



Universidad Austral de Chile

Facultad de Ciencias Forestales y Recursos Naturales

# Aplicación de *spectral unmixing* para mejorar la estimación de cobertura de macroalgas en el Estrecho de Magallanes

Patrocinante: Sr. Gerardo Soto G.

Co-patrocinante: Sra. Pirjo Huovinen

Trabajo de Tesina presentado como parte de los requisitos para optar al Título de **Ingeniero en Conservación de Recursos Naturales**

**JOSEBA ISMAEL IRIBARREN LINEROS**

VALDIVIA

2025

Índice de materias		Página
i	Calificación del Comité de Titulación	i
ii	Agradecimientos	ii
iii	Resumen	iii
1	INTRODUCCIÓN	1
1.1	Marco teórico	1
1.2	Objetivos	6
2	MÉTODOS	7
2.1	Flujo de trabajo y datos satelitales	7
2.2	Área de estudio	8
2.3	Extracción de píxeles puros	8
2.4	Clasificación de cobertura fraccional	11
2.5	Validación del modelo	13
2.6	Estimación de estacionalidad y tendencia	17
3	RESULTADOS	19
3.1	Endmembers	19
3.2	Validación del modelo	20
3.3	Influencia de la marea en el modelo	21
3.4	Limitaciones del modelo asociadas a la variabilidad estacional	22
3.5	Tendencias interanuales	25
4	DISCUSIÓN	28
5	CONCLUSIÓN	32
6	APÉNDICE	33
7	REFERENCIAS	33
Anexos	1 Ejemplo de imágenes en falso color para áreas de muestreo	
	2 Ejemplo de imágenes en NDVI para áreas de muestreo	
	3 Ejemplo de imágenes seleccionadas en falso color	
	4 Ejemplo de imágenes seleccionadas en NDVI	
	5 Ejemplo de imágenes seleccionadas en NDWI	

- 6 Contribución relativa de las bandas en análisis PCA
- 7 Tabla de valores para *endmembers*
- 8 Ejemplo de imágenes de validación
- 9 Grilla de polígonos para análisis de estacionalidad en aguas oceánicas
- 10 Valores de proporciones relativas de reflectancia en aguas oceánicas
- 11 Valores de reflectancia en aguas oceánicas para imágenes SR
- 12 Ejemplo de tendencia estival de macroalgas en dos parches

## i. Calificación de comité de titulación

		<b>Nota</b>
Patrocinante:	Sr. Gerardo Emanuel Soto González	6,7
Co-patrocinante:	Sra. Pirjo Sinikka Huovinen	6,5
Informante:	Sr. Iván Manuel Gómez Ocampo	6,5
Informante:	Sr. Horacio Augusto Samaniego Salinas	6,5

El Patrocinante acredita que el presente Trabajo de Titulación cumple con los requisitos de contenido y de forma contemplados en el Reglamento de Titulación de la Escuela. Del mismo modo, acredita que en el presente documento han sido consideradas las sugerencias y modificaciones propuestas por los demás integrantes del Comité de Titulación.



---

Sr. Gerardo Soto G.

## **ii. Agradecimientos**

Agradezco profundamente a mi familia por su constante apoyo, a Gerardo Soto por su guía y enseñanzas, a Pirjo Huovinen e Iván Gómez por brindarme la oportunidad de desarrollar este trabajo, y a Alen Miranda por hacer la estadía en el laboratorio más cálida y alimentar mi curiosidad. Asimismo, agradezco a los proyectos FONDECYT N°1241571, FONDECYT N°1242028 y FONDAP IDEAL N°15150003 por el financiamiento que hizo posible la realización de esta tesis.

### iii. RESUMEN

Los bosques de macroalgas del extremo austral de Chile constituyen ecosistemas altamente productivos y ecológicamente relevantes, pero su monitoreo a gran escala se ha visto limitado por las condiciones ambientales extremas y la falta de métodos capaces de capturar su variabilidad espacial y temporal con precisión. Este trabajo tuvo como propósito mejorar la estimación de la cobertura de macroalgas mediante técnicas de *spectral unmixing* aplicadas a imágenes satelitales de alta resolución, con el fin de representar de manera más realista la heterogeneidad de los píxeles en zonas costeras y aumentar la resolución de análisis a nivel subpíxel. Para ello, se extrajeron firmas espectrales representativas y se aplicó un modelo de *spectral unmixing* para estimar la cobertura de macroalgas. La metodología permitió identificar patrones espaciales y temporales de los bosques de macroalgas, evidenciar la influencia de factores ambientales como la marea y las condiciones de iluminación sobre las estimaciones, y detectar tendencias de cambio en la cobertura algal en el Estrecho de Magallanes y sus zonas circundantes. Proporcionando una base sólida para el monitoreo satelital de macroalgas en ambientes subantárticos.

**Palabras clave:** *detección remota, macroalgas, spectral unmixing, Sentinel-2.*

## 1. INTRODUCCIÓN

Los ecosistemas dominados por especies del orden Laminariales, denominados bosques de macroalgas, son uno de los hábitats más diversos y productivos de la Tierra (Smale et al. 2013, Wernberg et al. 2019). Estos bosques, también llamados *kelp forests* por su nombre en inglés, se extienden a lo largo del 25% de las costas del mundo, generalmente en latitudes medias y aguas someras con sustratos duros, presentando su máximo de biomasa algal alrededor de los 45°– 60° de latitud norte (Steneck & Johnson 2013, Wernberg et al. 2019). Estos ambientes son refugio para una gran diversidad de especies bentónicas y pelágicas, incluyendo las crías de múltiples especies pesqueras de importancia socioeconómica (Smale et al. 2013). En conjunto, estas grandes algas pardas conforman un grupo de especies fundacionales clave, también llamadas "ingenieras ecosistémicas", debido a su capacidad de modificar el ambiente y así crear hábitat para otras especies y sustentar redes tróficas costeras (Steneck & Johnson, 2013). De manera adicional, éstas proveen otros grandes servicios a los seres humanos, como pueden ser la defensa biogénica contra eventos climáticos extremos y el reciclaje de nutrientes (Smale et al. 2013, Wernberg et al. 2019).

Estudios recientes han evidenciado cambios significativos en estos ambientes, atribuibles a la acción directa e indirecta del ser humano (Smale 2020). Dado que las especies marinas son altamente dependientes de la temperatura (Pinsky et al. 2019), el aumento sostenido de ésta en muchas regiones del mundo —como consecuencia del cambio climático— ha obligado a numerosas especies marinas a desplazarse geográficamente en busca de condiciones térmicas más favorables para su supervivencia, lo que ha provocado alteraciones en la composición, estructura y funcionamiento de las comunidades bióticas (Poloczanska et al. 2013).

Esta tendencia también se ha documentado en los bosques de macroalgas. Un estudio recopilatorio realizado por Smale (2020), analizó los resultados de 33 investigaciones recientes sobre las tendencias poblacionales de diversas especies de macroalga frente a cambios en la temperatura oceánica, evidenciando alteraciones en la estructura y distribución de estos bosques marinos en diversas regiones del mundo. Cambios que probablemente han repercutido en los procesos ecológicos de estos ambientes, incluyendo la capacidad de secuestro de carbono que presentan (Smale 2020).

Este último aspecto es particularmente crítico, considerando que los bosques de macroalgas secuestran aproximadamente 173 millones de toneladas de carbono por año a escala global (RIC: 61–268), principalmente debido al transporte de biomasa algal hacia aguas profundas (Krause-Jensen y Duarte 2016). En este contexto, la pérdida de estos ecosistemas podría reducir de forma significativa su capacidad de secuestrar y trasladar carbono entre ambientes (Pessarrodona et al. 2018), y generando una posible intensificación del cambio climático.

A nivel regional, Chile alberga algunos de los bosques de macroalgas más extensos del hemisferio sur (Mora-Soto et al. 2021). En éstos habitan dos géneros del orden *Laminariales*, —*Lessonia* y *Macrocystis* (comúnmente llamados huiros)—, y un fucoide, *Durvillaea* (cochayuyo), que, pese a no ser un verdadero kelp, debido a su estructura interna boyante, se suele estudiar como parte del grupo funcional (Laukaityte & Riera 2022). De estos géneros sólo tres especies son exclusivamente submareales: *Macrocystis pyrifera*, *Lessonia trabeculata* y *Lessonia flavicans*. La primera domina al sur de los 42° S, mientras que las especies de *Lessonia* predominan entre los 18° y 42° S y 33° y 54° S, respectivamente (Laukaityte & Riera 2022).

Estas macroalgas poseen una relevancia económica significativa para Chile, uno de los grandes exportadores de algas pardas silvestres en el mundo, con una exportación anual de 390.000 toneladas secas, provenientes en su mayoría de la zona norte del país (Vásquez et al. 2024). Esta situación, trae

preocupación por el uso sustentable del recurso, por su rol en los ecosistemas costeros y como sustento de comunidades pesqueras (Vásquez 2008, Buschmann et al. 2014).

Recientemente ha aumentado el reconocimiento del valor ambiental de los bosques terrestres con baja influencia antrópica a nivel global, así como la necesidad de protegerlos, en contraste con los bosques degradados (Mackey et al. 2015, Potapov et al. 2017, Watson et al. 2018). Esta misma lógica puede aplicarse a los bosques de macroalgas, cuya condición prístina aún se encuentra en los bosques subantárticos de Sudamérica. Esta área ha mostrado una tendencia estable en la temperatura superficial del océano durante las últimas décadas, en contraste con la tendencia global de calentamiento asociada al cambio climático, lo que podría clasificarla como un refugio climático para macroalgas (Johnson & Lyman 2020, Mora-Soto et al. 2022). Además, la explotación de este recurso en esa área ha sido mucho menor que en otras zonas de Chile, aunque se desconocen los efectos de su uso por parte de comunidades prehispánicas y posteriores (Mora-Soto et al. 2021).

Sin embargo, a pesar de la aparente estabilidad ambiental en la región, ya se observan señales de transformación asociadas al cambio climático. Uno de los indicadores más evidentes es el retroceso generalizado de los glaciares de los Andes Patagónicos (Meier et al. 2018), con pérdidas estimadas entre 2000 y 2016 de  $-0.86 \pm 0.27$  metros de agua equivalente por año para la Patagonia Sur, y de  $-0.48 \pm 0.27$  metros de agua equivalente por año para los Andes fueguinos (Dussailant et al. 2019). Estos retrocesos han modificado los gradientes de salinidad y turbidez en los fiordos patagónicos (Huovinen et al. 2020, Palacios et al. 2021), creando nuevos ambientes que podrían ser colonizados por comunidades marinas. Esta idea se ve reforzada por una investigación de Palacios et al. (2021), en la que se evidenció en el fiordo de Yendegaia ( $54^{\circ} 52'S$   $68^{\circ} 43'O$ ) una colonización exitosa por parte de *M. pyrifera*, mostrando además una alta adaptabilidad fisiológica por parte de la especie.

Cabe destacar que *Macrocystis pyrifera* (conocido como huiro, huiro flotador, huiro canutillo o, en algunos casos, sargazo) es la especie dominante en los bosques subantárticos de la Patagonia, con una extensión superior a  $4.800 \text{ km}^2$  (Mora-Soto et al. 2020). Su plasticidad funcional y morfológica explica gran parte de su éxito ecológico en estos ambientes de fiordos y canales (Gómez et al. 2025), logrando además en esta zona formar los bosques más extensos de toda su distribución (Dayton 1985, Mora-Soto et al. 2020). Sus individuos pueden llegar a medir hasta 70 m de longitud, presentando un gradiente de fotoaclimatación y rendimiento fotosintético de las frondas a medida que disminuye la disponibilidad de luz en profundidad (Gómez et al. 2025).

Dada la importancia ecológica y las crecientes amenazas que enfrenta esta especie a nivel global, ha aumentado el interés por el monitoreo de *Macrocystis pyrifera* a diferentes escalas. En este contexto, su distribución y abundancia han sido estudiadas mediante técnicas in situ, y recientemente a través de teledetección aérea y satelital a nivel global (Cavanaugh et al. 2010, Johnson et al. 2011, Pfister et al. 2018, Arafeh-Dalmau et al. 2019, Bell et al. 2020, Mora-Soto et al. 2020, Cavanaugh et al. 2021), incluyendo investigaciones recientes en Chile (Friedlander et al. 2018, Huovinen et al. 2020, Mora-Soto et al. 2020, González-Aragón et al. 2025). Estos estudios han generado mapas de ocurrencia de esta macroalga utilizando imágenes satelitales de diversas constelaciones como Landsat y Sentinel-2, del USGS y la ESA, respectivamente (USGS s.f., ESA 2015).

La clasificación de la superficie terrestre a partir de imágenes satelitales puede ser realizada de múltiples formas, desde el uso de valores e índices espectrales, hasta modelos y algoritmos matemáticos complejos. Entre estos últimos, algunos de los más utilizados en la rama del aprendizaje de máquinas (*machine learning*) son los árboles de decisión, máquinas de vectores de soporte (Support Vector Machines - SVM), redes neuronales artificiales (Artificial Neural Networks - ANN), algoritmos de memoria temporal jerárquica (Hierarchical Temporal Memory - HTM), clasificadores de Máxima Verosimilitud (Maximum Likelihood Classifier - MLC), clasificadores bayesianos MLC (Bayesian MLC), clasificadores contextuales MLC (Contextual MLC), clasificadores de distancia mínima (Minimum Distance Classifier), algoritmos de clustering no supervisado (por ejemplo, kmeans) y modelos de mezcla espectral (Spectral Mixture Analysis - SMA), entre otros (Giri 2012). Estos últimos, ya han sido utilizados para el mapeo de los bosques de *M. pyrifera* en Chile (Friedlander et al. 2018, Huovinen et al. 2020, González-Aragón et al. 2025).

A diferencia de los métodos de clasificación, que categorizan cada píxel en una clase única, los modelos de SMA buscan separar las señales de diversos componentes dentro de un mismo píxel, utilizando técnicas de mezcla y desmezcla espectral (*spectral unmixing*), que descomponen los patrones de reflectancia de cada píxel en un conjunto de firmas espectrales representativas de cada componente (*endmembers*) (Keshava & Mustard 2002). De este modo, es posible estimar la proporción o fracción de cada componente presente en un píxel, es decir, su cobertura fraccional. En consecuencia, el *spectral unmixing* otorga una estimación más precisa de la cobertura de distintos componentes, sin embargo, también resulta ser un problema complejo, cuya resolución puede verse afectada por inexactitudes en el modelo, ruido en las observaciones, condiciones ambientales desfavorables, heterogeneidad de los *endmembers* o el tamaño del conjunto de datos, entre otros (Bioucas-Dias et al. 2012).

Es importante resaltar que existen diversos algoritmos de *spectral unmixing* (Bioucas-Dias et al. 2012, Quintano et al. 2012, Kale et al. 2019), los cuales se diferencian principalmente por dos factores: (i) el procedimiento utilizado para la extracción de los *endmembers* y (ii) el modelo matemático aplicado para descomponer el espectro de cada píxel.

En relación con el primer factor, los algoritmos de extracción de *endmembers* se agrupan en dos grandes categorías. La primera, basada en geometría convexa, incluye tanto los enfoques de proyección ortogonal (como por ejemplo el Índice de Pureza de Píxel o el Análisis de Componentes de Vértices), como los enfoques basados en el volumen del *simplex* o espacio multidimensional acotado (tales como el NFINDR o el Algoritmo de Crecimiento del Simplex). La segunda categoría corresponde a los métodos estadísticos que emplean herramientas de estadística de segundo orden y superior, así como técnicas de Inteligencia de Enjambre (*Swarm Intelligence*) (Kale et al. 2019). Además, se ha reportado el uso de modelos de *machine learning*, como redes neuronales artificiales, para la estimación de *endmembers* (Kumar et al. 2012, Licciardi et al. 2012).

El segundo factor depende de las suposiciones que realice el modelo sobre la reflectancia de la luz sobre la superficie (Keshava & Mustard 2002). Los modelos lineales asumen que la luz incidente interactúa únicamente con un material, de modo que la luz reflejada está casi completamente separada y la mezcla de señales ocurre únicamente en el sensor. En cambio, los modelos no lineales consideran las interacciones físicas por la luz dispersada sobre múltiples superficies (Bioucas-Dias et al. 2012).

Dentro de este contexto, y en relación a los estudios realizados en Chile, cabe acotar que aún no se han desarrollado productos de cobertura fraccional de alta resolución y extensión espacio-temporal en la zona subantártica, lo que permitiría caracterizar con mayor precisión la variabilidad de estos bosques marinos a lo largo de los diversos gradientes ambientales. Esta carencia se explica por diversos desafíos metodológicos vinculados a las particularidades ambientales de esta remota región. Específicamente, tres grandes obstáculos dificultan actualmente la estimación de la cobertura de macroalgas en la zona subantártica chilena.

El primero, y quizá el más evidente, es el gradiente longitudinal de cobertura de nubes que afecta la disponibilidad de píxeles con información relevante de la superficie terrestre, especialmente en la zona suroeste de la Patagonia. Esta nubosidad se asocia a una banda de precipitación que se extiende a lo largo de gran parte del Pacífico sur, con sistemas frontales asociados a ciclones migratorios que suelen desplazarse en dirección oeste a través de estrechas franjas latitudinales llamadas “*storm tracks*”

(Hoskins & Valdes 1990, Garreaud et al. 2009, Paruelo et al. 2015). A esto se suma el ascenso de los vientos del oeste a través de la ladera occidental de los Andes, produciendo precipitación orográfica, con valores en el continente entre dos y tres veces mayores que los de su contraparte oceánica (Garreaud et al. 2009).

El segundo obstáculo es la marcada variabilidad de las mareas, con rangos de hasta más de 10 metros en sectores como Punta Delgada (SHOA s.f.), lo que complica la detección precisa de las macroalgas sumergidas. El tercero se relaciona con la falta de máscaras de tierra confiables, es decir, capas binarias utilizadas para excluir sistemáticamente los píxeles correspondientes a tierra firme durante el análisis, lo que puede inducir errores en la clasificación de píxeles en zonas costeras.

Este estudio tiene como objetivo mejorar las estimaciones de cobertura de macroalgas mediante el uso de técnicas de *spectral unmixing*, superando las limitaciones de los enfoques actuales basados en clasificaciones categóricas (*hard classification*). Esta aproximación permite representar con mayor precisión la heterogeneidad de los píxeles en ecosistemas costeros, donde coexisten fracciones de macroalgas, agua y otros componentes dentro de una misma unidad espacial. Asimismo, la metodología posibilita detectar cambios en la extensión espacial de los bosques de macroalgas y variaciones en su densidad a nivel de píxel, lo que se traduce en una mayor sensibilidad frente a cambios sutiles y, en la práctica, en una mejora de la resolución de análisis a partir de imágenes satelitales. Esta aproximación permitirá comprender mejor las dinámicas espacio-temporales de macroalgas y proporciona una base sólida para conocer su real distribución en una región remota y de muy difícil acceso.

## **Objetivo General**

Estimar la cobertura fraccional de los bosques de macroalgas en el Estrecho de Magallanes mediante un análisis de *spectral unmixing* bilineal usando imágenes satelitales de alta resolución.

## **Objetivos específicos**

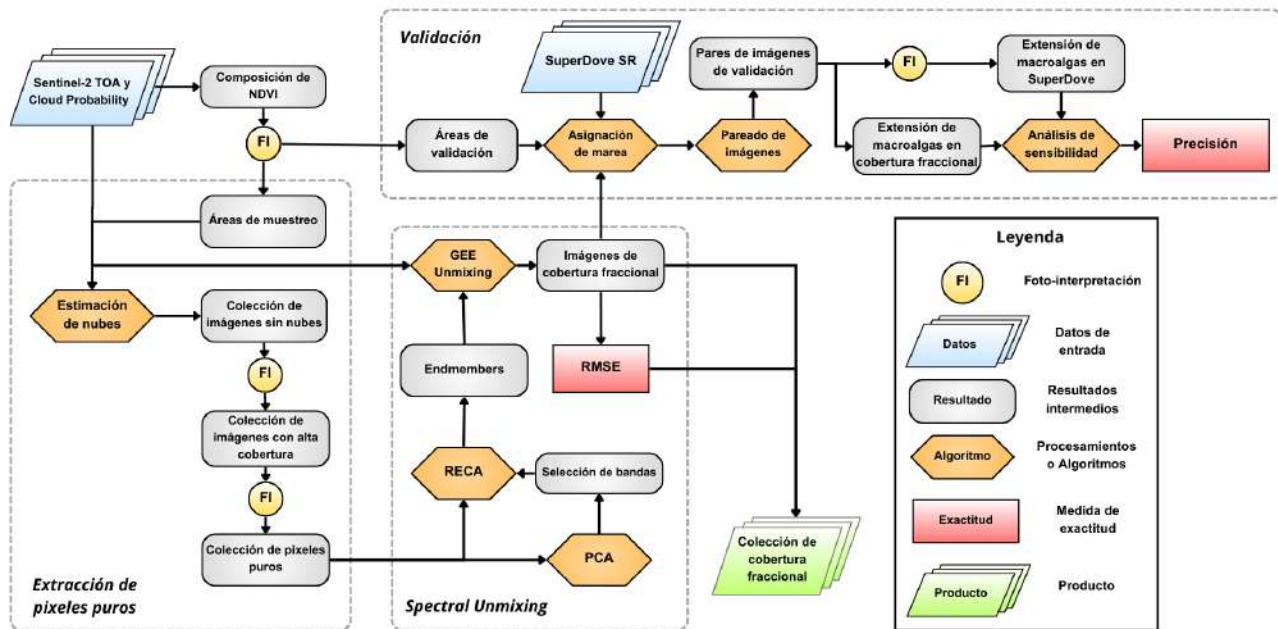
- I. Calcular y caracterizar endmembers de macroalgas, agua y tierra, a partir de datos espectrales de imágenes satelitales de alta resolución.
- II. Usar los endmembers de macroalgas, agua y tierra dentro de un análisis de *spectral unmixing* bilineal para estimar la cobertura fraccional de macroalgas en el Estrecho de Magallanes.

- III. Describir la estacionalidad de la cobertura estimada de los bosques de macroalga en el Estrecho de Magallanes mediante un modelo sinusoidal.
- IV. Describir la tendencia interanual de la cobertura estimada de los bosques de macroalga en el Estrecho de Magallanes mediante un modelo lineal.

## 2. MÉTODOS

### 2.1 Flujo de trabajo y datos satelitales

El flujo de trabajo para la generación de imágenes de cobertura fraccional de macroalgas a partir de imágenes Sentinel-2 comprende tres etapas principales: (i) la extracción de valores espectrales de píxeles puros; (ii) la construcción de un modelo de mezcla espectral (spectral unmixing) mediante un algoritmo de reconstrucción de endmembers y la función de pseudoinversa de Google Earth Engine (GEE); y (iii) la validación del modelo utilizando imágenes satelitales de muy alta resolución SuperDove. El detalle del proceso se presenta en la figura 1.



**Figura 1.** Esquema del Flujo de Trabajo del proceso empleado para generar imágenes de cobertura fraccional de macroalgas, basadas en imágenes Sentinel-2. Los recuadros punteados constituyen las tres principales etapas de este flujo. Ver el texto para obtener más detalles sobre el uso de los datos y su procesamiento.

Para este trabajo se utilizó como insumo la colección Sentinel-2 Level 1C disponible en GEE (Gorelick et al. 2017), conformada por imágenes corregidas orto- y radio-métricamente de reflectancia en el tope de la atmósfera (TOA) (ESA 2015–presente a).

## 2.2 Área de estudio

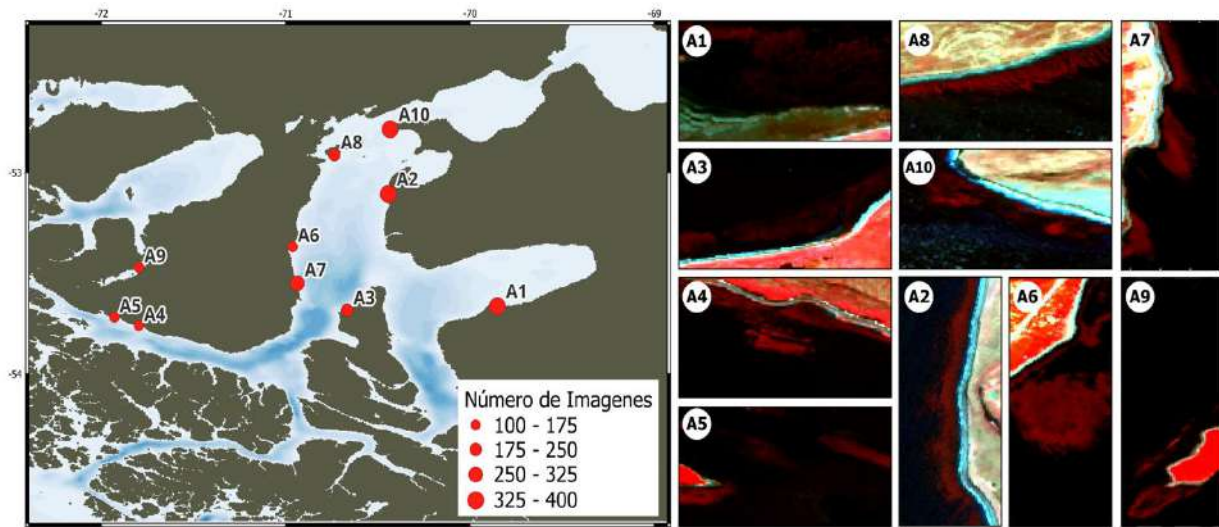
El área de estudio de esta investigación comprendió un polígono centrado en la zona del Estrecho de Magallanes, limitado al sur por el Monte Darwin, al oeste por el extremo occidental de la Península de Brunswick, al norte por la localidad de Cóndor (Santa Cruz, Argentina, al norte del Campamento Posesión) y al este por el límite sur-este del fiordo Garibaldi, abarcando específicamente desde los 52° 7' 57" S, 72° 27' 37" O hasta los 54° 44' 11" S, 68° 55' 21" O, con un área aproximada de 68.000 km<sup>2</sup> (figura 2).

Esta zona fue seleccionada por dos razones principales. En primer lugar, la zona subantártica alberga los bosques de *Macrocystis pyrifera* más extensos de toda su distribución (Dayton 1985, Mora-Soto et al. 2020), muchos de los cuales mantienen condiciones ecológicas prístinas (Mora-Soto et al. 2021), factor que facilita la extracción de píxeles puros, insumo necesario para la aplicación del *spectral unmixing*. Y en segundo, por su difícil acceso, debido a la geografía fragmentada y las condiciones climáticas extremas, que hacen de la detección remota una herramienta particularmente útil para estudiar estos ambientes.

## 2.3 Extracción de píxeles puros

Dentro del área de estudio se seleccionaron 10 áreas rectangulares de aproximadamente 1,5 km<sup>2</sup> cada una, procurando una distribución espacial uniforme a lo largo del Estrecho de Magallanes y áreas circundantes (figura 2). La selección se basó en una composición satelital que incluye los valores máximos de los promedios anuales del Índice de Vegetación de Diferencia Normalizada (NDVI) para los años 2015 a 2024 de la colección Sentinel-2. Esto permitió identificar zonas con cobertura significativa de algas en al menos un año del período considerado. El NDVI es ampliamente utilizado en teledetección para estimar la presencia de vegetación fotosintéticamente activa, y se calcula a partir de la diferencia normalizada entre las bandas del rojo e infrarrojo cercano (Tucker 1979). Este índice ha

demostrado ser eficaz para detectar parches de macroalgas en ambientes costeros (Cavanaugh et al. 2010, Nijland et al. 2019, Mora-Soto et al. 2020).



**Figura 2.** Área de estudio y localización de las áreas de muestreo utilizadas para la extracción de píxeles puros (mapa de la izquierda), mostrando la cantidad de imágenes Sentinel-2 con mínima cobertura nubosa, dentro del período entre el 19 de agosto de 2015 y el 29 de marzo de 2025. A la derecha se muestran imágenes representativas en falso color (R: NIR, G: Rojo, B: Verde) para cada área seleccionada.

Para el período entre el 19 de agosto de 2015 y el 29 de marzo de 2025, a cada imagen Sentinel-2 correspondiente a las áreas de muestreo se le aplicó una máscara de nubes basada en el producto Sentinel-2 Cloud Probability, generado mediante la librería *Sentinel Hub Cloud Detector* (Skakun et al. 2022). En este proceso se enmascararon todos los píxeles con una probabilidad de nubosidad superior al 50 %. Posteriormente, se estimó la cobertura de nubes calculando la proporción de puntos enmascarados dentro de una malla de puntos equidistantes ubicada sobre la superficie del agua en cada imagen, con entre 35 y 49 puntos según el área de muestreo.

Esta estrategia permitió evitar la sobreestimación de la nubosidad causada por nubes en áreas terrestres o por confusiones entre nieve y nubes en el producto Sentinel-2 Cloud Probability. Solo las imágenes con una estimación de cobertura de nubes basada en la colección de puntos equidistantes inferior al 10 % fueron consideradas para los análisis posteriores (cuadro 1; anexos 1 y 2).

A partir de este conjunto de imágenes con baja nubosidad, se realizó un proceso de fotointerpretación para cada área (Campbell & Wynne 2011, Jensen 2014), utilizando composiciones en falso color NIR–Rojo–Verde (bandas B8, B4 y B3 de Sentinel-2), NDVI y el Índice de Agua de

Diferencia Normalizada (Normalized Difference Water Index, NDWI). Ejemplos de estos índices calculados en un área de muestreo se encuentran en los anexos 3, 4 y 5. Se utilizaron estas composiciones de color con el fin de aumentar la probabilidad de identificar las imágenes con mayor densidad de macroalgas, las cuales fueron seleccionadas manualmente para la extracción de píxeles puros para las componentes de macroalgas, agua y superficie terrestre.

Para extraer píxeles puros de macroalgas, se dibujó manualmente sobre cada imagen una colección de polígonos que delimitó las zonas de mayor densidad algal. Posteriormente, se extrajeron los valores espectrales de todos los píxeles que intersectaran total o parcialmente con dichos polígonos (cuadro 1). De manera análoga, las componentes de agua y superficie terrestre se delimitaron mediante polígonos fijos para cada área considerando su consistencia temporal, evitando dibujar polígonos sobre áreas que mostraran cambios de clase en la colección de imágenes.

**Cuadro 1:** Resumen de imágenes seleccionadas y de extracción de píxeles puros de macroalgas para las áreas de muestreo.

Áreas	Long, Lat	Imágenes sin nubes	Imágenes seleccionadas	Píxeles puros de macroalga	Porcentaje de píxeles puros de macroalga
A1	-69.851, -53.664	341	24	2206	4.3%
A2	-70.443, -53.108	355	18	7085	13.9%
A3	-70.666, -53.684	226	22	3624	7.1%
A4	-71.796, -53.761	148	19	9894	19.4%
A5	-71.928, -53.718	131	13	4141	8.1%
A6	-70.962, -53.368	153	12	7950	15.6%
A7	-70.936, -53.551	298	23	11067	21.7%
A8	-70.735, -52.912	179	9	2185	4.3%
A9	-71.795, -53.470	130	7	1121	2.2%
A10	-70.434, -52.785	343	14	1729	3.4%
<b>Total:</b>		<b>2304</b>	<b>161</b>	<b>51002</b>	<b>100%</b>

Cabe destacar que, si bien la presencia de agua en los píxeles impide obtener valores completamente puros para la componente de macroalgas, se seleccionaron aquellos píxeles con la mayor pureza espectral posible a partir de sus valores de reflectancia y NDVI. Por otra parte, los píxeles de superficie terrestre incluyeron una amplia variedad de coberturas (como vegetación terrestre, suelo desnudo y rocas); sin embargo, al momento de determinar las firmas espectrales, esta heterogeneidad es sintetizada en una única firma representativa.

## 2.4 Clasificación de cobertura fraccional

A partir de los valores espectrales de los píxeles previamente clasificados como “puros”, se estimaron tres firmas espectrales representativas, que corresponden a macroalga, superficie terrestre y agua. En total, se utilizaron 51.002 píxeles puros de macroalgas (cuadro 1), y para las demás componentes se seleccionó aleatoriamente un número equivalente (51.002 píxeles por clase) desde el conjunto general de píxeles disponibles, a fin de mantener la proporcionalidad en el análisis. Este procedimiento se llevó a cabo utilizando un algoritmo de composición de *endmembers* basado en R (R-based Endmember Composition Algorithm, RECA), desarrollado por Seidel y Hlawitschka (2015), el cual adapta el algoritmo de modelado de *endmembers* (End Member Modeling Algorithm, EMMA) entregado por Weltje (1997) en forma de pseudocódigo. Este corresponde a un algoritmo de *spectral unmixing* bilineal, característica derivada directamente de la necesidad de estimar dos conjuntos de parámetros desconocidos simultáneamente, la matriz de composiciones de los miembros finales ( $B'$ ) y la matriz de proporciones de mezcla ( $M'$ ). Además de otros parámetros, como el número de *endmembers* ( $q$ ), el array de mezcla perfecta ( $X'$ ) y los errores ( $E$ ).

Este algoritmo fue utilizado con un umbral de error de convexidad de  $-6$ , 10.000 iteraciones y un exponente de ponderación estándar de 1, como recomienda Weltje (1997). El funcionamiento del modelo se puede resumir en cuatro pasos generales, los últimos dos iterativos.

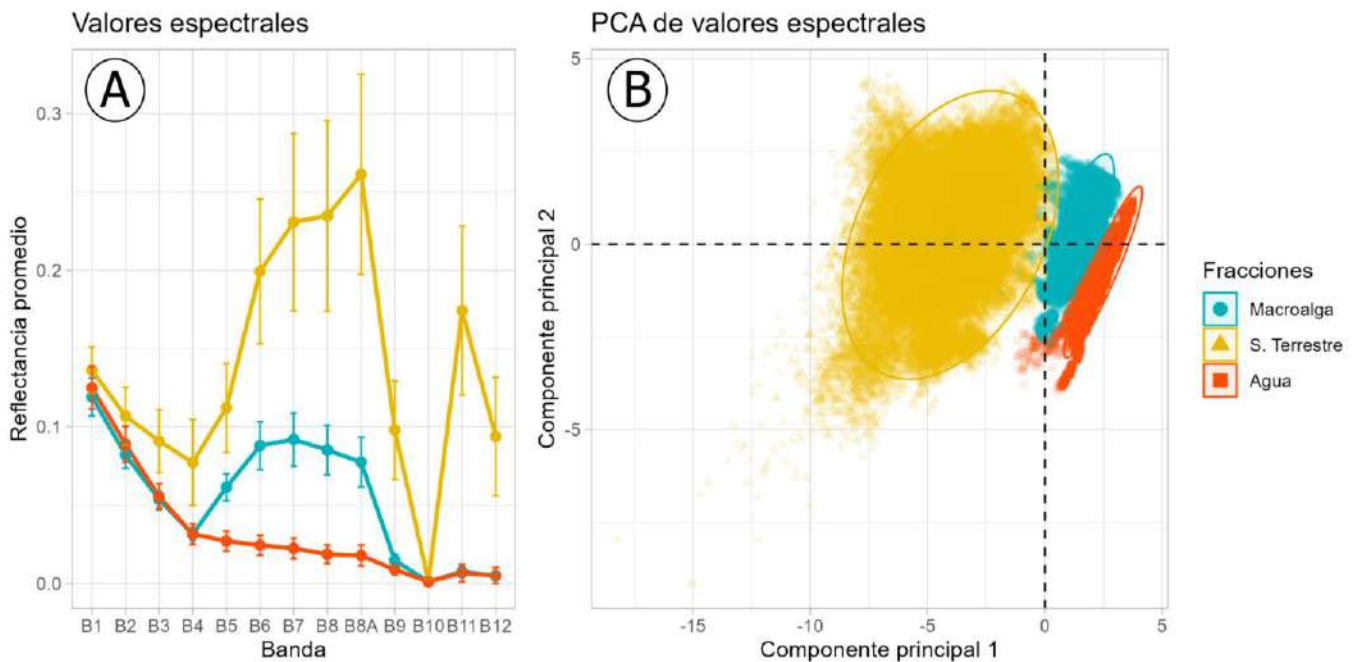
Paso 1: En el primer paso se selecciona el número de *endmembers* apoyándose en la proporción acumulada de la varianza y el coeficiente de determinación.

Paso 2: se genera una estimación inicial de los *endmembers* ( $B$ ) en base a un algoritmo de *c*-medias difuso.

Paso 3: utilizando  $B$ , se genera la matriz de proporciones de mezcla ( $M$ ) mediante una función pseudo-inversa, con la que se calcula el error de convexidad ( $c_1$ ) basado en la proporción de observaciones fuera del politopo de mezcla formado por los *endmembers* y la distancia de éstas al politopo.

Paso 4: si el error de convexidad ( $c_1$ ) supera el umbral establecido, el politopo se expande generando nuevos *endmembers* ( $B'$ ), con los cuales se recalcula la matriz de proporciones de mezcla ( $M'$ ). Este proceso iterativo se repite hasta que el error de convexidad sea inferior al umbral o se alcance el número máximo de iteraciones (Seidel y Hlawitschka 2015).

Para seleccionar las bandas espectrales utilizadas como insumo para el cálculo de *endmembers*, se realizó un análisis de componentes principales (PCA). En éste se observó una clara separación de los valores espectrales correspondientes a macroalgas, agua y superficie terrestre en las dos primeras dimensiones del PCA (figura 3), capturando un 87.6% de la varianza total en dichas dimensiones. Adicionalmente, se identificó que las bandas de aerosol (B1) y cirrus (B10) no presentaban una contribución significativa para explicar la varianza de los datos (anexo 6), por lo que fueron descartadas, utilizando las bandas B2 a B9, junto a la B11 y B12.



**Figura 3.** A: Promedio ( $\pm$ Dest. Est.) de valores espectrales para píxeles puros. B: PCA para valores espectrales de píxeles puros.

Una vez obtenidos los *endmembers*, se aplicó el algoritmo de *spectral unmixing* mediante una función de pseudo-inversa para estimar coberturas fraccionales a partir de imágenes Sentinel-2, previamente normalizadas a suma uno. En esta normalización, los valores del vector espectral de cada píxel fueron escalados de modo que su suma total fuera igual a uno, dado que los *endmembers* entregados por el algoritmo RECA se expresan en proporciones relativas de reflectancia.

El algoritmo de pseudo-inversa se aplicó bajo dos restricciones físicas: (i) las fracciones de las firmas espectrales deben sumar 1 (*sum-to-one constraint*), garantizando que representen proporciones de cobertura a nivel de píxel; y (ii) las fracciones no pueden ser negativas (*non-negativity constraint*), pues

las coberturas negativas carecen de sentido físico. El resultado es un mapa compuesto por tres bandas, cada una correspondiente a la fracción estimada de un componente.

## 2.5 Validación del modelo

La validación del modelo de cobertura fraccional se realizó mediante dos enfoques complementarios. Para el primero se calculó la Raíz del Error Cuadrático Medio (Root Mean Square Error, RMSE) para cada píxel, basado en la comparación de los valores espectrales originales de las imágenes y la reconstrucción de estos a partir de la ponderación de las firmas espectrales de los componentes con sus respectivas fracciones estimadas. Donde los valores de reflectancia de cada píxel para  $n$  componentes se entienden como:

$$R_b = \sum_{i=1}^n R_{i,b} F_i + \varepsilon_b \quad [1]$$

donde  $R_b$  es la reflectancia para una banda  $b$ ,  $R_{i,b}$  es el valor del *endmember*  $i$  en la banda  $b$ ,  $F_i$  es la fracción del *endmember*  $i$  y  $\varepsilon_b$  es el error residual en la banda  $b$ . A partir de estos últimos se calcula el RMSE de la siguiente manera para  $m$  bandas:

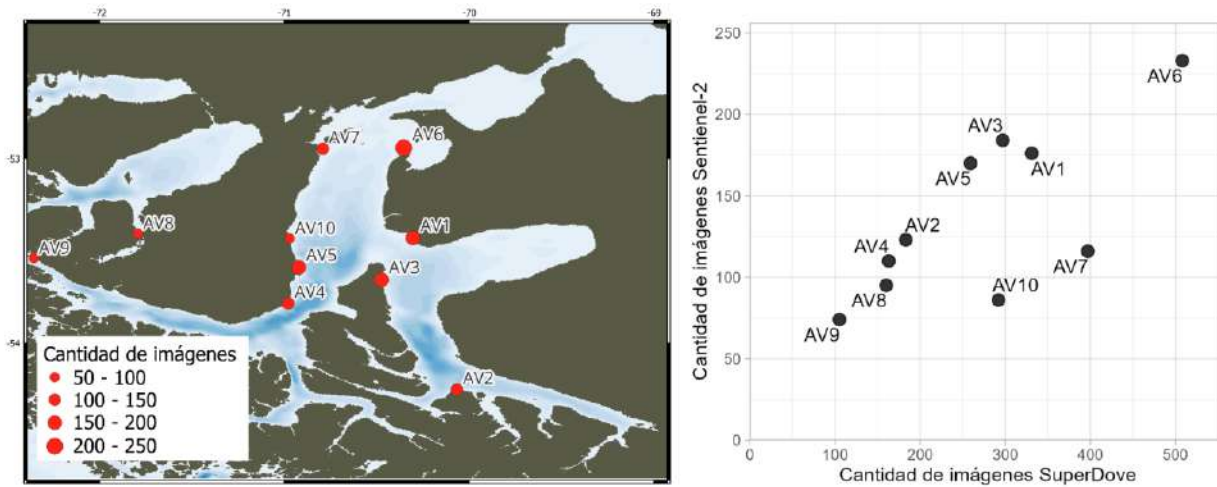
$$RMSE = [ m^{-1} \sum_{b=1}^m \varepsilon_b^2 ]^{1/2} \quad [2]$$

Esta medida de error, ampliamente utilizada en análisis de mezcla espectral (Souza et al. 2005, Ji et al. 2020, Alshahrani et al. 2025, Liu et al. 2025), permite evaluar la consistencia interna del modelo. El RMSE fue incorporado al producto final de cobertura fraccional de macroalgas como un indicador de posibles inconsistencias internas, asociadas a la presencia de coberturas no representadas por el modelo.

En segundo lugar, se evaluó la capacidad del modelo para generar predicciones confiables de la ocurrencia de macroalgas. La validación se llevó a cabo mediante la comparación entre la cobertura observada en imágenes de muy alta resolución de la constelación SuperDove (Planet Labs Inc., resolución espacial aproximada de 3 m) y la capa de cobertura fraccional de macroalgas derivada del modelo aplicado a imágenes Sentinel-2 (resolución de 10 m).

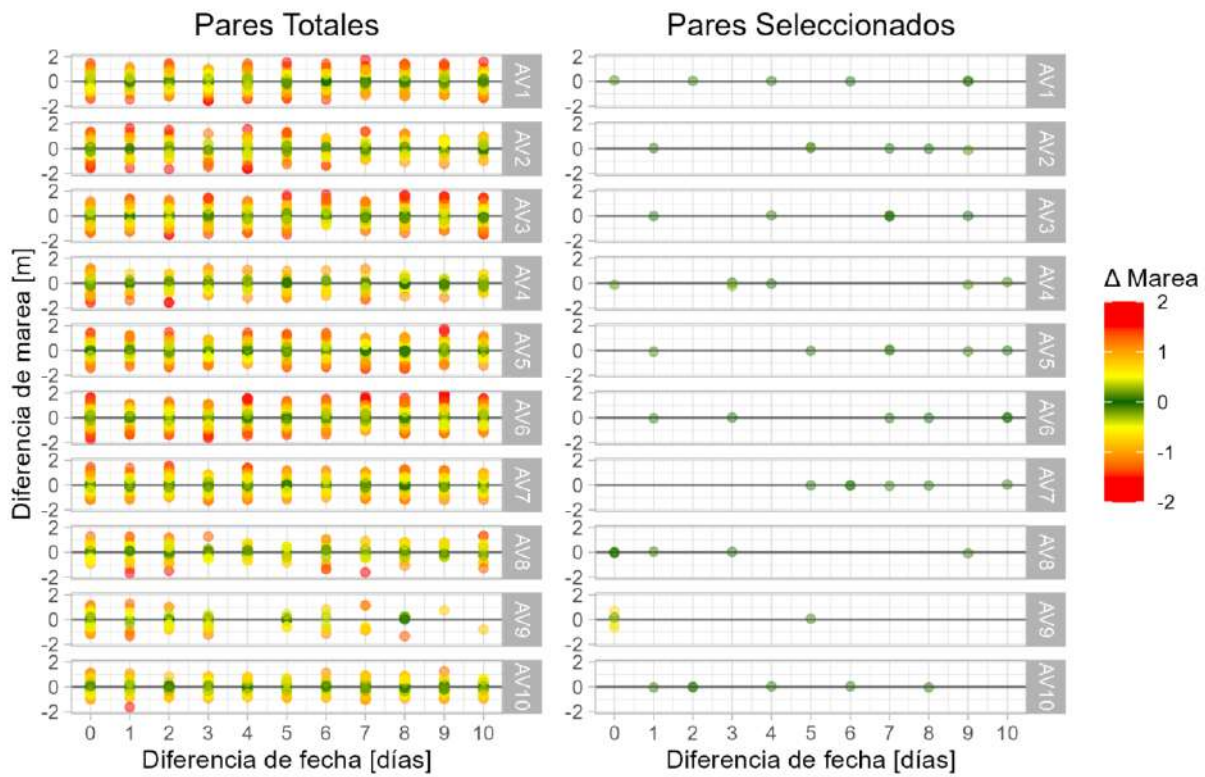
Se seleccionaron 10 áreas de validación siguiendo los mismos criterios utilizados para las áreas de muestreo y aplicando el mismo filtrado de cobertura nubosa sobre las imágenes Sentinel-2. Se utilizó el

período comprendido entre el 13 de marzo de 2020 y el 04 de julio de 2025, correspondiente al solapamiento operativo de ambas constelaciones (figura 4). En estas zonas se escogieron manualmente las imágenes SuperDove con baja nubosidad y sin anomalías de sensor. Finalmente, para las combinaciones de localización y fecha de ambos conjuntos de imágenes se estimó el nivel de marea correspondiente mediante el modelo empírico de mareas oceánicas EOT20 (Hart-Davis et al. 2021).

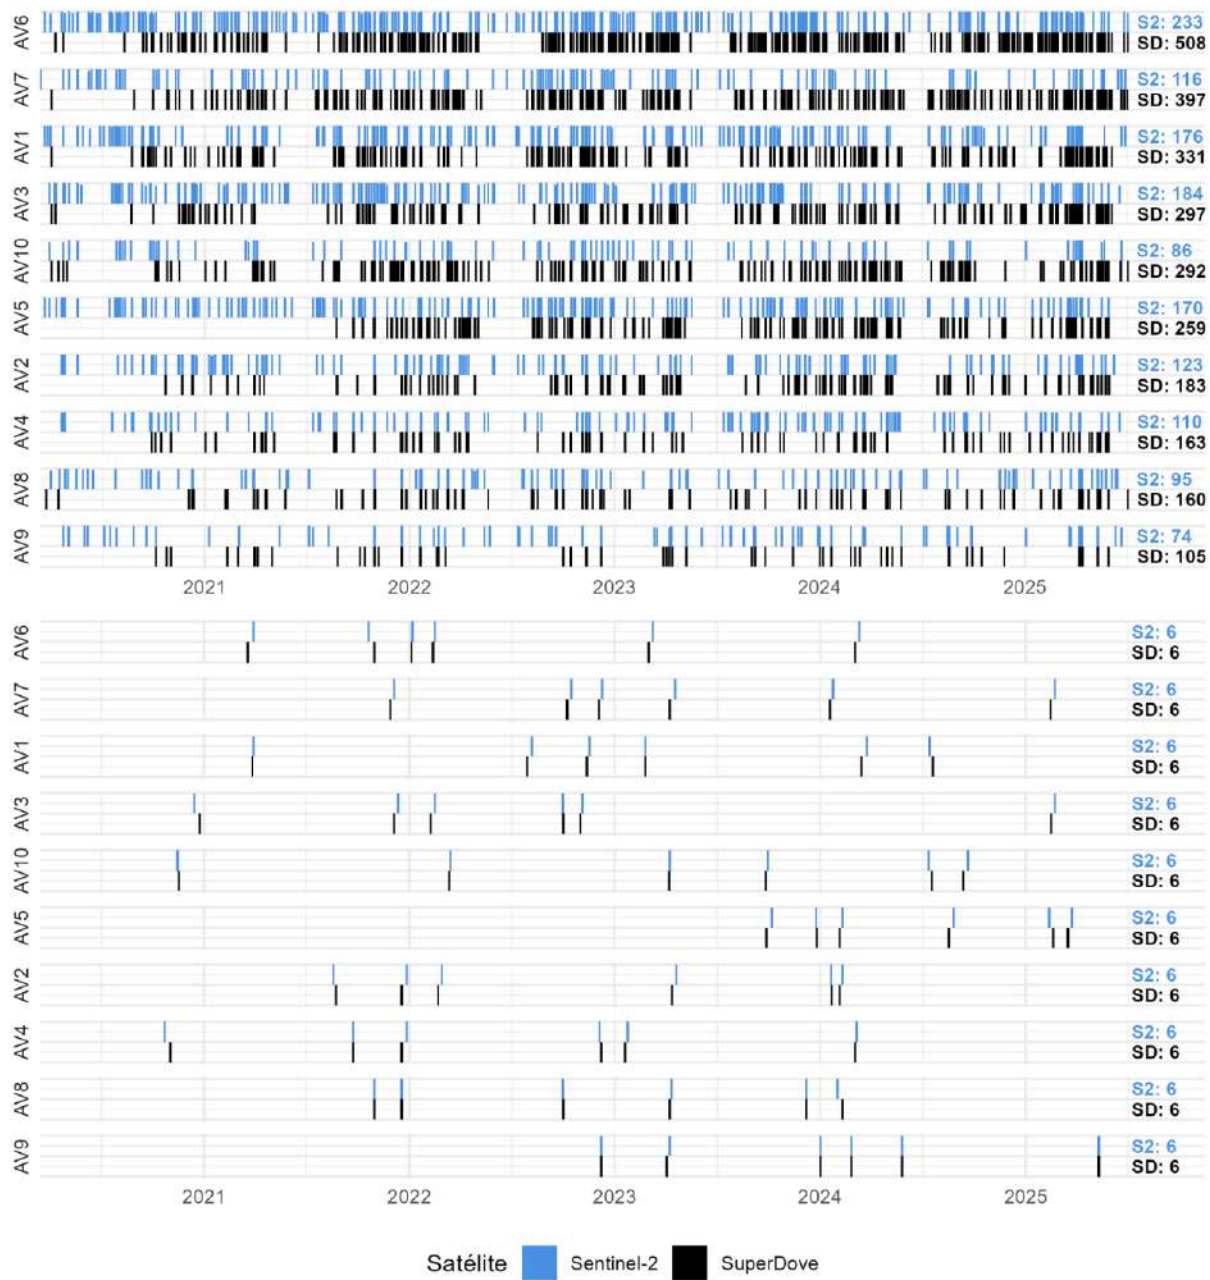


**Figura 4.** Área de estudio y localización de las áreas de validación (mapa de la izquierda), mostrando la cantidad de imágenes Sentinel-2 con mínima cobertura nubosa, dentro del periodo entre el 13 de marzo de 2020 y el 04 de julio de 2025. A la derecha se muestran cantidad de imágenes Sentinel-2 y SuperDove con mínima cobertura nubosa para el mismo periodo.

A partir de estos datos, se seleccionaron los mejores pares de imágenes Sentinel-2/SuperDove, minimizando las diferencias entre cada par considerando. Para ello se aplicaron cuatro criterios: (i) la diferencia en la hora de adquisición no podía superar una hora, con el fin de minimizar las variaciones en la iluminación solar; (ii) la diferencia entre las fechas de adquisición no podía ser superior a 10 días, para reducir los efectos de cambios fenológicos o de cobertura en las macroalgas entre observaciones; y (iii) en cada área no podía repetirse la misma imagen de SuperDove o Sentinel, evitando así la dependencia entre pares y garantizando la representatividad espacial del conjunto de validación. Finalmente, (iv) utilizando la selección de imágenes resultante de los primeros tres criterios, se seleccionaron 6 pares de imágenes por área con la menor diferencia en la marea estimada (figuras 5 y 6). En total se seleccionaron 60 pares de imágenes, descartando cuatro debido a condiciones atmosféricas desfavorables en las imágenes Sentinel-2.



**Figura 5:** Comparación de la diferencia temporal y de marea por área de validación entre todos los pares de imágenes Sentinel-2 y SuperDove con un límite de 10 días de diferencia. El panel de la derecha muestra los pares seleccionados para la validación.



**Figura 6:** Distribución temporal de las imágenes Sentinel-2 y SuperDove para cada área de validación entre el 13 de marzo de 2020 y el 4 de julio de 2025. Las barras verticales indican la fecha de cada imagen, y en el extremo derecho se muestra el total por colección (SD: SuperDove; S2: Sentinel-2). El panel superior incluye todas las imágenes disponibles, mientras que el inferior muestra únicamente los pares seleccionados para la validación.

Para cada imagen SuperDove, se dibujó el área con cobertura de macroalgas mediante fotointerpretación, utilizando composiciones en color verdadero, falso color (R: NIR, G: Rojo, B: Verde) y NDVI, generando un polígono representativo de dicha cobertura. Por otro lado, a cada imagen Sentinel-

2 se le aplicó el algoritmo de *spectral unmixing*, con tal de obtener la Cobertura Fraccional de Macroalgas (CFM). Además, se enmascararon todos los píxeles con altura  $\geq 5$  m (usando el Modelo digital de elevación del Shuttle Radar Topography Mission, SRTM), Cobertura Fracción de Superficie Terrestre (CFST) mayor a 0,45 o Cobertura Fracción de Agua (CFA) menor a 0,1 con el fin de limitar los análisis únicamente a la zona marina de las imágenes.

Dado que la cobertura extraída de las imágenes de alta resolución corresponden a polígonos binarios con presencia/ausencia de macroalgas, fue necesaria la binarización de la CFM estimada con el modelo. Posteriormente, se realizó un análisis de sensibilidad para evaluar la precisión del modelo usando distintos umbrales de binarización. Las áreas resultantes de las distintas binarizaciones se compararon con las áreas delimitadas manualmente en las imágenes SuperDove. La correspondencia entre ambos conjuntos de áreas se evaluó mediante dos índices complementarios: (i) el promedio del índice de sobreposición espacial de Jaccard, que mide la similitud espacial entre dos áreas dividiendo su intersección por su unión [3], y (ii) el coeficiente de determinación ( $R^2$ ) de la regresión lineal entre los tamaños de las áreas.

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad [3]$$

## 2.6 Estimación de estacionalidad y tendencia

Para analizar la variación temporal de la cobertura fraccional de macroalgas, se generaron polígonos de análisis a lo largo de toda la costa del área de estudio. Se fijó la línea de costa utilizando el modelo digital de elevación del *Shuttle Radar Topography Mission* (SRTM), y se generaron puntos equidistantes cada 5 km, los que fueron utilizados para generar un diagrama de Voronoi, posteriormente recortado mediante un *buffer* de 1 km hacia el mar desde la línea de costa. Además, se excluyeron aquellas unidades con un área menor a 2 km<sup>2</sup>, obteniéndose un total de 1.352 polígonos de análisis.

Para cada imagen en estos polígonos se estimó la cobertura nubosa utilizando el porcentaje de píxeles enmascarados según un umbral del 50% del producto *Sentinel-2 Cloud Probability*, conservando únicamente las imágenes con menos de 5% de enmascaramiento.

Con esto como insumo, se generaron dos análisis paralelos: estacionalidad y tendencia. Para el caso del estudio de la estacionalidad se calculó el promedio de la CFM por imagen dentro de cada polígono, estudiando la variación de estos valores a escala mensual, y haciendo un análisis de la fenología de estos bosques mediante un ajuste de una función sinusoidal con tendencia lineal:

$$y(t) = a + bt + b_1 \sin(\omega t + \phi) \quad [4]$$

Donde  $\omega$  corresponde a la frecuencia angular de un ciclo anual ( $2\pi / 365,25$ ) y  $\phi$  es el desfase de la onda sinusoidal. El ajuste se realizó mediante mínimos cuadrados no lineales usando el algoritmo de Levenberg-Marquardt (Marquardt 1963).

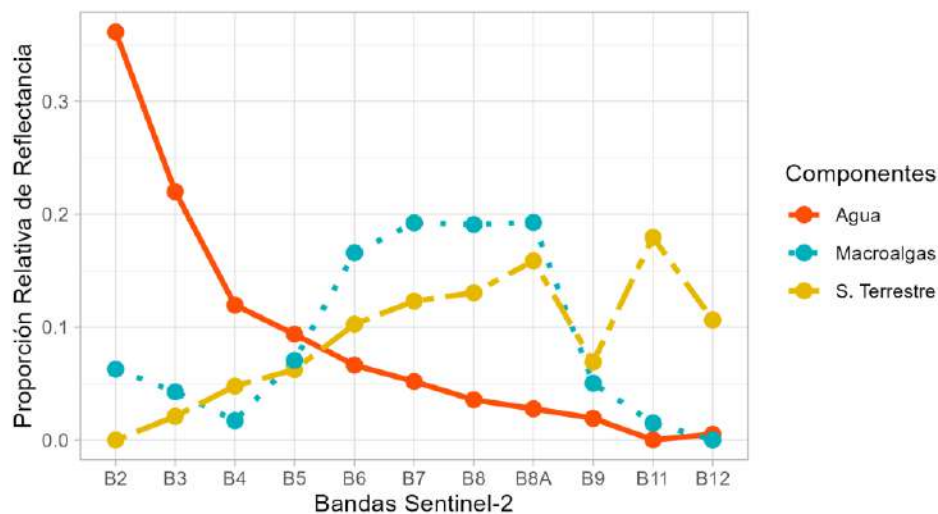
Adicionalmente, utilizando las imágenes libres de nubes dentro de los polígonos costeros, se estimó la tendencia interanual de la CFM a nivel de píxel mediante un modelo de regresión lineal. Para ello se generaron composiciones estivales, entre el 1 de diciembre y el 1 de febrero, desde el verano 2017–18 hasta el verano 2024–25, fechas en las cuales se maximiza el contraste de reflectancia para la detección de macroalgas en la zona, y empleando el percentil 25 de reflectancia con el fin de minimizar la influencia de píxeles afectados por aerosoles.

Posteriormente, la capa resultante se filtró para incluir solo píxeles con tendencias relativamente altas ( $R^2 > 0.6$ ), con al menos seis años y con una pendiente superior a 0.01 o inferior a  $-0.01$ . Esta pendiente equivale a un cambio anual del 1 % en la proporción total del píxel que se asigna a la clase “macroalgas” (es decir, un 1 % de transición anual desde o hacia la cobertura algal, respecto del total del píxel). Se excluyeron pendientes de menor magnitud porque correspondían con frecuencia a zonas sin presencia real de algas o a variaciones irrelevantes desde el punto de vista ecológico. Además, se descartaron áreas afectadas por contaminación por aerosoles, presencia de coberturas no consideradas por el modelo (por ejemplo, hielo), zonas de oleaje permanente y bahías con extensas áreas intermareales.

### 3. RESULTADOS

#### 3.1 Endmembers

La estimación de los *endmembers* alcanzó el umbral de error de convexidad de -6 después de 299 iteraciones, con valores negativos que representan solo el 0.816% de las proporciones de mezcla generadas a partir de la muestra de píxeles puros, indicando un buen ajuste del modelo y una proporción mínima de puntos de muestra que quedan fuera del politopo de mezcla formado por los *endmembers* (Weltje 1997). Los valores de los *endmembers* de macroalga, agua y superficie terrestre, en proporciones relativas de reflectancia (cociente de la reflectancia medida en una banda espectral respecto al total de las bandas), se encuentran en la figura 7; los valores exactos están disponibles en el anexo 7.



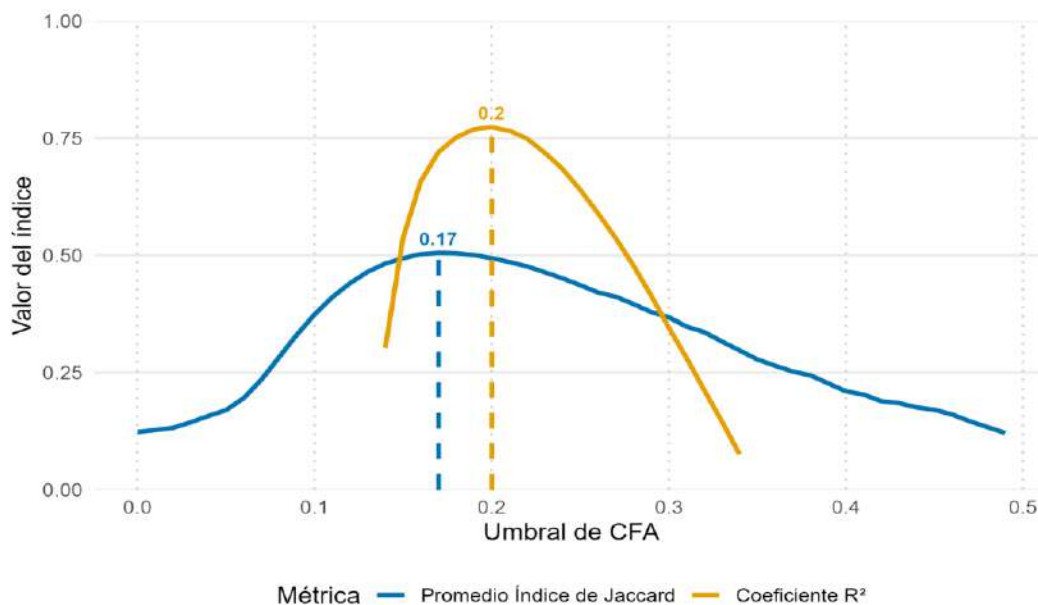
**Figura 7.** *Endmembers* estimados de macroalga, agua y superficie terrestres obtenidos mediante *spectral unmixing*, en valores de proporciones de reflectancia relativa.

Comparando los patrones de reflectancia de los píxeles puros con los *endmembers*, se pudo observar que estos últimos conservan formas claramente diferenciables entre agua, macroalgas y superficie terrestre. El agua presenta una caída monótona desde B2 hacia el SWIR, las macroalgas exhiben un aumento marcado en la región infrarroja cercano (B7–B8A) y la superficie terrestre alcanza sus máximos relativos en el infrarrojo lejano (especialmente B11). Estas diferencias en la forma permiten identificar qué bandas aportan más a la separabilidad entre componentes, destacando B2, B7–B8A y B11 como las que aportan más información para la discriminación de los mismos.

Es importante destacar que las macroalgas se diferencian de las otras dos componentes en distintas secciones del espectro. En el visible, se distinguen del agua debido a la fuerte absorbanza del agua en longitudes de onda mayores, lo que aumenta la proporción relativa de reflectancia de las macroalgas en esta región. En el infrarrojo cercano, las macroalgas se vuelven significativamente más brillantes que el agua gracias a la dispersión interna de la luz en sus tejidos (Thorhaug et al. 2007). Finalmente, en el infrarrojo lejano muestran una separación clara respecto de la superficie terrestre, producto de la alta absorción del agua en estas bandas, que atenúa la señal de las macroalgas y acentúa las diferencias con el sustrato terrestre.

### 3.2 Validación del modelo

Como resultado final del análisis validación, se determinó que el umbral de CFM de 0.17 maximiza el índice de Jaccard que alcanza un valor de 0,51. Mientras que el umbral de CFM de 0,20 maximiza el coeficiente de determinación ( $R^2$ ) que alcanza un valor de 0,77 (figura 8). La comparación de los polígonos de extensión de macroalgas delimitados manualmente en las imágenes SuperDove con los resultantes del umbral que maximiza el índice de Jaccard para las predicciones de CFM se pueden ver en el anexo 8.



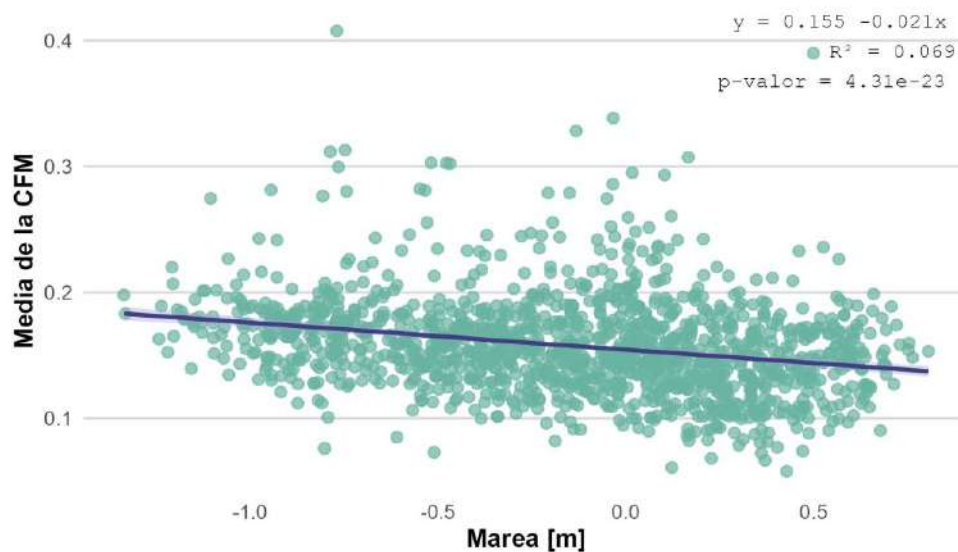
**Figura 8:** Desempeño del modelo en función del umbral de binarización de la CFM. Se muestran las variaciones del índice de Jaccard (línea azul) y del coeficiente de determinación ( $R^2$ ) (línea naranja) en relación con el umbral de CFA. Las líneas verticales punteadas indican los valores de umbral que maximizan cada métrica.

El análisis de sensibilidad reveló que ambas métricas de validación presentan un comportamiento no lineal, con un solo máximo local en función del umbral de binarización aplicado a la CFA, demostrando así que la selección del umbral de binarización ejerce una influencia considerable sobre el desempeño del modelo para determinar la extensión de macroalgas, con una reducción significativa en ambas métricas cuando se emplean valores excesivamente bajos o altos.

### 3.3 Influencia de la marea en el modelo

A partir de las imágenes Sentinel-2 adquiridas entre el 13 de marzo de 2020 y el 4 de julio de 2025 en las áreas de validación, considerando únicamente aquellas con una cobertura nubosa estimada del 0 %, se evaluó la influencia de la marea sobre los valores de la cobertura fraccional de macroalgas (CFM). Para ello, se aplicó el modelo de *spectral unmixing*, se calculó la CFM media de la zona acuática en cada imagen y se comparó con la marea estimada mediante el modelo EOT20.

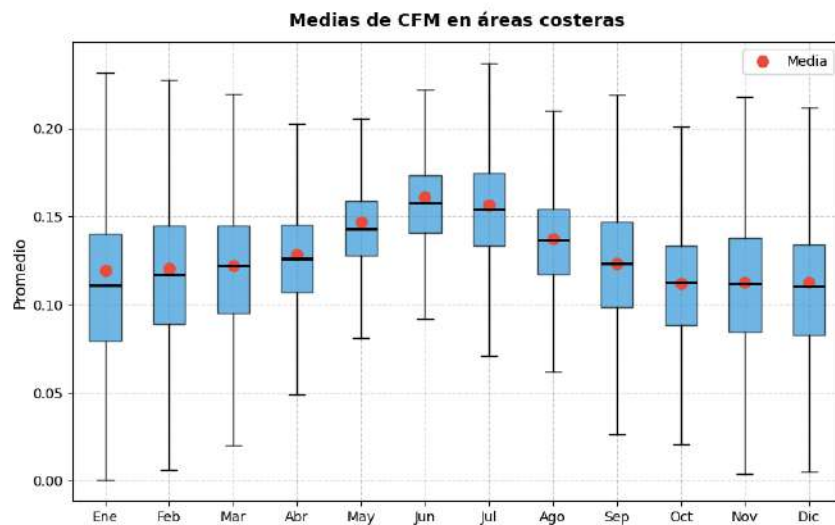
El análisis reveló que la marea explica aproximadamente un 7% de la varianza observada en la CFM, y que la pendiente del modelo es altamente significativa, indicando una disminución promedio de 0,021 unidades de CFM de cobertura (equivalente a un 2%), por cada metro de aumento en la marea (figura 9).




**Figura 9.** Relación lineal entre el promedio de la cobertura fraccional de macroalgas (CFM) y la marea estimada mediante el modelo EOT20, para todas las imágenes Sentinel-2 adquiridas entre el 13 de marzo de 2020 y el 4 de julio de 2025 en las áreas de validación, considerando únicamente aquellas con una cobertura nubosa estimada del 0%. El valor  $p$  corresponde a la significancia estadística de la pendiente asociada a la variable de marea.

### 3.4 Limitaciones del modelo asociadas a la variabilidad estacional

Durante el análisis de la variabilidad temporal de los bosques de macroalgas a lo largo de toda el área de estudio, se identificó un patrón anómalo en los valores de CFM. Contrario a lo esperado según la fenología conocida de *Macrocystis pyrifera* para áreas cercanas, los valores más altos de CFM se concentraron sistemáticamente hacia los meses de invierno (con máximos en junio y julio), cuando la biomasa algal debería estar cerca de su mínimo estacional (Van Tussenbroek 1993, Van Tussenbroek 1989, Huovinen et al. 2020), como muestra la figura 10. Por otra parte, los resultados del ajuste del modelo sinusoidal confirmaron la misma tendencia general y sincrónica a lo largo del área de estudio, encontrando los valores modelados de CFM su máximo estacional en invierno y mínimo estacional en verano (figura 11).

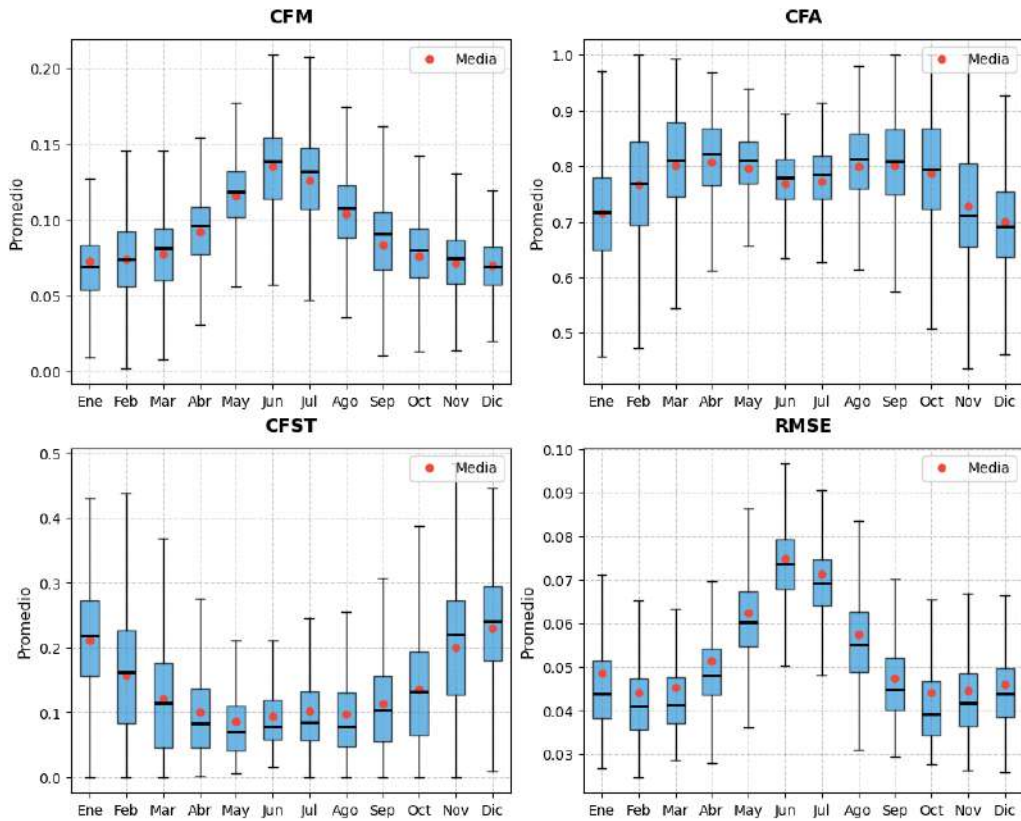


**Figura 10.** Valores promedio por imagen de Cobertura Fraccional de Macroalgas (CFM), agrupados mensualmente para 1352 áreas costeras en el Estrecho de Magallanes y zonas aledañas.



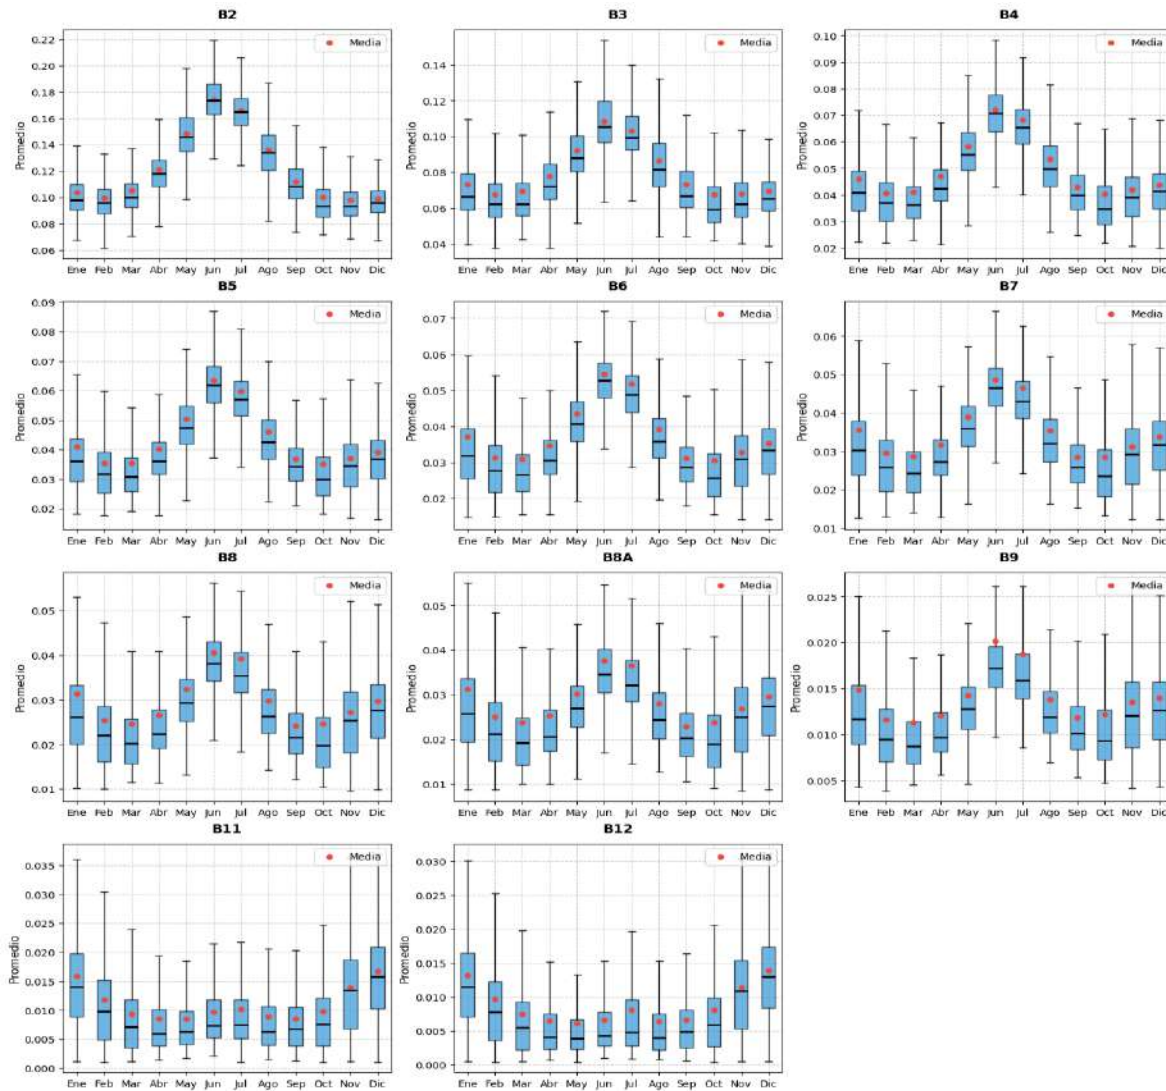
**Figura 11.** Día del año en que el modelo sinusoidal con tendencia lineal de la Cobertura Fraccional de Macroalgas (CFM) promedio por imagen, alcanza su mínimo y máximo estacional en 1.352 áreas costeras del Estrecho de Magallanes. La paleta de colores fue seleccionada para maximizar el contraste y visualización del patrón encontrado.

Con el objetivo de evaluar si este patrón era atribuible a características intrínsecas de la componente de agua del modelo, se generó una grilla de 125 polígonos cuadrados de 1 km<sup>2</sup> ubicados en aguas alejadas del litoral (a 3 km o más de distancia de la costa, ver anexo 9), donde se esperaba ausencia completa de macroalgas. En estas zonas se aplicó la misma metodología de selección y análisis utilizada para las zonas costeras. La figura 12 muestra los promedios mensuales de cada cobertura fraccional y del RMSE del modelo. Los resultados evidenciaron un aumento anómalo de la CFM hacia el invierno, acompañado de una disminución de la cobertura fraccional de superficie terrestre (CFST) y una disminución de la capacidad del modelo para separación los valores espectrales originales en los *endmembers* (mayor RMSE).



**Figura 12.** Valores promedio por imagen de Cobertura Fraccional de Macroalgas (CFM), Agua (CFA) y Superficie Terrestre (CFST), junto al promedio de la raíz del error cuadrático medio (RMSE) del proceso de *spectral unmixing*, agrupados mensualmente para áreas ubicados en aguas alejadas de la costa (>3 km).

De manera análoga al análisis anterior, usando los 125 polígonos seleccionados, se extrajeron los valores medios de las bandas espectrales de las imágenes utilizadas por el modelo de *spectral unmixing*. Como resultado, se observa un patrón muy similar en todas las bandas desde el espectro visible al infrarrojo cercano, presentando un máximo absoluto en el mes de junio-julio y un máximo relativo en enero-diciembre. Mientras que en las bandas del infrarrojo lejano también se observa un pequeño aumento de la reflectancia en invierno, presentando su máximo en los meses de verano (figura 13). Para observar cómo estos valores se traducen en valores de reflectancia relativa consultar el anexo 10. Este análisis de cambios en las bandas Sentinel-2 también se replicó para la colección Surface Reflectance (SR), procesadas con Sen2Cor (ESA, 2018), obteniéndose patrones estacionales muy similares (anexo 11), lo que refuerza la robustez de los resultados.

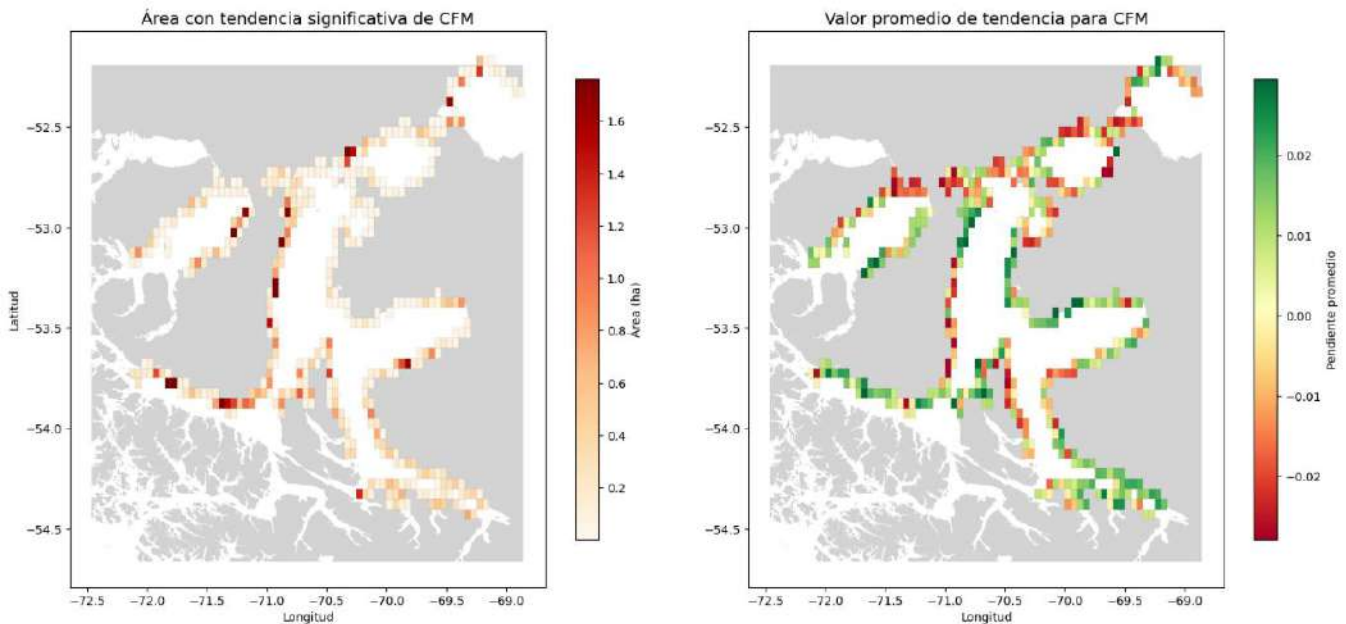


**Figura 13.** Valores promedio de reflectancia por imagen para las bandas espectrales de Sentinel-2 TOA utilizadas por el modelo de *spectral unmixing*, agrupados mensualmente para áreas ubicadas en aguas alejadas de la costa (>3 km).

### 3.5 Tendencias interanuales

Las tendencias calculadas a nivel de píxel bajo los criterios mencionados en la metodología, y agregadas espacialmente en una grilla de  $0.05^\circ$  mediante el conteo de píxeles con tendencia y el cálculo de su valor medio, muestran que existen patrones espaciales en la dinámica de la cobertura algal (figura 14). En particular, los mayores cambios en superficie se concentran en el extremo occidental del estrecho, especialmente en las costas de la península de Brunswick, incluyendo parte de la bahía Fundy, así como

en sectores puntuales de Isla Dawson, bahía Inútil y las cercanías de Puerto Sara (figura 14, panel izquierdo).

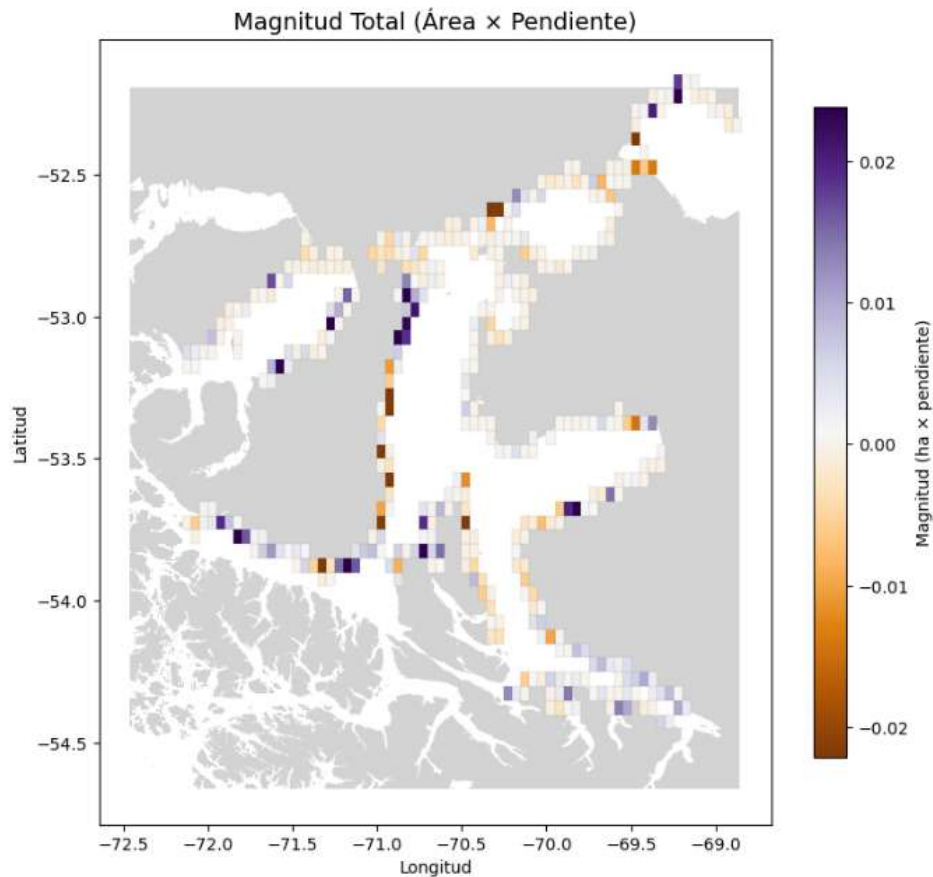


**Figura 14.** Mapas que muestran, para una grilla de 0.05° de latitud y longitud: a la izquierda, el área cubierta por píxeles con tendencia lineal significativa en la Cobertura Fraccional de Macroalgas (CFM), y a la derecha, la pendiente media de dicha tendencia, calculadas para los periodos de verano desde 2017–18 a 2024–25. Los rangos de color en ambos mapas se limitaron a los percentiles 2 y 98 para evitar la influencia de valores extremos en la visualización.

Por otra parte, los valores de pendiente media para la tendencia estival de la CFM se distribuyen entre -0,045 (-4,5%) y 0,042 (4,2%), con una media de 0.002 (0,2%). Si bien los patrones de ganancia y pérdida no evidencian un gradiente latitudinal ni longitudinal claro, sí presentan una distribución espacial heterogénea y con claras agrupaciones espaciales a esta escala de análisis.

Al analizar el producto entre la superficie de píxeles con tendencia distinta de cero y su pendiente media (figura 15), se identifican las zonas con mayor magnitud de cambio en la cobertura algal. Este análisis revela incrementos relevantes en el sector oriental de bahía Fundy, en Cabo Negro, en el sur de bahía El Águila y en el noroeste de isla Dawson. En contraste, se observa una disminución marcada en el tramo costero comprendido entre Punta Arenas y Puerto del Hambre, así como en los alrededores de Primera Angostura. Además, el resto de la península de Brunswick muestra agrupaciones espaciales locales de aumento y disminución sin un patrón espacial claro, tal como ocurre también dentro de bahía Inútil e Isla Dawson. Finalmente, el patrón espacial de la tendencia calculada dentro del seno

Almirantazgo, en el sector sureste de nuestra área de estudio, muestra un aumento relativamente homogéneo a lo largo de su extensión geográfica.



**Figura 15.** Mapa que muestra, para una grilla de  $0.05^\circ$  de latitud y longitud, la magnitud de la tendencia lineal en la Cobertura Fraccional de Macroalgas (CFM), entendiéndose esta como el producto entre el área de cambio y pendiente media de la tendencia lineal, calculadas para los periodos de verano desde 2017–18 a 2024–25. El rango de color se limitó a los percentiles 2 y 98 para evitar la influencia de valores extremos.

La capa de la tendencia lineal a nivel de píxel puede ser consultada en el apéndice A. En esta se detalla los valores de pendiente para la tendencia lineal. Así como los valores de CFM para el verano 2024-25.

#### 4. DISCUSIÓN

Los resultados muestran que el proceso metodológico, además de entregar un producto de alta resolución espacio-temporal, también permite identificar patrones generales analizables a macroescala, especialmente considerando el proceso de validación utilizado.

A partir de la aplicación del modelo de *spectral unmixing* se observó que, entre los *endmembers*, el componente agua fue el más fácil de identificar, dado que presenta la firma espectral más distintiva. En cambio, macroalgas y superficie terrestre mostraron mayor confusión en áreas con vegetación densa, lo que se explica por el solapamiento de sus firmas en las bandas del infrarrojo cercano, en donde comúnmente es posible detectar actividad fotosintética. No obstante, utilizando las coberturas fraccionales de manera conjunta, es posible generar máscaras de tierra confiables que permiten hacer un filtrado del ecosistema marino de interés.

En el desarrollo de este trabajo descubrimos que existe una ventaja en emplear los *endmembers* en valores de reflectancia normalizada, ya que los cambios en la iluminación afectan principalmente la magnitud absoluta de la reflectancia, pero no la forma de la curva espectral (Drumetz et al. 2016) y, por lo tanto, las proporciones relativas entre bandas. Gracias a ello, el modelo puede operar sin requerir un *endmember* de sombra, común en otros enfoques de *spectral unmixing* (Souza et al. 2005, Ji et al. 2020, Liu et al. 2025). Este punto es particularmente relevante en el área de estudio, donde la combinación de baja elevación solar y alta nubosidad genera sombras persistentes en las imágenes.

Dado que el modelo está diseñado para detectar macroalgas como una unidad funcional, los *endmembers* obtenidos no permiten distinguir de manera consistente a *Macrocystis pyrifera* (especie dominante en el área de estudio) de otras macroalgas, como *Lessonia*, en la zona submareal, o de las especies que prevalecen en el intermareal. Esta falta de diferenciación se debe a la alta similitud de sus firmas espectrales en Sentinel-2, y constituye una oportunidad para desarrollar *endmembers* más específicos, incorporando variabilidad interespecífica y mejorando los procesos de extracción de píxeles puros.

En el proceso de validación del modelo se observó que los umbrales óptimos para cobertura fraccional de macroalga en ambas métricas resultaron muy próximos entre sí (0.17 para el índice de Jaccard y 0.20 para el coeficiente  $R^2$ ), lo que sugiere robustez en la selección del umbral de binarización y sitúa el rango óptimo aproximadamente entre 0.15 y 0.22. En cuanto al desempeño del modelo, se

obtuvo un índice de Jaccard máximo de 0,51 y un coeficiente  $R^2$  de 0,77, indicativo de una sobreposición espacial moderada entre los datos de referencia basados en imágenes de muy alta resolución y los valores estimados del modelo. La discrepancia entre los valores máximos de ambas métricas sugiere que el modelo presenta mayor precisión en la estimación de las áreas totales de cobertura de macroalgas que en la predicción de su localización espacial exacta.

Cabe destacar que, en estas mismas áreas de validación, la correlación negativa observada entre la CFM y el nivel de marea no resulta sorprendente, ya que la marea modula el porcentaje de macroalga expuesta en la superficie oceánica, alcanzando su máximo durante los períodos de baja marea. Además, este resultado constituye una señal positiva, pues indica que las predicciones del modelo EOT20 reflejan adecuadamente las condiciones locales de marea.

Sin embargo, una línea metodológica con potencial de mejora para este modelo sería incorporar una estimación de marea que considere explícitamente los procesos físicos. A diferencia del EOT20, que se basa en un enfoque empírico y no incorpora la configuración costera (Hart-Davis et al. 2021), los modelos hidrodinámicos representan la geometría del entorno marino (incluyendo bahías, fiordos y estrechamientos) (Umgiesser et al. 2022), lo que permitiría describir de manera más fiel la propagación y modulación de las ondas de marea dentro del Estrecho de Magallanes y sus áreas circundantes. Esta capacidad de integrar la topografía y batimetría locales podría mejorar sustancialmente la estimación del nivel del mar y reducir la incertidumbre en contextos morfológicamente complejos (Umgiesser et al. 2022). Contar con una estimación de marea más precisa también ayudaría a separar este efecto de otros procesos estacionales presentes en la señal.

En esta línea, el patrón intraanual observado en la CFM, contiene máximos durante el invierno, en contraste con lo reportado en la literatura (Van Tussenbroek 1989, Van Tussenbroek 1993, Huovinen et al. 2020), indicando que estas variaciones no reflejarían la fenología real de *Macrocystis pyrifera*, sino una confusión espectral asociada a la geometría solar en altas latitudes (Xu et al. 2024). Este factor es de gran relevancia considerando que el ángulo cenital solar (ACS) varía en promedio entre  $\sim 33^\circ$  en el solsticio de verano y  $\sim 78.5^\circ$  en el de invierno.

Esta conclusión se ve reforzada por el análisis de los valores espectrales de las bandas de Sentinel-2 TOA en aguas profundas y alejadas de la costa, al mostrar una variación estacional atribuible a condiciones ambientales propias de las imágenes, lo que conlleva a sobreestimaciones de cobertura algal en invierno. Este patrón parece surgir de dos procesos complementarios. Primero, el aumento del ACS

reduce la irradiancia incidente por metro cuadrado, lo que explica la disminución de la reflectancia de primavera y otoño respecto a verano. Sin embargo, este mecanismo no explica por sí solo el incremento de la reflectancia durante los meses de invierno. Segundo, durante estos meses los elevados valores de ACS aumentan la importancia de la dispersión atmosférica, tanto por moléculas (efecto Rayleigh) como por aerosoles (efecto Mie) (Xu et al. 2024). Este incremento en la dispersión hace que más luz sea desviada hacia el sensor antes de alcanzar la superficie oceánica, elevando la reflectancia. Además, la curvatura terrestre amplifica estos efectos en ángulos solares extremos, lo que puede intensificar aún más la radiación registrada en la parte superior de la atmósfera (Xu et al. 2024). Este mismo comportamiento se replicó en la colección de reflectancia de superficie de Sentinel-2 (anexo 11), lo que evidencia que el efecto del ángulo solar persiste aun después del proceso de corrección.

De manera adicional, otra fuente de distorsión en los datos puede ser la interacción de la luz con la superficie del agua, generando una menor penetración de la radiación solar y un aumento de la reflectancia especular con ángulos solares más oblicuos (Hecht 2017, Masuda & Takashima 1996), efecto que interactúa con patrones estacionales de viento (Vásquez Anacona et al. 2023) y turbidez (Huovinen et al. 2016).

Si bien el modelo se basa en proporciones relativas de reflectancia, lo que en principio debería hacerlo más robusto frente a variaciones de iluminación, esta robustez no se sostiene plenamente bajo las condiciones observadas. Los cambios inducidos por la geometría solar y la reflectancia especular no afectan por igual a todas las bandas (anexo 10), alterando las proporciones resultantes de la normalización. Como consecuencia, aún después de la estandarización espectral, persisten distorsiones sistemáticas que conducen a sobreestimaciones de la cobertura algal durante el invierno. Este fenómeno también queda en evidencia con el aumento del RMSE, indicando una mayor discrepancia entre los valores espectrales originales y su reconstrucción a partir de las fracciones estimadas. En otras palabras, el modelo presenta una reducción de consistencia interna en períodos donde la iluminación es más oblicua.

Este hallazgo representa un punto de mejora crucial para futuras aplicaciones del modelo en regiones de altas latitudes, donde la geometría solar experimenta variaciones estacionales extremas. Las soluciones potenciales incluyen la incorporación de correcciones atmosféricas más robustas o modelos de mezcla espectral que consideren explícitamente el ángulo de incidencia solar. Complementariamente, la validación mediante fotografía aérea de baja altitud usando drones permitiría establecer una correspondencia directa entre los valores fraccionales estimados y el porcentaje real de cobertura algal a

escala subpíxel. A diferencia de la validación con imágenes SuperDove, basada en clasificación binaria de presencia/ausencia, las imágenes de drones de muy alta resolución (<10 cm/píxel) posibilitarían cuantificar la cobertura fraccional real mediante clasificación supervisada o fotointerpretación, evaluando así tanto la detección como la precisión cuantitativa del modelo para estimar proporciones de cobertura.

Pese a las limitaciones técnicas para evaluar patrones estacionales, el análisis de las tendencias interanuales reveló señales espaciales coherentes. La distribución de las tendencias promedio de la CFM mostró agrupaciones extensas (de varios kilómetros de costa) con ganancias y pérdidas, indicando que estos cambios no se manifiestan de manera aislada, sino articulados en grandes conjuntos de fragmentos de bosque submarino. Esta organización espacial podría estar vinculada a procesos de remoción y regeneración inducidos por forzantes de mesoescala, como marejadas intensas, fuertes oleajes o tormentas, capaces de producir daños localizados en la estructura de los bosques, seguidos por fases de recuperación (Ebeling et al. 1985, Dayton et al. 1992, Earp et al. 2024). La presencia de estos patrones agregados es concordante con la dinámica de ambientes altamente expuestos, donde eventos climáticos y oceanográficos episódicos actúan como pulsos de perturbación que reconfiguran la cobertura de macroalgas a lo largo de la costa (Ebeling et al. 1985, Dayton et al. 1992, Earp et al. 2024).

Si bien este estudio entrega una caracterización macroespacial de las tendencias en los bosques de macroalgas para el período comprendido entre los veranos 2017–18 y 2024–25, aún permanece abierta la posibilidad de realizar análisis más detallados que permitan comprender cómo operan estos cambios a escala de fragmento. Por ejemplo, evaluando si las ganancias o pérdidas de cobertura se concentran en los bordes externos de los parches o hacia sectores de sustratos de fondo marino más blandos, pues esto podría aportar información clave sobre los procesos ecológicos subyacentes. Esta línea de investigación se vuelve relevante considerando que, en muchos casos, la capa de tendencias a nivel de píxel sugiere patrones espaciales que podrían estar asociados a expansiones y retracciones heterogéneas y localizadas al interior de los fragmentos, como se observa en el anexo 12.

## 5. CONCLUSIÓN

Este estudio demuestra que la aplicación de un modelo de *spectral unmixing*, sustentado en la extracción de píxeles puros para el cálculo de *endmembers*, constituye una herramienta robusta para estimar la cobertura fraccional de macroalgas en ambientes costeros subantárticos. El procedimiento para identificar firmas espectrales representativas permitió aislar adecuadamente la señal de macroalgas, garantizando una base estable para el modelamiento a lo largo de toda la serie temporal.

Un hallazgo relevante es la influencia sistemática de la marea sobre las estimaciones del modelo. Aunque su efecto sobre la cobertura fraccional es acotado, constituye un factor que debe considerarse al interpretar la dinámica temporal del sistema, especialmente en el sector norte del estrecho, zona donde existen importantes variaciones en el nivel del mar y, por lo tanto, en la proporción de frondas expuestas o sumergidas. La incorporación explícita de este componente, ya sea como covariable o mediante ajustes en los criterios de composición, representa un camino claro para mejorar la robustez de las estimaciones.

Asimismo, los resultados muestran que el desempeño del modelo depende en parte de las condiciones de observación satelital, particularmente en invierno, donde la geometría solar introduce variaciones que pueden amplificar o atenuar las mezclas espectrales. Esto destaca la necesidad de desarrollar esquemas de corrección radiométrica más sensibles a estas condiciones, o de explorar alternativas que integren información angular en el proceso de *spectral unmixing*.

En conjunto, el trabajo evidencia que, pese a estas limitaciones, el modelo es útil para la identificación y delimitación de los bosques subantárticos de macroalga, así como de las tendencias estivales de estos, constituyendo una base sólida para el monitoreo continuo de bosques de macroalgas. Estudios futuros deberían profundizar en la optimización del conjunto de *endmembers*, en la corrección del efecto mareal y en la validación a escalas más finas, de modo de fortalecer su aplicabilidad como herramienta estándar para la observación de estos ecosistemas costeros.

## 6. APÉNDICES

A: La capa de tendencia lineal a nivel de píxel puede ser consultada mediante la siguiente aplicación de Google Earth Engine:

<https://geejoseba.users.earthengine.app/view/visualizador-de-la-tendencia-lineal-de-macroalgas>

## 7. REFERENCIAS

Alshahrani AA, O Bchir, MM Ben Ismail. 2025. Autoencoder-Based Hyperspectral Unmixing with Simultaneous Number-of-Endmembers Estimation. *Sensors*, 25(8), Article 8. <https://doi.org/10.3390/s25082592>

Arafeh-Dalmau N, G Montaña-Moctezuma, JA Martínez, R Beas-Luna, DS Schoeman, G Torres-Moye. 2019. Extreme Marine Heatwaves Alter Kelp Forest Community Near Its Equatorward Distribution Limit. *Frontiers in Marine Science*, 6. <https://doi.org/10.3389/fmars.2019.00499>

Bell TW, JG Allen, KC Cavanaugh, DA Siegel. 2020. Three decades of variability in California's giant kelp forests from the Landsat satellites. *Remote Sensing of Environment*, 238, 110811. <https://doi.org/10.1016/j.rse.2018.06.039>

Bioucas-Dias JM, A Plaza, N Dobigeon, M Parente, Q Du, P Gader, J Chanussot. 2012. Hyperspectral Unmixing Overview: Geometrical, Statistical, and Sparse Regression-Based Approaches. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2), 354–379. <https://doi.org/10.1109/JSTARS.2012.2194696>

Buschmann AH, S Prescott, P Potin, S Faugeton, JA Vásquez, C Camus, J Infante, MC Hernández-González, A Gutiérrez, DA Varela. 2014. The Status of Kelp Exploitation and Marine Agronomy, with Emphasis on *Macrocystis pyrifera*, in Chile. In N. Bourgoignon (Ed.), *Advances in Botanical Research* (Vol. 71, pp. 161–188). Academic Press. <https://doi.org/10.1016/B978-0-12-408062-1.00006-8>

Campbell JB, RH Wynne. 2011. Image Interpretation. En *Introduction to remote sensing* (5th ed., pp. 130–157). Guilford Press.

- Cavanaugh, KC, DA Siegel, BP Kinlan, DC Reed. 2010. Scaling giant kelp field measurements to regional scales using satellite observations. *Marine Ecology Progress Series*, 403, 13–27. <https://doi.org/10.3354/meps08467>
- Cavanaugh K, K Cavanaugh, T Bell, E Hockridge. 2021. An Automated Method for Mapping Giant Kelp Canopy Dynamics from UAV. *Frontiers in Environmental Science*, 8. <https://doi.org/10.3389/fenvs.2020.587354>
- Dayton PK. 1985. The Structure and Regulation of Some South American Kelp Communities. *Ecological Monographs*, 55(4), 447–468. <https://doi.org/10.2307/2937131>
- Dayton PK, MJ Tegner, PE Parnell, PB Edwards. 1992. Temporal and spatial patterns of disturbance and recovery in a kelp forest community. *Ecological Monographs*, 62(3), 421–445.
- Drumetz L, MA Veganzones, S Henrot, R Phlypo, J Chanussot, C Jutten. 2016. Blind hyperspectral unmixing using an Extended Linear Mixing Model to address spectral variability. *IEEE Transactions on Image Processing*, 25(8), 3890–3905. <https://doi.org/10.1109/TIP.2016.2579259>
- Dussailant I, E Berthier, F Brun, M Masiokas, R Hugonnet, V Favier, A Rabatel, P Pitte, L Ruiz. 2019. Two decades of glacier mass loss along the Andes. *Nature Geoscience*, 12(10), Article 10. <https://doi.org/10.1038/s41561-019-0432-5>
- Earp HS, DA Smale, PM Almond, HJN Catherall, A Gouraguine, C Wilding, PJ Moore. 2024. Temporal variation in the structure, abundance, and composition of *Laminaria hyperborea* forests and their associated understory assemblages over an intense storm season. *Marine Environmental Research*, 200, 106652. <https://doi.org/10.1016/j.marenvres.2024.106652>
- Ebeling AW, DR Laur, RJ Rowley. 1985. Severe storm disturbances and reversal of community structure in a southern California kelp forest. *Marine Biology*, 84(3), 287–294. <https://doi.org/10.1007/BF00392498>
- European Space Agency (ESA). 2015. Sentinel-2 User Handbook (Issue 1, Rev 2). [https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2\\_User\\_Handbook](https://sentinels.copernicus.eu/documents/247904/685211/Sentinel-2_User_Handbook)
- European Space Agency (ESA). 2015-presente. Sentinel-2 MSI Level-1C Top-of-Atmosphere Reflectance (COPERNICUS/S2) [Dataset]. Copernicus Open Access Hub & Google Earth Engine. [https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS\\_S2](https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2)

- European Space Agency (ESA). 2015-presente. Sentinel-2 Level-2A Surface Reflectance (COPERNICUS/S2\_SR) [Dataset]. Copernicus Open Access Hub & Google Earth Engine. [https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS\\_S2\\_SR](https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR)
- European Space Agency (ESA). 2018. Sen2Cor configuration and user manual (S2-PDGS-TS-09-003). <https://step.esa.int/main/third-party-plugins/sen2cor/>
- Friedlander AM, E Ballesteros, TW Bell, J Giddens, B Henning, M Hüne, A Muñoz, P Salinas-de-León, E Sala. 2018. Marine biodiversity at the end of the world: Cape Horn and Diego Ramírez islands. *PLOS ONE*, 13(1), e0189930. <https://doi.org/10.1371/journal.pone.0189930>
- Garreaud RD, M Vuille, R Compagnucci, J Marengo. 2009. Present-day South American climate. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 281(3), 180–195. <https://doi.org/10.1016/j.palaeo.2007.10.032>
- Giri, C. P. (Ed.). 2012. Remote sensing of land use and land cover: Principles and applications. CRC Press/Taylor & Francis Group.
- Gómez I, J Loaiza, M Palacios, D Osman, P Huovinen. 2025. Functionality of photobiological traits of the giant kelp (*Macrocystis pyrifera*) as key determinant to thrive in contrasting habitats in a sub-Antarctic region. *Science of The Total Environment*, 971, 179055. <https://doi.org/10.1016/j.scitotenv.2025.179055>
- González-Aragón D, R Muñoz, H Houskeeper, K Cavanaugh, W García-Tuñón, L Farías, C Lara, BR Broitman. 2025. Seasonal and inter-annual dynamics of a *Macrocystis pyrifera* forest in Concepcion Bay, Chile. *Ecological Informatics*, 87, 103103. <https://doi.org/10.1016/j.ecoinf.2025.103103>
- Gorelick N, M Hancher, M Dixon, S Ilyushchenko, D Thau, R Moore. 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hart-Davis MG, G Piccioni, D Dettmering, C Schwatke, M Passaro, F Seitz. 2021. EOT20: A global ocean tide model from multi-mission satellite altimetry. *Earth System Science Data*, 13(8), 3869–3884. <https://doi.org/10.5194/essd-13-3869-2021>
- Hecht E. 2017. *Optics* (5th ed.). Pearson.
- Hoskins BJ, PJ Valdes. 1990. On the existence of storm-tracks. *J. Atmos. Sci.* 47, 1854–1864.

- Huovinen P, J Ramírez, I Gómez. 2016. Underwater Optics in Sub-Antarctic and Antarctic Coastal Ecosystems. *PLOS ONE*, 11(5), e0154887. <https://doi.org/10.1371/journal.pone.0154887>
- Huovinen P, J Ramírez, M Palacios, I Gómez. 2020. Satellite-derived mapping of kelp distribution and water optics in the glacier impacted Yendegaia Fjord (Beagle Channel, Southern Chilean Patagonia). *Science of The Total Environment*, 703, 135531. <https://doi.org/10.1016/j.scitotenv.2019.135531>
- Jensen JR. 2014. Photogrammetry. En Remote sensing of the environment: An Earth resource perspective (2.<sup>a</sup> ed., pp. 129–176). Pearson Education Limited.
- Ji C, X Li, H Wei, S Li. 2020. Comparison of Different Multispectral Sensors for Photosynthetic and Non-Photosynthetic Vegetation-Fraction Retrieval. *Remote Sensing*, 12(1), 115. <https://doi.org/10.3390/rs12010115>
- Johnson CR, SC Banks, NS Barrett, F Cazassus, PK Dunstan, GJ Edgar, SD Frusher, C Gardner, M Haddon, F Helidoniotis, KL Hill, NJ Holbrook, GW Hosie, PR Last, SD Ling, J Melbourne-Thomas, K Miller, GT Pecl, AJ Richardson, ... N Taw. 2011. Climate change cascades: Shifts in oceanography, species' ranges and subtidal marine community dynamics in eastern Tasmania. *Journal of Experimental Marine Biology and Ecology*, 400(1–2), 17–32. <https://doi.org/10.1016/j.jembe.2011.02.032>
- Johnson GC, JM Lyman. 2020. Warming trends increasingly dominate global ocean. *Nature Climate Change*, 10(8), 757–761. <https://doi.org/10.1038/s41558-020-0822-0>
- Kale KV, MM Solankar, DB Nalawade, KV Kale, MM Solankar, DB Nalawade. 2019. Hyperspectral Endmember Extraction Techniques. In Processing and Analysis of Hyperspectral Data. IntechOpen. <https://doi.org/10.5772/intechopen.88910>
- Keshava N, JF Mustard. 2002. Spectral unmixing. *IEEE Signal Processing Magazine*, 19(1), 44–57. <https://doi.org/10.1109/79.974727>
- Krause-Jensen D, CM Duarte. 2016. Substantial role of macroalgae in marine carbon sequestration. *Nature Geoscience*, 9(10), 737–742. <https://doi.org/10.1038/ngeo2790>
- Kumar U, KS Raja, C Mukhopadhyay, TV Ramachandra. 2012. A Neural Network Based Hybrid Mixture Model to Extract Information from Non-linear Mixed Pixels. *Information*, 3(3), 420–441. <https://doi.org/10.3390/info3030420>

- Laukaityte S, R Riera. 2022. The status of research and utilisation on the subtidal kelp along the Chilean coast: A literature review. *Acta Oceanologica Sinica*, 41(12), 7–17. <https://doi.org/10.1007/s13131-022-2052-y>
- Licciardi G, PR Marpu, J Chanussot, JA Benediktsson. 2012. Linear Versus Nonlinear PCA for the Classification of Hyperspectral Data Based on the Extended Morphological Profiles. *IEEE Geoscience and Remote Sensing Letters*, 9(3), 447–451. <https://doi.org/10.1109/LGRS.2011.2172185>
- Liu Y, D Li, W Xiong, Q Han, L Ma. 2025. Fractional Impervious Surface Mapping on Multispectral Images With Visible Shadows via a Bundle-Based Sparse Unmixing Model. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 18, 13048–13061. <https://doi.org/10.1109/JSTARS.2025.3568537>
- Mackey B, DA DellaSala, C Kormos, D Lindenmayer, N Kumpel, B Zimmerman, S Hugh, V Young, S Foley, K Arsenis, JEM Watson. 2015. Policy Options for the World's Primary Forests in Multilateral Environmental Agreements. *Conservation Letters*, 8(2), 139–147. <https://doi.org/10.1111/conl.12120>
- Marquardt DW. 1963. "An Algorithm for Least-Squares Estimation of Nonlinear Parameters". *Journal of the Society for Industrial and Applied Mathematics*. 11 (2): 431–441.
- Masuda K, T Takashima. 1996. The effect of solar zenith angle and surface wind speed on water surface reflectivity. *Remote Sensing of Environment*, 57(1), 58–62. [https://doi.org/10.1016/0034-4257\(95\)00237-5](https://doi.org/10.1016/0034-4257(95)00237-5)
- Meier WJH, J Griebinger, P Hochreuther, MH Braun. 2018. An Updated Multi-Temporal Glacier Inventory for the Patagonian Andes With Changes Between the Little Ice Age and 2016. *Frontiers in Earth Science*, 6. <https://doi.org/10.3389/feart.2018.00062>
- Mora-Soto A, M Palacios, EC Macaya, I Gómez, P Huovinen, A Pérez-Matus, M Young, N Golding, M Toro, M Yaqub, M Macias-Fauria. 2020. A High-Resolution Global Map of Giant Kelp (*Macrocystis pyrifera*) Forests and Intertidal Green Algae (*Ulvophyceae*) with Sentinel-2 Imagery. *Remote Sensing*, 12(4), Article 4. <https://doi.org/10.3390/rs12040694>
- Mora-Soto A, A Capsey, AM Friedlander, M Palacios, PE Brewin, N Golding, P Dayton, B Van Tussenbroek, A Montiel, W Goodell, C Velasco-Charpentier, T Hart, EC Macaya, A Pérez-Matus, M Macias-Fauria. 2021. One of the least disturbed marine coastal ecosystems on Earth: Spatial

and temporal persistence of Darwin's sub-Antarctic giant kelp forests. *Journal of Biogeography*, 48(10), 2562–2577. <https://doi.org/10.1111/jbi.14221>

Mora-Soto A, C Aguirre, JL Iriarte, M Palacios, EC Macaya, M Macias-Fauria. 2022. A Song of Wind and Ice: Increased Frequency of Marine Cold-Spells in Southwestern Patagonia and Their Possible Effects on Giant Kelp Forests. *Journal of Geophysical Research: Oceans*, 127(6), e2021JC017801. <https://doi.org/10.1029/2021JC017801>

Nijland W, L Reshitnyk, E Rubidge. 2019. Satellite remote sensing of canopy-forming kelp on a complex coastline: A novel procedure using the Landsat image archive. *Remote Sensing of Environment*, 220, 41–50. <https://doi.org/10.1016/j.rse.2018.10.032>

Palacios M, D Osman, J Ramírez, P Huovinen, I Gómez. 2021. Photobiology of the giant kelp *Macrocystis pyrifera* in the land-terminating glacier fjord Yendegaia (Tierra del Fuego): A look into the future? *Science of The Total Environment*, 751, 141810. <https://doi.org/10.1016/j.scitotenv.2020.141810>

Paruelo JM, EG Jobbágy, M Oesterheld, RA Golluscio, MR Aguiar. 2015. The grasslands and steppes of Patagonia and the Río de la Plata plains. En T. T. Veblen, K. R. Young, & A. R. Orme (Eds.), *The physical geography of South America* (pp. 232–248). Oxford University Press.

Pfister CA, HD Berry, T Mumford. 2018. The dynamics of Kelp Forests in the Northeast Pacific Ocean and the relationship with environmental drivers. *Journal of Ecology*, 106(4), 1520–1533. <https://doi.org/10.1111/1365-2745.12908>

Pessarrodona A, PJ Moore, MDJ Sayer, DA Smale. 2018. Carbon assimilation and transfer through kelp forests in the NE Atlantic is diminished under a warmer ocean climate. *Global Change Biology*, 24(9), 4386–4398. <https://doi.org/10.1111/gcb.14303>

Pinsky ML, AM Eikeset, DJ McCauley, JL Payne, JM Sunday. 2019. Greater vulnerability to warming of marine versus terrestrial ectotherms. *Nature*, 569(7754), 108–111. <https://doi.org/10.1038/s41586-019-1132-4>

Poloczanska ES, CJ Brown, WJ Sydeman, W Kiessling, DS Schoeman, PJ Moore, K Brander, JF Bruno, LB Buckley, MT Burrows, CM Duarte, BS Halpern, J Holding, CV Kappel, MI O'Connor, JM Pandolfi, C Parmesan, F Schwing, SA Thompson, AJ Richardson. 2013. Global imprint of climate change on marine life. *Nature Climate Change*, 3(10), 919–925. <https://doi.org/10.1038/nclimate1958>


- Potapov P, MC Hansen, L Laestadius, S Turubanova, A Yaroshenko, C Thies, W Smith, I Zhuravleva, A Komarova, S Minnemeyer, E Esipova. 2017. The last frontiers of wilderness: Tracking loss of intact forest landscapes from 2000 to 2013. *Science Advances*, 3(1), e1600821. <https://doi.org/10.1126/sciadv.1600821>
- Quintano C, A Fernández-Manso, YE Shimabukuro, G Pereira. 2012. Spectral unmixing. *International Journal of Remote Sensing*, 33(17), 5307–5340. <https://doi.org/10.1080/01431161.2012.661095>
- Seidel M, M Hlawitschka. 2015. An R-Based Function for Modeling of End Member Compositions. *Mathematical Geosciences*, 47(8), 995–1007. <https://doi.org/10.1007/s11004-015-9609-7>
- Servicio Hidrográfico y Oceanográfico de la Armada de Chile. s.f. *Tablas de marea de la costa de Chile*. Recuperado el 17 de mayo de 2025, de <https://www.shoa.cl/php/index.php>
- Skakun S, J Wevers, C Brockmann, G Doxani, M Aleksandrov, M Batič, D Frantz, F Gascon, L Gómez-Chova, O Hagolle, D López-Puigdollers, J Louis, M Lubej, G Mateo-García, J Osman, D Peressutti, B Pflug, J Puc, R Richter, ... L Žust. 2022. Cloud Mask Intercomparison eXercise (CMIX): An evaluation of cloud masking algorithms for Landsat 8 and Sentinel-2. *Remote Sensing of Environment*, 274, 112990. <https://doi.org/10.1016/j.rse.2022.112990>
- Smale DA, MT Burrows, P Moore, N O'Connor, SJ Hawkins. 2013. Threats and knowledge gaps for ecosystem services provided by kelp forests: A northeast Atlantic perspective. *Ecology and Evolution*, 3(11), 4016–4038. <https://doi.org/10.1002/ece3.774>
- Smale DA. 2020. Impacts of ocean warming on kelp forest ecosystems. *New Phytologist*, 225(4), 1447–1454. <https://doi.org/10.1111/nph.16107>
- Souza CM, DA Roberts, MA Cochrane. 2005. Combining spectral and spatial information to map canopy damage from selective logging and forest fires. *Remote Sensing of Environment*, 98(2), 329–343. <https://doi.org/10.1016/j.rse.2005.07.013>
- Steneck RS, CR Johnson. 2013. Kelp forests: Dynamic patterns, processes and feedbacks. En M. D. Bertness, B. Silliman, & J. Stachowicz (Eds.), *Marine community ecology* (pp. 315–336). Sinauer.
- Thorhaug A, AD Richardson, GP Berlyn. 2007. Spectral reflectance of the seagrasses: *Thalassia testudinum*, *Halodule wrightii*, *Syringodium filiforme* and five marine algae. *International Journal of Remote Sensing*, 28(7), 1487–1501. <https://doi.org/10.1080/01431160600954662>

- Tucker CJ. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- United States Geological Survey (USGS). s.f.. Landsat program [Base de datos]. Recuperado el 25 de octubre de 2025, de <https://landsat.usgs.gov>
- Umgiesser G, C Ferrarin, M Bajo, D Bellafiore, A Cucco, F De Pascalis, M Ghezzi, W McKiver, L Arpaia. 2022. Hydrodynamic modelling in marginal and coastal seas—The case of the Adriatic Sea as a permanent laboratory for numerical approach. *Ocean Modelling*, 179, 102123. <https://doi.org/10.1016/j.ocemod.2022.102123>
- Van Tussenbroek IB. 1989. Seasonal growth and composition of fronds of *Macrocystis pyrifera* in the Falkland Islands. *Marine Biology*, 100(3), 419–430. <https://doi.org/10.1007/BF00391158>
- Van Tussenbroek BI. 1993. Plant and frond dynamics of the giant kelp, *Macrocystis pyrifera*, forming a fringing zone in the Falkland Islands. *European Journal of Phycology*, 28(3), 161–165. <https://doi.org/10.1080/09670269300650251>
- Vásquez JA. 2008. Production, use and fate of Chilean brown seaweeds: Re-resources for a sustainable fishery. *Journal of Applied Phycology*, 20(5), 457–467. <https://doi.org/10.1007/s10811-007-9308-y>
- Vásquez JA, C Morales, A Vallone. 2024. Brown seaweeds fishery and copper mining production: Two distant economic industries connected by socioecological impacts in Northern Chile. *Marine Policy*, 165, 106191. <https://doi.org/10.1016/j.marpol.2024.106191>
- Vásquez Anacona H, C Mattar, NG Alonso-de-Linaje, HH Sepúlveda, J Crisóstomo. 2023. Wind Simulations over Western Patagonia Using the Weather Research and Forecasting model and Reanalysis. *Atmosphere*, 14(7), 1062. <https://doi.org/10.3390/atmos14071062>
- Watson JEM, T Evans, O Venter, B Williams, A Tulloch, C Stewart, I Thompson, JC Ray, K Murray, A Salazar, C McAlpine, P Potapov, J Walston, JG Robinson, M Painter, D Wilkie, C Filardi, WF Laurance, PA Houghton, ... D Lindenmayer. 2018. The exceptional value of intact forest ecosystems. *Nature Ecology & Evolution*, 2(4), 599–610. <https://doi.org/10.1038/s41559-018-0490-x>
- Weltje GJ. 1997. End-member modeling of compositional data: Numerical-statistical algorithms for solving the explicit mixing problem. *Mathematical Geology*, 29(4), 503–549. <https://doi.org/10.1007/BF02775085>

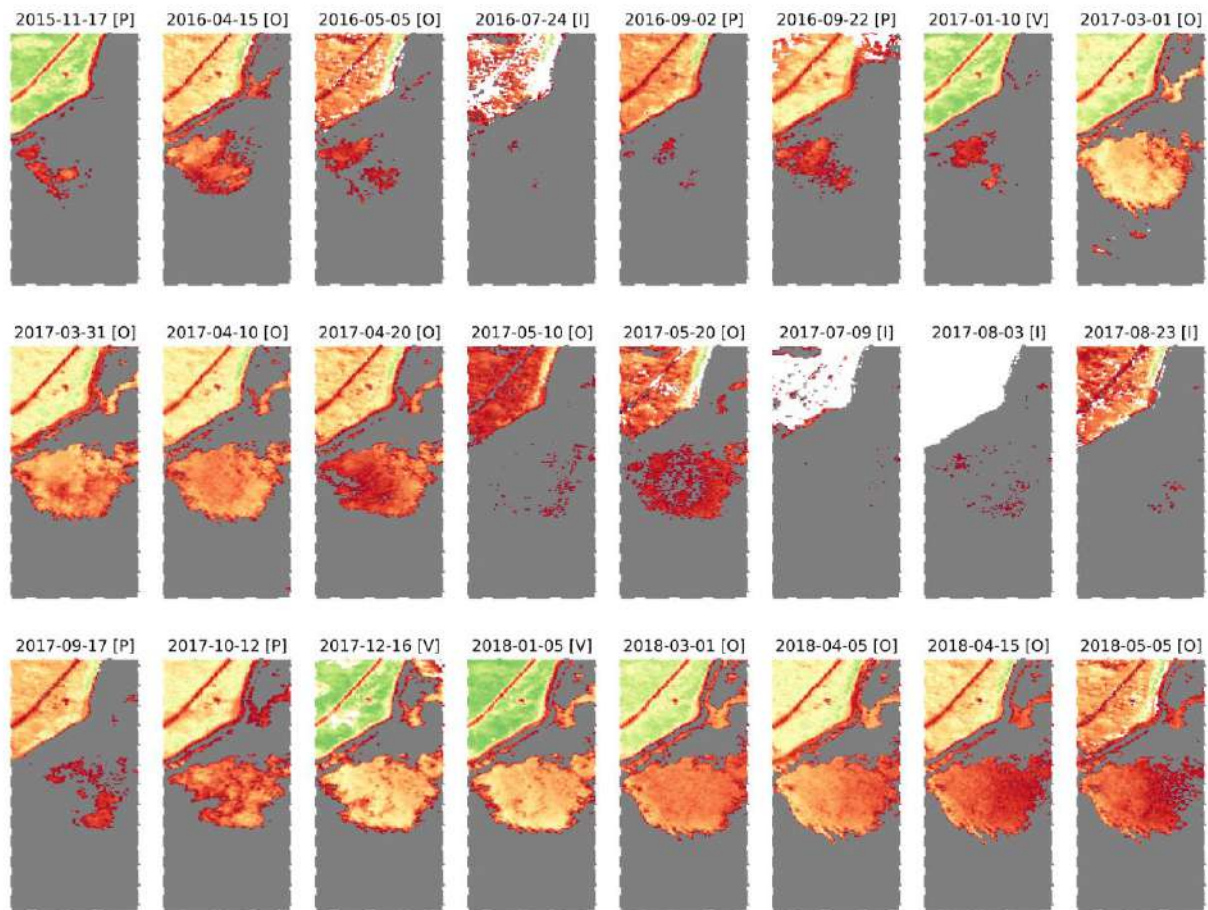
Wernberg T, K Krumhansl, K Filbee-Dexter, MF Pedersen. 2019. Status and trends for the world's kelp forests. En C. Sheppard (Ed.), *World seas: An environmental evaluation* (2.<sup>a</sup> ed., pp. 57–78). Academic Press.

Xu F, X He, P Shanmugam, Y Bai, X Jin, W Cai, D Wang, F Gong, Q Zhu. 2024. Effects of the Earth curvature on Mie-scattering radiances at high solar-sensor geometries based on Monte Carlo simulations. *Optics Express*, 32(4), 6706–6732. <https://doi.org/10.1364/OE.503365>


## 1. ANEXOS



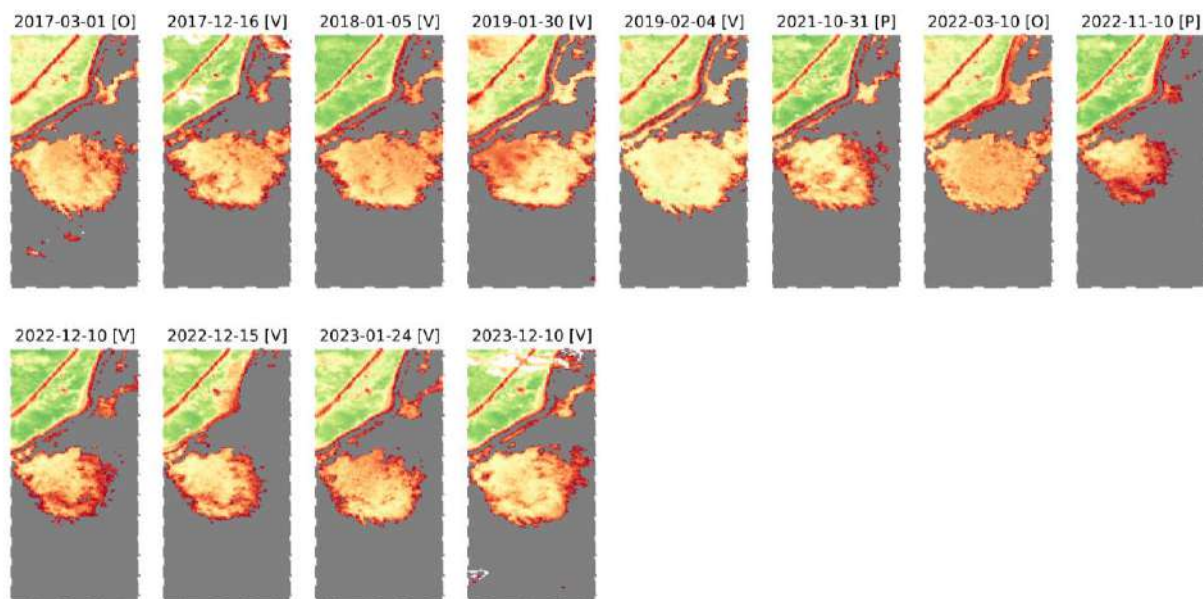
**Anexo 1.** Primeras 24 de 153 imágenes con cobertura estimada de nubes inferior al 10% para el área de muestreo A6, en color falso (R: NIR, G: Rojo, B: Verde), con recorte por percentiles al 2%. En color blanco píxeles enmascarados por probabilidad de nubes sobre 50%. Los títulos indican la estación: Verano (V), Otoño (O), Invierno (I) y Primavera (P).



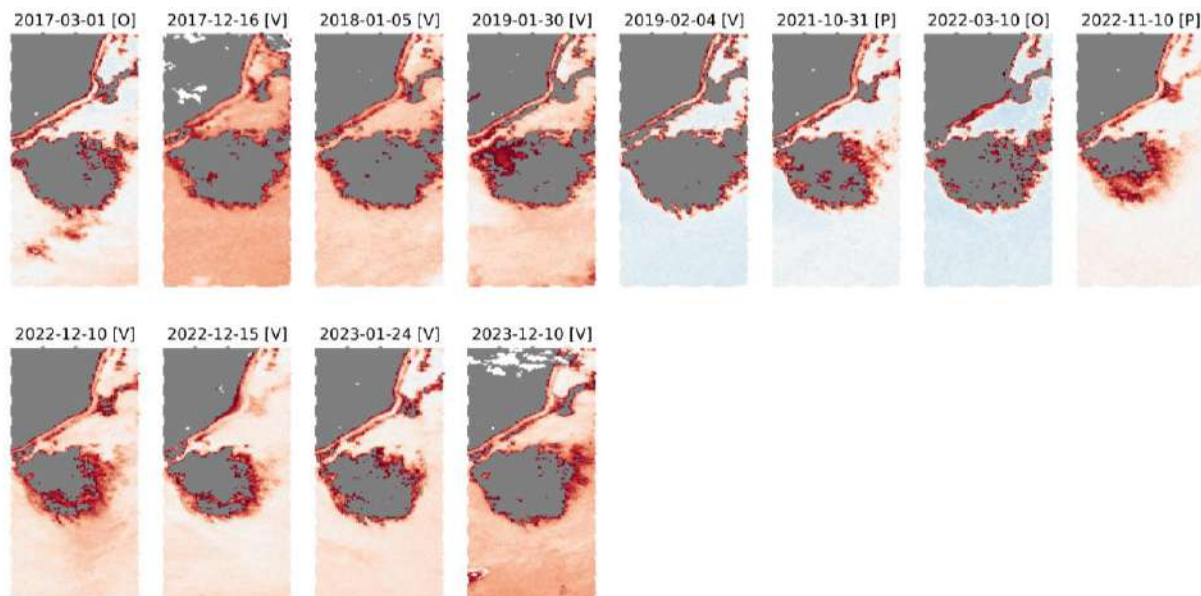
**Anexo 2.** Primeras 24 de 153 imágenes con cobertura estimada de nubes inferior al 10% para el área de muestreo A6, en NDVI, con color gris para valores bajo 0 y paleta Rojo-Amarillo-Verde para colores entre 0 y 1. En color blanco pixeles enmascarados por probabilidad de nubes sobre 50%. Los títulos indican la estación: Verano (V), Otoño (O), Invierno (I) y Primavera (P).



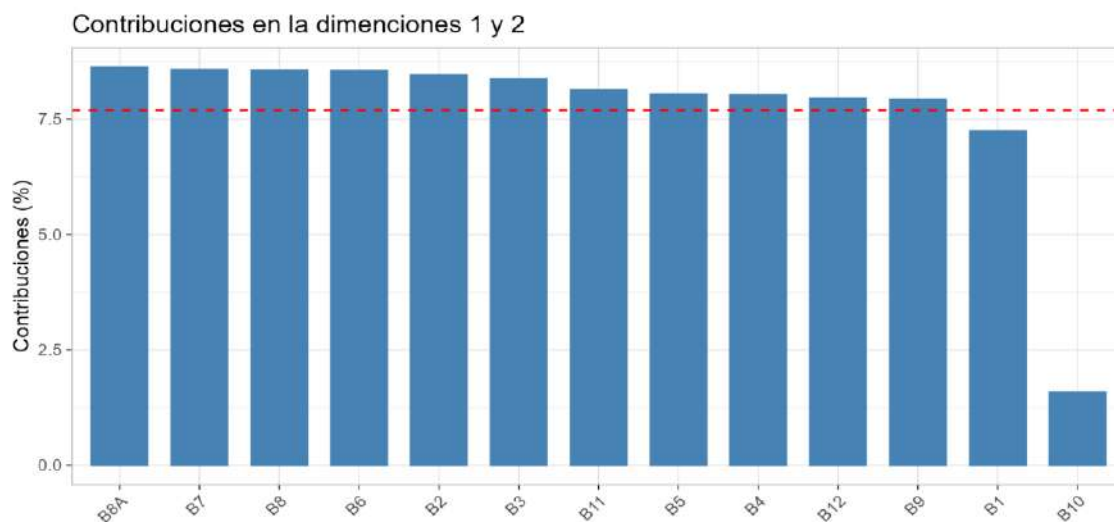
**Anexo 3.** Imágenes seleccionadas para la extracción de píxeles puros para el área de muestreo A6, en color falso (R: NIR, G: Rojo, B: Verde), con recorte por percentiles al 2%. En color blanco píxeles enmascarados por probabilidad de nubes sobre 50%. Los títulos indican la estación: Verano (V), Otoño (O), Invierno (I) y Primavera (P).



**Anexo 4.** Imágenes seleccionadas para la extracción de píxeles puros para el área de muestreo A6, en NDVI, con color gris para valores bajo 0 y paleta Rojo-Amarillo-Verde para colores entre 0 y 1. En color blanco píxeles enmascarados por probabilidad de nubes sobre 50%. Los títulos indican la estación: Verano (V), Otoño (O), Invierno (I) y Primavera (P).




**Anexo 5.** Imágenes seleccionadas para la extracción de píxeles puros para el área de muestreo A6, en NDWI, con color gris para valores bajo 0 y paleta Rojo-Azul para colores entre 0 y 1. En color blanco píxeles enmascarados por probabilidad de nubes sobre 50%. Los títulos indican la estación: Verano (V), Otoño (O), Invierno (I) y Primavera (P).



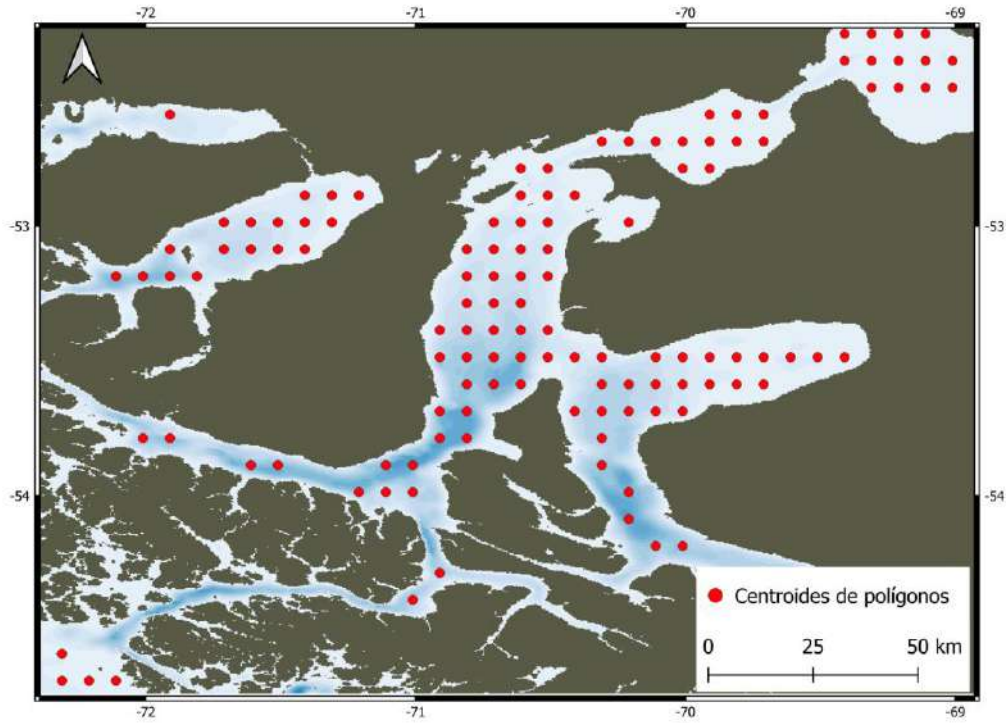
**Anexo 6.** Contribución relativa de cada banda Sentinel-2 para explicar la varianza de las dos primeras dimensiones del análisis PCA, realizado con los píxeles puros para las componentes de macroalga, agua y superficie terrestre.

Banda	S. Terrestre	Agua	Macroalga
B2	0.000	0.361	0.063
B3	0.021	0.220	0.043
B4	0.048	0.119	0.017
B5	0.062	0.094	0.071
B6	0.103	0.066	0.166
B7	0.123	0.052	0.192
B8	0.130	0.035	0.191
B8A	0.159	0.027	0.193
B9	0.069	0.019	0.050
B11	0.180	0.000	0.015
B12	0.106	0.005	0.000

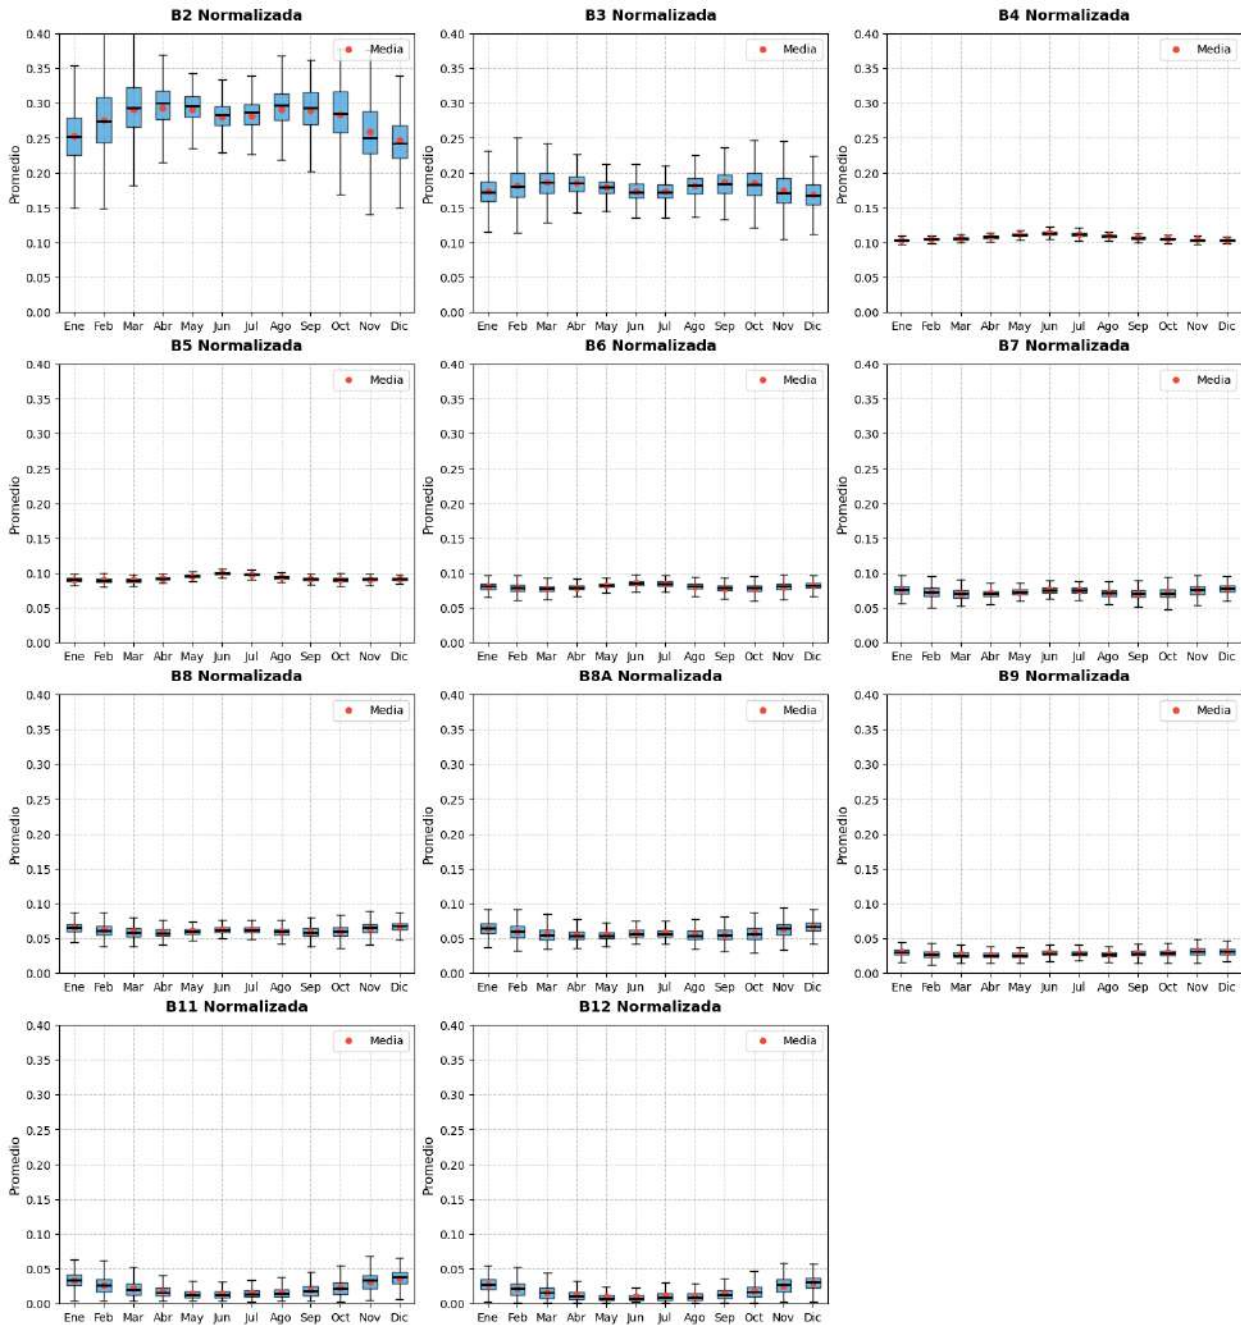
**Anexo 7.** Valores de los *endmembers* de Superficie Terrestre, Agua y Macroalga, en proporciones relativas de reflectancia.



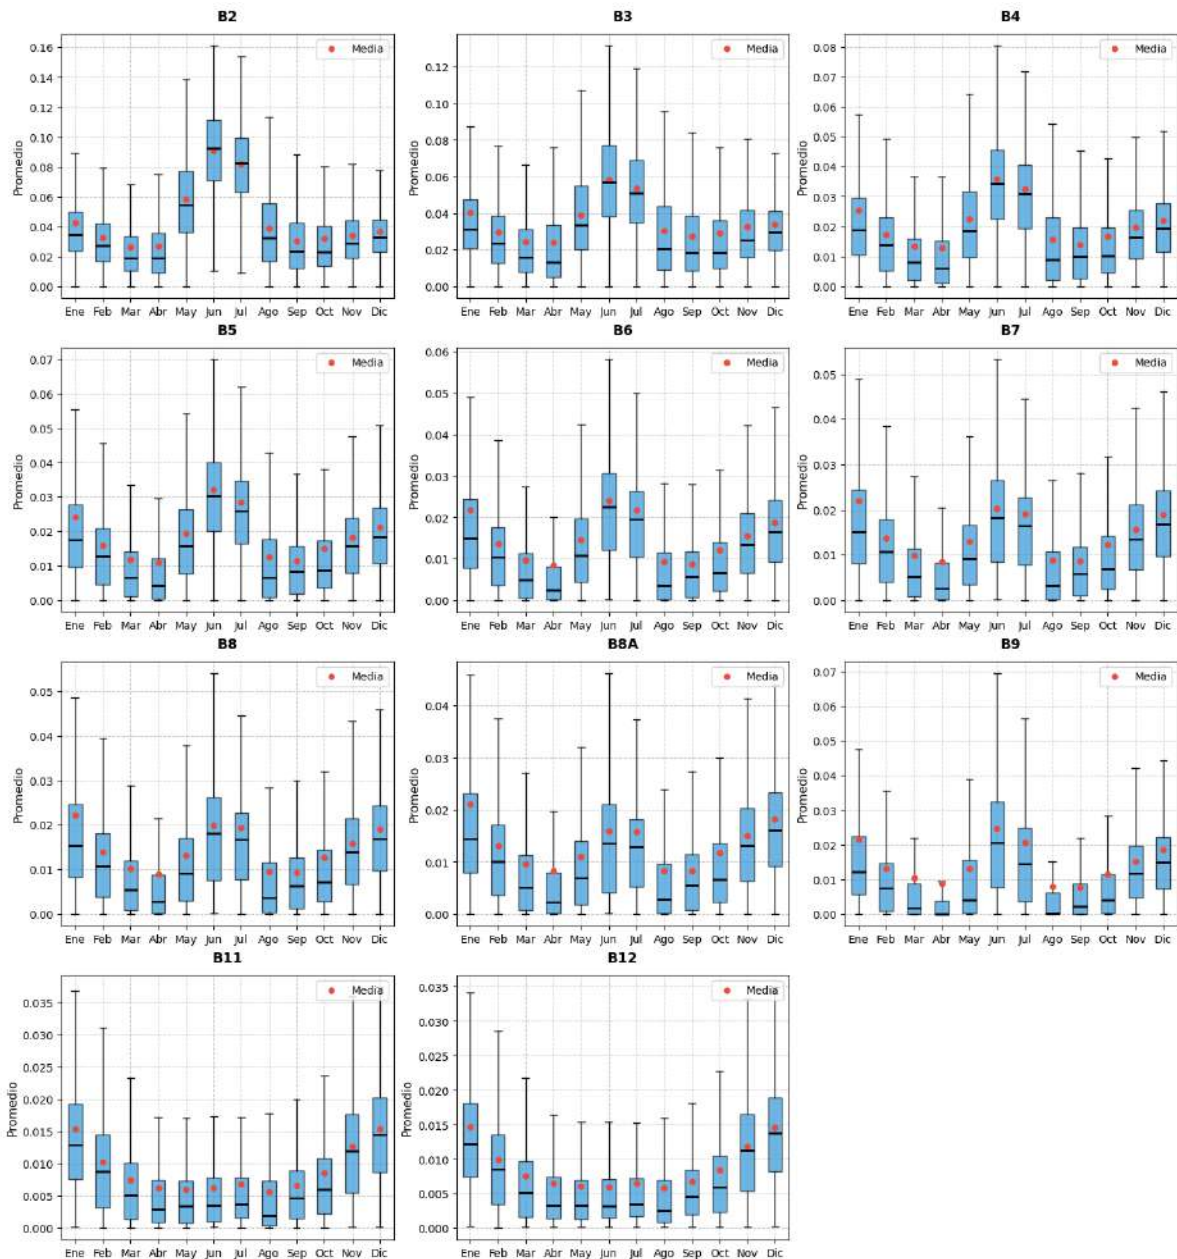
**Anexo 8.** Comparación entre imágenes SuperDove y la cobertura fraccional de macroalgas obtenida a partir de imágenes Sentinel-2 para el área de validación AV3. Los polígonos en rojo representan la extensión de bosques de macroalgas, delimitados manualmente mediante fotointerpretación en las imágenes SuperDove, y mediante la aplicación de un umbral de 0,17 sobre la fracción de macroalgas en las imágenes de cobertura fraccional. Los píxeles en blanco corresponden a aquellos con una probabilidad de nubes superior al 50 % según el *Sentinel-2 Cloud Probability*, mientras que los píxeles en color magenta indican las áreas enmascaradas tras aplicar un filtro para excluir píxeles con alguna de estas características: altura  $\geq 5$  m (según el *Shuttle Radar Topography Mission*, SRTM), fracción de superficie terrestre  $> 0,45$  o fracción de agua  $< 0,1$ .



**Anexo 9.** Ubicación de las 125 áreas de control en aguas oceánicas (más de 3 km desde la línea de costa), representadas mediante sus centroides, utilizadas para evaluar el comportamiento estacional del modelo en zonas sin presencia esperada de macroalgas.



**Anexo 10.** Valores promedio de las proporciones relativas (resultantes de una normalización a suma uno), por imagen, para las bandas espectrales de Sentinel-2 utilizadas por el modelo de *spectral unmixing*, agrupados mensualmente para áreas ubicadas en aguas alejadas de la costa (>3 km).



**Anexo 11.** Valores promedio de reflectancia por imagen para las bandas espectrales de Sentinel-2 SR utilizadas por el modelo de *spectral unmixing*, agrupados mensualmente para áreas ubicadas en aguas alejadas de la costa (>3 km).



**Anexo 12.** Ejemplo expansión y retracción de bosques de macroalga para dos parches: el de la izquierda ubicado al norte de la desembocadura del río Tres Brazos, y el de la derecha en Bahía Carrera. Los datos de tendencia corresponden a la pendiente de un modelo lineal en valores de porcentaje total de cobertura, conservando píxeles con  $R^2 > 0,6$ . Los píxeles con verde claro corresponden a las áreas del modelo con una CFM sobre 17% para la composición de verano 2024-25.