
- ❖ Nivel L2: productos que contienen variables geofísicas que se derivan de corregir atmosféricamente y aplicar algoritmos bio-ópticos sobre los L1B. Por ejemplo, en este trabajo se empleará el producto *chlor_a* que es la concentración de clorofila-a en mg/m^3 .
 - Nivel L2G: producto con datos obtenidos durante un periodo fijo y agrupados en una cuadrícula de $10^\circ \times 10^\circ$ (denominada *tile*) con proyección sinusoidal.
- ❖ Nivel L3: productos de las variables geofísicas agrupadas en dos categorías:
 - *Mapped*: se denominan SMI (**Standard Mapped Image**). Cada producto esta mapeado sobre una cuadrícula de píxeles para un solo parámetro geofísico, con una proyección de tipo equidistante cilíndrica (Plate Carrée).
 - *Binned*: cada producto consta de datos acumulados de todos los productos L2, para el instrumento y la resolución especificados. Pueden corresponder a un período de tiempo (por ejemplo, diario, 8 días, mensual, etc.) y ser almacenados en una cuadrícula sinusoidal global de área aproximadamente igual.

- ❖ Nivel L4: son datos resultantes de modelos o de análisis de datos de nivel inferior (por ejemplo, variables derivadas de mediciones múltiples). La productividad primaria del océano es un buen ejemplo de un producto de L4 (Ocean Biology Processing Group (OBPG) NASA, 1996).

Todos los productos MODIS (niveles 0-4) están disponibles de forma gratuita en los portales de la NASA. Los productos que son útiles para el color del mar, tales como las reflectancias sensadas remotamente para las bandas 412 nm a 678 nm (Rrs 412 a Rrs 678), el espesor óptico del aerosol a 869 nm (AOT869), coeficiente de atenuación difusa a 490 nm (KD490), clorofila-a, temperatura superficial del mar (SST), entre otros, pueden obtenerse desde el sitio de Ocean Color de la NASA <https://oceancolor.gsfc.nasa.gov/>. En la actualidad, la misión continúa, superando ampliamente las expectativas de vida útil de los dos satélites.

En el mismo año que fue lanzado Aqua-MODIS, la Agencia Espacial Europea (ESA) puso en órbita el instrumento MERIS a bordo de la plataforma ENVISAT-1 (*Environmental Satellite*) cuya órbita era heliosincrónica de aproximadamente 790 km. El espectrorradiómetro de imágenes de resolución media (MERIS) operaba en el rango espectral del visible al infrarrojo cercano, configurado con 15 bandas espectrales de 412 a 900 nm. El instrumento escaneaba la superficie terrestre por el método *push broom*. La cámara de detectores (CCDs) realizaban un muestreo espacial en la dirección perpendicular al desplazamiento del satélite, mientras que el desplazamiento del propio satélite permitía el muestreo longitudinal. El campo de visión de MERIS era de 68,5° alrededor del nadir, lo que daba un ancho de barrido de 1.150 km cubierto por cinco módulos ópticos idénticos (cámaras) dispuestos en forma de abanico. La resolución espacial en el nadir era de 300m, productos de resolución completa, y se degradaba a 1,2 km por un promedio de 4 × 4 píxeles, productos de resolución reducida. La cobertura global se obtenía en tres días independientemente de las nubes y el brillo solar. MERIS medía la radiación solar reflejada desde la superficie de la Tierra y las nubes en las regiones espectrales de luz visible y del infrarrojo cercano. En consecuencia, la observación estaba nominalmente limitada al lado diurno de la Tierra. La misión principal de este sensor era medir el color del mar y las zonas costeras. Pero también fue capaz de estimar índices de vegetación, la radiación fotosintéticamente disponible, la presión superficial, el contenido total de la columna de vapor de agua de todas las superficies y la fracción de radiación fotosintéticamente activa absorbida. La misión ENVISAT finalizó en mayo del 2012 (https://www.esa.int/SPECIALS/Eduspace_ES/SEM306E3GXF_0.html).

En 2009, la Agencia India de Investigación Espacial (ISRO) lanzó con éxito el OCM-2 a bordo del satélite OCEANSAT-2. OCM-2 fue diseñado para proporcionar continuidad con el instrumento OCM del OCEANSAT-1 (1999-2010). Los principales objetivos de OceanSat-2 fueron estudiar los vientos superficiales y caracterización de la atmósfera más baja y la ionosfera, los estratos superficiales oceánicos, las concentraciones de clorofila, el monitoreo de las floraciones de fitoplancton y los sedimentos suspendidos en el agua. Este sensor tiene un ancho de barrido de 1.240 km y tiene dos modos de operación: cobertura de área local (LAC) con una resolución espacial de 360 m y transmisión en tiempo real, y cobertura de área global (GAC) cuya resolución espacial es de 4 km. Con respecto a la disponibilidad de los datos, los usuarios tienen acceso abierto desde portales como Open Data de la NASA (<https://www.earthdata.nasa.gov/eosdis/daacs/obdaac>), a productos nivel 1-B (correctos atmosféricamente), que pueden ser manipulados desde SeaDAS. Así también, los productos de

nivel 2 que consisten en concentración de clorofila-*a*, materia total suspendida (TSM), coeficientes de atenuación difusa (Kd-490 nm) y profundidad óptica de aerosol (AOD) a 865 nm y nivel 3 (promedios semanales y mensuales generados aun en prueba). OCEANSAT-2 es parte de una constelación virtual de satélites a cargo del Comité de Satélites de Observación de la Tierra (*The Committee on Earth Observation Satellites-CEOS*).

Era evidente que los avances en el estudio del color del mar se estaban dando de forma contundente. En el 2011, bajo el marco del *Joint Polar Satellite System (JPSS)*, un programa conjunto entre la Administración Nacional Oceánica y Atmosférica de los Estados Unidos (NOAA) y la NASA, se lanza el satélite Suomi National Polar Partnership (Suomi NPP) llevando bordo el sensor VIIRS (*Visible Infrared Imager Radiometer Suite*). VIIRS fue diseñado para extender y mejorar la serie de mediciones iniciadas por sus predecesores, el Radiómetro Avanzado de Muy Alta Resolución (AVHRR), MODIS y SeaWiFS. VIIRS es un radiómetro *Whiskbroom*, es decir que la imagen se obtiene gracias a la rotación de un espejo o prisma que mueve instantáneamente el punto de vista IFOV, perpendicularmente a la dirección de vuelo. Con 22 canales que van desde 0.412 μm a 12.01 μm , 5 de estos canales son bandas de alta resolución y 16 están diseñadas como bandas de resolución moderada. Una de estas bandas corresponde a la banda Día / Noche, es una banda pancromática sensible a las longitudes de onda visibles y cercanas al infrarrojo, y con esta banda VIIRS puede observar las luces nocturnas en la Tierra con una mejor resolución espacial y temporal comparada a sus predecesores. Las geometrías de órbita y escaneo de VIIRS proporcionan cobertura global cada dos días. VIIRS, del mismo modo que MODIS, es un sensor multidisciplinario que proporciona a los usuarios operacionales y de investigación datos que se usan para estimar las propiedades de nubes y aerosoles, el color del mar, la temperatura de la superficie terrestre y oceánica, el movimiento y la temperatura del hielo, los incendios y el albedo de la Tierra. Los climatólogos también usan datos VIIRS para mejorar nuestra comprensión del cambio climático global (NASA, 2011). Por otra parte, la resolución temporal de dos días es un requisito indispensable para la ecología oceánica y la investigación del carbono porque las concentraciones microscópicas de plantas marinas (fitoplancton) son muy variables, particularmente en las zonas costeras. La resolución VIIRS de 750 m en todo su escaneo proporciona una mejora sustancial para los estudios costeros y estuarinos, en comparación con las resoluciones de MODIS y SeaWiFS. VIIRS también tiene bandas infrarrojas de onda corta que se pueden usar para correcciones de aerosol de agua turbia (NASA, 2011). Las bandas visibles de MODIS tienen anchos característicos de 10 nm, en comparación con 20 nm o más de VIIRS. El propósito de estas bandas en común es el siguiente: la banda de 412 nm detecta la presencia de CDOM y sedimentos suspendidos; las bandas 443, 490, 510 y 555 nm determinan las concentraciones de clorofila. Para MODIS, la banda 13 a 667 nm, la banda 14 a 678 nm y la banda 15 a 748 nm permiten la determinación de la altura de la línea de fluorescencia (nflh). Para ambos instrumentos, las bandas de 865 nm se utilizan para la corrección de aerosoles atmosféricos (Martin, 2014).

Para continuar con la serie de misiones del programa europeo Copernicus, se desarrolló el Sentinel-3, probablemente la misión más completa de la familia de satélites Sentinel y la continuación del satélite de observación terrestre ENVISAT. Sentinel-3 carga cuatro instrumentos a bordo: el Radiómetro para la Temperatura Superficial del Mar y la Tierra (SLSTR), el Altímetro Radar de Apertura Sintética (SRAL), el Radiómetro de Microondas (MWR) y el sensor que nos interesa para este estudio, el Instrumento para el Color de la Tierra y los Océanos (OLCI). El primer Sentinel-3 se lanzó en 2016 (Sentinel-3A) y el

segundo (Sentinel-3B) en 2018. OLCI es la continuación de MERIS, pero con 21 canales espectrales en lugar de 15, un ancho de barrido de 300 km y resolución espacial de 300 m. Un solo Sentinel-3 puede obtener una cobertura global dentro de los cuatro días y los dos satélites en conjunto pueden hacerlo en dos días. Los mismos principios utilizados previamente para la calibración radiométrica y espectral MERIS se utilizan para Sentinel-3 / OLCI, lo que garantiza un alto nivel de precisión y estabilidad radiométrica.

Actualmente la NASA está desarrollando la misión PACE (*Plankton, Aerosols Clouds, and ocean Ecosystem*). Este nuevo satélite tiene como objetivo brindar continuidad a los datos MODIS y tendrá especial atención en la obtención de datos globales de color de mar, nubes, y aerosoles en la atmósfera (<https://pace.oceansciences.org/>). El sensor principal de PACE es el *Ocean Color Instrument* (OCI). OCI es un radiómetro de imágenes hiperespectrales cuya cobertura se extiende desde 320 a 890 nm en el espectro del ultravioleta (UV) al infrarrojo cercano (NIR), con un ancho de banda de 5 nm (Werdell and McClain, 2018). Esta característica permitirá la medición continua de la luz a una resolución de longitud de onda más fina que los sensores satelitales anteriores de la NASA, lo que ampliará los registros de datos de color del océano para estudios climáticos. También incluye 7 bandas discretas de 940 nm a 2260 nm en el espectro infrarrojo de onda corta (SWIR). Los datos de OCI serán digitalizados a 16 bits. PACE realizará una cobertura global en 2 días con una resolución de 1 km. La misión está programada para lanzarse en enero de 2024 (McClain et al., 2022).

A continuación se muestra el estado y planes a futuro para las misiones satelitales desarrolladas para el estudio del color del mar. La Tabla 4.1 es una actualización y adaptación de lo presentado en el reporte del IOCCG (IOCCG-2018:Rpt17). En cuanto a los tipos de sensores utilizados para estudios oceanográficos, la medición principal que realizan y los parámetros que se pueden derivar de ellos, se resumen en el esquema ilustrado en la Figura 4.1.

4.1 SATÉLITES QUE MIDEN EL COLOR DEL MAR

Status	Sensor	Plataforma	Agencia	Fecha de lanzamiento	Órbita	Resolución espacial	Bandas (400–1000 nm)	Tiempo de revisita (sobre el ecuador)
No operativo	SeaWiFS	SeaStar	NASA (USA)	1997-2010	Polar	4 y 1 km	8	2 días
	MERIS	Envisat	ESA/EUMESAT	2002-2012	Polar	1.2 y 0.3 km	15	2 días
Operativo	MODIS-Terra	Terra (EOS-AM1)	NASA (USA)	1999	Polar	1 km	9	1 día
	MODIS-Aqua	Aqua (EOS-PM1)	NASA (USA)	2000	Polar	1 km	9	1 día
	OCM-2	Oceansat-2	ISRO (India)	2009	Polar	300 m	8	2-3 días
	GOCI	KOMPSAT	KARI/KIOST (Corea del S.)	2010	Geoestac.	500 m	8	30 min
	VIIRS	Suomi NPP	NOAA (USA)	2011	Polar	750 m	7	1 día
	ABI	Himawari-8&9, GOES-R	JMA (Japón)/ NOAA-NASA (USA)	2014	Geoestac.	500 m–2 km	4	10 min
	OLCI	Sentinel 3A	ESA/EUMESAT	2016	Polar	300 m	21	1 día (3A y 3B)
	VIIRS	JPSS-1/NOAA-20	NOAA/NASA (USA)	2017	Polar	750 m	7	1 día
	SGLI-2	GCOM-C	JAXA (Japón)	2017	Polar	250 m	9	2-4 días
	OLCI	Sentinel 3B	ESA/EUMESAT	2018	Polar	300 m	21	1 día (3A y 3B)
	VIIRS	JPSS-2, JPSS-3	NOAA (USA)	2022	Polar	750m	7	1 día
En desarrollo	OCM-3	Oceansat-3	ISRO (India)	2022	Polar	300 m	13	2–3 días
	OLCI	Sentinel 3 C/D	ESA/EUMESAT	2023/2025	Polar	300 m	21	1 día (3A, 3B y 3CD)
	OCI	PACE	NASA (USA)	2024	Polar	1 km	Hiperspectral 5 nm (340–890 nm)	1 día
		SABIAMAR	CONAE (ARG)	2025	Polar	200-400-800 m	15	2 días

Tabla 4.1: Satélites de color del mar actualmente en órbita. Fuente: Groom et al. (2019).

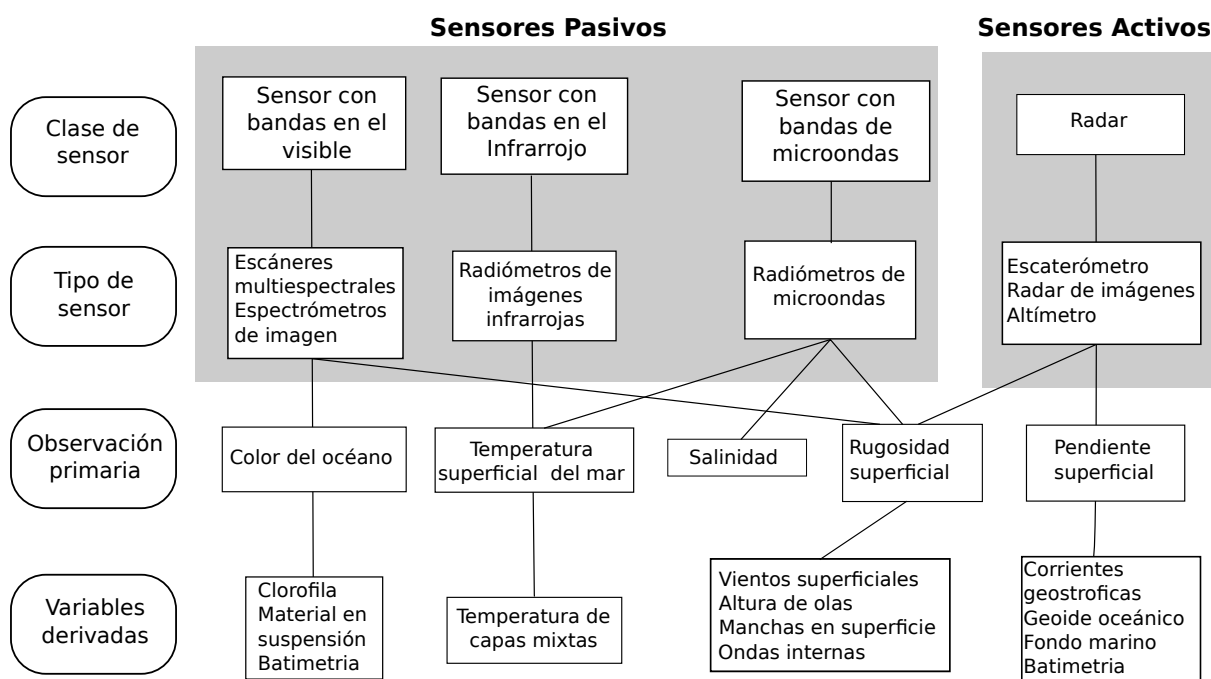


Figura 4.1: Esquema que ilustra los diferentes métodos de teleobservación y las clases de sensores utilizados en oceanografía satelital, junto con sus aplicaciones. Fuente: adaptado de Robinson (2004)

Una de las principales ideas de la presente tesis es la intercomparación de dos tipos de sensores: aquellos diseñados para estudios oceánicos y aquellos considerados tradicionales, es decir, destinados a aplicaciones terrestres. Se eligieron los satélites Aqua MODIS y Suomi NPP VIIRS para representar el primer tipo de sensores, y Landsat 8/OLI y Sentinel-2/MSI representarán el segundo tipo de sensores. Tanto OLI como MSI se escogieron por varios motivos. Si bien las misiones Landsat-8 como Sentinel-2 son misiones orientadas a estudios terrestres, debido a su calidad mejorada en comparación con las misiones más antiguas en términos de relación señal / ruido (SNR), han demostrado ser útiles para estimar la reflectancia del agua y de allí el mapeo de los parámetros de calidad del agua (Vanhellmont and Rud-

dick, 2016). La constelación virtual de L8 y S2 ofrece una buena resolución espacial sobre la zona de estudio, de 10 a 30 metros. Esta propiedad resulta muy útil para evaluar en detalle la dinámica de variables sobre las aguas costeras y continentales. Por otra parte, con cuatro canales visibles (dos en el azul y uno en cada una de las regiones verde y roja del espectro) y un rendimiento radiométrico adecuado, OLI y MSI son capaces de monitorear ciertos indicadores de calidad del agua (Pahlevan et al., 2018). Además de las cuatro bandas en el visible, MSI tiene tres bandas adicionales en el infrarrojo cercano (NIR) que permiten el uso de algoritmos para estimar la concentración de Cl-a (Pahlevan et al., 2018). Una característica que distingue a los sensores de color del mar respecto de los sensores tradicionales, es la corrección atmosférica que se aplica en la imagen para poder estimar variables sobre el medio acuático. MODIS y VIIRS entregan productos ya corregidos atmosféricamente como la Cl-a, el coeficiente de atenuación difusa (KD490), la radiación fotosintéticamente disponible (PAR), etc. Para el caso de Landsat 8 y Sentinel-2, es el usuario final quien debe llevar a cabo la corrección. En la actualidad, el rendimiento de algoritmos para la corrección atmosférica en las imágenes MSI y OLI se implementa través de los procesadores ACOLITE (Vanhellemont and Ruddick, 2016) y *SeaWiFS Data Analysis System* (SeaDAS) (Franz et al., 2014), permitiendo a los usuarios utilizar estas herramientas para procesar una imagen y luego estimar propiedades bio-ópticas del agua. Son numerosos los trabajos y estudios que corroboran de manera positiva el uso de Landsat 8 y Sentinel-2 para aplicaciones marinas: Franz et al. (2014), Vanhellmont and Ruddick (2015), Vanhellmont and Ruddick (2016), Pahlevan et al. (2017c), Pahlevan et al. (2017b); entre otros. A continuación, se desarrollará una breve reseña de estos satélites terrestres.

4.2. Satélites diseñados para ambientes terrestres: Landsat 8 y Sentinel-2

Puesto en órbita el 11 de febrero de 2013, Landsat 8 (anteriormente Misión de Continuidad de Datos de Landsat, LDCM) es el satélite Landsat más recientemente lanzado de una serie continua de satélites de teleobservación terrestres que comenzó en 1972. Sus productos estándar son gratuitos y están disponibles en Centro de Observación y Ciencia de los Recursos de la Tierra (EROS) través de la plataforma del Servicio Geológico de los Estados Unidos (USGS) (USGS, 2016). Los objetivos generales de la misión son proporcionar continuidad de datos junto a Landsat 4, 5 y 7, y ofrecer cobertura de la Tierra en periodos de 16 días; poniendo especial enfoque en la superficie terrestre y en las costas marinas. L8 orbita la Tierra a la misma distancia que lo hace MODIS (705 km), de manera sincronizada con el Sol y en un tiempo de 98.9 minutos completa la órbita alrededor de nuestro planeta (USGS, 2016). La carga útil del satélite consta de dos instrumentos:

- ❖ *Operational Land Imager* (OLI): sensor que recibe radiación del espectro visible, infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR). Tiene una resolución espacial de 15 m en pancromático y de 30 m en multiespectral.
- ❖ *Thermal Infrared Sensor* (TIRS): sensor que mide la temperatura de la superficie terrestre utilizando dos bandas del infrarrojo térmico (banda 10 y 11). Los datos producidos por este sensor tienen una resolución espacial de 100 m.

Ambos sensores escanean por líneas (*pushbroom*) con un ancho de barrido de 180 km y una resolu-

ción radiométrica de 12 bits. El L8 cuenta con 11 bandas, tres más que sus antecesores. Las bandas del sensor OLI, son similares al ETM+ del Landsat 7. Un cambio fue la banda 5 de OLI (0.845-0.855 μm), refinada para excluir los efectos por absorción de vapor de agua en 0.825 μm que correspondía al centro de banda del IRC del ETM+ (banda 4: 0,775–0,900 μm). OLI también tiene dos bandas nuevas además de las bandas heredadas de Landsat (1-5, 7 y Pan). La banda *Coastal/ Aerosol* (Banda 1: 0.435-0.451 μm), principalmente para las observaciones del color del mar y en el infrarrojo la nueva banda *Cirrus* (Banda 9: 1.36-1.38 μm) que ayuda a la detección de nubes compuestas por cristales de hielo (USGS (2016)). Además, cada producto incluye una banda de calidad que proporciona información detallada acerca de la presencia de nubes, agua y/o nieve. Por otra parte el sensor TIRS capta datos en dos bandas espectrales iguales a los sensores anteriores TM y ETM+ (Ariza and Posada, 2013). El tamaño aproximado de la escena es de 170 km de norte a sur por 183 km de este a oeste (106 km por 114 km).

A diferencia de MODIS, los productos de Landsat 8 están categorizados por la USGS como (Ariza and Posada, 2013):

- ❖ Nivel 0 (L0): corresponde a imágenes digitales con todas las transmisiones de datos y objetos sin formato, pero ordenados de manera secuencial por bandas multispectrales.
- ❖ Nivel 1 *Radiometric* (L1R): son datos de imágenes corregidas radiométricamente. Se obtienen a partir de datos L0 y son escalados a valores de radiancia espectral o reflectancia.
- ❖ Nivel *Sistematic* (L1G): en este nivel se encuentran los productos de datos del nivel L1R con correcciones geométricas sistemáticas aplicadas y en una proyección cartográfica. Están referenciados en WGS84 (*World Geodetic System* 1984).
- ❖ Nivel 1 Gt (L1Gt): son productos como L1G que utilizan la información de posición a bordo o efemérides.
- ❖ Nivel 1 *Terrain* (L1T): productos definidos a partir de los L1R con correcciones geométricas sistemáticas. Esta corrección se realiza en base a puntos de control terrestre (GCP) o información de posición integrada a bordo para luego generar una imagen proyectada y referenciada a WGS84. De modo auxiliar, los datos también cuentan con una corrección topográfica para considerar el desplazamiento del terreno debido al relieve.

Un producto L1 completo consta de 13 archivos, incluidas las imágenes correspondiente a las 11 bandas, un archivo de metadatos específico del producto y una imagen de la banda de evaluación de calidad (QA). Los archivos son todas imágenes de extensión GeoTIFF (*Geographical Tagged Image File Format*) de 16 bits. Landsat 8 genera productos en un sistema de coordenadas universal transversal de Mercator (UTM). Se usa por conveniencia como un método para proporcionar datos en imágenes digitales dentro de una cuadrícula con referencia a la Tierra que es compatible con otros conjuntos de datos con igual referencia. La principal ventaja de OLI respecto a las misiones de color del mar como MODIS, es su buena resolución espacial que proporciona la capacidad de mapear componentes ópticamente activos (OAC) en cuerpos de agua como lagos, estanques, ríos, humedales, y aguas cercanas a la costa. Sin embargo, el tiempo de revisita es de 16 días, por lo que no sería muy útil para estudiar en detalle

fenómenos que varían día a día. En relación a las bandas, la nueva banda costera / aerosol centrada en 443 nm permite la determinación de las propiedades ópticas inherentes (IOPs) en el agua (Pahlevan et al., 2017c).

Respecto a Sentinel-2, la Agencia Espacial Europea (ESA) en el marco del Programa Copernicus, fue la encargada de poner en órbita el par de satélites que conforman la constelación de Sentinel-2 (S2). El 23 de junio de 2015 tuvo lugar el lanzamiento de Sentinel-2A (S2A) y el 7 de marzo de 2017 el Sentinel-2B (S2B). Siendo ambos satélites operativos, tienen un tiempo de revisita de cinco días. Los dos satélites tiene a bordo el *MultiSpectral Imager* (MSI), una cámara óptica con 13 bandas espectrales que abarcan desde el azul hasta el infrarrojo de onda corta (SWIR) con una resolución espacial de 10 m (cuatro bandas), 20 m (seis bandas) y 60 m (tres bandas). El ancho de barrido es de 290 km. La altitud orbital promedio es de 786 km (ESA, 2015). Al igual que L8, la reducción del ancho de determinadas bandas espectrales en S2 limita la influencia de los componentes atmosféricos, incluido el vapor de agua. S2 cuenta con cinco bandas en el visible e infrarrojo (VNIR) que son útiles para la corrección atmosférica, como en L8, VIIRS y MODIS. Adicionalmente, la inclusión de una banda espectral en el azul (Banda 1: 443 nm), permite una corrección más precisa de aerosoles. Esta banda también se emplea para correcciones atmosféricas en MODIS. Asimismo, se adicionó una banda que permite la detección de cirros (Banda 10: 1375 nm) (ESA, 2015).

Los productos de S2 están disponibles en el *Open Access Hub* de Copernicus ESA y se organizan de la siguiente forma:

- ❖ Nivel 1B (S2 MSI L1B): radiancias a tope de atmósfera (TOA) en la geometría del sensor.
- ❖ Nivel 1C (S2 MSI L1C): reflectancias a tope de atmósfera (TOA). Están georreferenciadas en UTM dentro de una rejilla o cuadrícula. Cada zona de la cuadrícula se divide en 100 x 100 km *tiles* o teselas.
- ❖ Nivel 2 (S2 MSI L2A): reflectancias a nivel del suelo (BOA) y georreferenciadas en UTM.

4.3. La misión satelital SABIA-Mar

El objetivo principal de la Misión SABIA-Mar (Satélite de Aplicaciones Basadas en la Información Ambiental del Mar) es medir el color del mar de modo de proveer información y productos para el estudio de los ecosistemas marinos, el ciclo del carbono, la dinámica costera y los hábitats marinos (CONAE, 2016).



Figura 4.2: Insignia de la misión SABIA-Mar.

La misión SABIA-Mar se encuentra actualmente en fase de diseño y construcción en la Argentina, por parte de la CONAE junto a otras empresas y organismos del sistema científico-tecnológico nacional (VENG, INVAP, CNEA, UNLP, entre otras). El lanzamiento y puesta en órbita del satélite SABIA-Mar está previsto actualmente para el año 2025. Una vez que esté operativa la misión SABIA-Mar, proveerá información satelital regional de gran importancia, con formatos compatibles con las actuales misiones de color del mar. Estos datos podrán ser incorporados a los sistemas de monitoreo actuales, realimentando la sinergia entre los sistemas de monitoreo *in-situ* y remoto. Además de su valiosa importancia a nivel regional, SABIA-Mar contribuirá a la continuidad de las series temporales actuales en variables de interés para estudios climáticos globales (CONAE, 2016).

Con órbita polar helio-sincrónica y revisita de 2 días, el satélite SABIA-Mar operará en dos escenarios:

- ❖ Escenario Global: con una cobertura geográfica de 120° en latitud (entre -60° y +60° de latitud, con variaciones estacionales) y una resolución espacial de 800 m.
- ❖ Escenario Regional: enfocado en las costas de Sudamérica, comprendiendo desde la línea de la costa hasta los 650 km mar adentro, además de incluir a las aguas interiores de Latinoamérica. La resolución espacial prevista es de 200/400 m.

El satélite SABIA-Mar contará con instrumentos diseñados específicamente para mediciones en el mar que abarcan una serie de bandas espectrales en los rangos visible, infrarrojo cercano e infrarrojo de onda corta del espectro electromagnético. Llevará a bordo los siguientes instrumentos principales para el estudio del color del mar:

- ❖ Cámara VIS-NIR (rango visible-infrarrojo cercano): cámara óptica de 11 bandas que cubre el rango desde los 412nm hasta los 865nm con resolución espacial de 200m a nadir en el escenario regional y 800m en el escenario global, con un ancho de barrido de aproximadamente 1400km.
- ❖ Cámara NIR-SWIR (rango infrarrojo cercano-infrarrojo de onda corta): cámara óptica de 6 bandas que cubre el rango desde 750nm hasta 1640nm con resolución espacial de 400m a nadir en el escenario regional y un ancho de barrido de aproximadamente 1400km.

Así mismo, la carga útil del satélite incluye un sistema de colecta de datos (DCS) para recolectar datos generados por plataformas distribuidas en tierra; una cámara de alta sensibilidad (HSC) para adquirir imágenes de luces nocturnas y un receptor GNSS de demostración tecnológica

A continuación se muestra, en la tabla 4.2, las bandas espectrales de las cámaras de SABIA-Mar y sus principales aplicaciones científicas.

λ [nm]	Ancho de banda [nm]	Aplicaciones científicas
412	10	Materia orgánica disuelta coloreada y concentración de clorofila.
443	10	Absorción máxima de Cl-a.
490	10	Cl-a y otros pigmentos.
510	10	Cl-a, turbidez, mareas rojas y absorción del O ₃
555	10	Algoritmos bio-ópticos y turbidez.
620	10	Cianobacterias, ficocianina, sedimentos en suspensión y turbidez.
665	10	Cl-a, línea base de la señal de fluorescencia y turbidez.
680	7.5	Cl-a y pico de línea de fluorescencia (FLH).
710	10	FLH, detección de floraciones algales nocivas, Cl-a en aguas muy turbias, corrección atmosférica en aguas turbias.
750	10	Corrección atmosférica mar abierto.
765	10	Corrección atmosférica mar abierto, altitud de aerosoles, absorción molecular y altitud de nubes.
865	20	Corrección atmosférica mar abierto, referencia de vapor de agua sobre el océano y turbidez.
1044	20	Corrección atmosférica en aguas turbias y turbidez.
1240	20	Corrección atmosférica en aguas turbias y turbidez.
1610	60	Corrección atmosférica aguas en turbias.

Tabla 4.2: Bandas espectrales previstas para las cámaras de SABIA-Mar y sus aplicaciones científicas.

Para cumplir con sus objetivos, la Misión SABIA-Mar generará una serie de productos de interés, no sólo para la comunidad científica sino también para sectores productivos. Las variables bio-geo-físicas que producirá y distribuirá a la comunidad de usuarios son: la radiancia saliente de la superficie del mar, la concentración de clorofila-a (Cl-a), el coeficiente de atenuación difusa en 490nm, la turbidez y la radiación disponible para la fotosíntesis. A partir de esta información será posible generar productos de gran valor para la gestión de recursos pesqueros, manejo de emergencias, gestión de la calidad del agua, turismo, vigilancia del mar y estudios climáticos, entre otros (CONAE, 2016).

Validación con datos de campo

5.1. Introducción

El producto primario generado a partir de sensores remotos para observación del mar es la radiancia normalizada que emerge del agua $[L_W]_N$ a determinadas longitudes de onda. Otros productos tales como la concentración de Cl-*a* o las propiedades ópticas inherentes al mar, se derivan de $[L_W]_N$. Tanto la validación de $[L_W]_N$ como la de los valores derivados de esta radiancia (por ej. $\rho_w(\lambda)$) son un requisito y constituyen la base para verificar el grado de precisión de los productos (Bailey and Werdell, 2006).

En general, una validación se basa en comparaciones directas con observaciones puntuales *in situ* (Zibordi et al., 2006), estableciendo de esta forma un enlace entre mediciones satelitales y de campo. En cuanto a la verificación de algoritmos geofísicos, sean semianalíticos o empíricos, estos deben ser evaluados criteriosamente junto a un sistema de validación. Como resultado, se logra un análisis del error estadístico que indica el sesgo y la desviación estándar de los datos producidos a partir de estimaciones satelitales comparadas con un conjunto de mediciones independientes y confiables de la misma propiedad oceánica (Robinson, 2010). Para las misiones satelitales, contar con una base de datos de campo sólida representa una ventaja dado que los datos recopilados para la validación de productos de un cierto sensor generalmente pueden ser utilizados para validar los productos de otro sensor, es decir, existe una muy buena coherencia en los productos entre misiones (Mcclain et al., 2002).

A modo de evitar inconsistencias en la práctica, el Grupo de Procesamiento de Biología Oceánica de la NASA (*Ocean Biology Processing Group* OBPG) estableció en el año 2006 un protocolo de validación (Bailey and Werdell, 2006) utilizando un repositorio de datos oceanográficos y atmosféricos *in situ* (SeaBASS) y datos recolectados por el sensor SeaWiFS. Dentro del repositorio de libre acceso <https://seabass.gsfc.nasa.gov/>, se puede ingresar a una base de datos bio-ópticos NOMAD (*NASA Bio-Optical Marine Algorithm Dataset*) que reúne mediciones de campo distribuidos globalmente (<https://seabass.gsfc.nasa.gov/wiki/NOMAD>). La idea central del protocolo fue definir pasos con criterios orientados a:

- ❖ la calidad de datos de campo,
- ❖ la calidad de los píxeles,
- ❖ criterios temporales (ventana temporal),
- ❖ criterios espaciales (ventana de píxeles),
- ❖ flags y máscaras,
- ❖ estadísticos para la validación y el análisis de los resultados de la misma.

En la Sección 5.2 se explicará en detalle esta técnica desarrollada por Bailey and Werdell (2006), que es ampliamente adoptada por la comunidad para el desarrollo de algoritmos y la validación de datos de color de mar.

5.1.1. Objetivos del capítulo

El objetivo principal de este capítulo será evaluar el desempeño del algoritmo OC3 de MODIS y VIIRS en el Golfo San Jorge en relación a mediciones de campo correspondientes a dos campañas realizadas en el golfo.

Como objetivo secundario, se propone exponer una metodología en base al protocolo de validación de Bailey and Werdell (2006), adaptándola a la disponibilidad de datos y a los sensores propuestos. Se busca dejar plasmada una técnica que sirva no sólo para el área de estudio, sino también para otras zonas, para otros parámetros bio-ópticos y otros satélites con características similares a los utilizados aquí.

5.2. Descripción del protocolo de validación de Bailey y Werdell

Tal como se mencionó al inicio de este capítulo, la primer variable empleada por Bailey and Werdell (2006) en el desarrollo del protocolo fue la $[L_w]_N$. Por lo general, se utilizan las radiancias $L_w(443)_N$ y $L_w(555)_N$ porque son productos comunes para muchos instrumentos y poseen un papel fundamental en los algoritmos diseñados para estimar concentración de clorofila-*a*. Con SeaWIFS, se utilizaron las radiancias $L_w(412)_N$, $L_w(443)_N$, $L_w(490)_N$, $L_w(510)_N$ y $L_w(555)_N$.

En relación a la calidad de los datos *in-situ*, Bailey and Werdell (2006) controlaron previamente el set de datos a fin de eliminar las observaciones redundantes en un sitio determinado. Para la implementación del protocolo se usó el SeaBASS, cuyos datos recolectados en campo fueron testeados por el proyecto SIMBIOS (*Sensor Inter-comparison and Merger for Biological and Interdisciplinary Oceanic Studies*) (McClain et al., 2002). Esto permitió definir y documentar una serie de estrategias y requerimientos que aseguran coherencia y consistencia en los datos. Conjuntamente, se presentaron metodologías que establecen técnicas de muestreo con el fin de estandarizar las prácticas realizadas por quien hace las mediciones en campo, y por otro lado, caracterizar los errores inherentes a los instrumentos utilizados (Mueller et al., 2003; Hooker et al., 2002; Werdell and Bailey, 2005).

Respecto a los datos satelitales, el protocolo estableció ciertas pautas. Las imágenes SeaWiFS GAC (Cobertura de Área Global) con resolución de 1.1 km pero con píxeles espaciados en intervalos de 4.4 km no se consideraron, ya que las imágenes con bajas resoluciones espaciales o con datos submuestreados antes del análisis de validación agregan incertidumbre no cuantificable a los resultados. Luego, se planteó el cálculo del tamaño de muestra (N) mínimo necesario para la confiabilidad estadística mediante una fórmula que relaciona la varianza muestral, el valor crítico de la prueba t de Student y el requisito de precisión radiométrica para las bandas utilizadas. Por otra parte, en el protocolo se definió una ventana espacial de 5x5 píxeles de SeaWiFS centrada alrededor del sitio de medición en campo. Comúnmente, las ventanas son de 3x3, 5x5 o 7x7, y el criterio de selección dependerá de: el número de píxeles buenos y píxeles excluidos (N), de la resolución espacial del sensor utilizado, de la variable que se va evaluar y de las características ambientales de la zona donde esta ubicada la estación de muestreo. Además, se descartaron los píxeles no válidos, enmascarados por los indicadores de calidad (flags). Si se conservan más de la mitad de los píxeles de la ventana y su variabilidad relativa está dentro de un umbral estadístico predefinido (el protocolo utilizó un CV no mayor a 0.15), se procede a calcular el promedio de los píxeles válidos y dicho valor se lo considera adecuado para la comparación con la observación *in situ*.

En cuanto al criterio temporal, dado que el paso del satélite muchas veces no coincide con el momento en que se está realizando la medición *in situ*, es necesario fijar una ventana temporal a la hora de seleccionar la imagen. En el protocolo se fijó una ventana de ± 3 horas entre la pasada del satélite y el momento en que se recolectó el dato de campo.

Por último, la validación se completó con la evaluación del dato satelital en función del dato medido en campo. Esto se llevó a cabo por medio de métricas estadísticas y modelos de regresión lineal. Trabajos como los de Dogliotti (2007) en la Plataforma Continental Patagónica (PCP), Garcia et al. (2005) en el Atlántico Sudoccidental y Océano Austral, Werdell et al. (2009), en la Bahía Chesapeake (USA), Mélin et al. (2007) en el Mar Adriático y Fleming and Korb (2004) en el mar de Scotia; realizaron validaciones siguiendo este protocolo (Bailey and Werdell, 2006), para evaluar el desempeño de algoritmos que estiman Cl-a con imágenes SeaWiFS y MODIS.

5.3. Datos *in situ*

5.3.1. Campañas oceanográficas en el marco de la iniciativa Pampa Azul

Las campañas que se eligieron para la validación corresponden a:

- Enero 2014: a bordo del buque canadiense Coriolis II (ISMER/UQAM), la campaña comenzó en enero de 2014 y finalizó en marzo del mismo año. Consistió en el desarrollo de un estudio integral del Golfo San Jorge (GSJ) tanto en materia oceanográfica como de geología marina. Respecto a la toma de muestras, se contemplaron ocho parámetros esenciales para comprender la columna de agua del golfo y el Agujero Azul (localizada a unos 500 km al este del golfo entre los paralelos 45°S y 47°S y los meridianos 60°O y 61°O) y su posterior estudio: clorofila, fitoplancton, luz, salinidad, temperatura, PH, oxígeno y turbidez.
- Noviembre de 2016: se inició el 7 de noviembre de 2016 a bordo del buque oceanográfico ARA 'Puerto Deseado' y duró 20 días. La época del año elegida para efectuar esta campaña fue primavera, dado que en esta estación se dan los picos de productividad primaria, en coincidencia con la formación de los principales frentes oceanográficos, en particular al sur y al norte del GSJ (Glembocki et al., 2015; Andreo, 2015).

En la campaña de Coriolis II todos los datos de superficie se tomaron hasta una profundidad de 2 metros. En cambio, en la campaña de 2016-A.R.A. "Puerto Deseado" se recolectaron muestras de agua a profundidades de entre 3 a 8 metros con botellas oceanográficas Niskin y muestras de agua superficial con balde. En ambos casos, a bordo del barco se filtraron muestras de 500 ml de agua de mar para análisis de Cl-a a través de filtros GF/F y se almacenaron a -80°C. En el laboratorio del CENPAT (Centro Nacional Patagónico), la Cl-a se extrajo en acetona al 90% y se midió mediante fluorometría según Strickland and Parsons (1972) También se determinaron absorción de material particulado, sólidos suspendidos totales (SST) y turbidez. Respecto a las prácticas de laboratorio, Bailey and Werdell (2006) señalan que la determinación completa del error de medición inherente del instrumento de campo es esencial para cualquier esfuerzo de validación. Idealmente, los instrumentos y técnicas de medición también deben estar correctamente calibrados y desplegados de manera consistente con protocolos bien definidos. En este caso, fue utilizado un Fluorómetro Turner 111, un instrumento de laboratorio calibrado con estándar de Cl-a pura de cianobacteria *Anacystis nidulans* (Sigma C-6144). Las metodologías de muestreo en las campañas se ajustan al propuesto en *Ocean Optics Protocols For Satellite Ocean Color Sensor Validation* de la NASA (Mueller et al., 2003).

A partir de los datos procesados del 2014, se han realizado diversos trabajos. Flores Melo et al. (2018) y Carbajal et al. (2018) caracterizaron la física, la dinámica de los nutrientes y la biología del frente sur en el Golfo de San Jorge (GSJ); Williams et al. (2018) estudiaron las propiedades bio-ópticas de esta región (absorción por fitoplancton (a_{phy}), por partículas no algales (a_{NAP}), por materia orgánica disuelta coloreada (a_{CDOM})) para evaluar la calidad de los productos satelitales del color del mar, particularmente la calidad de las estimaciones de Cl-a. Con los datos de ambas campañas (verano austral 2014 y la primavera 2016), Torres et al. (2018) analizaron la distribución de macronutrientes y su relación con la estratificación y la biomasa productora primaria en la columna de agua.

En la Figura 5.1 se representa la ubicación geográfica del total de las estaciones de muestreo correspondientes para ambas campañas y aquellas estaciones que sirvieron para la comparación con los datos satelitales. Las fechas y coordenadas de los muestreos que se utilizaron para la validación, se detallan en las Tablas 5.1 y 5.2. Asimismo, se muestran cuáles fueron los satélites que pasaron en tales fechas, para indicar la fuente de los datos explicados en la siguiente sección.

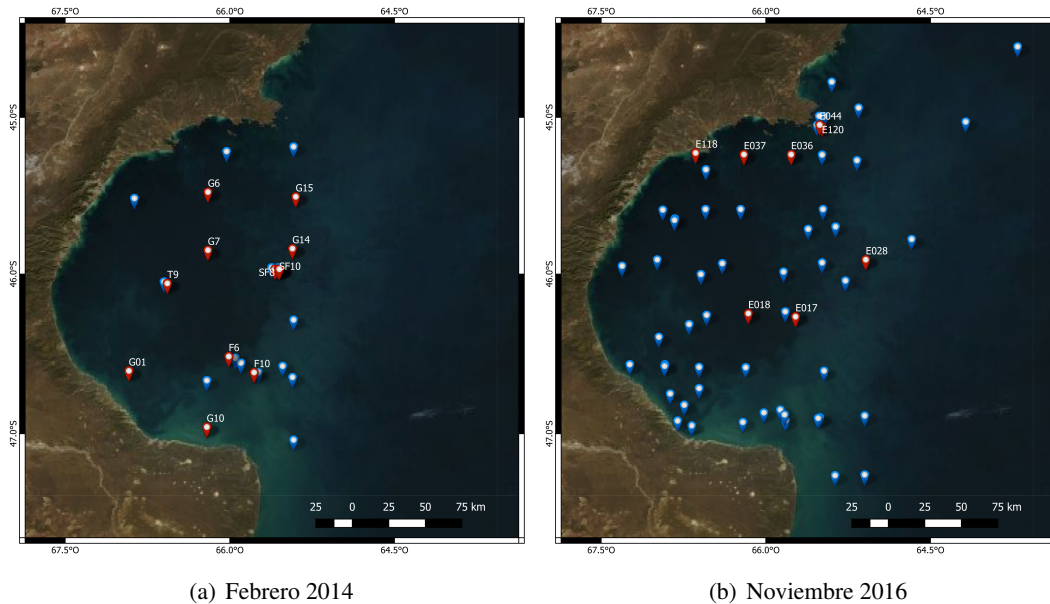


Figura 5.1: Estaciones de medición de las campañas en el GSJ en el marco Pampa Azul. Las marcas en azul indican el total de estaciones para ambas campañas y las marcas en rojo aquellas estaciones donde se lograron realizar las comparaciones con los datos satelitales (*match-ups*). Ver coordenadas en Tablas 5.1 y 5.2.

Fechas Campaña 2014	Estación	Lat (dec)	Long (dec)	Hora UTC	Sensores	
					MODIS (pasada hr UTC)	VIIRS (pasada hr UTC)
03/02/2014	T9	-46.04	-66.57	17:10	18:05	17:48
07/02/2014	SF8	-45.95	-65.59	15:37	19:20	18:18
08/02/2014	SF12	-45.95	-65.56	14:17	18:25	17:54
	F6	-46.5	-66.01	16:36		
	SF10	-45.95	-65.55	20:13		
	F10	-46.6	-65.78	21:40		
12/02/2014	G14	-45.82	-65.43	15:06	18:00	18:24
	G15	-45.49	-65.4	20:43		
13/02/2014	G6	-45.46	-66.2	13:43	18:45	18:00
	G7	-45.83	-66.2	17:53		
14/02/2014	G10	-46.94	-66.21	13:00	17:50	17:42
	G01	-46.59	-66.92	18:43		

Tabla 5.1: Fechas y coordenadas geográficas de las estaciones correspondientes a la Campaña 2014 donde se lograron los *match-ups* y la respectiva hora de pasada del satélite utilizado para la comparación.

Fechas Campaña 2016	Estación	Lat (dec)	Long (dec)	Hora UTC	Sensores	
					MODIS (pasada hr UTC)	VIIRS (pasada hr UTC)
17/11/2016	E017	-46.21	-65.82	16:15	18:45	
	E018	-45.95	-65.59	20:00		
19/11/2016	E028	-45.89	-65.09	16:23	18:30	
20/11/2016	E036	-45.22	-65.77	13:00	19:15	18:42
	E037	-45.22	-66.20	18:10		
22/11/2016	E118	-45.21	-66.46	13:15	19:00	18:06
	E120	-45.04	-65.50	15:00		
	E044	-45.03	-65.51	15:45		

Tabla 5.2: Fechas y coordenadas geográficas de las estaciones correspondientes a la Campaña 2016 donde se lograron los *match-ups* y la respectiva hora de pasada del satélite utilizado para la comparación.

5.4. Datos satelitales

En este trabajo se utilizaron datos satelitales provenientes de los sensores MODIS del satélite Aqua y VIIRS de SUOMI-NPP. El criterio de selección de la imágenes se basó en las fechas coincidentes con las campañas, como se observa en las Tablas 5.1 y 5.2 y en la calidad de la imagen.

Las imágenes MODIS y VIIRS se descargaron del portal de *Ocean Color*¹ de la NASA como productos de Nivel-2 ya generados a partir de productos de Nivel-1A o Nivel-1B, en formato NetCDF. De los diferentes productos disponibles, sólo se descargaron los del color del mar (OC). Cada escena cubre toda la zona del golfo, es un producto del tipo LAC: cobertura de área local (resolución completa). Por ejemplo, para el día 08/02/2014, se descargaron las imágenes A2014039182500.L2_LAC_OC.nc de MODIS y V2014039175400.L2_SNPP_OC.nc de VIIRS. Una vez abiertas en el programa SeaDAS (*SeaWiFS Data Analysis System*), se re proyectaron a UTM/WGS84. SeaDAS es un programa de análisis de imágenes desarrollado por el Grupo de Procesamiento de Biología Oceánica (OBPG) de la NASA para el procesamiento, visualización y control de calidad de todos los productos de datos de múltiples satélites como SeaWiFS, Aqua MODIS, SNPP VIIRS y actualmente incorporó la posibilidad de procesar imágenes Landsat 8 (Franz et al., 2014) y Sentinel-2 (Pahlevan et al., 2018). Es de libre uso y descarga (Fu et al., 1996), (Franz et al., 2005).

5.4.1. Algoritmo bio-óptico para los sensores

Si bien se han desarrollado diferentes tipos de algoritmos para la estimación de Cl-a a partir de datos satelitales, en este capítulo se trabajó con el OCx, un algoritmo polinomial de grado cuatro que relaciona las bandas azul y verde, donde el valor x expresa la cantidad de bandas empleadas. Fue desarrollado por John O'Reilly originalmente para SeaWiFS y luego adaptado a MODIS (O'Reilly et al., 1998). Dicho algoritmo estándar se utiliza en trabajos como los de Romero et al. (2006), Dogliotti et al. (2014) y Andreo (2015) para estimaciones satelitales de Cl-a en la Plataforma Continental Argentina. Con este algoritmo, la concentración de clorofila-a se puede calcular según la ecuación descripta en 2.7 del Capítulo 2.

En la Tabla 5.3 se muestran las longitudes de onda y los coeficientes utilizados para los sensores, en particular aquellos utilizados en este trabajo. Los coeficientes son resultado del ajuste del algoritmo a

¹<https://oceancolor.gsfc.nasa.gov/>

partir de datos marinos bio-ópticos de la NASA².

Algoritmo	Sensor	λ_{azul}	λ_{verde}	a_0	a_1	a_2	a_3	a_4
OC3S	SeaWiFS	443>490	555	0.2515	-2.3798	1.5823	-0.6372	-0.5692
OC4	SeaWiFS	443>490>510	555	0.3272	-2.9940	2.7218	-1.2259	-0.5683
OC2M	MODIS	488	547	0.2500	-2.4752	1.4061	-2.8233	0.5405
OC3M	MODIS	443>488	547	0.2424	-2.7423	1.8017	0.0015	-1.2280
OC3V	VIIRS	443>486	550	0.2228	-2.4683	1.5867	-0.4275	-0.7768
OC2	OLI/Landsat 8	482	561	0.1977	-1.8117	1.9743	-2.5635	-0.7218
OC3	OLI/Landsat 8	443>482	561	0.2412	-2.0546	1.1776	-0.5538	-0.4570

Tabla 5.3: Diferentes algoritmos empíricos operativos por la NASA para estimar concentración de Cl-a. Fuente: <https://oceancolor.gsfc.nasa.gov/>.

5.5. Metodología de comparación

5.5.1. Definición del protocolo

Para realizar una comparación entre las mediciones de campo con estimaciones satelitales se necesita primero establecer un criterio para determinar si dichos datos son comparables. En la presente sección se explica la definición de un protocolo utilizando como referencia el de Bailey y Werdell. En la Figura 5.2 se puede ver el diagrama de flujo correspondiente.

Además de los valores de Cl-a *in situ* que fueron facilitados de las campañas de campo, la información complementaria como requisito previo a la validación incluye fecha, hora, latitud y longitud de las estaciones de medición. Para futuros trabajos, resulta útil considerar también la velocidad y dirección del viento, altura de las olas, descripción de nubosidad, presión atmosférica, concentración de ozono y la profundidad óptica de aerosoles (Bailey and Werdell, 2006). Además, es aconsejable trabajar con aquellas muestras recolectadas entre las 9 a.m y las 4 p.m (hora local) para garantizar una iluminación solar adecuada.

En cuanto al manejo de los datos satelitales, se consideraron ciertos aspectos. Se debe tener presente las escalas de los fenómenos geofísicos observados, en especial aquellos de escala local que pueden incidir en las mediciones de campo. Las resoluciones espaciales de la mayoría de los satélites de color del mar, incluso la futura misión SABIA-Mar, se encuentran en el rango de los 200 m a 1.1 km (a nadir). Por consiguiente, los datos de campo deben ser recopilados idealmente en regiones donde la variabilidad espacial del parámetro geofísico estudiado sea relativamente estable para un área mayor que la resolución espacial del instrumento satelital. De esta forma se minimizan posibles efectos generados por la variabilidad a pequeña escala de los mediciones de campo, dado que el sensor remoto promedia la variabilidad dentro de cada píxel (Bailey and Werdell, 2006)).

²NOMAD:NASA bio-Optical Marine Algorithm Dataset

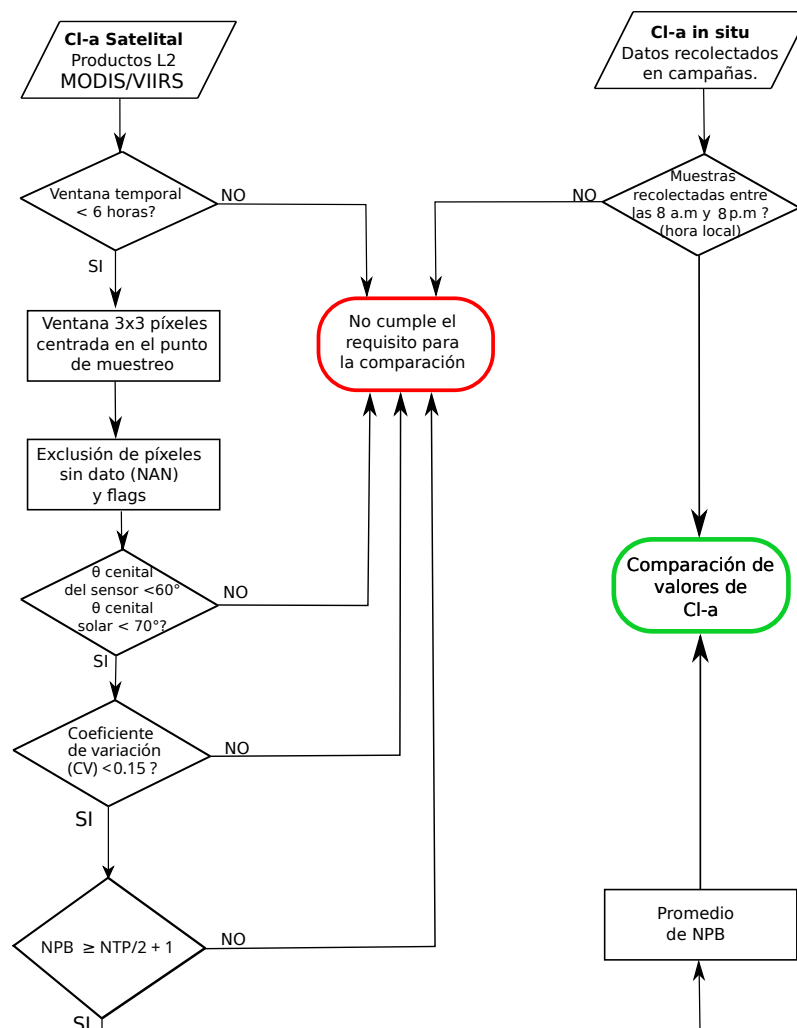


Figura 5.2: Diagrama de flujo del proceso de comparación de valores de Cl-a, basado en el protocolo propuesto por el Grupo de Procesamiento de Biología Oceánica de la NASA (OBPG, *Ocean Biology Processing Group's*) en Bailey and Werdell (2006). NTP: N° total de píxeles en la ventana, NPB: N° de píxeles buenos.

Para la selección de imágenes, se tuvo en cuenta una ventana temporal que aquí se definió como una proporción entre una escala corta para reducir los efectos de la variabilidad temporal en los datos *in situ* y una escala grande como para permitir mayor posibilidad de una coincidencia. Se asume que la iluminación es adecuada y las condiciones atmosféricas son razonablemente estables durante este período (Bailey and Werdell, 2006). Para ambas campañas, se descargaron aquellas imágenes que coincidían con el día de las mediciones, estableciéndose una ventana de ± 6 horas. Asimismo, se aplicó un criterio (filtro) temporal a los puntos de muestreo *in situ*. Se escogieron los puntos que se encontraban dentro de un rango horario de 8:00 hs a 20:00 hs., teniendo en cuenta la presencia de luz solar en el momento del año en que fueron realizadas las campañas (verano y primavera).

En aquellas imágenes que cumplieron con la condición temporal, se ubicaron geográficamente las posiciones de las respectivas estaciones de muestreo para cada campaña. Una vez centrado el píxel con la estación, se genera una ventana de píxeles que rodea al punto de muestreo. Aquí se delimita el criterio espacial. En este trabajo se utilizó una ventana de 3x3 píxeles considerando que en imágenes MODIS

Aqua/Terra el tamaño de un píxel es de 1km y en imágenes VIIRS es de 750m. Es importante tener en cuenta que el protocolo de Bailey and Werdell (2006) establece, desde un enfoque multi-sensor, una ventana de 3x3 píxeles y que el aumento del tamaño de esta ventana implicaría posibles errores causados por la variabilidad espacial del parámetro estudiado. Se excluyeron los píxeles de suelo y nubes, activando los flags LAND y CLDICE. Estos indicadores de calidad de productos de *Ocean Color* de la NASA (ver Tabla 5.4), se deben tener en cuenta para evitar el uso de píxeles que pueden generar imprecisiones de las estimaciones satelitales. Se controló la dispersión de los valores de los píxeles en cada ventana por medio del desvío estándar (σ), los valores mínimos y máximos, y el coeficiente de variación (CV) definido como el cociente entre el desvio estándar y la media. De este modo, se evalúa la homogeneidad en la región de validación. Las regiones con variaciones extremas entre los píxeles representadas por un CV mayor a 0.15, se excluyen. Estas indicarían la presencia de anomalías (por ejemplo: bordes de nubes) haciendo que los resultados de validación no sean precisos (IOCCG, 2019). Adicionalmente, se excluyen píxeles con ángulos de visión y cenital solar que exceden los 60° y 75°, respectivamente. Dentro de la ventana, la cantidad de píxeles útiles para la validación (NPB: número de píxeles buenos) debe cumplir con la condición mínima de ser mayor o igual a $NTP/2 + 1$ (NTP: número total de píxeles en la ventana). Una vez determinados los píxeles de buena calidad (NPB), se calcula el promedio entre ellos y este valor es el que se utiliza para la comparación con los valores *in situ*.

Flags	Descripción
ATMFAIL	Falla en la corrección atmosférica
LAND	Máscara para suelo
PRODWARN	Advertencia por error de uno o más algoritmos
HIGLINT	Sunglint (destello por reflexión especular)
HILT	Radiación saturada
HISATZEN	Ángulo cenital satelital, valor elevado
COASTZ	Aguas someras (< 30 m) – costa
STRAYLIGHT	Radiación saturada principalmente en píxeles ubicados en los bordes de las nubes
CLDICE	Máscara para nubes o hielo
COCCOLITH	Detección de Cocolitofóridos
TURBIDW	Determinación de agua turbia
HISOLZEN	Ángulo cenital solar, valor elevado
LOWLW	Baja radiancia en los 550 nm (posiblemente por sombra de nubes)
CHLFAIL	Falla con el algoritmo de clorofila
ABSAER	Determinación de aerosoles absorbentes
CHLWARN	Clorofila fuera de límites (<0.01 o >100 mg m ⁻³)
PRODFAIL	Fallas generadas por uno o más productos derivados de algoritmos.

Tabla 5.4: Flags que se utilizan para indicar la calidad de los productos Ocean Color de nivel 2. Fuente: <https://oceancolor.gsfc.nasa.gov/atbd/ocl2flags/>.

5.5.2. Análisis estadístico

Concluida esta etapa, el siguiente paso es analizar los resultados de las comparaciones. Para ello, se evaluó el grado de relación entre las estimaciones satelitales y las mediciones de campo con gráficos de dispersión y modelos de regresión. Al igual que en trabajos de referencia (Dogliotti, 2007; Bailey and

Werdell, 2006), se utilizó un modelo II de regresión a la hora de analizar la interacción de los datos. De allí, se obtuvieron las pendientes y el coeficiente de determinación (r^2). La elección de este modelo se debe a que funciona adecuadamente para evaluar la correlación entre dos variables que poseen algún error asociado a sus mediciones. El error representa la desviación de cualquier tipo debido a un proceso aleatorio, no solo un error de medición. La ventaja consiste en que del modelo explica la incertidumbre tanto en x como en y al minimizar los errores en ambas direcciones. Para la estimación de la pendiente de la recta que mejor se aproxima al conjunto de datos, el modelo I utiliza el método de mínimos cuadrados ordinarios OLS (por sus siglas en inglés), donde los valores de la pendiente y del intervalo de confianza cambian proporcionalmente a las unidades de medida. Por ejemplo, al multiplicar todos los valores de y por diez, se produce una estimación de la pendiente diez veces mayor, mientras que al multiplicar todos los valores de x por diez, se obtiene una estimación de la pendiente diez veces menor. La pendiente está sesgada por la presencia del error de medición en la variable explicativa. Por ello, OLS debe usarse solo cuando x se fija por experimento o es una variable aleatoria medida sin error, o con un pequeño error en comparación con y . No es el caso de los métodos disponibles en el modelo II, donde la pendiente estimada del eje principal no se escala proporcionalmente a las unidades de medida (Legendre and Legendre, 2012). Previo a este análisis estadístico, los datos de clorofila fueron transformados logarítmicamente. Esta decisión se basa en que muchas variables geofísicas marinas son tradicionalmente transformadas logarítmicamente antes del cálculo de las métricas de error ya que la incertidumbre y la varianza son proporcionales a la concentración, y los valores de los datos frecuentemente abarcan múltiples órdenes de magnitud (Seegers et al., 2018). El resultado final de esta transformación es la conversión de la métrica del espacio lineal al multiplicativo. En términos generales, el uso de métricas lineales o multiplicativas depende de las características del modelo, la variable de interés y sus incertidumbres. Aquellos con incertidumbres constantes (homocedasticidad), como la temperatura del agua, se evalúan adecuadamente con métricas lineales. Aquellos cuya incertidumbre varía proporcionalmente con el valor de los datos, como la clorofila, se evalúan de mejor manera con métricas multiplicativas. Las métricas lineales tienen las mismas unidades que la variable examinada, mientras que las métricas multiplicativas son adimensionales (Seegers et al., 2018).

Para la estimación de errores, se trabajó con el cociente y la diferencia entre valores satelitales y de campo, el promedio, mediana y el rango semi-intercuartil de cada cociente. Para cada par comparativo (*in situ*-satélite) se calculó el error relativo (ER) y su error cuadrático medio (RMSE), ambas métricas con valores logarítmicos. A continuación se detallan las expresiones de las cantidades utilizadas:

1) Rango semi-intercuartil, donde Q_1 es el percentil 25 y Q_3 el percentil 75:

$$SIQR = \frac{Q_3 - Q_1}{2} \quad (5.1)$$

2) Error medio (log):

$$EM_{log} = \frac{1}{n} \sum_{i=1}^n (\log Cla_{sat} - \log Cla_{insitu}) \quad (5.2)$$

3) Error cuadrático medio (log):

$$RMSE_{log} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\log Cla_{sat} - \log Cla_{insitu})^2} \quad (5.3)$$

En trabajos recientes (Seegers et al., 2018), se advierte el hecho de que no siempre la naturaleza de los datos oceánicos a validar es gaussiana, por lo que ocasionalmente estas medidas usuales no brindan información del todo precisa sino se las complementa con métricas sin tanta sensibilidad a los valores atípicos y a las distribuciones no gaussianas (Willmott and Matsuura, 2005). Tanto el RMSE como el r^2 y la pendiente son métricas útiles para las actividades de validación, pero sólo con una interpretación prudente y en combinación con métricas de error adicionales recién mencionadas (Seegers et al., 2018). Por otra parte, las métricas basadas en desviaciones simples, como el sesgo (Bias) y el error absoluto medio (MAE), a menudo proporcionan datos más sólidos y sencillos para evaluar algoritmos de color del mar con distribuciones y valores atípicos no gaussianos (Seegers et al., 2018). Es por ello que en este trabajo introduciremos el cálculo de los siguiente estadísticos:


$$Bias = 10 \left(\frac{\sum_{i=1}^n \log Cla_{sat} - \log Cla_{insitu}}{n} \right) \quad (5.4)$$

$$MAE = 10 \left(\frac{\sum_{i=1}^n |\log Cla_{sat} - \log Cla_{insitu}|}{n} \right) \quad (5.5)$$

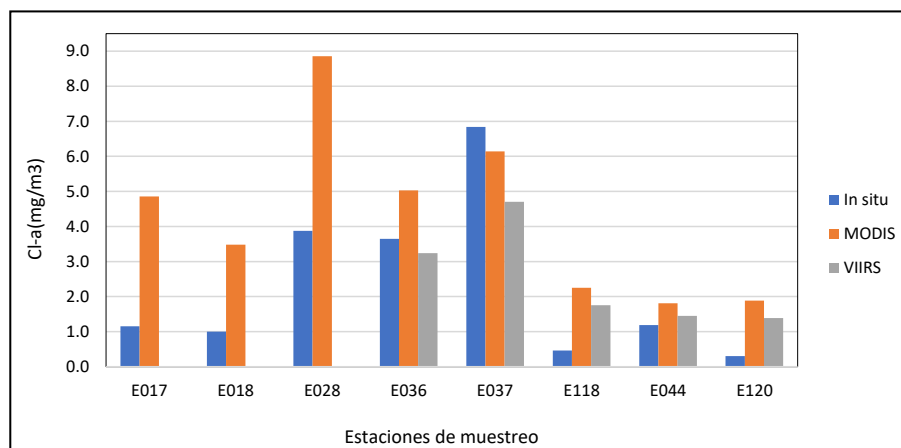
Es importante aclarar que en las dos campañas el número de coincidencias o *matchups* no fue el adecuado para desarrollar buenas estadísticas. Como puede observarse en la Figura 5.1, de las 33 estaciones de medición correspondientes a la campaña del 2014, 12 de ellas se ajustaron a los requisitos establecidos por el protocolo y, además, las imágenes satelitales estaban libres de nubes para poder realizar comparaciones con VIIRS. Para el análisis con MODIS, se utilizaron 11 de las 12 estaciones, debido a que una de las imágenes presentaba importante nubosidad (Tabla 5.1). Para la campaña siguiente, del total de 71 estaciones, 8 cumplían con los criterios y no presentaban nubes para MODIS. Respecto a VIIRS, sólo se logró la comparación con 5 estaciones de las 8, debido a la baja calidad de las imágenes satelitales y presencia de nubes (Tabla 5.2). El número de observaciones (n) utilizadas en las comparaciones puede influir en la calidad de las estimaciones. Cuanto menor es n , menor será la capacidad para calcular el error estándar del modelo. Como consecuencia, la exactitud de los coeficientes de regresión estimados se reduce.

5.6. Resultados

En la Figura 5.3 se muestran comparativamente el valor de Cl-a obtenido *in situ* y de las imágenes satelitales para cada estación de muestreo. De estos resultados se puede apreciar que los valores de concentración de Cl-a medidos en la campaña del 2014, oscilaron entre 0.28 y 2.69 mg.m⁻³. Y los valores derivados de las mediciones satelitales, variaron entre 0.47 y 4.61 mg.m⁻³. En la campaña del 2016, los valores oscilaron entre 0.31 y 6.83 mg.m⁻³, mientras que los respectivos a las estimaciones satelitales, entre 1.38 y 8.85 mg.m⁻³. En general, el algoritmo satelital tendió a subestimar los valores de Cl-a en la campaña del 2014 y a sobrestimar en el 2016. Esto se evidenció con los valores menores a la unidad de los cocientes $Cl_{a,sat}/Cl_{a,insitu}$ en el primer caso y valores mayores a la unidad en el segundo caso.



(a) Febrero 2014



(b) Noviembre 2016

Figura 5.3: Comparación entre valores estimados por satélites MODIS y VIIRS y las mediciones en cada estación de las campañas del año 2014 y 2016. (ver estaciones en Figura 5.1)

Asimismo, para cada fecha donde se realizó la comparación, se generaron mapas de Cl-a estimada satelitalmente (Figuras 5.4, 5.5 y 5.6). Todos los mapas se elaboraron en SeaDAS a partir del producto L2 descargado previamente desde el portal de Ocean Color (Sección 5.4).

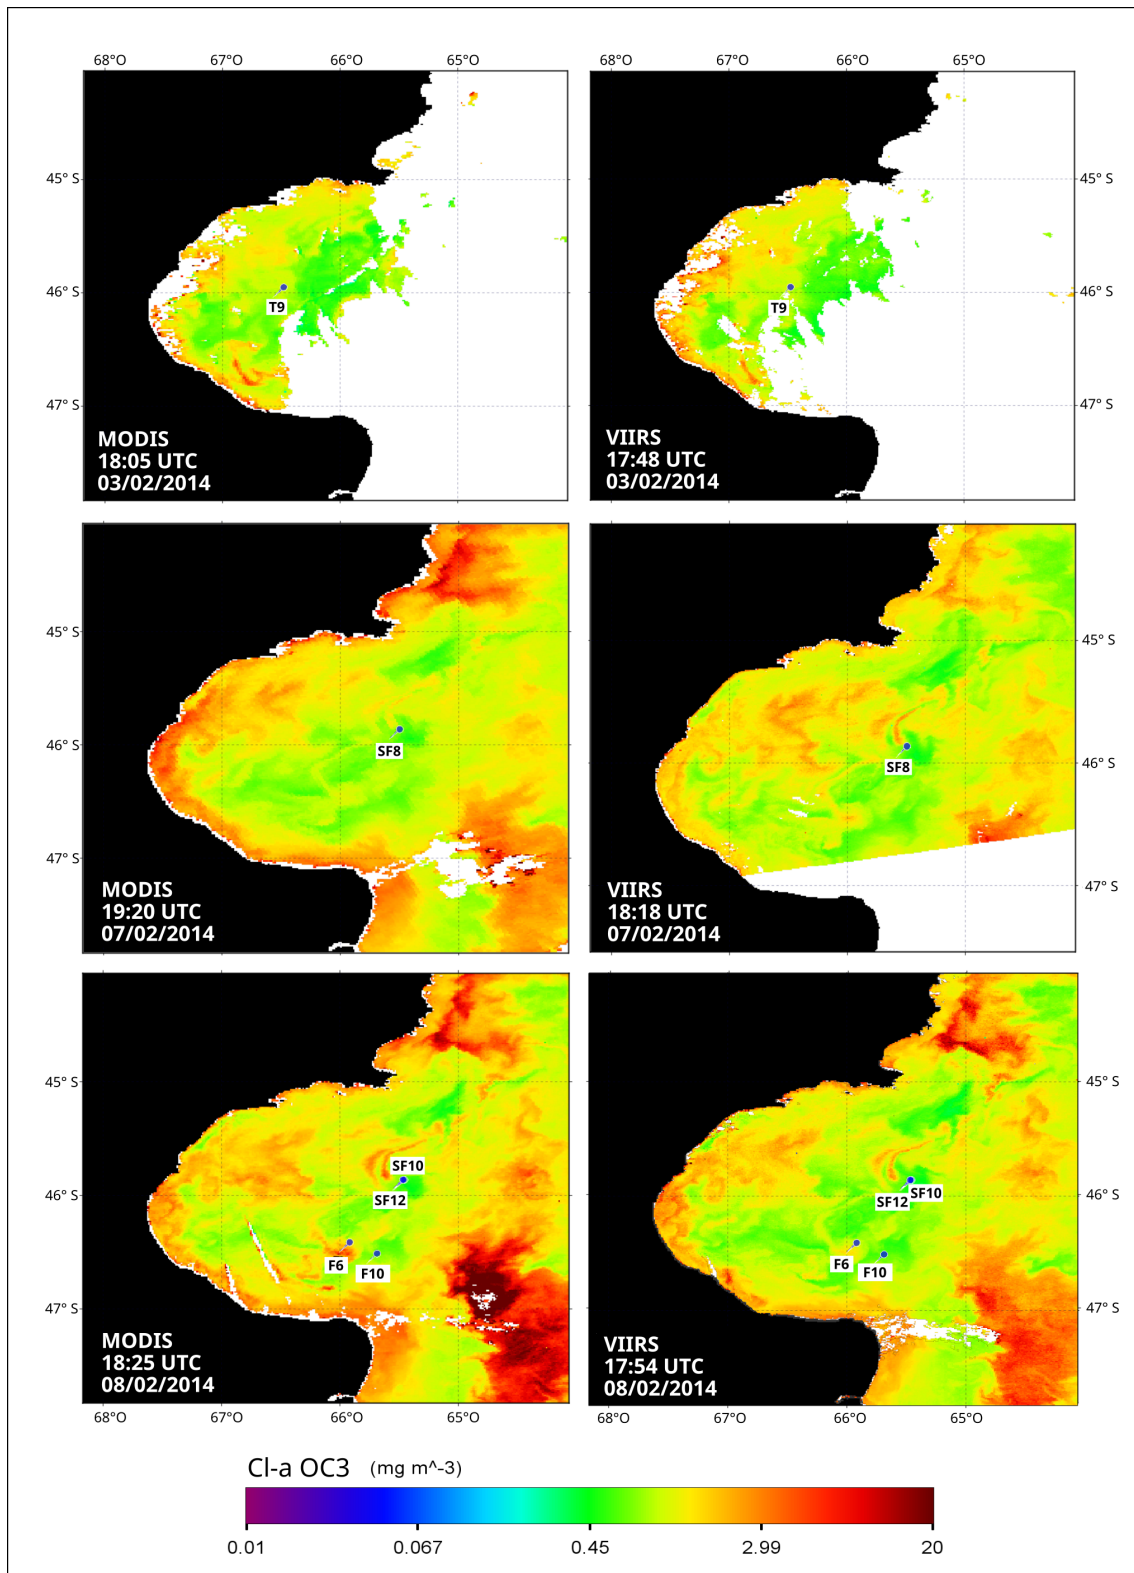


Figura 5.4: Mapas de Cl-a de MODIS y VIIRS para la campaña 2014 y estaciones de muestreo donde se lograron los matchups. (ver figura 5.1)

5.6 RESULTADOS

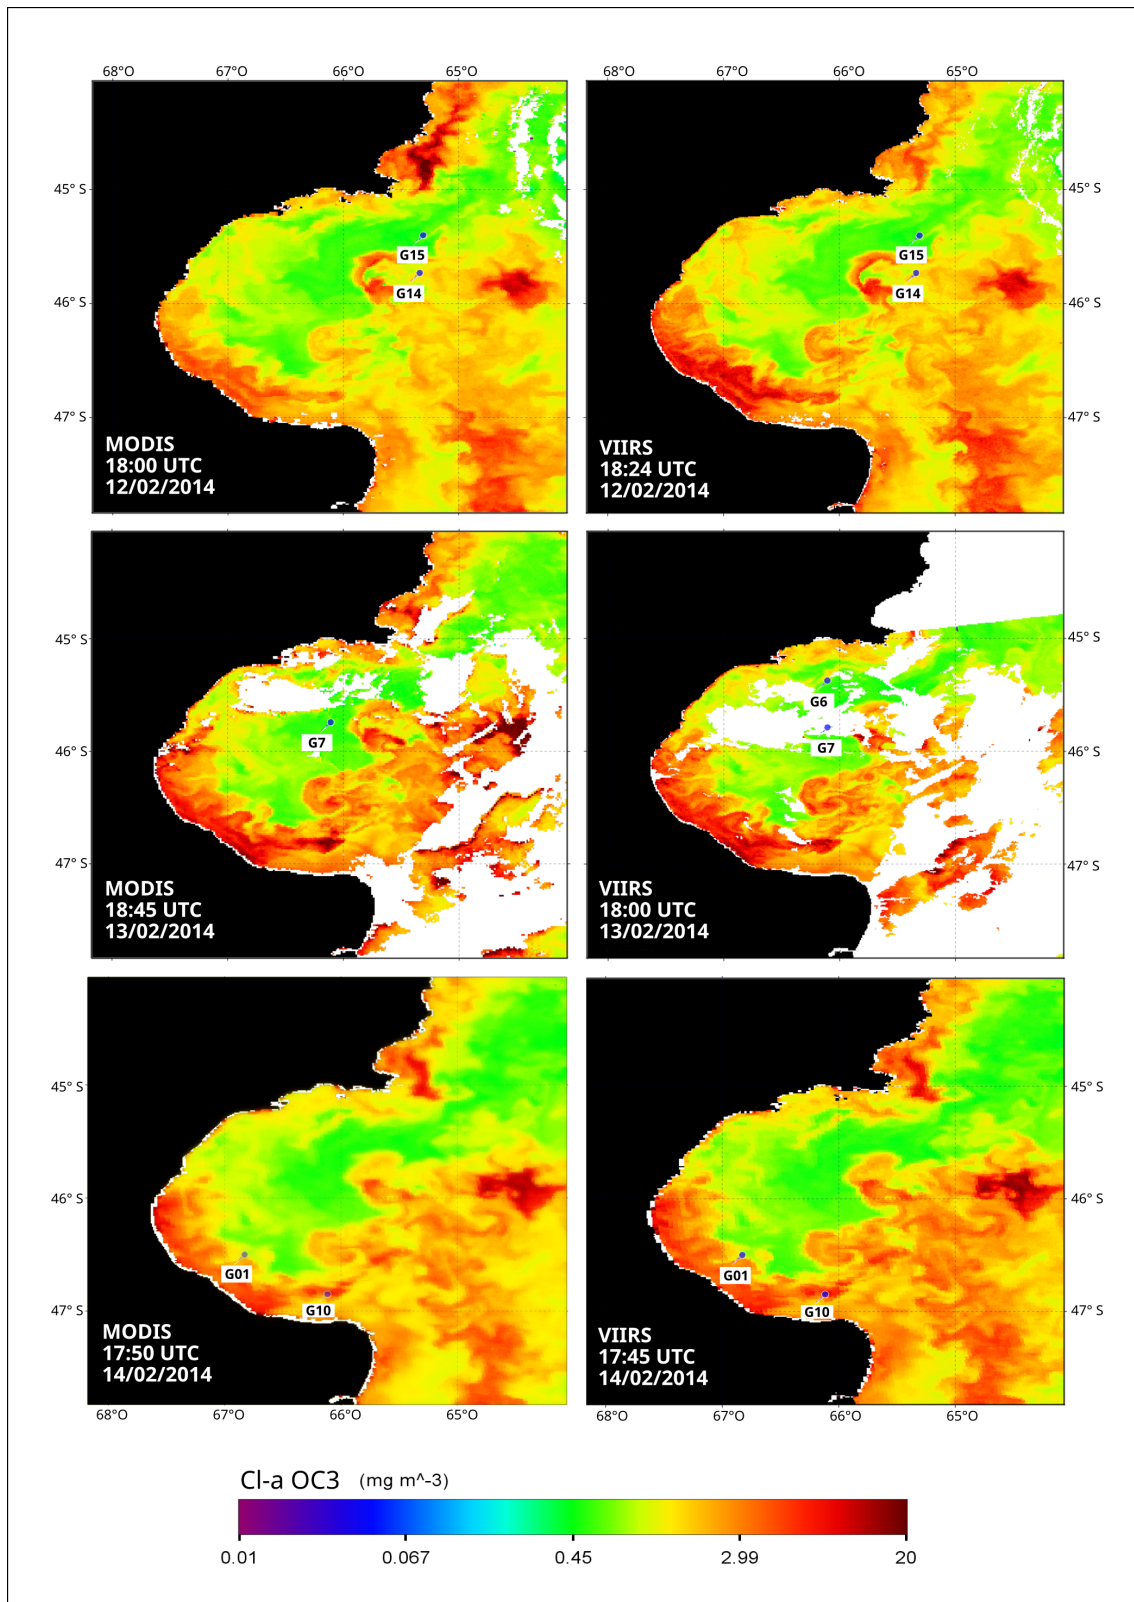


Figura 5.5: Mapas de Cl-a de MODIS y VIIRS para la campaña 2014 y estaciones de muestreo donde se lograron los matchups. (ver figura 5.1)

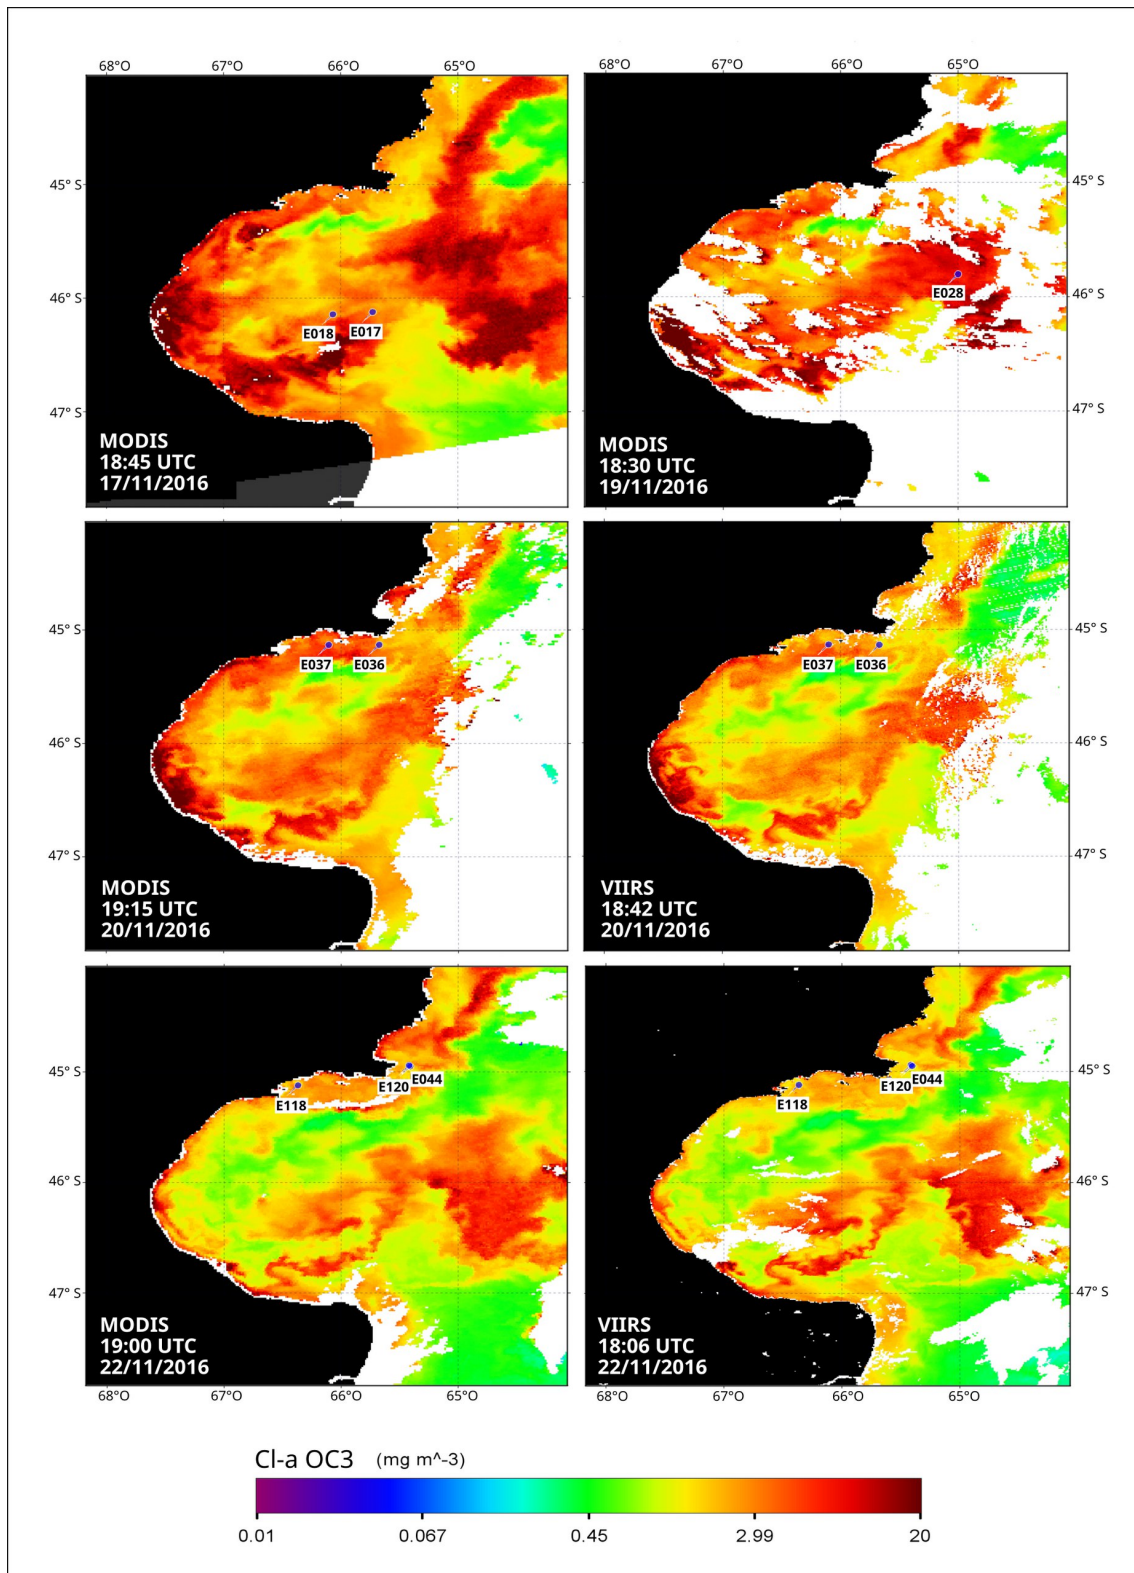


Figura 5.6: Mapas de Cl-a estimada satelitalmente para la campaña del 2016 y estaciones de muestreo donde se lograron los matchups (ver Figura 5.1)

A continuación, en las Tablas 5.5 y 5.6 se mostrarán los resultados del análisis estadístico relacionado al performance del algoritmo OCx estimado por los sensores MODIS y VIIRS en cada una las campañas.

MODIS vs.:	n	SIQR	RMSE _(log)	EM _(log)	BIAS	MAE
Campaña 2014	11	0.394	1.022	0.010	1.023	1.320
Campaña 2016	8	1.453	1.252	0.411	1.437	1.529

Tabla 5.5: Métricas de evaluación para los resultados de la comparación entre los datos obtenidos mediante MODIS y las Campañas 2014/2016.

VIIRS vs.:	n	SIQR	RMSE _(log)	EM _(log)	BIAS	MAE
Campaña 2014	12	0.388	1.010	-0.013	0.970	1.433
Campaña 2016	5	1.470	1.150	0.140	1.379	1.560

Tabla 5.6: Métricas de evaluación para los resultados de la comparación entre los datos obtenidos mediante VIIRS y las Campañas 2014/2016.

Para medir la dispersión de las distribuciones sesgadas se utiliza el rango semi-intercuartil (SIQR) porque es débilmente afectado por valores extremos. El SIQR es una medida de variabilidad que indica la magnitud de los desvíos de los valores que posee una variable con respecto al valor central de la distribución. El SIQR se calculó según la ecuación 5.1, para la campaña 2014 fue del orden de 0.394 para MODIS y 0.388 para VIIRS (Tablas 5.5 y 5.6). Es decir que los valores sesgados no están muy dispersos respecto al valor central. Por otra parte, el error medio (Ecuación 5.2) es una estimación del sesgo y permite evaluar la precisión de las predicciones. En el caso de la campaña del 2014, se obtuvieron valores de 0.019 y -0.013 para MODIS y VIIRS respectivamente. Esto señala la tendencia de los valores de MODIS a levemente sobrestimar la CI-a y de VIIRS a subestimar. Para la campaña del 2016, los errores medio resultaron positivos (0.41 y 0.14 para MODIS y VIIRS respectivamente), evidenciando una tendencia a la sobrestimación por parte de los datos satelitales (ver Tablas 5.5 y 5.6). La Figura 5.3 muestra estas tendencias. Así mismo, se puede observar en la Figura 5.6 como los mapas correspondientes al año 2016 tienen más píxeles con valores elevados de CI-a. El RMSElog (ecuación 5.3) es un cálculo del error del conjunto total de datos satelitales. Para las estimaciones de MODIS, el RMSE de la campaña 2014 fue menor (RMSElog=1.022) que el de la campaña 2016 (RMSElog=1.252). Al igual que MODIS, la estimaciones de VIIRS obtuvieron un RMSE menor (1.010) para la campaña del 2014 y un RMSE mayor (1.150) para la campaña del 2016.

Hasta aquí se trabajó con estadísticos que suelen emplearse para evaluar el performance de algoritmos desarrollados para estimar variables geofísicas a partir de mediciones satelitales del color del mar: métricas de mínimos cuadrados, en particular el error cuadrático medio (RMSE), el coeficiente de determinación (r^2) y la pendiente de regresión. Sin embargo, el RMSE es una métrica apropiada para prácticas de validación cuando la distribución de los errores es gaussiana y el objetivo de una investigación es resaltar la sensibilidad a los valores atípicos (Chai and Draxler, 2014). Al depender de la distribución de las magnitudes del error y el tamaño de la muestra, subraya aún más su sensibilidad adicional a los valores atípicos o *outliers* y al orden del conjunto de datos (Seegers et al., 2018). EL RMSE coloca más peso en los errores grandes que en los pequeños (como resultado de elevar al cuadrado cada término), y por lo tanto enfatiza datos atípicos de manera inconsistente con la mediana de los datos de la muestra. Asimismo, el r^2 no solo es sensible a valores atípicos, sino que también se puede interpretar de forma

confusa cuando el conjunto de datos es variado. Esto se debe a que la varianza explicada por el modelo de regresión (o varianza de predicción) se normaliza con la varianza total, entonces un modelo con un error fijo tendrá diferentes coeficientes de determinación cuando se aplica en áreas con rangos amplios de datos frente a rangos reducidos (por ejemplo, el rendimiento en el océano a escala global versus a escala regional o local) (Seegers et al., 2018). Respecto a la pendiente, vale aclarar que no es una métrica de error. Si bien puede ser útil para evaluar el rendimiento del modelo en rangos amplios de datos, también pueden informar fácilmente un valor próximo a la unidad para un modelo fuertemente sesgado y de baja precisión, lo que complica su interpretación y utilidad. Por tal motivo y con el fin de analizar la relación entre los datos desde una perspectiva alternativa, se incluyeron las métricas Bias (ec. 5.4) y MAE (ec. 5.5). Estos valores se calcularon primero en un espacio logarítmico y luego se lleva a cabo una transformación inversa para interpretar correctamente los resultados. El bias cuantifica el promedio de la diferencia entre este estimador y el valor esperado. Brinda una descripción simple de la dirección sistemática del error, indicando si hay sobre o subestimación en la comparación. Los valores utilizados fueron transformados logarítmicamente, de modo que el bias se encontrará alrededor del uno. Si un bias supera la unidad, indica sobrestimación, si un bias es menor a la unidad, indica un sesgo negativo (subestimación). Por ejemplo, un bias igual a 1.2 indica que el modelo es 20% mayor en promedio que la variable observada. En el presente trabajo, las estimaciones de MODIS en las campañas 2014 y 2016 se obtuvieron bias de 1.023 y 1.437 respectivamente (Tabla 5.5). Esto significa que en ambos casos hubo una sobrestimación del 2,3% y del 43,7%. Para el caso de VIIRS, en las campañas 2014 y 2016 se obtuvieron bias de 0.970 y 1.379 respectivamente (Tabla 5.6). Es decir que en la primer campaña hubo subestimación del 3% y en la segunda campaña los valores sobrestimaron el valor real de CI-a en un 37.9% .

Por otra parte, el MAE es una métrica apropiada para distribuciones no gaussianas o desconocidas (muchas veces quien analiza los datos no conoce con exactitud la naturaleza de la distribución del conjunto de datos). Mientras que el MAE da el mismo peso a todos los errores, el RMSE penaliza la varianza porque, como ya me mencionó, da más peso a errores con valores más grandes que a los errores con valores más pequeños. Por definición, el RMSE nunca será menor que el MAE (Chai and Draxler, 2014). Adicionalmente, si se precisara una métrica más robusta, es posible calcular la desviación absoluta mediana (MAD), puesto que las estimaciones absolutas medianas son menos sensibles a los outliers. Al igual que el bias, aquí se usaron valores transformados logarítmicamente, en consecuencia, este indicador absoluto siempre será mayor a la unidad. Entonces, un MAE de 1.5 indica un error de medición del 50%. Las estimaciones de MODIS en las campañas tuvieron MAE del orden de 1.320 para el 2014 y de 1.529 para el 2016 (errores del 32% y 52.9% respectivamente) (Tabla 5.5). Por otra parte, las estimaciones de VIIRS presentaron errores del 43.3% para la campaña del 2014 y del 56% para el 2016 (Tabla 5.6). Estos valores elevados sugieren la influencia del tamaño de la muestra, como se señaló con anterioridad.

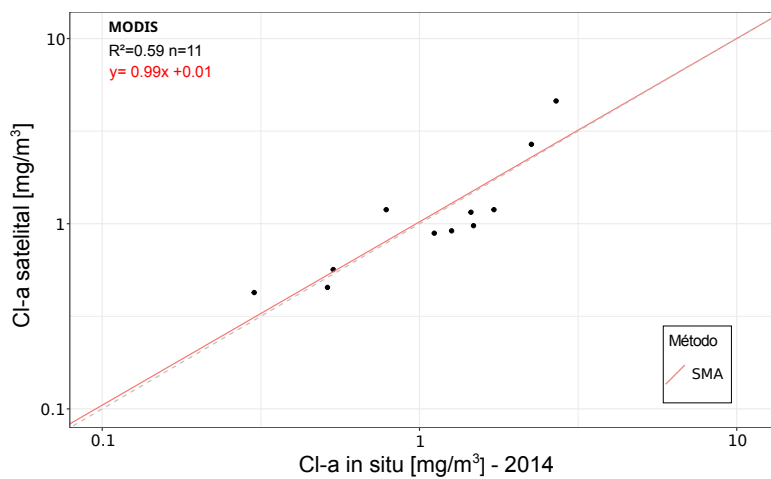
En cuanto a los resultados de las regresiones, los mismos se muestran en los gráficos 5.7 y 5.8 y en las tablas 5.7 y 5.8. Se obtuvieron coeficientes de determinación (r^2) aceptables considerando las pocas muestras que se emplearon en el modelo. Para la campaña 2014, el $r^2=0.59$ para MODIS y para VIIRS fue $r^2=0.54$. La bondad del ajuste se podría mejorar aumentando la cantidad de pares de comparación (puntos *matchups*). Los coeficientes para la campaña 2016 fueron de $r^2=0.67$ para las estimaciones de MODIS y $r^2=0.82$ para VIIRS. Respecto a las pendientes, la que mejor se ajustó al set de datos, fue obtenida por el método SMA (*Standard Major Axis*) en la campaña 2014 con MODIS. El SMA es la estandarización del método MA (*Mayor Axis*). El MA suele usarse con variables en diferentes unidades físicas, cuando el propósito del análisis es comparar pendientes (por ejemplo, en diferentes sitios de muestreo) calculadas a partir de variables medidas de manera idéntica. También puede ser útil cuando el propósito del estudio es comparar la pendiente de los datos empíricos con un valor dado por hipótesis. Como se mencionó en la Sección 5.5.2, la pendiente del eje mayor no se escala proporcionalmente a las unidades de medida. Por esta razón, es deseable que las variables sean dimensionalmente homogéneas antes de la regresión del modelo II. Esta homogeneización se logra con el SMA. Otra alternativa para hacer las variables dimensionalmente homogéneas es con el método RMA (*Range Major Axis*). El estimador RMA se escala proporcionalmente a las unidades de x e y y no es insensible a la covarianza, como es el caso de SMA. Pero si en la dispersión de los datos hay muchos *outliers* o valores atípicos, pueden tener una influencia indeseable en la estimación de la pendiente. De todas formas, la lectura del valor de la pendiente se debe hacer con cuidado ya que aun cuando n es muy pequeño o la correlación es débil, se puede obtener una pendiente cercana a ± 1 .

MODIS		Modelo II de regresión				
Campaña	Algoritmo	Pendiente	Ord. Origen	n	R ²	Método
2014	OC3	0.99	0.01	11	0.59	SMA
2016	OC3	0.54	0.48	8	0.67	RMA

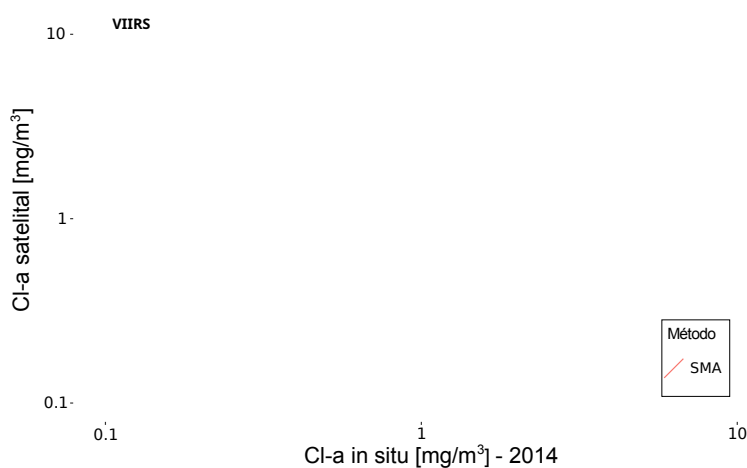
Tabla 5.7: Resultados del modelo II de regresión para la relación entre la CI-a medida en cada campaña y la CI-a estimada por MODIS, con las pendientes obtenidas por los métodos RMA y SMA y el coeficiente de determinación para cada caso.

VIIRS		Modelo II de regresión				
Campaña	Algoritmo	Pendiente	Ord. Origen	n	R ²	Método
2014	OC3	0.81	-0.010	12	0.54	SMA
2016	OC3	0.40	0.290	5	0.82	RMA

Tabla 5.8: Resultados del modelo II de regresión para la relación entre la CI-a medida en cada campaña y la CI-a estimada por VIIRS, con las pendientes obtenidas por los métodos RMA y SMA y el coeficiente de determinación para cada caso.

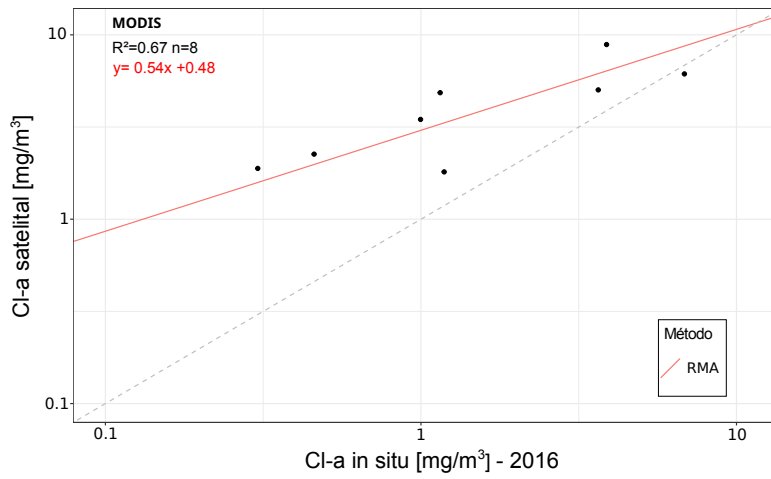


(a) MODIS

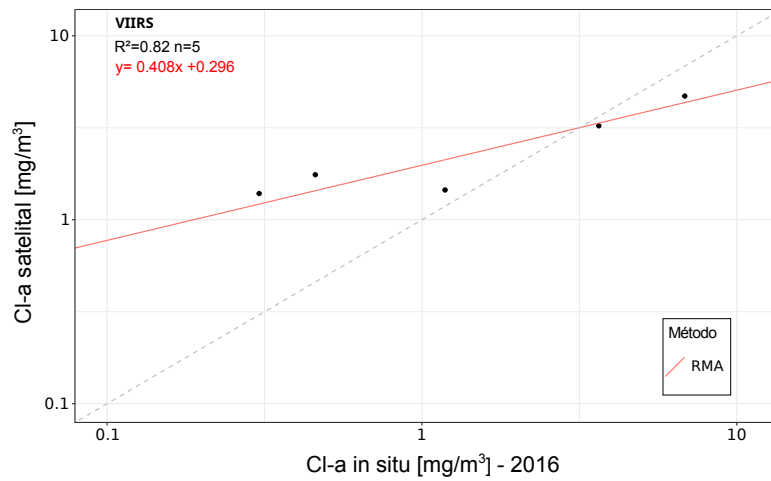


(b) VIIRS

Figura 5.7: Gráfico de dispersión de la relación entre los datos de campo 2014 y satelitales MODIS (a) y VIIRS (b). En la parte superior izquierda se muestran los resultados obtenidos con el modelo de regresión II. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$.



(a) MODIS



(b) VIIRS

Figura 5.8: Gráfico de dispersión de la relación entre los datos de campo 2016 y satelitales MODIS (a) y VIIRS (b). En la parte superior izquierda se muestran los resultados obtenidos con el modelo de regresión II. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$.

5.7. Conclusiones y Discusiones

En general, hay determinados motivos que explican las diferencias entre la clorofila estimada por sensores satelitales y la clorofila medida *in situ* (Gregg and Casey, 2004):

- ❖ presencia de materia orgánica disuelta (CDOM),
- ❖ sedimentos en suspensión,
- ❖ diversidad de especies de fitoplacton,
- ❖ presencia de aerosoles absorbentes de radiación,
- ❖ sunglint / nubes / hielo,
- ❖ calibración.

Muchos de estos motivos pueden afectar el rendimiento de los algoritmos de corrección atmosférica, alterando la precisión del cálculo de Cl-a. El algoritmo estándar de corrección atmosférica se basa en la suposición del píxel negro, es decir, la radiancia que emerge del agua en la región del NIR es cero o despreciable. Entonces si hay sustancias presentes en el agua que dispersan demasiado la luz o de aerosoles en la atmósfera que absorben energía en la región azul del espectro electromagnético (como ser, aerosoles asociados a emisiones de polvo o a zonas urbanas) pueden afectar su funcionamiento reduciendo así la precisión de las estimaciones satelitales de la Cl-a (Dogliotti, 2007).

Los resultados aquí alcanzados sugieren que el algoritmo OC3 tanto de MODIS como de VIIRS son estimadores aceptables de la concentración de Cl-a en el GSJ. Para la campaña Coriolis 2014 se obtuvieron resultados similares al trabajo de Williams et al. (2018), donde se evaluó el performance del algoritmo OC3 de MODIS en diferentes ventanas temporales. Los resultados más próximos a los expuestos aquí, fueron para una ventana de 12 horas ($r^2=0.46$) y para una de 6 horas ($r^2=0.48$). No obstante, se debe tener precaución al interpretar los valores estimados en zonas donde se producen picos de Cl-a. Esto puede indicar que el algoritmo OC3 puede no ser tan preciso en estas áreas o que otros factores, como los mencionados al inicio de esta sección, pueden afectar las mediciones. También, a lo largo de toda la región costera del GSJ, existe una mayor variabilidad espacial de la concentración de Cl-a. Por lo cual, el algoritmo puede enfrentar desafíos al estimar con precisión en estas áreas. Respecto a esto, es importante mencionar que trabajos como los de Cucchi Colleoni and Carreto (2001); Romero et al. (2006); Carreto et al. (2007); Fernández et al. (2007a); Glembocki et al. (2015); Williams et al. (2016); Torres et al. (2018); Williams et al. (2018); Segura et al. (2021) observaron que la concentración de Cl-a en el GSJ no es uniforme, y esta variabilidad puede estar influenciada por factores como las corrientes oceánicas, los patrones de mezcla vertical y la disponibilidad de nutrientes. Asimismo, la variabilidad espacial y temporal de las propiedades bio-ópticas puede afectar el registro y la interpretación de las mediciones de Cl-a satelital. También se debe considerar el tipo de aguas que caracteriza el GSJ para comprender la aplicación y el performance de los algoritmos. Según Williams et al. (2016), la elevada concentración de CDOM supone que son aguas de Caso II. En aquel trabajo, el algoritmo OC3M tendió a sobrestimar la concentración de Cl-a en el GSJ en relación con las mediciones de campo. Sin embargo, OC3M mostró

un buen rendimiento incluso en casos en los que la $Cl-a$ y la $CDOM$ no estaban relacionadas. Esto indica que el algoritmo fue eficaz en regiones costeras y de plataforma, donde la complejidad óptica del agua puede ser alta. Destaca además que, a diferencia de otras regiones costeras, en el GSJ la influencia continental es insignificante debido a la falta de ríos que desemboquen en el golfo. En su lugar, propone que los frentes de marea estacionales impulsan la variabilidad espacial y temporal de las propiedades bio-ópticas en el GSJ. En un estudio más reciente, Williams et al. (2018) señala que existe una buena correlación entre $aCDOM$ y a la absorción por el fitoplancton. Esto supone que las propiedades ópticas del agua en esta región están influenciadas principalmente por el fitoplancton y $CDOM$ covariante, con lo cual las aguas se pueden clasificar como Caso I. Entonces, la variabilidad y complejidad de las aguas del golfo pueden no ajustarse perfectamente a esta categorización binaria (Mobley et al., 2004).

Respecto a las métricas de rendimiento, lo ideal es no usar muchos estadísticos que tiendan a ser redundantes entre sí. Esto puede generar decisiones parciales en la evaluación de un modelo (Seegers et al., 2018). Tampoco trabajar con un solo estadístico suponiendo que cubre todos los criterios de rendimiento. Lo recomendado es llevar a cabo una metodología la cual combine métricas y gráficos que se complementen sin ser repetitivos (Seegers et al., 2018).

La tarea de validar sensores de color del mar requiere un gran esfuerzo dedicado a la recolección de datos *in situ* para garantizar que sean los suficientes a fin de evaluar el desempeño de sensores satelitales de escala regional y global (Bailey and Werdell, 2006). Más mediciones en distintas épocas del año ayudaría a un análisis estacional de la validez de las estimaciones satelitales en esta región. El conocimiento de la composición específica de la comunidad fitoplanctónica y de la información bio-óptica en las estimaciones satelitales de $Cl-a$, también es importante para entender posibles errores en las comparaciones (Dogliotti, 2007). Para interpretar correctamente los resultados de la validación es importante entender las características del sensor y las limitaciones de los algoritmos para la corrección atmosférica y la estimación de productos, sin dejar de lado las condiciones ambientales.

Comparación Intersatelital

6.1. Introducción

Desarrollar una comparación bajo un enfoque inter satelital (*multisensor*) puede mejorar el análisis de validación que utiliza un solo sensor. Por ejemplo, VIIRS o MODIS pueden proporcionar información sobre la variación temporal de los procesos naturales por su tiempo de revisita diaria y OLI es capaz proporcionar información sobre la variación espacial del mar en las proximidades de un sitio de validación. Esto permite reducir las discrepancias causadas por la falta de coincidencia temporal y espacial entre datos satelitales e *in situ*. Las intercomparaciones buscan identificar sesgos y tendencias de datos originados por sensores o algoritmos, que son imposibles de detectar comparando únicamente con mediciones de campo dispersas (IOCCG, 2007). Si se puede establecer una buena correspondencia entre los datos de los sensores, se pueden combinar para el monitoreo de actividades y fenómenos a escala local y regional.

Un sensor remoto integra la radiación emergente del agua sobre el campo de visión instantáneo (IFOV). La medida adquirida instantáneamente de una propiedad oceánica es un valor promedio sobre la región definida por la intersección del IFOV con la superficie del agua. Esta región se denomina huella o (*footprint*) del sensor, y será la que determinará la resolución espacial del mismo. Es un sistema de escaneo en el que la superficie del mar está cubierta por huellas contiguas pero no superpuestas. El conjunto resultante de mediciones es directamente comparable con la forma en que un modelo bidimensional describe el mar, representando las variables oceánicas como promedios dentro de cada celda de una cuadrícula rectangular (Robinson, 2010). De esta manera, el uso de grillas resulta adecuado para comparaciones de CI-a (u otras variables) estimadas por diferentes satélites. Representa una comparación *celda x celda* en lugar de *pixel x pixel*. Así, se estandariza una metodología en la cual sólo hay que volcar los datos extraídos de cada sensor sobre una grilla con celdas geográficamente referenciadas y luego llevar a cabo la comparación deseada.

6.1.1. Objetivos del capítulo

El objetivo principal de este capítulo será mostrar la factibilidad de usar datos de diferentes sensores para estudiar la variabilidad espacial y temporal de la CI-a en el GSJ. Para ello, se evaluará el desempeño de las estimaciones de CI-a OC3 (O'Reilly et al., 1998) de Landsat 8 y Sentinel-2 en relación a la CI-a obtenida por MODIS. Se determinó como valor de referencia el producto MODIS, dado que fue validado previamente en la zona de estudio, demostrando que es un estimador aceptable de esta variable bio-óptica (Dogliotti, 2007; Dogliotti et al., 2009, 2014; Williams et al., 2016, 2018).

6.2. Metodología

6.2.1. Obtención de imágenes

Se trabajó con satélites Aqua/MODIS, Landsat 8/OLI y Sentinel-2/MSI. La selección de imágenes se basó en fechas cuyas pasadas coincidieran, escogiendo escenas libres de nubes y con ángulo de visión del sensor de 0° aproximadamente a nadir (nadir IFOV). También se consideró que si el ángulo cenital solar es próximo a 0°, hay probabilidades de que la escena presente sunlint. Por esta razón, es conveniente buscar imágenes que no coincidan exactamente con el mediodía. Esta pauta considera las limitaciones en la confiabilidad de los algoritmos de corrección atmosférica en ángulos de visión y cenital solar extremos (Bailey and Werdell, 2006). La hora de pasada sobre la zona de estudio de los satélites utilizados, cumple con este criterio: Aqua/MODIS 19:20 UTC (ARG 16:20), S2 14:10 UTC (ARG 11:10), L8 14:06 UTC (ARG 11:06).

De la página web de Ocean Color de la NASA se descargaron las imágenes correspondientes a MODIS. Para esta tesis se utilizaron los productos de Nivel 2 (L2), es decir, variables geofísicas derivadas de los datos del Nivel 1 mediante la aplicación de correcciones atmosféricas, la calibración del sensor y los algoritmos bio-ópticos. Una vez descargados los archivos (por ejemplo: A2017247191500.L2_LAC_OC.nc producto *Ocean Color* de Aqua MODIS 1km Local Area Coverage), se abrieron con SeaDAS para realizar un recorte o *subset* sobre la zona de estudio y luego se re proyectaron a UTM/WGS84 (misma proyección de la grilla). Este recorte se exportó como archivo de extensión GeoTIFF.

Por otra parte, las imágenes Landsat 8 (L8) y Sentinel-2 (S2) se descargaron desde el Portal del USGS EarthExplorer y Copernicus Open Access Hub. En esta tesis se trabajó con imágenes nivel 1 (Landsat 8 OLI/TIRS C1 Level-1 y Sentinel-2 Level-1C TOA). Si bien, como se explicó en la sección 4.2, estos dos sensores están diseñados principalmente para aplicaciones terrestres, han demostrado resultados prometedores para trabajos en aguas costeras y continentales (Franz et al., 2014; Vanhellmont and Ruddick, 2016; Pahlevan et al., 2017b; Poddar et al., 2019; Oostende, 2015). Para la zona de estudio se utilizaron imágenes L8 path/row: 228/092 y S2 T19GFJ. En el caso de Sentinel-2, si bien existía la posibilidad de descargar varias escenas o *tiles* para cubrir el área total de la grilla, se optó por utilizar sólo un *tile* a fin de acelerar el tiempo de procesamiento. La elección del *tile* se basó en que la imagen abarque zona costera y mar.

La Tabla 6.1 muestra las fechas de las imágenes descargadas teniendo en cuenta la coincidencia de pasada de los tres satélites y de los criterios recién expuestos. El año 2014 no se consideró para la comparación pues Sentinel-2 aún no estaba operativo (se puso en órbita en junio del 2015). El año 2016 sólo se buscaron coincidencias con las fechas de la campaña oceanográfica para la validación con datos *in situ* (Capítulo 5). Durante los años 2017-2019 se encontraron cinco fechas coincidentes que cumplían con los requisitos para la comparación, no así los siguientes años 2020 y 2021.

Fechas evaluadas
2017-01-30
2018-08-30
2018-11-01
2018-12-03
2019-10-03

Tabla 6.1: Fechas que coinciden las pasadas MODIS, L8 y S2 utilizadas para la comparación.

6.2.2. Procesamiento de imágenes L8 y S2: Algoritmos de corrección atmosférica

A diferencia de los productos MODIS y VIIRS, para obtener parámetros del color del mar a partir de una imagen L8 o S2, se deben procesar las radiancias recolectadas por cada sensor. Este procesamiento incluye la corrección atmosférica que es necesaria para obtener reflectancias R_{rs} o bien reflectancias ρ_w que servirán como *inputs* para diferentes algoritmos de estimación de propiedades oceánicas. En el presente trabajo, las imágenes L8 y S2 fueron procesadas y corregidas con Acolite y el módulo L2gen de SeaDAS. Estos programas se eligieron porque son de libre acceso y cuentan con muchos trabajos de referencia en los que se lograron buenos resultados para estudios acuáticos (Capítulo 5, sección 5.4).

ACOLITE es un programa para imágenes Landsat (5/7/8) y Sentinel-2 (A/B) desarrollado en RBINS (*Royal Belgian Institute of Natural Sciences*). Permite el procesamiento simple y rápido para aplicaciones marinas y de aguas continentales. Las características incluyen generación de imágenes RGB, corrección Rayleigh (mediante el código de transferencia radiativa 6SV), corrección atmosférica y extracción de regiones rectangulares de interés (definidas por coordenadas de límite). Las salidas de nivel 2 son reflectancia marina (ρ_w), reflectancia sensada remotamente (R_{rs}), concentración de clorofila-*a* (empleando el mismo algoritmo OC3 de la NASA), concentración de sedimentos en suspensión, turbidez, entre otros parámetros. Todos ellos se pueden guardar como mapas PNG con la opción de exportarlos como imágenes GeoTIFF y conjuntos de datos geolocalizados en un archivo NetCDF (NetCDF). Lo que distingue a este procesador son las opciones que ofrece al usuario para llevar a cabo la corrección atmosférica en base a las siguientes bandas espectrales:

- ❖ Infrarrojo de onda corta (SWIR)
- ❖ Combinación Rojo/ Infrarrojo cercano: Red/NIR
- ❖ Combinación Infrarrojo cercano / Infrarrojo de onda corta: NIR/SWIR.

La corrección SWIR emplea las bandas 6 y 7 (~ 1609 y ~ 2201 nm respectivamente) de Landsat 8 y fue desarrollado originalmente para aguas turbias y extremadamente turbias (Vanhellemont y Ruddick, 2015a). Cuando el algoritmo (*Dark Spectrum Fitting*) emplea bandas SWIR considera que debido a la absorción extremadamente alta del agua a 1.6 y $2.2 \mu\text{m}$ la señal remanente en estas bandas, luego de la corrección Rayleigh, es causada por la dispersión de aerosoles. Entonces, la reflectancia emergente del agua en las bandas SWIR es cero. Estas correcciones las realiza con las tablas de consulta basadas en el modelo de transferencia radiativa 6SV (Vermote et al., 2006). Por otro lado, la corrección Red/NIR utiliza las bandas 4 y 5 (655 y 865 nm). Y por último, NIR/SWIR cuenta con dos posibilidades de combinación de bandas: 5 y 6 (865 y 1600 nm) o 5 y 7 (865 y 2200 nm). Si bien esta configuración de bandas esta pensada para el sensor OLI de Landsat, las bandas de Sentinel-2 (S2/MSI) son comparables con Landsat 8 (L8/OLI) en términos de la longitud de onda central. Las principales diferencias en el conjunto de bandas son la adición en S2/MSI de bandas *red edge* (704 , 740 , 781 nm), una banda NIR adicional (834 nm) y una banda de vapor de agua a 940 nm.

Por otro lado, el OBP de la NASA distribuye un paquete de software denominado Sistema de Análisis de Datos SeaWiFS (SeaDAS) que proporciona una herramienta estandarizada para la producción, visualización y análisis de productos de color del océano de una serie de radiómetros multiespectrales de observación de la Tierra. SeaDAS contiene un *generador* multisensor de nivel 1 a nivel 2 (l2gen) que puede leer radiancias a TOA de (producto de nivel 1), realizar el proceso de corrección atmosférica y estimar Rrs, entre otras propiedades geofísicas derivadas. El código l2gen se puede adaptar para trabajar con cualquier sensor que tenga un conjunto suficiente de bandas espectrales que abarquen la región azul a verde del espectro visible (es decir, de 400 a 700 nm), con al menos dos bandas en el infrarrojo cercano (NIR) a IR de onda corta (SWIR) para respaldar la corrección atmosférica. El algoritmo emplea las bandas NIR y SWIR para estimar la contribución de aerosoles, asumiendo que la radiancia emergente del agua en el NIR es despreciable (Franz et al., 2015). Sobre aguas costeras turbias (píxeles no negros), la corrección atmosférica se realiza a través de un enfoque iterativo, mediante el cual se utilizan propiedades ópticas inherentes (IOP) modeladas para estimar las Rr distintas de cero en las bandas de onda del infrarrojo cercano (NIR) (Gordon and Wang, 1994; Bailey et al., 2010; Mobley et al., 2016).

6.2.3. Algoritmo OC3

Tanto Acolite como L2gen, usan el algoritmo OC3 (*Ocean Chlorophyll blue-green ratio*) desarrollado por O'Reilly (O'Reilly et al., 1998) para estimar la concentración de la clorofila-a (ecuación 2.7)

Como se mencionó en el Capítulo 2, a medida que aumenta la concentración de la biomasa fitoplanctónica, la reflectancia en la región azul del espectro disminuye y aumenta ligeramente en el verde. Por lo tanto, para obtener estimaciones cuantitativas, se puede usar una relación entre las Rrs del azul y verde. Este algoritmo fue ajustado para L8/OLI (Franz et al., 2015) y este ajuste se aplicó para S2/MSI (Vanhellmont and Ruddick, 2016; Pahlevan et al., 2017b) en la configuración de 3 bandas (~ 440, 490 y 560 nm) y los coeficientes expresados en la Tabla 6.2.

Algoritmo	Sensor	Rrs (λ) _{azul}	Rrs (λ) _{verde}	a_0	a_1	a_2	a_3	a_4
OC3M	MODIS	443>488	547	0.2424	-2.7423	1.8017	0.0015	-1.2280
OC3 L8	OLI/Landsat 8	443>482	561	0.2412	-2.0546	1.1776	-0.5538	-0.4570
OC3 S2	MSI/ Sentinel-2	443>483	561	0.2412	-2.0546	1.1776	-0.5538	-0.4570

Tabla 6.2: Coeficientes estándar calibrados para cada sensor.

6.2.4. Grillado

Para poder comparar datos provenientes de sensores con diferentes resoluciones espaciales es necesario como primer paso referenciar todas las mediciones a una grilla común, tal como se mencionó al comienzo de este capítulo. Aquí se probaron grillas de diferentes resoluciones espaciales, siendo la de 5 km de lado la que resultó más adecuada en términos de tiempos de procesamiento.

La proyección elegida en este trabajo fue la UTM/WGS'84 (*Universal Transverse Mercator*). Se eligió este sistema porque es ampliamente utilizado en cartografía, topografía, sistemas de información geográfica (SIG), navegación y otras aplicaciones que requieren una representación precisa y localizada de la Tierra. Además, la zona de estudio es acotada y las deformaciones no son significativas. El sistema UTM/WGS'84 es una combinación de un sistema geodésico y uno de proyección: el sistema UTM y el sistema geodésico WGS'84 (World Geodetic System 1984). UTM es una rejilla de coordenadas utilizada para representar la superficie de la Tierra en un plano bidimensional. Divide la Tierra en 60 zonas rectangulares de 6 grados de longitud cada una. Cada zona está numerada del 1 al 60 y se extiende desde 80 grados de latitud sur hasta 84 grados de latitud norte. El sistema UTM se construye geoméricamente de manera que los meridianos y paralelos se transforman en una red regular y rectangular, conservando los ángulos originales. Es lo que se denomina, una proyección conforme. En la red creada, los meridianos y paralelos constituyen una cuadrícula, grilla o *grid*, de modo que una recta ubicada entre dos paralelos forma un ángulo constante con los meridianos. En este sistema, la localización geográfica de un punto se realiza con coordenadas (x,y) UTM.

6.2 METODOLOGÍA

Como ejemplo de grillas, encontramos los productos de nivel 3 de MODIS y VIIRS que utilizan la grilla Sinusoidal, como se muestra en la Figura 6.1. En tanto las imágenes de las misiones Landsat se ubican en una cuadrícula mundial de referencia conocida como WRS (Worldwide Reference System), proyectada en UTM/WGS'84 (Universal Transverse Mercator) (ver Figura 6.2 (a)). Mientras que las imágenes L1C y L2A de Sentinel-2 están posicionadas sobre una grilla de $100 \times 100 \text{ km}^2$ proyectada en UTM/WGS'84 (ver Figura 6.2 (b)).

En este trabajo se utilizó QGIS para elaborar las grillas (formato *shape*) con celdas de $5 \times 5 \text{ km}$ sobre el Golfo San Jorge (Figura 6.3). Cada celda está identificada con un Id y están geográficamente referenciadas, como recién se mencionó, bajo el sistema de proyección UTM/WG84. Para descartar datos inútiles, la grilla se ajustó para que comenzara desde la línea de costa y así evitar celdas sobre tierra. El total de celdas de la grilla es de 1358, donde cada una de ellas contiene aproximadamente 25 píxeles MODIS, 27889 de L8 y 62500 píxeles de S2.


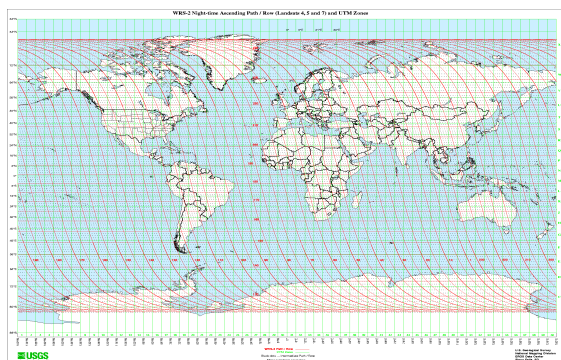
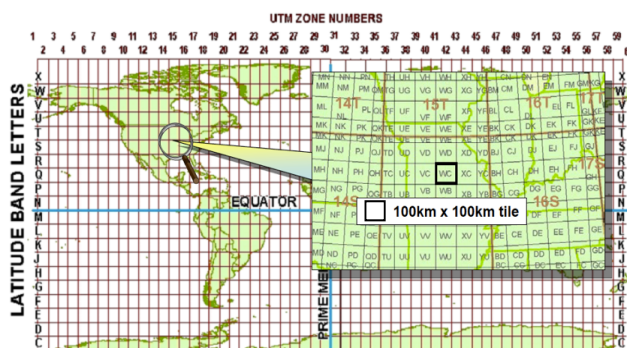


Figura 6.1: Grilla sinusoidal empleada por la NASA para productos MODIS y VIIRS. Fuente: <https://landweb.modaps.eosdis.nasa.gov>.



(a) Worldwise Reference System (WRS) utilizado por las misiones Landsat.



(b) Cuadrícula para las imágenes de la misión Sentinel-2.

Figura 6.2: Grillas correspondientes a las imágenes Landsat 8 (a) y Sentinel-2 (b). Fuentes: <https://landsat.gsfc.nasa.gov> y <https://sentinels.copernicus.eu/>.




Figura 6.3: Cuadrícula generada para la zona de estudio. Cada celda de 5 km se identificó con un Id y fueron geográficamente referenciadas con el sistema UTM/WG84. Para evitar datos inútiles, la grilla se ajustó para que comenzara desde la línea de costa y así reducir el número de celdas sobre tierra.

Los productos de CI-a obtenidos por cada sensor se almacenaron en formato GeoTIFF con el mismo sistema de proyección (UTM/WGS'84). Posteriormente, el análisis fue llevado a cabo en QGIS donde se cargaron los archivos GeoTIFF (rásters) y el archivo shape de la grilla. Las celdas en común entre los sensores (ejemplificadas en la Figura 6.4 como la zona gris) se usaron para la comparación. Es por ello, como se mencionó anteriormente, fue una comparación *celda x celda*. El análisis entre los valores fue posible con la herramienta "Estadística de Zona". Este complemento de QGIS permite calcular varios estadísticos para los valores de los píxeles de una capa ráster (por ej. el geotiff de cada imagen) que se encuentren dentro de cada polígono que conforma una capa vectorial (por ej. las celdas 5x5 km de la grilla). Luego se genera una tabla asociada a la capa vectorial con el valor del estadístico seleccionado. Para la comparación se utilizó la mediana de los valores de CI-a estimada por cada sensor. A diferencia de la media, la mediana no es sensible a valores extremos y arroja un valor real dentro del conjunto de datos. Es una medida que permite visualizar la tendencia central de los datos en caso de distribuciones sesgadas.

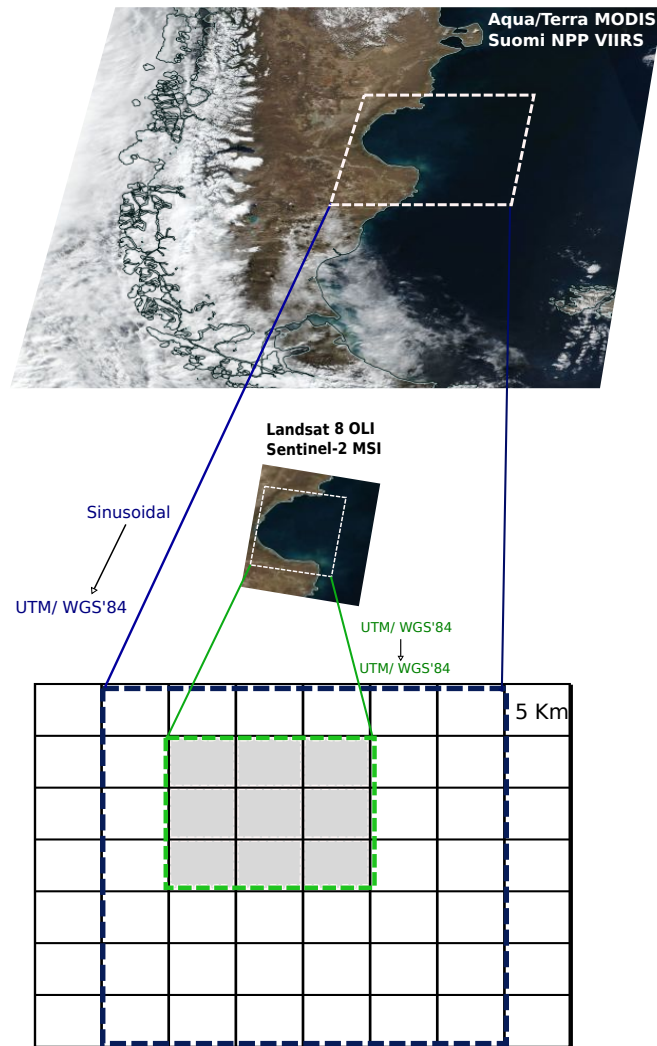


Figura 6.4: Esquema utilizado para la comparación inter-satelital sobre una grilla con celdas de 5 km. La metodología consistió en convertir la proyección original de cada imagen en la proyección de la grilla (UTM/WGS'84) y de esta forma comparar los valores satelitales dentro de cada celda. El recuadro azul muestra la reproyección para el caso de MODIS y el recuadro en verde para los casos de L8 y S2, para estos dos casos no fue necesario reproyectar dado que las proyecciones originales coincidían con la de la grilla.

Por otro lado, se incorporó al set de datos un *buffer* de distancia respecto a la línea de costa (Figura 6.5) para una mejor interpretación de las comparaciones. El *buffer* de distancia se genera con QGIS a partir de la línea de costa hasta 150 km hacia el Este del Golfo. De esta forma se pretende explorar si el algoritmo de aguas abiertas tiene un buen desempeño para aguas costeras.

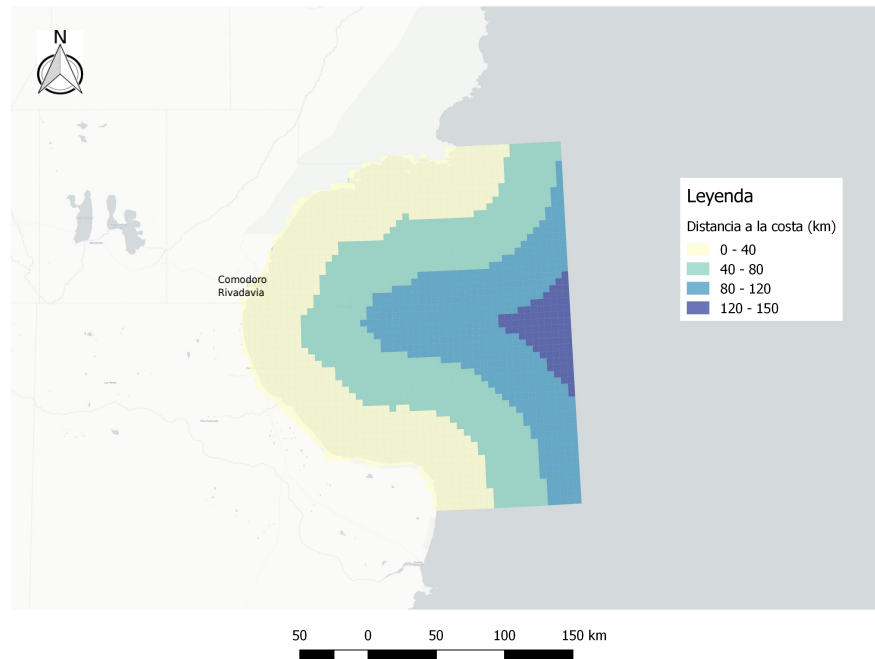


Figura 6.5: *Buffer* de distancia a la costa.

6.2.5. Análisis estadístico

Para análisis de precisión y consistencia de productos se trabajó con métricas tradicionales como el coeficiente de determinación (r^2) resultante del modelo de regresión II y la raíz del error cuadrático medio (RMSE). A su vez, se emplearon otras métricas como el sesgo (Bias) y la desviación estándar relativa (RSD), también denominada Coeficiente de Variación (CV), para analizar la distribución de los valores respecto a su media.

1) Error cuadrático medio:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{Cla_{sat2} - Cla_{sat1}}{Cla_{sat1}} \right)^2}. \quad (6.1)$$

2) Desviación Estándar Relativa:

$$RSD = \left(\frac{Std}{\bar{E}} \right) * 100. \quad (6.2)$$

3) Bias:

$$Bias = \frac{1}{n} \sum_{i=1}^n Cla_{sat2} - Cla_{sat1}. \quad (6.3)$$

En estas expresiones, $sat1$ es la CI-a derivada MODIS y $sat2$ la derivada por los sensores a L8 o S2. Por otra parte, Std es el desvío estándar entre los valores y \bar{E} es el promedio de $sat2$.

6.3. Resultados


La Tabla 6.3 muestra los resultados de las comparaciones que se llevaron a cabo entre MODIS y L8 y entre MODIS y S2 para las fechas mencionadas en la Tabla 6.1. En la tabla de resultados, la primer columna indica los pares de comparación según el programa de procesamiento utilizado. Por ejemplo: MODIS vs L8 Acolite, indica la comparación entre la CI-a estimada por MODIS y la CI-a estimada por Landsat 8 procesada con Acolite. Luego, el valor n representa la cantidad de celdas de la grilla en común entre las dos imágenes.

	MODIS vs:	n	R ²	RMSE	RSD (%)	BIAS
20170130	L8 Acolite	786	0.65	0.76	103	0.21
	S2 Acolite	343	0.46	0.81	86	0.16
	L8 L2gen	778	0.74	0.40	68	1.00
	S2 L2gen	373	0.25	2.38	194.68	2.48
20180830	L8 Acolite	802	0.29	0.58	19.59	0.42
	S2 Acolite	334	0.73	0.49	43.53	0.56
	L8 L2gen	983	0.75	0.19	12.30	0.84
	S2 L2gen	347	0.87	0.15	8.28	1.11
20181101	L8 Acolite	764	0.22	0.84	112.00	0.11
	S2 Acolite	369	0.04	0.72	214.35	0.24
	L8 L2gen	780	0.77	0.41	84.66	0.67
	S2 L2gen	370	0.72	0.84	57.59	1.47
20181203	L8 Acolite	786	0.40	0.69	30.32	0.30
	S2 Acolite	328	0.87	0.52	39.40	0.47
	L8 L2gen	967	0.72	0.30	38.71	0.74
	S2 L2gen	343	0.88	0.28	63.91	0.75
20191003	L8 Acolite	793	0.34	0.70	9.35	0.29
	S2 Acolite	367	0.29	0.34	18.17	0.41
	L8 L2gen	975	0.62	0.44	12.45	0.56
	S2 L2gen	367	0.63	0.42	7.16	0.58


Tabla 6.3: Métricas de evaluación para las comparaciones L8 vs. MODIS y S2 vs. MODIS

Análisis del día 30/01/2017

Para este día, los datos se distribuyeron de una manera más amplia, como puede verse en los gráficos de dispersión de las Figuras 6.6 y 6.7, así como también en los histogramas de frecuencia en la Figura 6.8. Aquí, en particular la Figura 6.8 (c), se visualiza la dispersión de los valores estimados con S2 a través de SeaDAS, donde la mayoría osciló entorno a los 5 mgm^{-3} , pero también se registraron valores de Cl-a superiores a los 20 mgm^{-3} (corroborando el sesgo que presentó la predicción).




(a) Acolite L8




(b) L2gen L8

Figura 6.6: Modelo II de regresión lineal para la relación entre las estimaciones de L8 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen L8 procesada con Acolite y la figura (b) con L2gen (b). Fecha 30/01/2017.



(a) Acolite S2



(b) L2gen S2

Figura 6.7: Modelo II de regresión lineal para la relación entre las estimaciones de S2 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen S2 procesada con Acolite y la figura (b) con L2gen (b). Fecha 30/01/2017.

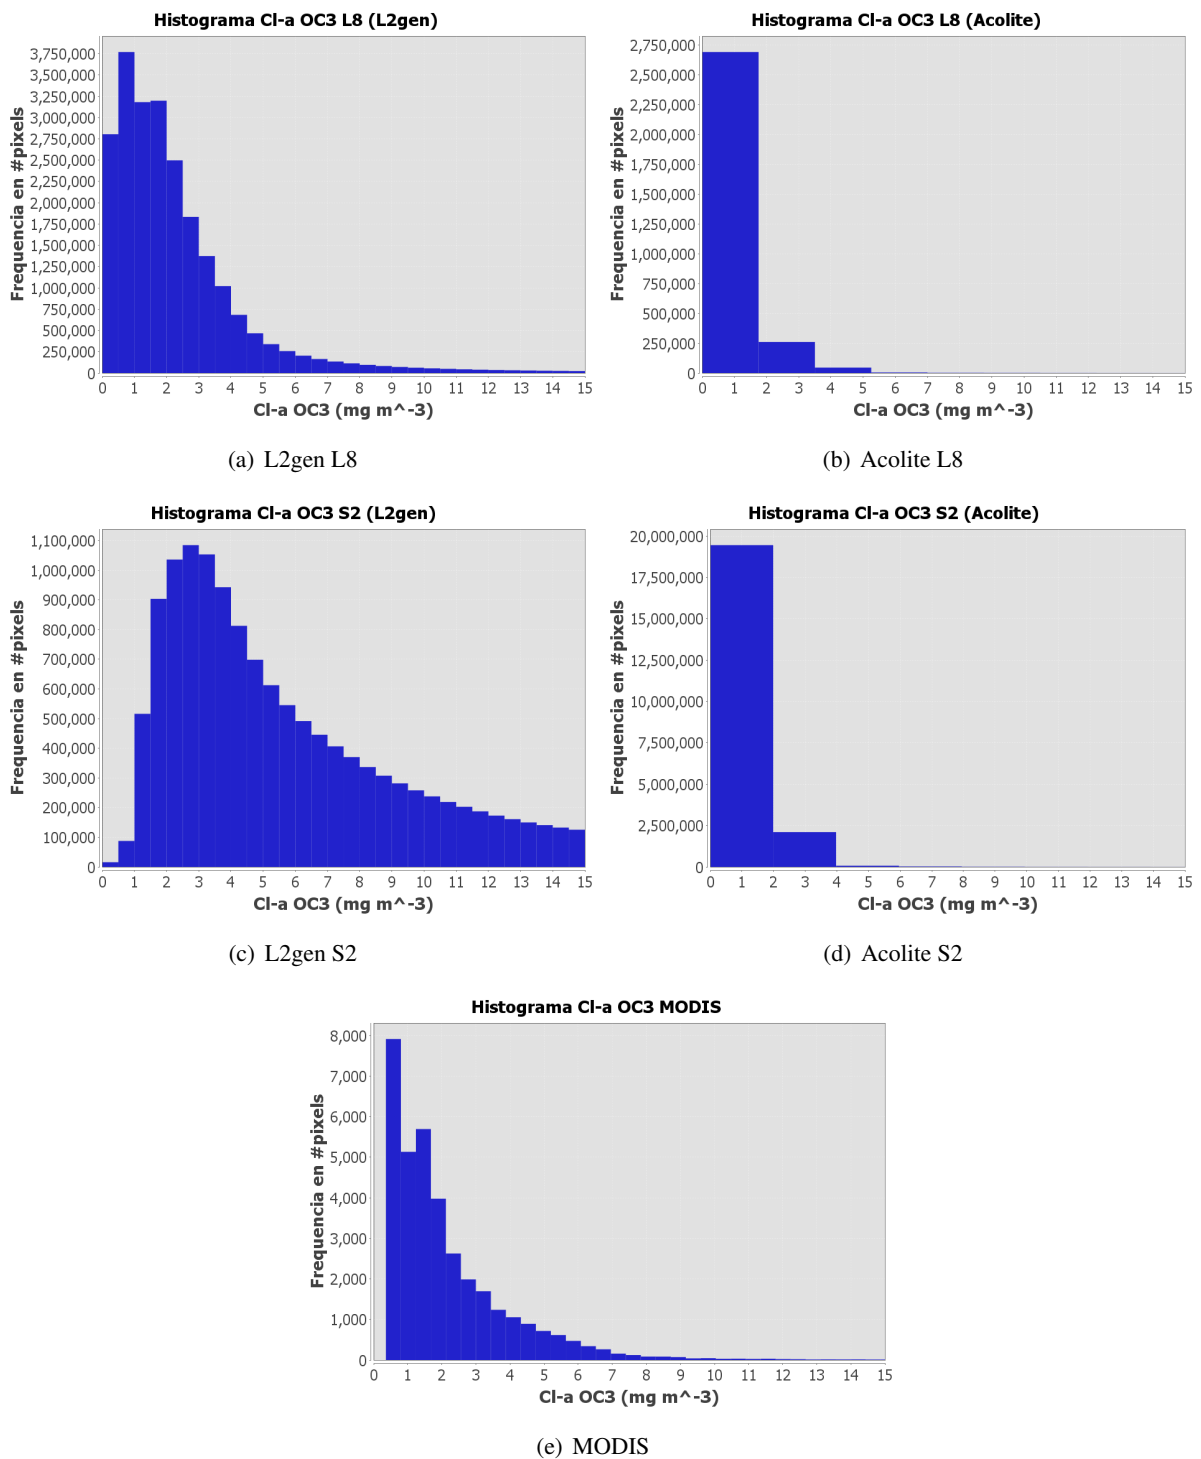


Figura 6.8: Histogramas de frecuencia para cada imagen L8 y S2, procesadas con Acolite y L2gen, junto al histograma de la imagen de referencia MODIS. Fecha: 30/01/2017.

Las imágenes de la fecha 30/01/2017 presentaron valores elevados de CI-a, principalmente en la franja costera hacia el sur (ver mapa de la Figura 6.9). Con ambos programas se generaron estimaciones aproximadas a MODIS. A excepción de S2 procesada con L2gen ($r^2 = 0.25$), con un error y un coeficiente de variación muy altos (RMSE=2.38 y RSD=194.68 % respectivamente) tendió a sobre-estimar en un 48 % (Tabla 6.3).

6.3 RESULTADOS

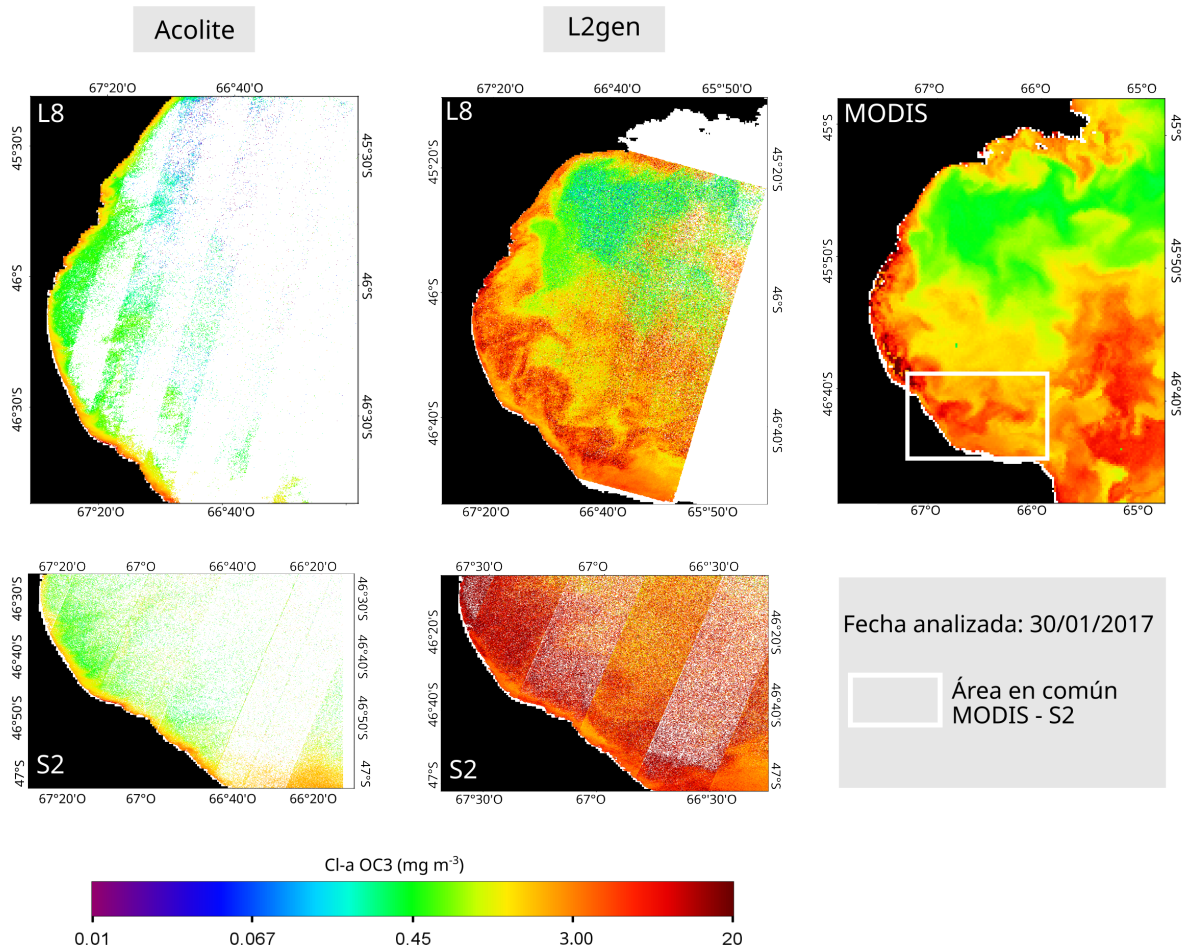


Figura 6.9: Mapas de Cl-a obtenidos con el algoritmo OC3 a partir de Landsat 8 y Sentinel-2 en comparación con el mapa de Cl-a de MODIS. En la parte superior se muestran los mapas correspondientes a Landsat 8 procesados con Acolite y L2gen, y el mapa de referencia de MODIS. En la parte inferior, se encuentran los mapas de S2 generados con Acolite y L2gen. El recuadro blanco sobre MODIS indica el área que cubre la imagen S2. Fecha: 30/01/2017.

Para analizar en detalle la imagen S2, se llevó a cabo un control de los flags. Se observó que los siguientes flags se activaron en la mayoría de los píxeles: TURBIDW (detección de aguas turbias); LOWLW (radiancia emergente muy baja); CHLFAIL (falla derivada del algoritmo OC3); MAXAERTER (iteraciones para la corrección NIR alcanzaron su máximo); MODGLINT (moderada contaminación por glint) y ATMWARN (advertencia de corrección atmosférica). La falla pudo haberse debido al desempeño del algoritmo que emplea L2gen sobre Sentinel-2 por la presencia de aguas ópticamente complejas, lo que explica que Acolite haya logrado mejores estimaciones. Ahora si analizamos los flags de la imagen MODIS, el único flag representativo en cuanto a cantidad de píxeles, fue el indicador de aguas turbias (flag TURBIDW). Este flag se activa, de manera coincidente, sobre el área que abarca la imagen S2 de esta fecha (Figura 6.10).




Figura 6.10: Flag TURBIDW en color gris oscuro de la imagen MODIS sobre la zona sur del Golfo San Jorge. Fecha: 30/01/2017.

Análisis del día 30/08/2018

Respecto al día 30/08/2018, las estimaciones de S2 con SeaDAS fueron buenas en relación con los valores de concentración de Cl-a de MODIS ($r^2=0.87$) con el error más bajo (RMSE= 0.15). Si bien hubo una tendencia a la sobre-estimación en un 11 %, esto no afectó el buen ajuste de los datos. En cambio, en la misma fecha, las estimaciones de L8 con Acolite presentaron una muy baja correlación ($r^2=0.29$) (Tabla 6.3). Todos estos resultados se reflejan en los mapas de la Figura 6.11, donde se observa que con L2gen se obtienen mapas de Cl-a con los mismos patrones que MODIS. Con Acolite, el bandeo continuo apareciendo como en las fechas analizadas, especialmente en la imagen L8.

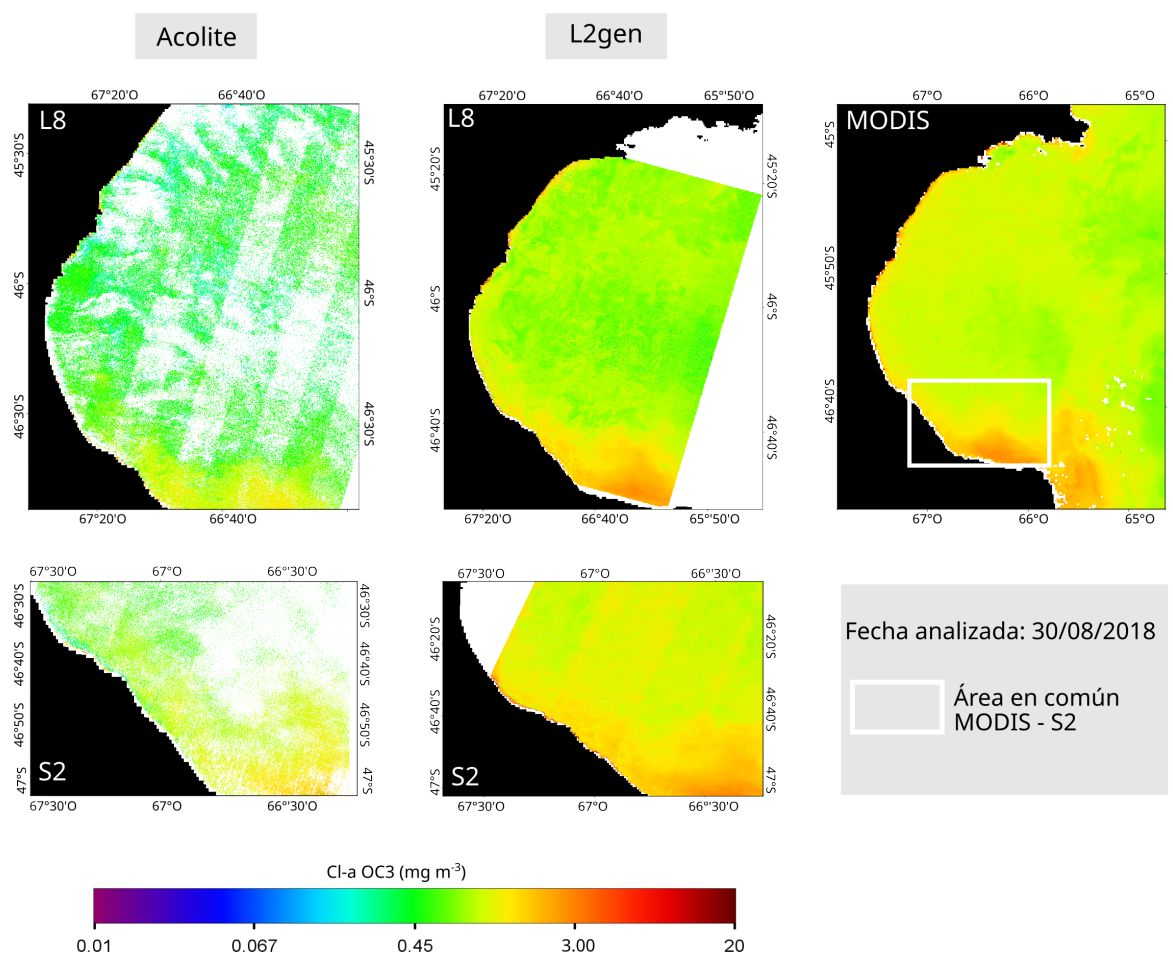




Figura 6.11: Mapas de Cl-a obtenidos con el algoritmo OC3 a partir de Landsat 8 y Sentinel-2 en comparación con el mapa de Cl-a de MODIS. En la parte superior se muestran los mapas correspondientes a Landsat 8 procesados con Acolite y L2gen, y el mapa de referencia de MODIS. En la parte inferior, se encuentran los mapas de S2 generados con Acolite y L2gen. El recuadro blanco sobre MODIS indica el área que cubre la imagen S2. Fecha: 30/08/2018.

Los gráficos de dispersión de las Figuras 6.12 y 6.13 muestran que, en comparación de otras fechas, los puntos cercanos y alejados de la costa, se encuentran más agrupados. La causa de esto podría deberse a que esta fecha presenta valores de Cl-a distribuidos espacialmente de manera más homogénea en todo el Golfo, como bien se aprecia en los mapas de la Figura 6.11. Es decir, no hay patrones que indiquen floraciones algales o áreas con valores muy elevados de Cl-a.




(a) Acolite L8

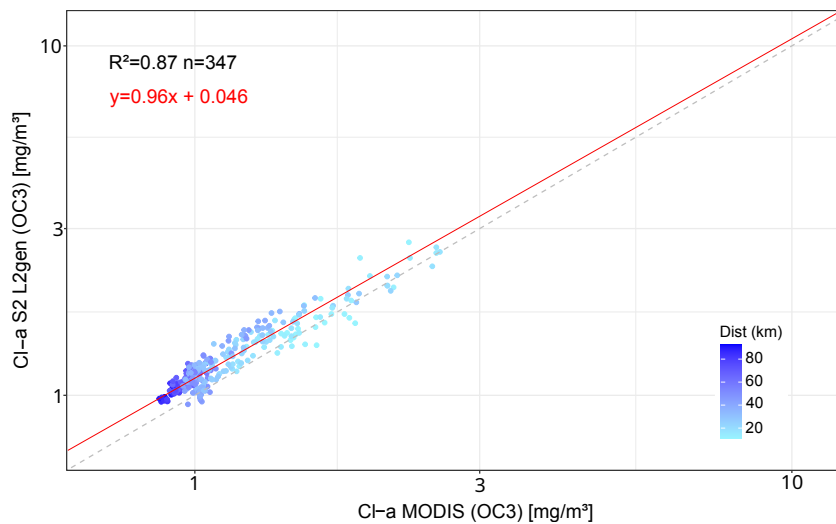


(b) L2gen L8

Figura 6.12: Modelo II de regresión lineal para la relación entre las estimaciones de L8 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen L8 procesada con Acolite y la figura (b) con L2gen (b). Fecha 30/08/2018.



(a) Acolite S2



(b) L2gen S2

Figura 6.13: Modelo II de regresión lineal para la relación entre las estimaciones de S2 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen S2 procesada con Acolite y la figura (b) con L2gen (b). Fecha 30/08/2018.

Para analizar más en detalle la distribución de valores, se generaron los histogramas de frecuencia correspondientes a esta fecha (Figura 6.14). Las estimaciones con L2gen para S2 (figura 6.14 (c)) y L8 (figura 6.14 (a)), oscilaron entre entre 0.70 y 1.75 mgm^{-3} , siendo 1-1.25 mgm^{-3} los valores más frecuentes. Este patrón fue similar a los valores de MODIS. En cambio, el valor más frecuente de las estimaciones de L8 generadas con Acolite, fue mucho menor ($\sim 0,25 \text{mgm}^{-3}$).

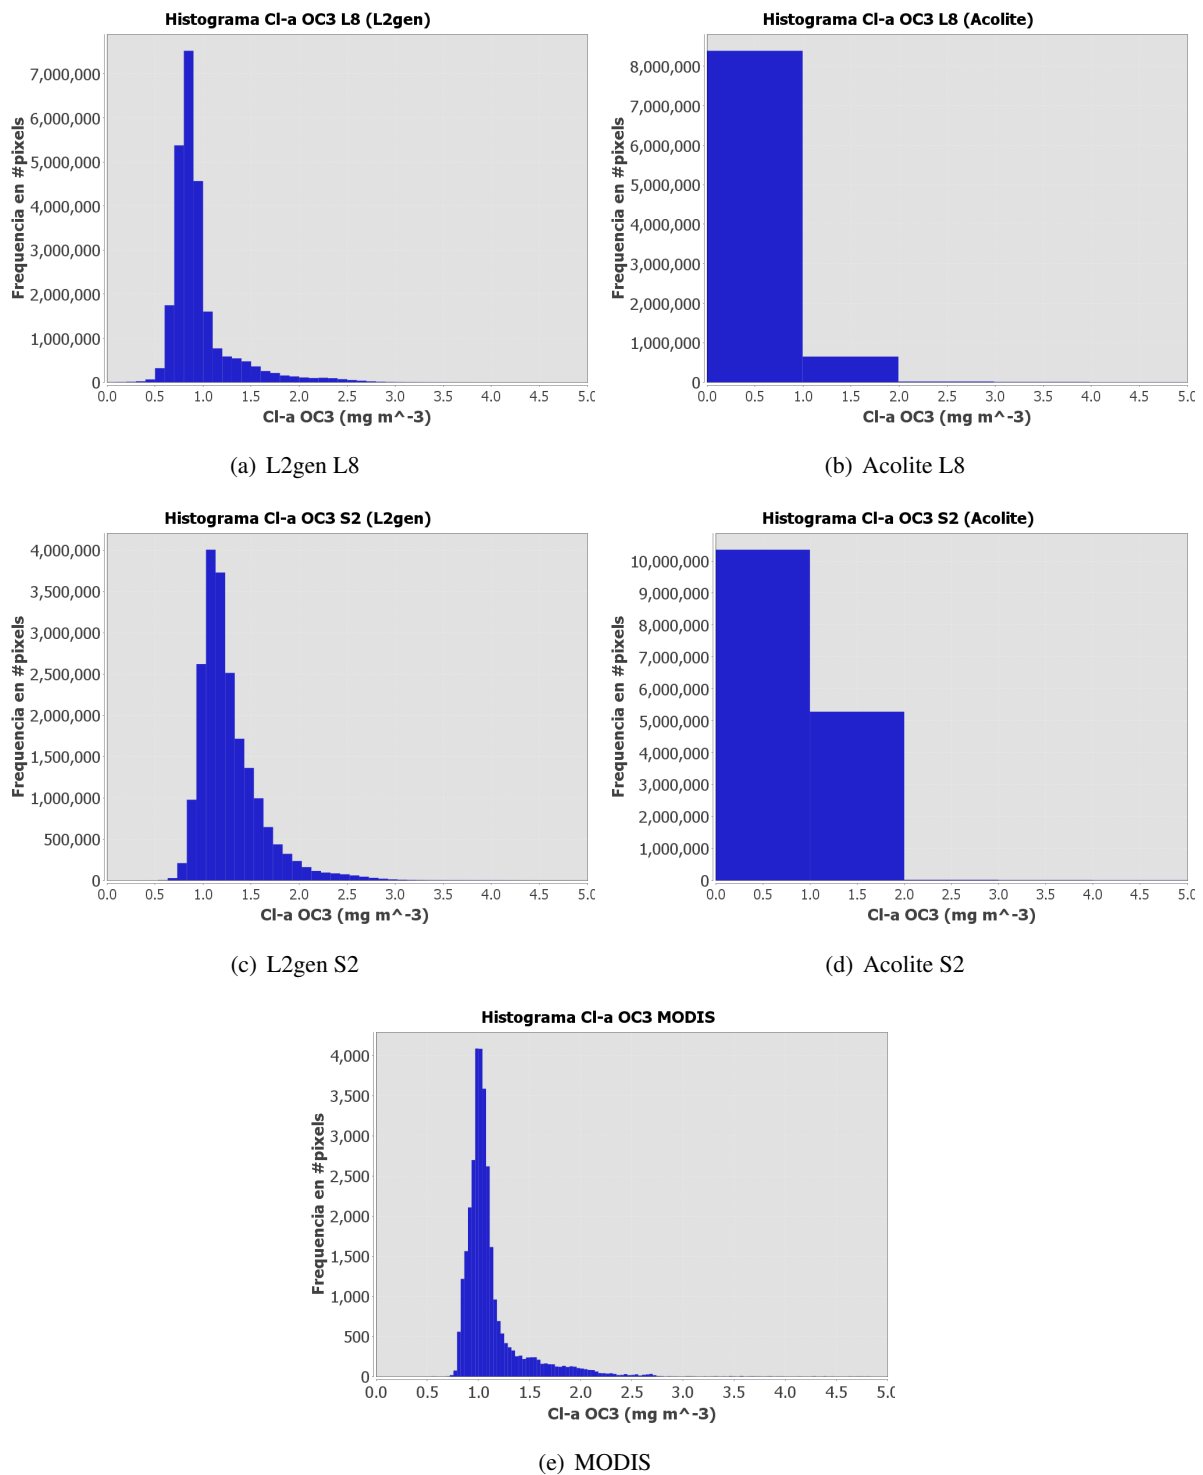




Figura 6.14: Histogramas de frecuencia para cada imagen L8 y S2, procesadas con Acolite y L2gen, junto al histograma de la imagen de referencia MODIS. Fecha: 30/08/2018

Análisis de la fecha: 01/11/2018

En esta fecha analizada, se obtuvieron las correlaciones más bajas de todas las fechas. Como se puede ver en la tabla 6.3, tanto los valores de L8 y S2 generados con Acolite, resultaron ser las estimaciones menos precisas. En tanto los productos derivados de L2gen para ambos sensores se ajustaron mejor a los valores de MODIS, siendo $r^2 = 0,77$ en el caso de L8 y $r^2 = 0,72$ con S2 (ver Figuras 6.15 y 6.16). Como se mencionó al comienzo, estos resultados son esperables ya que L2gen es el mismo procesador que utiliza MODIS para la generación de sus productos. De estas estimaciones, sólo S2 sobre-estimó en un 47 % (bias= 1.47) los valores de referencia y con un porcentaje muy elevado en la dispersión de su datos (RSD=214.35 %).




(a) Acolite L8

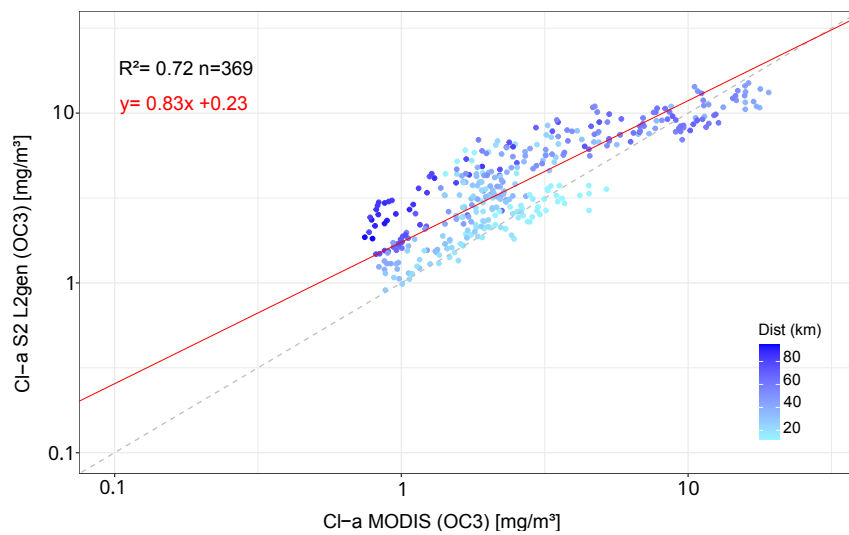


(b) L2gen L8

Figura 6.15: Modelo II de regresión lineal para la relación entre las estimaciones de L8 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen L8 procesada con Acolite y la figura (b) con L2gen (b). Fecha 01/11/2018



(a) Acolite S2



(b) L2gen S2

Figura 6.16: Modelo II de regresión lineal para la relación entre las estimaciones de S2 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen S2 procesada con Acolite y la figura (b) con L2gen (b). Fecha 01/11/2018

6.3 RESULTADOS

Las imágenes de esta fecha presentaron valores muy elevados de CI-a, tal como se puede apreciar en la Figura 6.17 donde se ven valores próximos a los $20\text{mg}/\text{m}^3$, especialmente la imagen de referencia MODIS y las imágenes de L8 y S2 procesadas con L2gen. Esto puede indicar la presencia de un florecimiento algal, como así también un error del algoritmo a causa de, por ejemplo, nubes no detectadas. Dichos factores posiblemente afectaron la bondad del ajuste de los modelos.

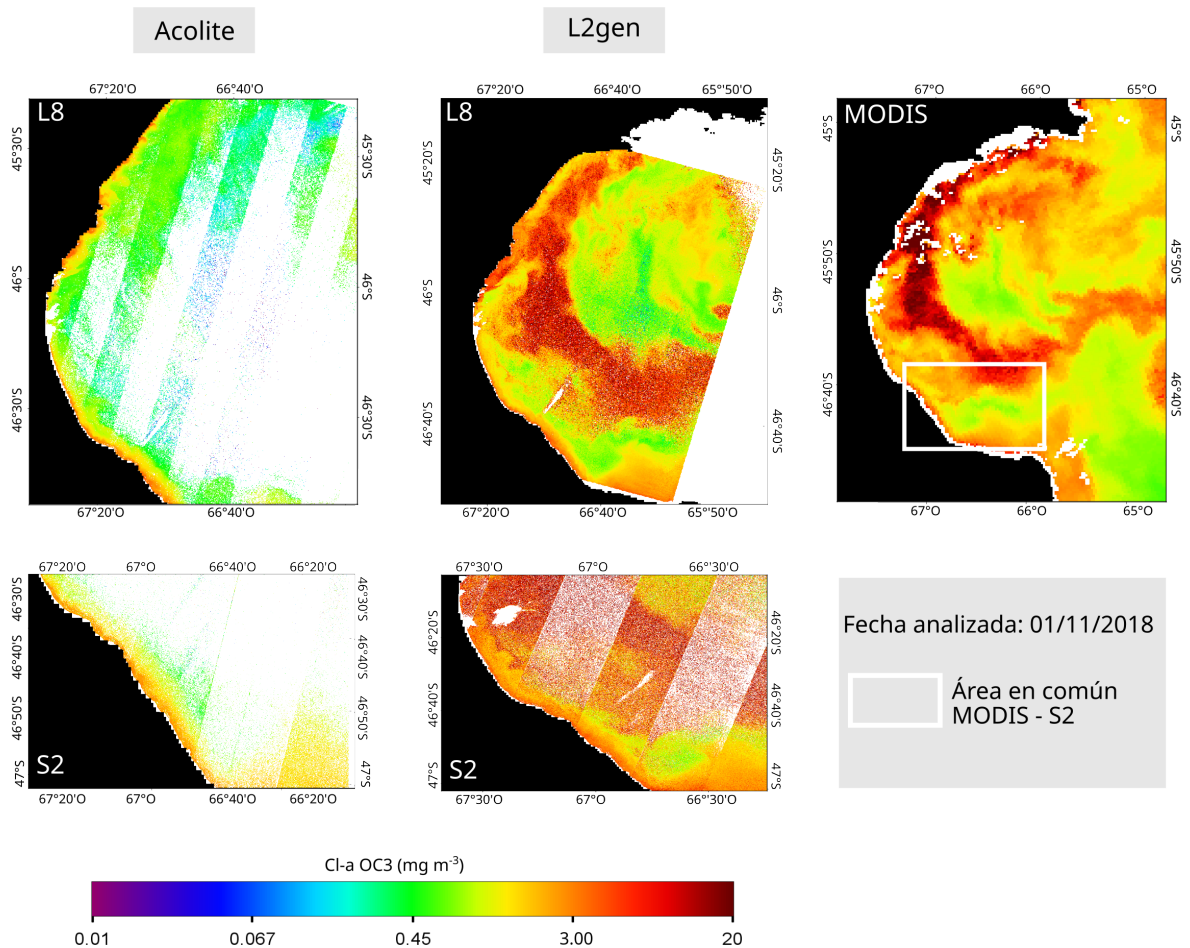


Figura 6.17: Mapas de CI-a obtenidos con el algoritmo OC3 a partir de Landsat 8 y Sentinel-2 en comparación con el mapa de CI-a de MODIS. En la parte superior se muestran los mapas correspondientes a Landsat 8 procesados con Acolite y L2gen, y el mapa de referencia de MODIS. En la parte inferior, se encuentran los mapas de S2 generados con Acolite y L2gen. El recuadro blanco sobre MODIS indica el área que cubre la imagen S2. Fecha: 01/11/2018.

Para explorar cuál pudo haber sido la causa de las estimaciones con ajustes pobres a los valores de referencia, se analizaron en detalle los indicadores de calidad (*flags*) de la imagen MODIS de este día. Como se puede ver en la Figura 6.18, los indicadores de *stray light* (STRAYLIGHT) y de falla general del producto (PRODFAIL) se encontraron activos en la zona donde los valores de CI-a satelital eran elevados ($>10\text{mg}/\text{m}^3$). En cuanto al *Stray light*, hace referencia a una luz parásita ocasionada por el brillo de los píxeles adyacentes que altera el valor de la reflectancia. Por lo general, este fenómeno ocurre en cercanías de las costas y en el borde de las nubes (Hooker et al., 2003). Dado que la escena tiene una nubosidad parcial, la cantidad de píxeles marcados fue elevada. Además, la presencia de esta luz dispersa o parásita altera la relación azul/verde, lo que conduce a una sobre-estimación significativa de la concentración de CI-a (Terauchi et al., 2014). Por otra parte, el indicador PRODFAIL indica al menos una falla en

la generación de los productos L2. A veces la falla puede deberse a una perturbación de la temperatura superficial del mar (también indicada por SSTWARN y SSTFAIL) y puede estar relacionado con diversos fenómenos (Jiang and Wang, 2013).

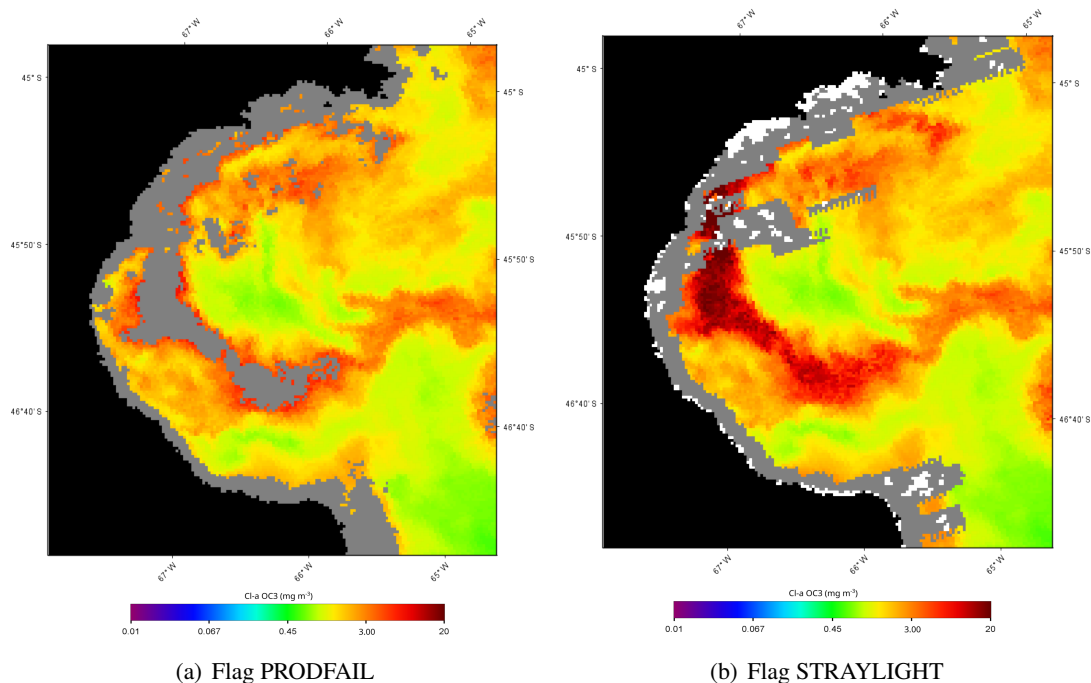


Figura 6.18: Flags que afectaron más píxeles en la imagen de nivel 2 de MODIS. Los flags de falla general del producto (a) y luz saturada (b) se muestran coloreados en gris oscuro. Fecha: 01/11/2018.

Para evaluar si estos píxeles pudieron afectar el resultado de las estimaciones, se enmascararon y excluyeron de la imagen MODIS para calcular nuevamente los estadísticos. En la Tabla 6.4 se puede observar las correlaciones resultantes, donde se muestra que sólo el caso de S2 procesada con Acolite mejoró el coeficiente de determinación (r^2 pasó de ser 0.04 a 0.11). Aún así, esta sigue siendo una correlación débil. Este aumento en el coeficiente de determinación se debe a que los valores de concentración de Cl-a estimados con S2 en la zona con flags eran bajos. Al excluir los píxeles dudosos, cuyos valores eran muy elevados, la correlación mejoró. El efecto de esta exclusión se comprende mejor al observar el gráfico de dispersión de Acolite S2 (Figura 6.16 (a)) donde los puntos cercanos a la costa (píxeles que coinciden con los flags de MODIS) están muy separados de los puntos alejados a la costa, es decir, tienen tendencias diferentes. En el resto de los gráficos de dispersión (6.15 y 6.16 (b)) se observa que los puntos alejados y cercanos a la costa tienen tendencias similares. Por eso que al excluir píxeles dudosos (que coinciden con la zona costera), la correlación no varía sino que resulta levemente más baja al reducir el número de píxeles (n) analizados. Una disminución en " n " puede afectar negativamente el valor de r^2 , ya que el modelo podría volverse menos preciso, menos capaz de explicar la variabilidad y estadísticamente menos confiable.

20181101 MODIS vs:	Con píxeles dudosos		Sin píxeles dudosos	
	n	R ²	n	R ²
L8 Acolite	764	0.22	730	0.21
S2 Acolite	369	0.04	330	0.11
L8 L2gen	780	0.77	736	0.61
S2 L2gen	370	0.72	331	0.62

Tabla 6.4: Resultados de excluir celdas que contienen píxeles con los flags STRAYLIGHT y PRODFAIL activados. El valor de "n" representa el número de celdas de la grilla incluidas en el análisis.

Comparación con una imagen S3:

Se procedió a descargar para la misma fecha una imagen Sentinel-3 (S3) desde la página de *Ocean Color*: <https://oceancolor.gsfc.nasa.gov/> para examinar si presentaba los mismos patrones de Cl-a que MODIS. El algoritmo aplicado en S3 (Chl_a) es una versión refinada del tradicional OCx. Combina el OCx de O'Reilly con el índice de color (CI) de Hu et al. (2012) y fue desarrollado principalmente para aguas marinas oligotróficas. Se define como la diferencia de las reflectancias R_{sr} de tres bandas: la verde, azul y roja (Hu et al., 2012). Si bien usan algoritmos diferentes, aquí resulta interesante hacer una interpretación visual de la imagen S3 para analizar si este sensor detecta la misma situación que MODIS.

Las imágenes de nivel 2 de procesamiento correspondiente a Cl-a de MODIS y de S3 se observan en la Figura 6.19. Se destaca la mejor resolución espacial del sensor OLCI de S3 por sobre MODIS. Los datos OLCI se adquieren en una resolución de aproximadamente 300 m (*Full Resolution-FR*) o de 1.2 km (*Reduce Resolution-RR*). El mapa aquí presentado es de 300 m. Se puede notar que ambos mapas presentan la misma distribución espacial de la concentración superficial de clorofila-a, incluyendo las regiones de valores altos.

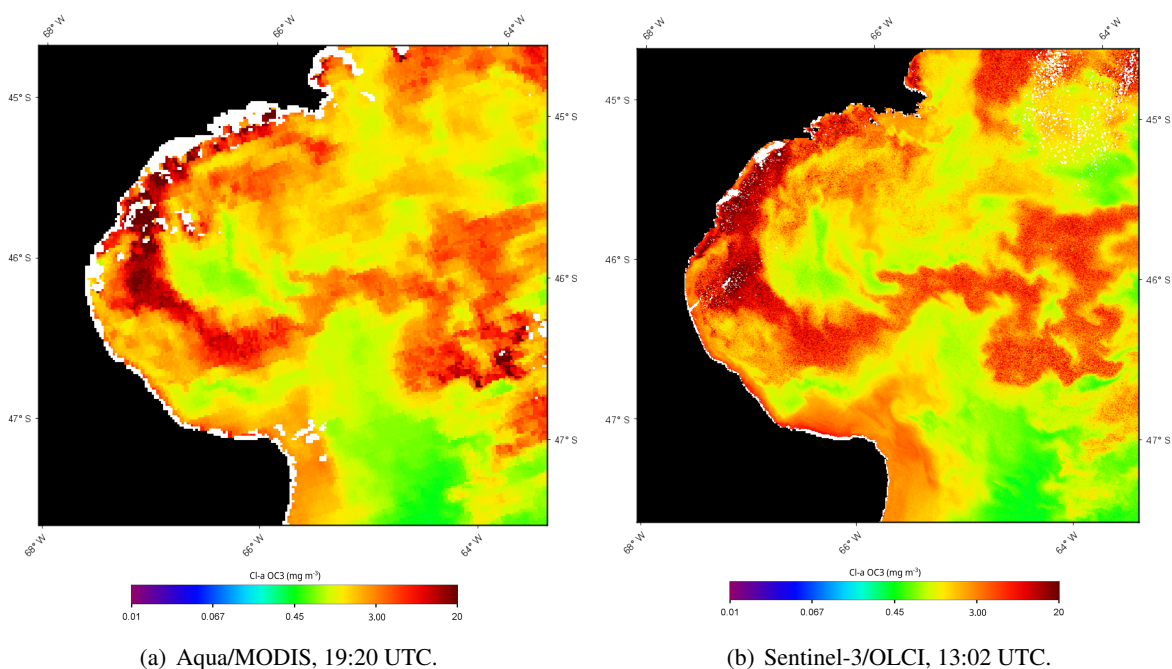


Figura 6.19: Mapas de Cl-a de MODIS y Sentinel-3, ambos son productos de nivel 2 en su resolución original. Fecha: 01/11/2018.

Se llevó a cabo un análisis de regresión para observar la relación de las estimaciones de S3 respecto de MODIS (ver Fig. 6.20). Los datos mostraron una buena relación ($r^2=0.72$), la variación de las estimaciones de MODIS pueden ser explicadas por S3. Para averiguar si el modelo podría mejorarse al excluir los píxeles de baja o mala calidad, se observaron los flags de la imagen S3. La Figura 6.21 se muestra el flag que más píxeles afectó en la imagen S3. A diferencia de MODIS, el indicador de aguas turbias (TURBIDW) fue el más notable y se activó en 86295 píxeles, en tanto el flag STRAYLIGHT en sólo en 23786 y el flag PRODFAIL correspondiente a píxeles sobre la tierra.




Figura 6.20: Modelo II de regresión lineal para la relación entre las estimaciones de Sentinel-3 vs. las estimaciones de MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión.




Figura 6.21: Flag TURBIWD en color gris sobre la imagen Sentinel-3 Fecha: 01/11/2018.

6.3 RESULTADOS


Se realizó nuevamente el análisis sin los píxeles donde el flag TURBWID estaba activo. En la Tabla 6.5 se observan los diferentes coeficientes de determinación obtenidos cuando se eliminan las celdas que contienen los píxeles dudosos (aquellos cuya calidad pudo haber sido afectada por la presencia de aguas turbias) y cuando no. Las estimaciones mostraron una correlación ligeramente mejor al excluir los píxeles enmascarados por el flag TURBWID ($r^2=0.78$ a $r^2=0.83$). Esto podría sugerir que cuando hay presencia sedimentos u otras sustancias ópticamente activas, además de la Cl-a, las estimaciones pueden verse alteradas.

20181101 MODIS vs:	Con pixeles dudosos		Sin pixeles dudosos	
	n	R ²	n	R ²
Sentinel-3	1307	0.78	889	0.83


Tabla 6.5: Resultados de excluir celdas que contienen píxeles con el flag TURBIWD activado. El valor de n representa el número de celdas de la grilla que se incluyeron en el análisis.

Análisis de la fecha: 03/12/2018

En esta fecha, si bien la mayoría de las estimaciones de L8 y S2 tendieron ser menores respecto al valor de referencia MODIS (usando Acolite, L8 subestimó en un 70% (bias=0.30) y S2 en un 53% (bias=0.47); con L2gen, L8 subestimó sólo en un 26% (bias=0.74) y S2 en un 25% (bias=0.75)), se observaron los mejores ajustes del análisis general (ver Tabla 6.3). Aquí, la CI-a derivada de S2 con L2gen, presentó el mejor ajuste de los datos ($r^2=0.88$). La CI-a obtenida con Acolite del mismo sensor, también arrojó buenos resultados ($r^2= 0.87$) (ver Figuras 6.22 y 6.23).



(a) Acolite L8



(b) L2gen L8

Figura 6.22: Modelo II de regresión lineal para la relación entre las estimaciones de L8 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen L8 procesada con Acolite y la figura (b) con L2gen (b). Fecha 03/12/2018.

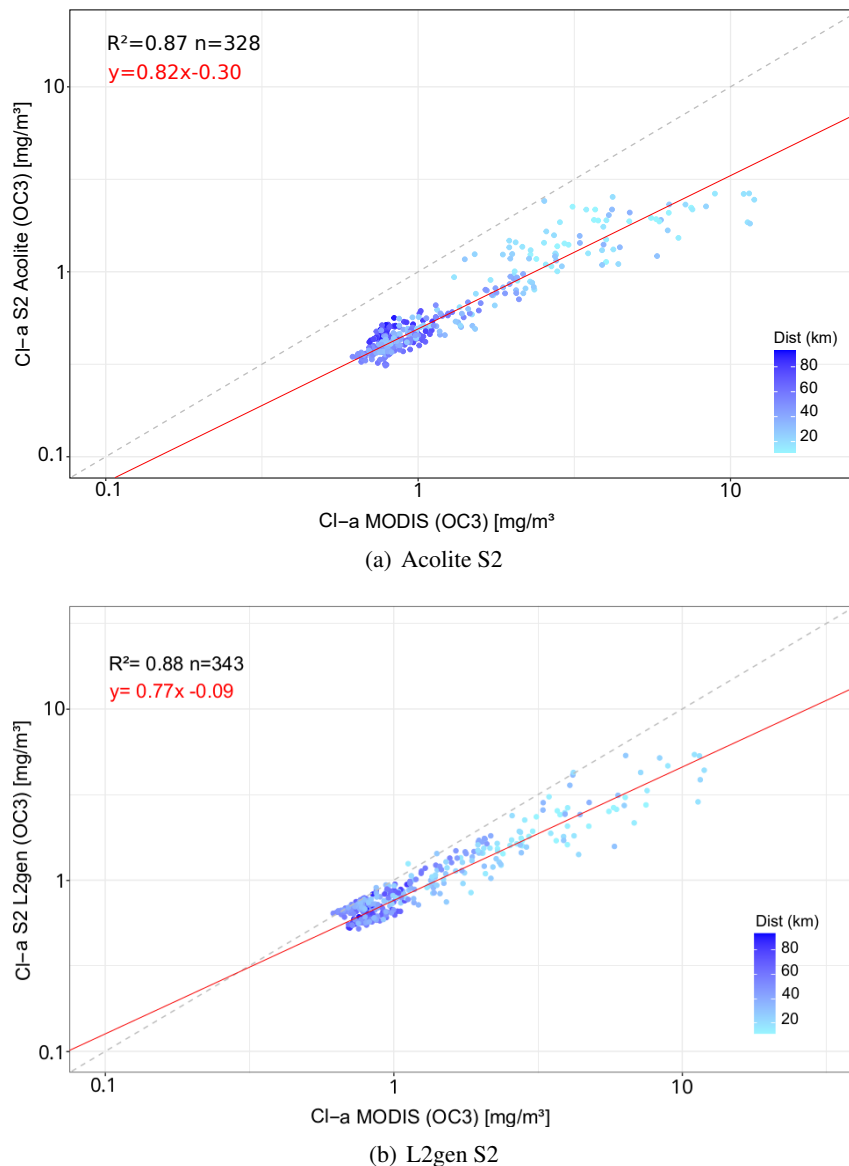


Figura 6.23: Modelo II de regresión lineal para la relación entre las estimaciones de S2 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen S2 procesada con Acolite y la figura (b) con L2gen (b). Fecha 03/12/2018.

La Figura 6.24 muestra diferentes mapas de CI-a: los mapas correspondientes a L8 y S2 procesados con Acolite y L2gen y el mapa de referencia de MODIS. Aquí es posible apreciar que en esta fecha la subestimación de los valores se dió principalmente en el centro del Golfo, y en el caso de L8 también en la zona norte de la costa. También se observa que en las imágenes L8 procesadas con Acolite y las imágenes S2 con L2gen, presentaron un efecto bandado.

Por otra parte, los datos menos dispersos respecto a su media fueron los estimados con Acolite para L8 (RSD=30.32%) y los más dispersos fueron los valores de S2 procesados con L2gen (RSD=63.91%).

La precisión de las estimaciones sobre las aguas costeras se puede analizar quitando del modelo de regresión las celdas próximas a la línea de costa. Este análisis se muestra en la Tabla 6.6, donde se exponen los resultados estadísticos cuando no se consideran las celdas ubicadas a menos de 40 km

de la costa. Podemos observar que en esta fecha sólo el caso de L8 procesado con L2gen logró una mejor correlación ($r^2=0.86$). En el gráfico b) de la Figura 6.22 se pueden ver como los puntos más claros (aquellos cercanos a la costa) están más dispersos y alejados de la línea $y=x$.

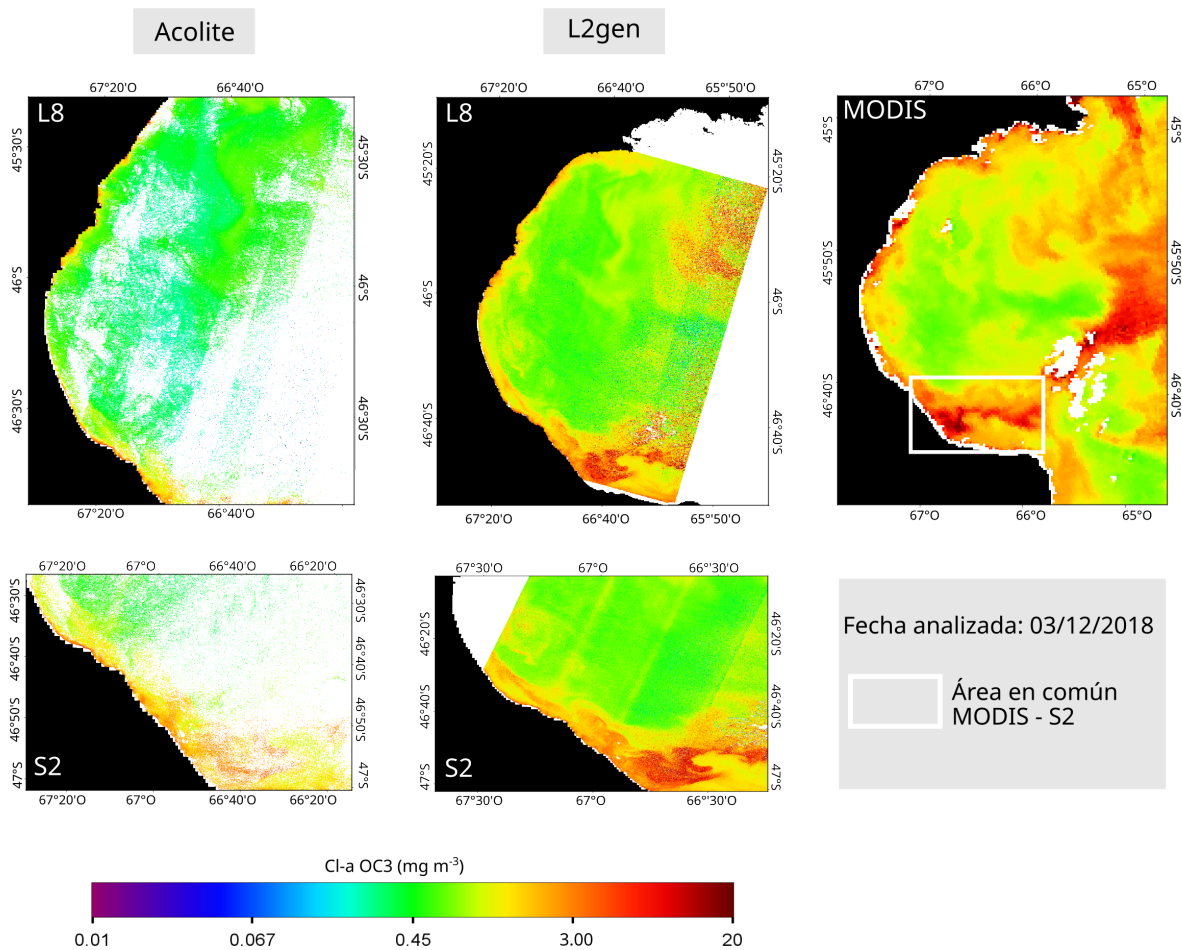



Figura 6.24: Mapas de CI-a obtenidos con el algoritmo OC3 a partir de Landsat 8 y Sentinel-2 en comparación con el mapa de CI-a de MODIS. En la parte superior se muestran los mapas correspondientes a Landsat 8 procesados con Acolite y L2gen, y el mapa de referencia de MODIS. En la parte inferior, se encuentran los mapas de S2 generados con Acolite y L2gen. El recuadro blanco sobre MODIS indica el área que cubre la imagen S2. Fecha: 03/12/2018.

20181203 MODIS vs:	Se incluye la costa		Se excluye la costa (>40 km)	
	n	R ²	n	R ²
L8 Acolite	786	0.40	350	0.02
S2 Acolite	328	0.87	133	0.52
L8 L2gen	967	0.72	454	0.86
S2 L2gen	343	0.88	133	0.60


Tabla 6.6: Resultados estadísticos obtenidos a partir de una distancia mayor a 40 km de la costa. El valor de n representa el número de celdas incluidas en el análisis Fecha: 03/12/2018.

Análisis del día 03/10/2019

Por último, el análisis de las imágenes para el día 03/10/2019 tuvo resultados similares al análisis de la fecha 01/11/2018 (Tabla 6.3). Las estimaciones derivadas de L2gen presentan una correlación aceptable frente a las estimaciones de MODIS ($r^2= 0.62$ y $r^2= 0.63$ para L8 y S2 respectivamente), pero no así con Acolite ($r^2= 0.34$ para L8 y $R^2= 0.29$ para S2). En las Figuras 6.25 y 6.26 se observan estas correlaciones y también cómo los puntos que representan los píxeles más próximos a la costa se encuentran más dispersos respecto a los píxeles alejados de la costa.




(a) Acolite L8




(b) L2gen L8

Figura 6.25: Modelo II de regresión lineal para la relación entre las estimaciones de L8 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen L8 procesada con Acolite y la figura (b) con L2gen (b). Fecha 03/10/2019.



(a) Acolite S2



(b) L2gen S2

Figura 6.26: Modelo II de regresión lineal para la relación entre las estimaciones de S2 vs. MODIS. La línea roja representa la recta de regresión y la línea de puntos, la recta $y = x$. La escala de colores indica la distancia a la costa, siendo los puntos azules más claros los más cercanos a la costa. En la esquina superior izquierda del gráfico se muestran los resultados de la regresión. La figura (a) corresponde a la imagen S2 procesada con Acolite y la figura (b) con L2gen (b) Fecha 03/10/2019.

6.3 RESULTADOS

Los mapas representados en la Figura muestran que los valores de referencia MODIS son elevados en la mayor parte del GSJ, mientras que en los mapas de las estimaciones realizadas con L8 y S2 procesadas con Acolite y L2gen, los valores elevados de Cl-a se encuentran en su mayoría próximos a la costa.

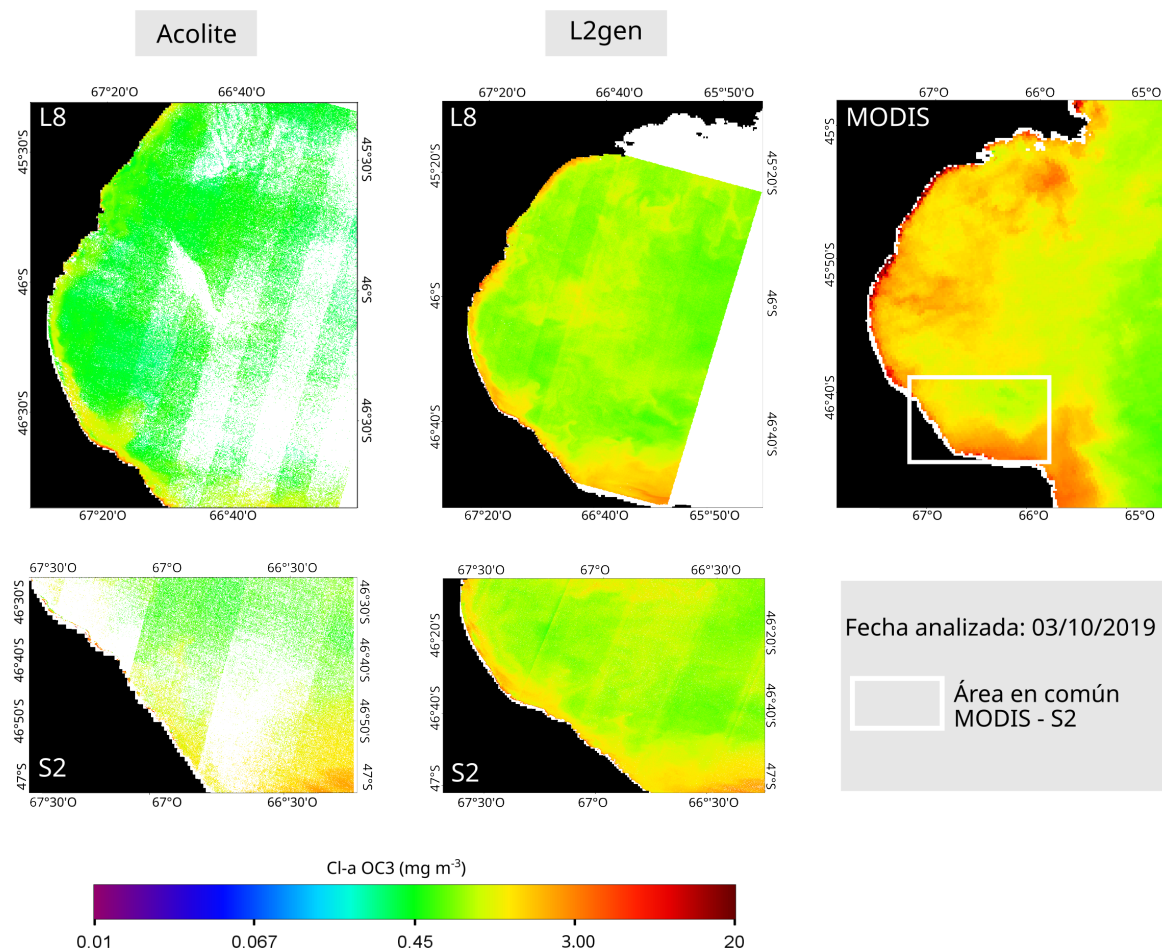


Figura 6.27: Mapas de Cl-a obtenidos con el algoritmo OC3 a partir de Landsat 8 y Sentinel-2 en comparación con el mapa de Cl-a de MODIS. En la parte superior se muestran los mapas correspondientes a Landsat 8 procesados con Acolite y L2gen, y el mapa de referencia de MODIS. En la parte inferior, se encuentran los mapas de S2 generados con Acolite y L2gen. El recuadro blanco sobre MODIS indica el área que cubre la imagen S2. Fecha: 03/10/2019.

Para averiguar si la distancia a la costa impacta negativamente en las correlaciones, se dispuso a eliminar las celdas de hasta 40 km de distancia a la costa. El mismo procedimiento realizado para la fecha 03/12/2018. La Tabla 6.7 muestra los resultados de las nuevas regresiones. Las únicas estimaciones que lograron una mejoría en el ajuste fueron aquellas derivadas de L8 con L2gen. Esto tiene sentido dado que L8 en esta fecha tendió a subestimar las altas concentraciones de Cl-a, como se evidencia en el gráfico (b) de la Figura 6.25 y el bias negativo del 44%. A diferencia de las estimaciones con Acolite, donde fuera de la costa, los valores de Cl-a son muy bajos en comparación de MODIS que además de las concentraciones muy elevadas sobre la costa, el resto del Golfo presenta valores altos. Al quitar celdas costeras, la correlación se debilita.

20191003 MODIS vs:	Se incluye la costa		Se excluye la costa (>40 km)	
	n	R ²	n	R ²
L8 Acolite	793	0.34	352	0.20
S2 Acolite	367	0.29	133	0.002
L8 L2gen	975	0.62	456	0.71
S2 L2gen	367	0.63	133	0.18

Tabla 6.7: Resultados de excluir celdas ubicadas en zona costera. Fecha: 03/10/2019.

6.4. Resumen y Conclusiones

En ese capítulo se desarrolló una metodología para comparar valores de *Cl-a* generadas por las pasadas coincidentes de diferentes sensores satelitales en la zona de estudio del GSJ, fijando un sensor como referente. El primer aspecto a tener en cuenta fue que la cantidad de imágenes coincidentes depende de las órbitas de los sensores. Si bien en esta tesis se hizo una selección manual de las imágenes, existe una forma de encontrarlas en forma automática. Es una consideración para trabajos futuros.

Por otro lado, para comparar sensores con diferentes resoluciones fue necesario referenciar todas las mediciones a una grilla común. En este trabajo, para poder llevar a cabo las comparaciones se generó una grilla que abarcó todo el GSJ con celdas de 5x5 km, proyectada en UTM/WGS'84 (Universal Transverse Mercator).

Se puso especial foco en las imágenes registradas por sensores no específicamente diseñados para el estudio del color del mar, tales como Landsat 8 y Sentinel-2 para evaluar su desempeño respecto de MODIS. Con el fin de obtener la concentración de *Cl-a* fue necesario llevar a cabo un procesamiento específico en cada caso, dado que estos sensores terrestres no incluyen este parámetro en sus productos publicados. Para este procesamiento se usaron dos softwares libres, a saber: Acolite y SeaDASS (módulo L2gen). En ambos programas se trabajaron como entrada imágenes nivel 1 de L8 y S2 (Landsat 8 OLI/TIRS C1 Level-1 y Sentinel-2 Level-1C TOA, respectivamente). El esquema de corrección atmosférica para cada sensor fue el mismo. Es decir que cada programa se configuró para que se aplique la corrección atmosférica que emplea las bandas NIR, que es el mismo esquema utilizado en la obtención de productos L2 de MODIS. En este caso, el producto *Chlor_a* de la NASA obtenido con el algoritmo OC3 a partir de las reflectancias *Rrs* del azul y verde (ver detalles en la sección 6.2.3). Estas reflectancias derivan del algoritmo de corrección atmosférica que emplea dos bandas en la región del NIR (por ej., 748 nm y 869 nm para MODIS), donde las contribuciones de radiación emergente del agua son generalmente pequeñas y se pueden estimar con precisión a través de un enfoque iterativo como se describe en Bailey et al. (2010).

Una vez encontradas las coincidencias y procesadas las imágenes, se ubicaron los datos en una grilla común. Se comparó la mediana de los valores ubicados dentro de cada celda correspondientes a la *Cl-a* derivada por cada sensor. Para realizar las comparaciones entre sensores se tomó como referencia la *Cl-a* estimada con MODIS. En todos los casos se calcularon estadísticos previamente establecidos, a saber: coeficiente de determinación (r^2), error cuadrático medio (RMSE), bias y la desviación estándar relativa (RSD).

El proceso de comparación también incluyó la elaboración de mapas de *Cl-a* para todos los casos y el uso de histogramas de frecuencia en las fechas donde era necesario analizar más en detalle la distribución de los datos. Para todas las fechas se presentaron los gráficos de regresión lineal con el propósito de detectar valores atípicos y observar tendencias en la relación entre cada par de variables. A fin de poder evaluar la influencia de los valores en píxeles sobre la costa, se integró a los gráficos de regresión una escala referida a la distancia a la costa. También se tuvieron en cuenta los indicadores de calidad de la imagen MODIS para la evaluación de aquellas fechas que presentaron errores muy elevados o estimaciones poco precisas.

En la mayoría de las fechas estudiadas se obtuvieron buenas correspondencias entre las estimaciones de los sensores OLI y MSI respecto a MODIS. Por ejemplo, el 03/12/2018 fue la fecha con las mejores correlaciones y una aceptable (el caso de L8 Acolite). En tanto el 30/08/2018 también registró buenas correlaciones y muy buenos ajustes, a excepción de un caso (L8 Acolite). En cambio, 01/11/2018 fue la fecha con los valores de determinación más bajos donde además se observó que la imagen MODIS contenía varios píxeles de calidad dudosa. Para este caso especial se complementó el análisis con una imagen Sentinel-3 (mapa de CI-a e indicadores de calidad) para contar con otra fuente de datos satelitales y tratar de determinar las causas de los errores y confirmar la ocurrencia de eventos como las floraciones algales. En ambas imágenes de color del mar se observaron regiones de alta concentración de CI-a que influyeron en el buen desempeño de los algoritmos que están ajustados a condiciones de aguas abiertas (aguas caso I), activando varios indicadores de calidad. En MODIS se activaron los indicadores PROD-FAIL y STRAYLIGHT y en S3 el indicador TURBIWD. Se tuvo en cuenta que en primavera se registra la mayor extensión de valores elevados de CI-a en el Golfo SJ (Andreo, 2015; Glembocki et al., 2015).

En las fechas donde se trabajaron con flags (30/01/2017, 01/11/2018), se tuvo presente que la exclusión o no un píxel en el procesamiento, en función de los indicadores de calidad, debe considerar los elementos identificados en la imagen y en los registros de campo.

Como ya está establecido, para los productos de color del mar los píxeles con nubes se enmascaran por defecto. Sin embargo, hay muchos píxeles claros sin enmascarar cerca de las nubes que se ven afectados por la contaminación relacionada a la nubosidad (Jiang and Wang, 2013). Esta contaminación produce valores elevados de radiancia TOA en píxeles cercanos, alterando la calidad de los datos de color del mar. De modo que, en lo posible, no deben usarse y deben ser enmascarados (Jiang and Wang, 2013). Además de las nubes, existen otros factores que afectan la calidad de la escena: el ángulo cenital solar y ángulo visual del sensor, el viento; o fenómenos como el sunglint (la reflexión especular del sol en el agua), el skylint (la reflexión especular del cielo en el agua) o whitecaps (la reflexión por las burbujas disueltas en el agua). Muchos de estos factores ya están identificados por los flags. El filtrado de píxeles a veces puede implicar un enmascaramiento excesivo de píxeles, con la exclusión de información que no necesariamente es incorrecta. Por ejemplo, para las imágenes MODIS de este trabajo, el flag STRAYLIGHT generalmente abarcaba la mayoría de los píxeles de la costa, lo que llevaría al enmascaramiento de muchas celdas de la zona de estudio. En relación a esto, un trabajo reciente de validación de datos de reflectancia VIIRS y MODIS en aguas costeras y marinas (Barnes et al., 2019), se señaló que el flag STRAYLIGHT afecta los datos adquiridos sobre las costas y estuarios, y puede reducir la disponibilidad de datos útiles cercanos de la costa. El trabajo concluye que no existe un consenso real sobre qué flags particulares deben aplicarse para procesar y validar datos satelitales. Por otra parte, el efecto bandedo que presentaron muchas de las imágenes L8 y S2 no se corrigió aplicando filtros para evitar modificar los valores reales de los píxeles. Esta alteración descrita en Vanhellefont and Ruddick (2016), también estuvo presente en trabajos como Caballero et al. (2022) y Pahlevan et al. (2017c).

Los resultados aquí alcanzados indican que el sensor MSI tuvo un buen desempeño en relación a MODIS, especialmente cuando se utiliza L2gen para su procesamiento. La distribución espacial de la CI-a influyó en la precisión de las estimaciones, cuando la distribución era uniforme, el ajuste fue mejor y la relación entre los valores comparados fue más fuerte. Por otra parte, para realizar un análisis

más detallado del efecto de los píxeles cercanos a la costa, debería tenerse en cuenta incluso escenas o *tiles* que abarquen áreas más lejanas de la región costera, con el fin de evaluar de forma más precisa el rendimiento.

En relación a OLI, los resultados mostraron que también tuvo un buen desempeño en relación a MODIS, principalmente cuando se utiliza L2gen. A diferencia de MSI, se pudo observar el efecto negativo de la cercanía a la costa, sobre todo cuando los píxeles situados en este sector tenían valores de Cl-a muy elevados. Asimismo, la distribución heterogénea de la Cl-a en el GSJ no impactó en el rendimiento del algoritmo OC3 calculado con este sensor.

Por otro lado, la variabilidad relativa de las estimaciones no afectó el desempeño de OLI y MSI en relación a MODIS. La mayoría de las estimaciones con CV o RSD elevado presentaron un buen r^2 . Esto podría significar que aunque los datos sean muy variables en relación con su media, los modelos de regresión fueron capaces de explicar una parte significativa de esta variabilidad y ajustarse bien a la tendencia general de los datos. Por lo que resulta interesante considerar la variabilidad como una característica natural de los datos.

En cuanto al efecto de los píxeles dudosos, sólo se evaluó cuando la imagen MODIS presentaba valores extremos de Cl-a y habían nubes en la escena. En general, los píxeles dudosos coincidían con la región costera. Sólo las estimaciones de S2 con Acolite mejoraron muy levemente al eliminar estos píxeles del análisis. En el resto de los casos se observó que los píxeles alejados y cercanos a la costa tuvieron tendencias similares. Por tal motivo, al excluir píxeles dudosos (coincidentes con la costa), la correlación entre las estimaciones de OLI/MSI y MODIS no varió.

Los sensores MSI y OLI resultaron útiles para estudiar la calidad del agua en el Golfo San Jorge. Como pudo verse en este capítulo, se logró cuantificar la concentración de Cl-a con valores similares a los que se pueden obtener con un sensor del color del mar como MODIS. Sin embargo, la precisión de las estimaciones puede verse afectada cuando el golfo presenta una distribución espacial poco uniforme de Cl-a o cuando se registran valores muy elevados de este parámetro. En estos casos se debería evaluar si OC3 OLI y MSI son apropiados para toda la zona de estudio, y además tener en consideración la corrección atmosférica aplicada a las imágenes.

La metodología de inter-comparación satelital aquí desarrollada, aportó información sobre la posibilidad de usar datos de diferentes sensores para estudiar las aguas del Golfo San Jorge, en este caso, a través de la variable Cl-a. Se trabajó con datos de OLI/Landsat 8, MSI/Sentinel-2 y MODIS/Aqua, no obstante, esta metodología también es aplicable en más sensores como por ejemplo OLCI/Sentinel-3, utilizado en una de las fechas del análisis. Se demostró que si se establece una buena correspondencia temporal y espacial entre los datos, es factible combinarlos y lograr un monitoreo continuo, a diferencia de aquellos seguimientos donde se utiliza un solo sensor. Tal como se mencionó al comienzo de este capítulo, MODIS puede proporcionar información sobre la variación temporal de los procesos naturales por su tiempo de revisita diaria y OLI con MSI son capaces de proporcionar información sobre la variación espacial. Esto posibilita la fusión de datos, proceso que se refiere a la combinación de datos coincidentes de más de un sensor satelital (IOCCG, 2007). Para el estudio del color del mar, esto es de suma importancia ya que permitiría mejorar la cobertura y la resolución temporal, y en menor medida, mejorar la precisión de la información de las variables que se desean estudiar.

Discusiones y Conclusiones generales

En esta tesis se llevó a cabo el estudio de la CI-a satelital en el Golfo San Jorge (GSJ). Primero se analizaron datos correspondientes a dos campañas oceanográficas realizadas en los años 2014 y 2016, y se generaron mapas de CI-a satelital coincidentes con los momentos de muestreo de dichas campañas. Se usaron imágenes de los sensores de color del mar MODIS/Aqua y VIIRS/Suomi-NPP para evaluar el desempeño de OC3 en la zona de estudio. Luego, se analizaron solamente datos satelitales a través de una comparación intersatelital en fechas correspondientes a los años 2017, 2018 y 2019. Para esta instancia, se utilizaron imágenes MODIS/Aqua, OLI/Lansat 8 y MSI/Sentinel-2.

Respecto a la zona de estudio, el Golfo San Jorge es una de las regiones de mayor productividad y diversidad de ambientes del Mar Argentino (Fernández et al., 2007a). Es el golfo más grande del litoral marítimo argentino, donde no hay aportes fluviales y existen frentes de marea a lo largo de toda su costa que producen intensas mezclas verticales y horizontales (Matano and Palma, 2018). Estas son zonas altamente productivas, por lo que los valores elevados de clorofila satelital se asocian a estos sistemas frontales (Andreo, 2015; Romero et al., 2006), a diferencia de otras aguas costeras donde la presencia de materia orgánica disuelta o sedimentos en suspensión es mucho mayor. Por otro lado, la presencia de fuertes vientos es otra característica importante del GSJ. Estos vientos transportan grandes cantidades de polvo terrestre que contienen nutrientes y otros compuestos que son depositados en la superficie del mar (Paparazzo et al., 2018; Crespi-Abril et al., 2018). Los sedimentos atmosféricos constituyen otra fuente de nutrientes para los productores primarios, pero también pueden generar turbidez en las aguas e incluso aportar contaminantes. La heterogeneidad que caracteriza las aguas del GSJ es destacable tanto en términos espaciales como temporales. Esto se debe a la mezcla generada por las corrientes de marea, a la estratificación de las aguas (Glembocki et al., 2015; Torres et al., 2018) y la advección estacional de aguas de baja salinidad (Akselman, 1996). Estos factores influyen en las características físicas, químicas y biológicas del golfo, lo que contribuye a su diversidad y complejidad (Torres et al., 2018).

Uno de los ejes de la tesis fue la puesta en práctica de protocolos para la comparación de datos de diferentes orígenes: *in situ* con satelitales, y satelitales de diferentes sensores. Para ello se analizaron distintas métricas estadísticas para poder establecer errores, entre ellas: el coeficiente de determinación (r^2), el error relativo (ER) y su error cuadrático medio (RMSE), el rango semi-intercuartil, el coeficiente de variación, el bias y el error absoluto medio (MAE).

En el caso de las comparaciones entre CI-a medida *in situ* y la satelital, el valor de referencia o verdad de campo fueron los datos de las campañas de medición. Para este caso se pudo observar una buena correspondencia entre las mediciones de campo del 2014 y 2016 con los valores estimados por MODIS ($r^2 = 0,59 - 0,67$ respectivamente) y VIIRS ($r^2 = 0,54 - 0,82$ respectivamente). No obstante, es clara la necesidad de contar con más datos de campo para poder generar o ajustar algoritmos regionales que se adecúen mejor a nuestros mares y costas.

Una vez chequeada que la CI-a satelital del sensor MODIS/Aqua es representativa de los valores *in situ* (verdad de campo), se la tomó como valor de referencia para la comparación de CI-a intersatelital. Además, el sensor MODIS/Aqua cuenta con una larga serie temporal de datos ampliamente validados por la comunidad científica a nivel global. A nivel regional en nuestra zona de estudio también fue validado (Dogliotti, 2007; Dogliotti et al., 2009, 2014; Williams et al., 2016, 2018). Debido a la baja disponibilidad de mediciones continuas en campo, la intercomparación de la CI-a satelital entre diversos sensores resultó ser una buena alternativa para incrementar la cantidad de datos en la región de estudio. A partir de la intercomparación de datos de múltiples sensores, con la posterior validación y calibración cruzada, se genera la denominada fusión o combinación de datos. Como se mencionó en el Capítulo 6, esta fusión permite identificar sesgos o tendencias en datos originados por sensores o algoritmos, lo que resultaría imposible de detectar únicamente en comparaciones con pocas mediciones *in situ*. En el análisis de las imágenes para la comparación intersatelital, se pudo observar la dinámica particular que presenta la zona costera del GSJ. En los días 30/01/2017, 01/11/2018 y 03/10/2019 se registraron concentraciones elevadas de CI-a y la activación de varios indicadores de calidad de las imágenes MODIS y S3 (para el caso del día 01/11/2018). Al mismo tiempo, los algoritmos de L8 y S2 mostraron baja correlación con los datos MODIS, evidenciando la necesidad de ajustes adicionales tanto en las correcciones atmosféricas como en los algoritmos de CI-a. En este sentido, es importante el análisis de la absorción y/o dispersión de los componentes ópticamente activos como el CDOM, la CI-a o el material en suspensión (propiedades óptica inherentes), al igual que la característica espectral del agua (propiedad óptica aparente) en las diferentes áreas que integran el GSJ, Tal como se desarrolló por primera vez en el trabajo de Williams et al. (2016).

En cuanto a la disponibilidad de datos satelitales, es importante mencionar que si bien aun MODIS recopila datos valiosos y genera productos consistentes, la vida útil del sensor (tanto en Aqua como en Terra) está concluyendo. Se estima que Terra MODIS concluirá la misión en diciembre de 2025, mientras que Aqua MODIS permanecerá operativo y generará el conjunto completo de productos hasta el final de la misión en agosto de 2026 (<https://aqua.nasa.gov/sites/default/files/AquaStatus.pdf>). Cuando MODIS finalice su vida operativa, se espera la continuidad de los datos con VIIRS a bordo de los satélites Suomi NPP y JPSS-1. Es importante considerar que actualmente se encuentra operativo el sensor OLCI (Instrumento de color del Océano y la Tierra, en inglés *Ocean*

and Land Colour Instrument) de la misión satelital Sentinel-3 operada conjuntamente por la ESA y EUMETSAT. La continuidad de la serie temporal de MODIS está garantizada por el sensor VIIRS, por lo que los análisis realizados también serán válidos para la misión SABIA-Mar. Como trabajo a futuro es importante también incorporar el sensor Sentinel-3 de ESA/EUMETSAT. Como se menciona en IOCCG (2007), resulta oportuno para las aplicaciones del color del mar, aprovechar las características en común de las misiones satelitales actuales y futuras como por ejemplo el tipo de órbita polar, longitudes de onda, respuesta espectral; para combinar y fusionar datos. Trabajos como los de Gregg et.al (1998) han demostrado que la combinación o fusión de datos de múltiples satélites coincidentes puede mejorar en gran medida la cobertura diaria y global del océano. Se necesitan diversas misiones para complementar y mejorar la ciencia del color del mar. El objetivo principal de la fusión de datos es mejorar la resolución temporal y la cobertura y, en menor medida, mejorar la precisión.

En ambos procesos de comparación de datos, se visualizaron algunos aspectos que podrían generar diferencias entre los valores:

- ❖ La presencia de componentes ópticamente activos distintos de Cl-a, como materia orgánica disuelta coloreada (CDOM) o sedimentos, puede hacer que los algoritmos que relacionan las reflectancias azul y verde, arrojen valores sesgados.
- ❖ La diversidad de especies de fitoplacton identificadas en el GSJ, también puede modificar las características ópticas del agua, causando una variación en la radiación emergente del agua, independientemente de los cambios en la concentración de Cl-a. Por lo que es posible recuperar valores erróneos de Cl-a.
- ❖ En toda la región costera del GSJ, la concentración de Cl-a presenta una mayor variabilidad espacial. Sería recomendable utilizar algoritmos que se ajusten mejor a esta característica para lograr estimaciones más precisas.
- ❖ La variabilidad espacio-temporal de las propiedades ópticas marinas puede afectar en diferentes maneras. Esta característica debe tenerse en cuenta al comparar y combinar productos de color del mar resultantes de mediciones realizadas en diferentes momentos con sensores de diferentes resoluciones.
- ❖ Las condiciones ambientales pueden afectar el desempeño del esquema de corrección atmosférica y producir discrepancias entre los productos satelitales.
- ❖ La calidad de las imágenes utilizadas es un aspecto importante en las comparaciones y puede ser analizado a partir de los indicadores de calidad correspondiente.

Para finalizar, es importante destacar la importancia de contar con datos in-situ (ya sea de boyas o de campañas oceanográficas) de todas las variables que generará la misión SABIA-Mar. Como se ha podido ver en este trabajo, estos datos constituyen la única forma de establecer algoritmos regionales capaces de generar información certera de nuestros mares y costas. Como aporte concreto a la misión SABIA-Mar, tanto los protocolos de comparación como los estadísticos para establecer medidas de errores serán incluidos en los planes de calibración y validación de los productos de la misión (CONAE, 2016).

Bibliografía

- Acha, E. M., Mianzan, H. W., Guerrero, R. A., Favero, M., and Bava, J. (2004). Marine fronts at the continental shelves of austral south america: Physical and ecological processes. *Journal of Marine Systems*, 44(1):83–105.
- Ahn, J., Park, Y., Kim, W., and Lee, B. (2016). Simple aerosol correction technique based on the spectral relationships of the aerosol multiple-scattering reflectances for atmospheric correction over the oceans. *Optics Express*, 24.
- Akselman, R. (1996). *Estudios ecológicos en el Golfo San Jorge y adyacencias (Atlántico Sudoccidental): Distribución, abundancia y variación estacional del fitoplancton en relación a factores físico-químicos y la dinámica hidrológica*. PhD thesis, Facultad de Ciencias Exactas y Naturales. Universidad de Buenos Aires.
- Andreo, V. (2015). Variabilidad espacio-temporal de florecimientos fitoplanctónicos en el talud y plataforma continental de la Patagonia Argentina usando sensores remotos. Master's thesis, Universidad Nacional de Cordoba.
- Antione, D., André, J.-M., and Morel, A. (1996). Oceanic primary production: Estimation at global scale from satellite (Coastal Zone Color Scanner) chlorophyll. *Global Biogeochemical Cycles*, 10.
- Arena, M., Delgado, A. L., Pratalongo, P., Celleri, C., and Vitale, A. (2021). Validation of the atmospheric correction of Landsat OLI imagery and turbidity retrievals using AERONET-OC data from the Bahía Blanca site. In *2021 XIX Workshop on Information Processing and Control (RPIC)*, pages 1–6.
- Ariza, A. and Posada, E. (2013). Descripción y corrección de productos Landsat 8 LDCM (Landsat Data Continuity Mission) Versión 1.0.
- Bailey, S. W., Franz, B. A., and Werdell, P. J. (2010). Estimation of near-infrared water-leaving reflectance for satellite ocean color data processing. *Opt. Express*, 18(7):7521–7527.
- Bailey, S. W. and Werdell, P. J. (2006). A multi-sensor approach for the on-orbit validation of Ocean Color satellite data products. *Remote Sensing of Environment*, 102:12–23.
- Baldoni, A., Molinari, G., Reta, R., and Guerrero, R. (2015). *Atlas de temperatura y salinidad de la plataforma continental del Atlántico Sudoccidental: períodos cálido y frío*. Instituto Nacional de Investigación y Desarrollo Pesquero (INIDEP), Mar del Plata, 1a edition.
- Barnes, B. B., Cannizzaro, J. P., English, D. C., and Hu, C. (2019). Validation of VIIRS and MODIS reflectance data in coastal and oceanic waters: An assessment of methods. *Remote Sensing of Environment*, 220:110–123.

- Bigg, G., Jickells, T., Liss, P., and Osborn, T. (2003). The role of the oceans in climate. *International Journal of Climatology*, 23:1127 – 1159.
- Caballero, I., Roca, M., Santos-Echeandía, J. J., Bernárdez, P. P., and Navarro, G. (2022). Use of the Sentinel 2 and Landsat 8 satellites for Water Quality Monitoring: An early warning tool in the Mar Menor Coastal Lagoon. *Remote Sensing*, 14-12.
- Carbajal, J. C., Rivas, A., and Chavanne, C. (2018). High-Frequency Frontal Displacements South of San Jorge Gulf during a Tidal Cycle Near Spring and Neap Phases: Biological implications between tidal states. *Oceanography*, 31:60–69.
- Carreto, J., Carignan, M., and Montoya, N. (2007). *Ecología del fitoplancton en los sistemas frontales del Mar Argentino*, volume 5, page 169.
- Chai, T. and Draxler, R. R. (2014). Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7:1247–1250.
- Chuvieco, E. and Salinero, E. (1996). *Fundamentos de Teledetección Espacial*. Manuales universitarios. Rialp.
- Codd, G. A., Morrison, L. F., and Metcalf, J. S. (2005). Cyanobacterial toxins: risk management for health protection. *Toxicology and Applied Pharmacology*, 203(3):264–272. Risk Cyanobacterial Toxins: Occurrence, Ecology, Detection, Toxicology and Health Effects Assessment.
- Compagnucci, M. and Tauro, C. (2016). Algorithm Theoretical Bases Document: Diffuse Attenuation Coefficient at 490 nm ($k_d(490)$). CONAE SABIA-Mar Science Team Document, CONAE.
- CONAE (2016). Misión SABIA-Mar. <https://www.argentina.gob.ar/ciencia/conae/misiones-espaciales/sabia-mar>.
- Council, N., Sciences, D., Board, S., Studies, D., Board, O., and Operations, C. (2011). *Assessing the Requirements for Sustained Ocean Color Research and Operations*. National Academies Press.
- Crespi-Abril, A., Gonçalves, R., De Cian, A., Barbieri, E., Papparazzo, F., and Soria, G. (2018). Dust concentration in San Jorge Gulf and adjacent shelf (Patagonia, Argentina). pages 19–24.
- Cucchi Colleoni, D. and Carreto, J. (2001). Variación estacional de la biomasa fitoplanctónica en el Golfo San Jorge. Resultados de las campañas de investigación OB- 01/00, OB- 03/00, OB- 07/00, OB- 10/00 y OB- 12/00. INIDEP, Informe Técnico 49, 30 pp.
- Dans, S., Cefarelli, A., Galván, D., Góngora, M., Martos, P., Varisco, M., Alvarez Colombo, G., Blanc, S., Bos, P., Bovcon, N., Charo, M., Cinquini, M., Derisio, C., Dogliotti, A., Ferreyra, G., Funes, M., Giberto, D., Halm, C., Hozbor, M., and Zarate, M. (2021). El Golfo San Jorge como Área Prioritaria de Investigación, Manejo y Conservación en el marco de la Iniciativa Pampa Azul. *Ciencia e Investigación*, 71:21–43.
- Dierssen, H. M. (2010). Perspectives on empirical approaches for ocean color remote sensing of chlorophyll in a changing climate. *Proceedings of the National Academy of Sciences of the United States of America*, 107 40:17073–8.
- Dogliotti, A. (2007). *Estimación de la biomasa fitoplanctónica mediante el sensoramiento remoto del color del mar y datos de campo en la Plataforma Continental Patagónica*. PhD thesis, Universidad de Buenos Aires.

- Dogliotti, A., Lutz, V., and Segura, V. (2014). Estimation of primary production in the southern Argentine continental shelf and shelf-break regions using field and remote sensing data. *Remote Sensing of Environment*, 140:497–508.
- Dogliotti, A., Schloss, I., Almandoz, G., and Gagliardini (2009). Evaluation of SeaWiFS and MODIS chlorophyll a products in the Argentinean Patagonian Continental Shelf. *International Journal of Remote Sensing*, 30:251–273.
- ESA (2015). *Sentinel-2 User Handbook*.
- Falkowski, P. G. (2012). Ocean Science: The power of plankton. *Nature*, 483:S17–S20.
- Fernández, M. (2006). *Características físico-químicas de los sedimentos del Golfo San Jorge y su relación con los organismos bentónicos del sector*. PhD thesis, Universidad de Nacional de Mar del Plata.
- Fernández, M., Carreto, J., Mora, J., and Roux, A. (2005). Physico chemical characterization of the benthic environment of the golfo san jorge, argentina. *Journal of the Marine Biological Association of the United Kingdom*, 85(6):1317–1328.
- Fernández, M., Cucchi Colleoni, D., Roux, A., Marcos, A., and Fernández, E. (2007a). Caracterización físico-química del sistema bentónico en el sector sur del Golfo San Jorge, Argentina. *Revista de biología marina y oceanografía*, 42:177–192.
- Fernández, M., Mora, J., Roux, A., Colleoni, D., and Gasparoni, J. (2007b). New contribution on spatial and seasonal variability of environmental conditions of the golfo san jorge benthic system, argentina. *Journal of the Marine Biological Association of the UK*, 88:227 – 236.
- Fleming, A. and Korb, R. (2004). A comparison of satellite and cruise chlorophyll-a measurements in the Scotia Sea, Antarctica. IEEE International Geoscience and Remote Sensing Symposium, 2004. IGARSS '04. volume 5, pages 3485–3488.
- Flores Melo, X., Schloss, I., Chavanne, C., Almandoz, G., Latorre, M., and Ferreyra, G. (2018). Phytoplankton Ecology during a Spring-Neap Tidal Cycle in the Southern Tidal Front of San Jorge Gulf, Patagonia. *Oceanography*, 31:70–80.
- Franz, B., Bailey, S., Kuring, N., and Werdell, J. (2014). Ocean Color Measurements from Landsat-8 OLI using Seadas.
- Franz, B., Bailey, S., Kuring, N., and Werdell, J. (2015). Ocean color measurements with the Operational Land Imager on Landsat-8: Implementation and evaluation in SeaDAS. *Journal of Applied Remote Sensing*, 9:096070.
- Franz, B., MacDonald, M., Ruebens, M., and Wang, L. (2005). The seaDAS Processing and Analysis System: SeaWiFS, MODIS, and Beyond. *AGU Fall Meeting Abstracts*.
- Fu, G., Schieber, B., Settle, K., Darzi, M., McClain, C., and Arrigo, K. (1996). SeaDAS: A processing package for ocean color satellite imagery. *Proceedings twelfth int. conf. on interactive inform. and processing systems for meteorol., oceanogr., and hydrol*, pages 451–456.
- Garcia, C., Tavano Garcia, V., and McClain, C. (2005). Evaluation of SeaWiFS chlorophyll algorithms in the Southwestern Atlantic and Southern oceans. *Remote Sensing of Environment*, 95:125–137.
- Glembocki, N. G., Noemí, G., Góngora, M. E., Gagliardini, D. A., and Orensanz, J. M. (2015). Synoptic oceanography of San Jorge Gulf (argentina): A template for Patagonian red shrimp (*Pleoticus muelleri*) spatial dynamics. *Journal of Sea Research*, 95:22–35.

- Glorioso, P. D. (1987). Temperature distribution related to shelf-sea fronts on the Patagonian Shelf. *Continental Shelf Research*, 7(1):27–34.
- Gordon, H. and Voss, K. (2004). MODIS normalized water-leaving radiance algorithm theoretical basis document.
- Gordon, H. R. and Wang, M. (1994). Retrieval of water-leaving radiance and aerosol optical thickness over the oceans with SeaWiFS: a preliminary algorithm. *Appl. Opt.*, 33(3):443–452.
- Gregg, W. W. and Casey, N. W. (2004). Global and regional evaluation of the SeaWiFS chlorophyll data set. *Remote Sensing of Environment*, 93.
- Gregg, W. W. and Rousseaux, C. S. (2014). Decadal trends in global pelagic ocean chlorophyll: A new assessment integrating multiple satellites, in situ data, and models. *Journal of Geophysical Research Oceans*, 119:5921–5933.
- Groom, S., Sathyendranath, S., Ban, Y., Bernard, S., Brewin, R., Brotas, V., Brockmann, C., Chauhan, P., Choi, J.-k., Chuprin, A., Ciavatta, S., Cipollini, P., Donlon, C., Franz, B., He, X., Hirata, T., Jackson, T., Kampel, M., Krasemann, H., Lavender, S., Pardo-Martinez, S., Mélin, F., Platt, T., Santoleri, R., Skakala, J., Schaeffer, B., Smith, M., Steinmetz, F., Valente, A., and Wang, M. (2019). Satellite Ocean Colour: Current Status and Future Perspective. *Frontiers in Marine Science*, 6.
- Guerrero, R. and Piola, A. (1997). *Masas de agua en la Plataforma Continental Argentina*, volume 1, pages 107–118.
- Guidi, L., Tattini, M., and Landi, M. (2017). *How Does Chloroplast Protect Chlorophyll Against Excessive Light?*
- Gómez, J. D., Pérez, D. R., Martín, C. M., Rodríguez, Y. C., and G., D. R. (2012). *Estudio de aguas continentales mediante teledetección*. UNED España.
- Herr, D. and Galland, G. (2009). *The Ocean and Climate Change: Tools and Guidelines for Action*. IUCN.
- Hoepffner, N. and Sathyendranath, S. (1994). Determination of the major groups of phytoplankton pigments from the absorption spectra of total particulate matter. *J. Geophys. Res.*, 98.
- Hooker, S., Firestone, E., Patt, F., Barnes, R., Eplee, R., E, R., Franz, B., Robinson, W., Feldman, G., and Bailey, S. (2003). Algorithm Updates for the Fourth Seawifs Data Reprocessing.
- Hooker, S., Firestone, E., Zibordi, G., Berthon, J.-F., D'Alimonte, D., Maritorena, S., Mclean, S., Sildam, J., and McClain, C. (2002). Results of the second SeaWiFS Data Analysis Round Robin, march 2000 (DARR-00).
- Hu, C., Chen, Z., Clayton, T. D., Swarzenski, P., Brock, J. C., and Muller-Karger, F. E. (2004). Assessment of estuarine water-quality indicators using MODIS medium-resolution bands: Initial results from Tampa Bay, FL. *Remote Sensing of Environment*, 93:423–441.
- Hu, C., Lee, Z., and Franz, B. (2012). Chlorophyll a algorithms for oligotrophic oceans: A novel approach based on three-band reflectance difference. *Journal of Geophysical Research: Oceans*, 117(C1).
- IOCCG (2000). *Remote Sensing of Ocean Colour in Coastal, and Other Optically-Complex Waters*, volume No. 3 of *Reports of the International Ocean Colour Coordinating Group*. IOCCG, Dartmouth, Canada.

- IOCCG (2006). *Remote Sensing of Inherent Optical Properties: Fundamentals, Tests of Algorithms, and Applications*, volume No. 5 of *Reports of the International Ocean Colour Coordinating Group*. IOCCG, Dartmouth, Canada.
- IOCCG (2007). *Ocean-Colour Data Merging*, volume No. 6 of *Reports of the International Ocean Colour Coordinating Group*. IOCCG, Dartmouth, Canada.
- IOCCG (2008). *Why Ocean Colour? The Societal Benefits of Ocean-Colour Technology*, volume No. 7 of *Reports of the International Ocean Colour Coordinating Group*. IOCCG, Dartmouth, Canada.
- IOCCG (2010). *Atmospheric Correction for Remotely-Sensed Ocean-Colour Products*, volume No. 10 of *Reports of the International Ocean Colour Coordinating Group*. IOCCG, Dartmouth, Canada.
- IOCCG (2019). *Uncertainties in Ocean Colour Remote Sensing*, volume No. 18 of *Reports of the International Ocean Colour Coordinating Group*. IOCCG, Dartmouth, Canada.
- Isla, F., Iantanos, N., and Estrada, E. (2002). Playas reflectivas y disipativas macromareales del Golfo San Jorge, Chubut. *Latin American Journal of Sedimentology and Basin Analysis*, 9(2):155–164.
- Jeffrey, S. and Vesk, M. (2005). Introduction to marine phytoplankton and their pigments signatures. *Phytoplankton Pigments in Oceanography-Guidelines to Modern Methods*, pages 37–84.
- Jensen, J. (2013). *Remote Sensing of the Environment: Pearson New International Edition: An Earth Resource Perspective*. Pearson Education Limited.
- Jerlov, N. (1971). Optical studies of Ocean Waters. Technical report, Swedish Deep-Sea Expedition.
- Jiang, L. and Wang, M. (2013). Identification of pixels with stray light and cloud shadow contaminations in the satellite ocean color data processing. *Appl. Opt.*, 52(27):6757–6770.
- Kramer, S. and Siegel, D. (2019). How can phytoplankton pigments be best used to characterize surface ocean phytoplankton groups for Ocean Color Remote Sensing algorithms? *Journal of Geophysical Research: Oceans*.
- Legendre, P. and Legendre, L. (2012). *Numerical Ecology*. Developments in Environmental Modelling. Elsevier Science.
- Martin, S. (2014). *An Introduction to Ocean Remote Sensing*. Cambridge University Press.
- Matano, R. and Palma, E. (2018). Seasonal variability of the oceanic circulation in the Gulf of San Jorge, Argentina. *Oceanography (Washington D.C.)*, 31.
- McClain, C., Esaias, W., Feldman, G., Gregg, W., Hooker, S., and Frouin, R. (2002). The proposal for the NASA Sensor Intercalibration and Merger for Biological and Interdisciplinary Oceanic Studies (SIMBIOS) Program, 1995.
- McClain, C. R., Franz, B. A., and Werdell, P. J. (2022). Genesis and Evolution of NASA's Satellite Ocean Color Program. *Frontiers in Remote Sensing*, 3.
- Miller, R., Castillo, C., and McKee, B. (2007). *Remote Sensing of Coastal Aquatic Environments: Technologies, Techniques and Applications*. Remote Sensing and Digital Image Processing. Springer Netherlands.
- Mobley, C., Stramski, D., Bissett, W., and Boss, E. (2004). Optical Modeling of Ocean Waters: Is the Case 1 - Case 2 Classification Still Useful? *Oceanography (Washington D.C.)*, 17.

- Mobley, C., Werdell, J., Franz, B., Ahmad, Z., and Bailey, S. (2016). Atmospheric Correction for Satellite Ocean Color Radiometry. Technical report, Goddard Space Flight Center.
- Morel, A., Hout, Y., Gentili, B., Werdell, J., B Hooker, S., and Franz, B. (2007). Examining the consistency of products derived from various ocean color sensors in open ocean (Case 1) waters in the perspective of a multi-sensor approach. *Remote Sensing of Environment*, 111.
- Morel, A. and Prieur, L. (1977). Analysis of variations in ocean color. *Limnology and Oceanography*, 22:709–722.
- Mueller, J., Bidigare, R., Trees, C., Balch, W., Dore, J., Drapeau, D., Karl, D., Van Heukelem, L., and Perl, J. (2003). Ocean optics protocols for satellite Ocean Color sensor validation, Revision 5, Volume V: Biogeochemical and bio-optical measurements and data analysis protocols. Technical report, Goddard Space Flight Space Center.
- Mélin, F., Zibordi, G., and Berthon, J.-F. (2007). Assessment of satellite Ocean Color products at a coastal site. *Remote Sensing of Environment*, 110:192–215.
- NASA (1999). Moderate Resolution Imaging Spectroradiometer MODIS. <https://modis.gsfc.nasa.gov/>.
- NASA (2011). Joint Polar Satellite System, Suomi NPP. https://www.nasa.gov/mission_pages/NPP/main/index.html.
- Ocean Biology Processing Group (OBPG) NASA (1996). Ocean Color Web. <https://oceancolor.gsfc.nasa.gov>.
- Oostende, M. V. (2015). Comparison between simulated Landsat-7, Landsat-8, Sentinel-2 and Sentinel-3 satellite data for detecting inland water quality variables.
- O'Reilly, J., Maritorena, S., Mitchell, B., Siegel, D., Carder, K., Garver, S., Kahru, M., and McClain, C. (1998). Ocean color chlorophyll algorithms for SeaWiFS. *Journal of Geophysical Research*, 103:937–953.
- Pahlevan, N., K Chittimalli, S., V Balasubramanian, S., and Vellucci, V. (2018). Sentinel-2/Landsat-8 product consistency and implications for monitoring aquatic systems. *Remote Sensing of Environment*, 220:19–29.
- Pahlevan, N., Roger, J.-C., and Ahmad, Z. (2017a). Revisiting short-wave-infrared (SWIR) bands for atmospheric correction in coastal waters. *Opt. Express*, 25(6):6015–6035.
- Pahlevan, N., Sarkar, S., Franz, B., V Balasubramanian, S., and He, J. (2017b). Sentinel 2 Multispectral Instrument (MSI) data processing for aquatic science applications: Demonstrations and validations. *Remote Sensing of Environment*, 201:47–56.
- Pahlevan, N., Schott, R., Franz, B., Zibordi, G., Markham, B., Bailey, S., B. Schaaf, C., Ondrusek, M., Greb, S., and Strait, C. (2017c). Landsat 8 remote sensing reflectance (Rrs) products: Evaluations, intercomparisons, and enhancements. *Remote Sensing of Environment*, 190:289–301.
- Palma, E. and Matano, R. (2012). A numerical study of the Magellan Plume. *Journal of Geophysical Research*, 117.
- Palma, E., Matano, R., and Piola, A. (2003). A numerical study of the Southwestern Atlantic Shelf circulation: barotropic response to tidal and wind forcing. *Journal of Geophysical Research*, 109:1–17.

- Pampa Azul, P. (2015). Pampa Azul: una iniciativa estratégica para el Atlántico Sur. <http://www.pampazul.gob.ar/>.
- Paparazzo, F., Crespi-Abril, A., Gonçalves, R., Barbieri, E., Gracia Villalobos, L., Solís, M., and Soria, G. (2018). Patagonian dust as a source of macronutrients in the Southwest Atlantic ocean. *Oceanography*, 31:33–39.
- Piola, A. R., Martínez Avellaneda, N., Guerrero, R. A., Jardón, F. P., Palma, E. D., and Romero, S. I. (2010). Malvinas slope water intrusions on the Northern Patagonia Continental Shelf. *Ocean Science*, 6(1):345–359.
- Pisoni, J. P., Rivas, A. L., and Tonini, M. H. (2020). Coastal upwelling in the San Jorge Gulf (Southwestern Atlantic) from remote sensing, modelling and hydrographic data. *Estuarine, Coastal and Shelf Science*, 245:106919.
- Poddar, S., Chacko, N., and Swain, D. (2019). Estimation of Chlorophyll-a in Northern Coastal Bay of Bengal Using Landsat-8 OLI and Sentinel-2 MSI Sensors. *Frontiers in Marine Science*, 6.
- Ponce, J. and Rabassa, J. (2012). La plataforma submarina y la costa atlántica argentina durante los últimos 22.000 años. *Ciencia Hoy*.
- Pruter, A. (1987). Sources, quantities and distribution of persistent plastics in the marine environment. *Marine Pollution Bulletin*, 18:305–310.
- Richardson, L. and LeDrew, E. (2006). *Remote Sensing of Aquatic Coastal Ecosystem Processes: Science and Management Applications*. Remote Sensing and Digital Image Processing. Springer Netherlands.
- Rivas, A. L. and Piola, A. R. (2002). Vertical stratification at the shelf off northern Patagonia. *Continental Shelf Research*, 22(10):1549–1558.
- Robinson, I. (2004). *Measuring the Oceans from Space: The principles and methods of satellite oceanography*. Springer Praxis Books. Springer Berlin Heidelberg.
- Robinson, I. (2010). *Discovering the Ocean from Space: The unique applications of satellite oceanography*. Springer Praxis Books. Springer Berlin Heidelberg.
- Romero, S., Piola, A., Charo, M., and Garcia, C. (2006). Chlorophyll-a variability off Patagonia based on SeaWiFS data. *J. Geophys. Res*, 111.
- Ruddick, K. G., Ovidio, F., and Rijkeboer, M. (2000). Atmospheric correction of seaWiFS imagery for turbid coastal and inland waters. *Appl. Opt.*, 39(6):897–912.
- Sarmiento, J. L., Slater, R. and Barber, R., Bopp, L., Doney, S. C., Hirst, A. C., Kleypas, J., and et al. (2004). Response of ocean ecosystems to climate warming. *Global Biogeochemical Cycles*, 18.
- Seegers, B. N., Stumpf, R. P., Schaeffer, B. A., Loftin, K. A., and Werdell, P. J. (2018). Performance metrics for the assessment of satellite data products: an Ocean Color case study. *Optics Express*, 26.
- Segura, V., Silva, R., Luz Clara, M., Martos, P., Cozzolino, E., and Lutz, V. (2021). Primary production and plankton assemblages in the fisheries ground around San Jorge Gulf (Patagonia) during spring and summer. *Plankton and Benthos Research*, 16:24–39.
- Solorza, N. and Tropper, I. (2016). Algorithm Theoretical Bases Document: Turbidity (T). CONAE SABIA-Mar Science Team Document, CONAE.

- Strickland, J. and Parsons, T. (1972). *A Practical Handbook of Seawater Analysis*. Number n.º 167;n.º 1977 in *A Practical Handbook of Seawater Analysis*. Fisheries Research Board of Canada.
- Tauro, C. and Compagnucci, M. (2016). Algorithm Theoretical Bases Document: Daily Mean Photosynthetically Available Radiation (PAR). CONAE SABIA-Mar Science Team Document, CONAE.
- Tauro, C. and Tropper, I. (2016). Algorithm Theoretical Bases Document: Normalized Water Leaving Radiance ($[I_w]_n$). CONAE SABIA-Mar Science Team Document, CONAE.
- Terauchi, G., Tsujimoto, R., Ishizaka, J., and Nakata, H. (2014). Preliminary Assessment of Eutrophication by Remotely Sensed Chlorophyll-a in Toyama Bay, the Sea of Japan. *Journal of Oceanography*, 70.
- Torres, A., Paparazzo, F., Williams, G., Rivas, A., Solís, M., and J.L., E. (2018). Dynamics of Macronutrients in the San Jorge Gulf during spring and summer. *Oceanography*, 31:25–32.
- Tropper, I. and Tauro, C. (2016). Algorithm Theoretical Bases Document: Chlorophyll-a concentration (Chl-a). CONAE SABIA-Mar Science Team Document, CONAE.
- USGS (2016). *Landsat 8 (L8) Data Users Handbook*.
- Vanhellemont, Q. and Ruddick, K. (2015). Advantages of high quality SWIR bands for Ocean Colour processing: Examples from Landsat-8. *Remote Sensing of Environment*, 161:89–106.
- Vanhellemont, Q. and Ruddick, K. (2016). Acolite for Sentinel 2: Aquatic Applications of MSI Imagery. *Royal Belgian Institute for Natural Sciences, Operational Directorate Natural Environment*.
- Vanhellemont, Q. and Ruddick, K. (2016). Acolite for Sentinel-2: Aquatic Applications of MSI Imagery. In *Living Planet Symposium*, volume 740 of *ESA Special Publication*.
- Vermote, E., Tanre, D., Deuze, J., Herman, M., and Morcrette, J.-J. (2006). Second simulation of a satellite signal in the solar spectrum-vector (6SV).
- Wang, M. and Shi, W. (2007). The NIR-SWIR combined atmospheric correction approach for MODIS ocean color data processing. *Opt. Express*, 15(24):15722–15733.
- Werdell, P. and McClain, C. (2018). *Satellite Remote Sensing: Ocean Color*.
- Werdell, P. J. and Bailey, S. W. (2005). An improved in-situ bio-optical data set for ocean color algorithm development and satellite data product validation. *Remote Sensing of Environment*, 98:122–140.
- Werdell, P. J., Bailey, S. W., Franz, B. A., Jr., L. W. H., Feldman, G. C., and McClain, C. R. (2009). Regional and seasonal variability of chlorophyll-a in Chesapeake Bay as observed by SeaWiFS and Aqua MODIS. *Remote Sensing of Environment*, 113:1319–1330.
- Williams, G., Larouche, P., and Dogliotti, A. (2016). Bio-optical properties of the San Jorge Gulf (Argentina). Victoria, CB, Canada. Ocean Optics XXIII Conference.
- Williams, G., Larouche, P., Dogliotti, A., and Latorre, M. (2018). Light Absorption by Phytoplankton, Non-Algal Particles, and Dissolved Organic Matter in San Jorge Gulf in Summer. *Oceanography*, 31:40–49.
- Willmott, C. and Matsuura, K. (2005). Advantages of the mean Absolute Error (MAE) over the Root Mean Square Error (RMSE) in assessing average model performance. *Climate Research*, 30:79–82.

- Wilson, C., Sastre, V., Hoffmeyer, M., Rowntree, V., Fire, S., Santinelli, N., Ovejero, S., D'Agostino, V., Marón, C., Doucette, G., Broadwater, M., Wang, Z., Montoya, N., Seger, J., Adler, F., Sironi, M., and Uhart, M. (2015). Southern right whale (*Eubalaena australis*) calf mortality at Península Valdés, Argentina: Are harmful algal blooms to blame? *Marine Mammal Science*, 32.
- Yoder, J. (2010). Ocean colour radiometry: Early successes and a look towards the future.
- Zibordi, G., Holben, B., Hooker, S. B., Mélin, F., Berthon, J.-F., Slutsker, I., Giles, D., Vandemark, D., Feng, H., Rutledge, K., Schuster, G., and Al Mandoos, A. (2006). A network for standardized Ocean Color validation measurements. *Eos Transactions American Geophysical Union*, 87.
- Zingone, A. and Enevoldsen, H. O. (2000). The diversity of harmful algal blooms: a challenge for science and management. *Ocean and Coastal Management*, 43(8):725–748.

