

• RESERVOIR CO2 •

SEGUIMIENTO DE ECOSISTEMAS MARINOS: Posidonia Oceanica

Ignacio de la Calle

Maruska Mole, Masuma Chowdhury, Nadiia Basos, Eduardo Alonso, María Ramírez

• CONSERVACIÓN •

• POSIDONIA OCEANICA •

• BIOINDICADOR •

Objetivos



Desarrollar la metodología y explorar las herramientas necesarias para proveer de,

una cartografía periódica, rutinaria y actualizada de habitats marinos

hacer un seguimiento temporal de la evolución y estado de los habitats marinos

empleando imágenes de Sentinel-2 y técnicas de Inteligencia Artificial

ayudar en la gobernanza y conservación de estos ecosistemas marinos

elevado coste e infraestructura alrededor de métodos de muestreo más tradicionales

**homegenización de la metodología de análisis, resolución espacial, referencias temporales
y la obtención de datos**



Objetivos

Costa Mediterránea Española

1. Generación de una cartografía de Posidonia oceánica a partir de datos satelitales en todo el arco mediterráneo de las costas españolas.

Sentinel-2 (10m) de 2021

Batimetría (100m)

Datos *in situ*

EMODNET

Dirección General de Biodiversidad, Bosques y Desertificación

2. Elaboración de una metodología de evaluación de la calidad de la cartografía producida que permita cuantificar la precisión.

Red Neuronal entrenada y validada con datos *in situ*

La metodología de estimación de calidad se basa en terminología típica de estas redes

3. Estudio piloto en una zona determinada para la realización de un seguimiento temporal de las praderas.

Añualidades 2017 a 2021, zona cubierta dentro de un *tile*

Datos *in situ* y batimétricos de alta resolución

Metodología

Corrección atmosférica y preparación de las imágenes

Red Neuronal

Filtrado de Ruido

Matriz de Confusión y definición de Métricas de calidad

Comparación de cartografía (estudios temporales)



Metodología: Corrección Atmosférica



Antes de AC

AC por imagen tarda en media entre 15 minutos y 1 hora de tiempo de procesado dependiendo del tamaño de la imagen.



Después de AC

2000 imágenes -> 80 días (24h)

La principal tarea de esta fase, y quizá la más compleja e importante y con mayor impacto en los resultados del proyecto, es el de la corrección atmosférica (AC).

La AC elimina la contribución de la atmósfera a la señal recogida por los sensores del satélite, dejando como resultado final la contribución sobre la superficie del mar.

Después de llevar a cabo la AC se evalúa de nuevo la calidad de las imágenes resultantes, eliminando aquellas con residuos de reflejos solares, turbulencias o aquellas con condiciones de mar embravecido.

De las imágenes resultantes de este proceso de AC y control de calidad, se extraen las bandas RGB que se emplean para realizar el *stack* de imágenes. Este *stack* se realiza *tile a tile* y es empleado como entrada de la red neuronal que se lleva a cabo en la siguiente fase del proyecto.



Metodología: *Stack* de Imágenes

Región	Sentinel-2 Tile	Imágenes por stack	Calidad
Andalucía	T30SWF	9	media
	T30SXF	9	baja
	T30SUF	7	baja
	T30SVF	7	media
	T30STF	9	baja
Islas Baleares	T31SCC	7	alta
	T31SCD	9	media
	T31SDD	5	media
	T31TDE	7	media
	T31SED	5	alta
	T31TEE	5	alta
	T31TFE	7	alta
Cataluña	T31TCE	5	baja
	T31TCF	9	media
	T31TDF	7	baja
	T31TDG	9	baja
	T31TEG	9	baja
Murcia	T30SXG	7	baja
	T30SYG	9	baja
Valencia	T30SXH	5	media
	T30SYH	5	media
	T30SYJ	9	baja
	T31TBE	5	baja

¿ Qué ?

Promedio de imágenes satelitales.

¿ Objetivo ?

Mitigar el efecto de los píxeles borrados, barcos en zonas de la imagen, olas muy grandes y otras anomalías, así como para reducir ciertos patrones ruidosos artefactos de las imágenes, se realiza un *stack* píxel por píxel para las bandas azul (B), verde (G) y la banda roja (R) de todas las imágenes procesadas correspondientes a un mismo *tile*.

El *stack* es una imagen de buena calidad que sirve de entrada de la Red Neuronal.

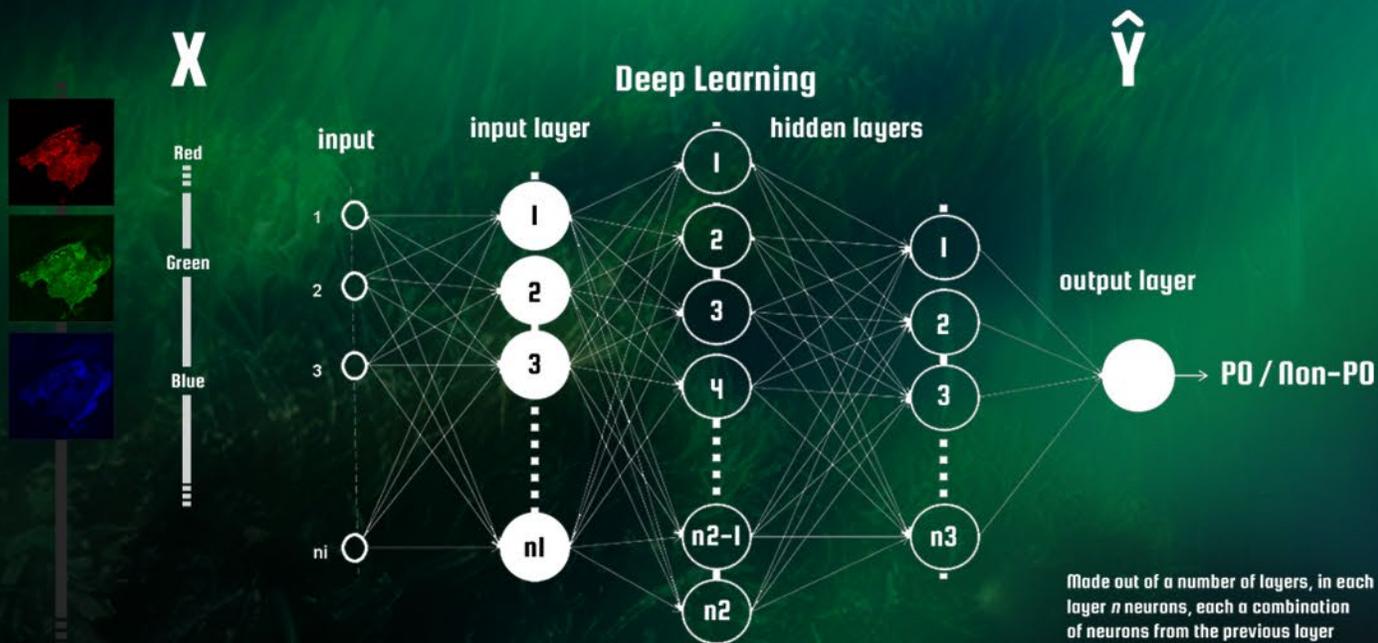


Stack de imágenes por región y tile

Por cada *tile* hay potencialmente un total de 73 imágenes disponibles para 2021.

Para cada *tile* el *stack* se compone de entre 5-9 imágenes.

Metodología: Red Neuronal (NN)



Se ha empleado un modelo NN de aprendizaje profundo cuyo objetivo es el de entrenar una función basada en el conjunto de datos satelitales (bandas RGB) y batimétricos (X), y el conjunto de datos *in situ* correspondientes a la región de estudio (Y) para generar una clase de predicción en PO y Non-PO (\hat{Y}), que, a su vez, debe coincidir lo más posible con los datos *in situ* (Y).

La NN ha de ser entrenada, para lo cual es necesario definir un conjunto de entrenamiento a partir de los datos *in situ* (Y). Este entrenamiento se hace por regiones y franja temporal.



El resultado final es un conjunto de coeficientes que define la red neuronal, que basándose en el color RGB de cada píxel, cada píxel es asignado un 1 o 0 dependiendo de si pertenece a la clase PO o Non-PO.

Metodología: Matriz de Confusión y definición de Métricas de calidad

		Valores de Predicción	
		Non-PO	PO
Valores Reales	Non-PO	Verdaderos Negativos (TN)	Falsos Positivos (FP)
	PO	Falsos Negativos (FN)	Verdaderos Positivos (TP)

La Matriz de Confusión es una herramienta que permite la visualización del desempeño de un algoritmo que se emplea en aprendizaje supervisado.

Métricas



$$\text{Precisión} = \text{TP} / (\text{TP} + \text{FP})$$

como de seguros estamos de lo que estamos midiendo

$$\text{Exactitud} = (\text{TP} + \text{TN}) / (\text{TP} + \text{FP} + \text{FN} + \text{TN})$$

como de alejados estamos del valor real

$$\text{Exhaustividad Positiva} = \text{TP} / (\text{TP} + \text{FN})$$

$$\text{Exhaustividad Negativa} = \text{TN} / (\text{TN} + \text{FP})$$

Tasa de verdaderos positivos

Tasa de verdaderos negativos



Metodología: Comparación de cartografía para estudio temporal

1	Median Mean Variance Standard deviation	muestra la mediana de la serie temporal completa muestra la media de la serie temporal completa muestra la varianza muestra la desviación estándar (la raíz cuadrada de la varianza)
2	Range Variety Maximun Majority Number of changes	muestra la amplitud de los cambios, max-min muestra el número de valores únicos (solo para mapas binarios o categóricos) muestra el máximo histórico (para mapas continuos), alguna vez sucedió (para mapas binarios) muestra el valor más frecuente (solo para mapas binarios o categóricos) muestra el número de cambios entre intervalos de tiempo consecutivos (inestabilidad) (mejor para mapas binarios o categóricos)
3	Last map minus first Last map vs. first, matrix of change	muestra los cambios entre los dos extremos temporales muestra aparición, desaparición, presencia o ausencia (solo para mapas binarios o categóricos)
4	Linear regression slope (tendencia, R^2 y RMSE)	muestra la tasa de cambio, crecimiento y decrecimiento (computacionalmente caro)



Resultados

Preparación de Datos Satelitales e *in situ*

Procesado de Imágenes Satelitales

Producción de Cartografía de PO

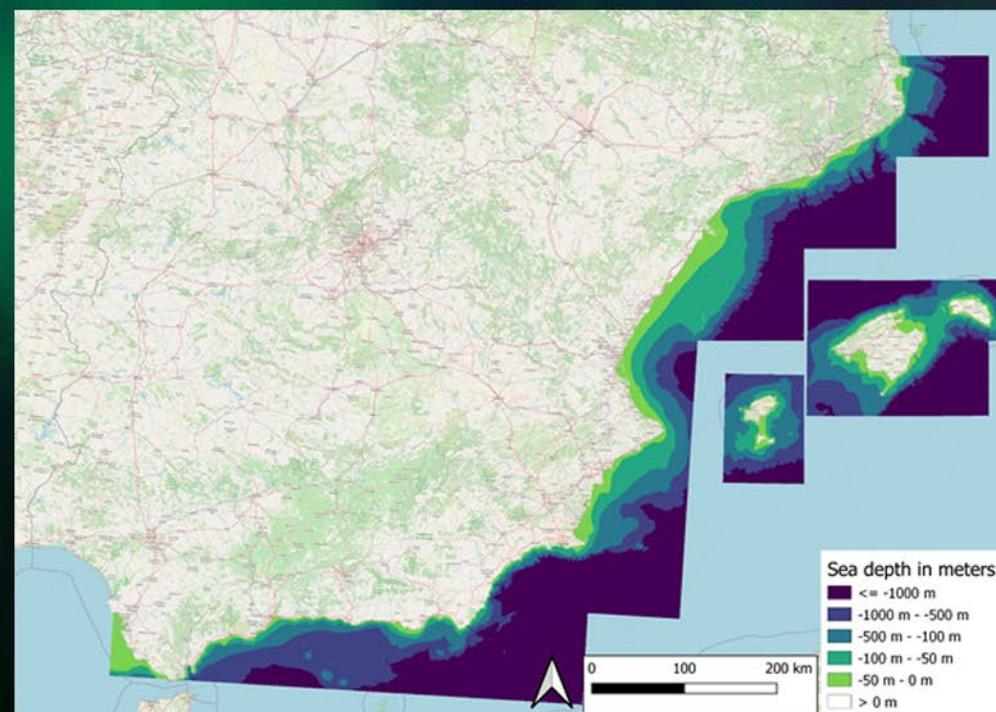
Estudio temporal de evolución de las praderas



Resultados: Sentinel-2 y Batimetría

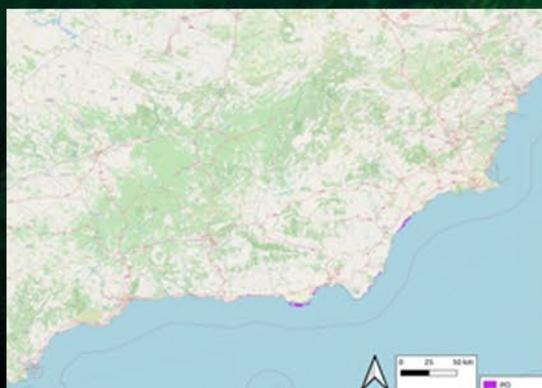
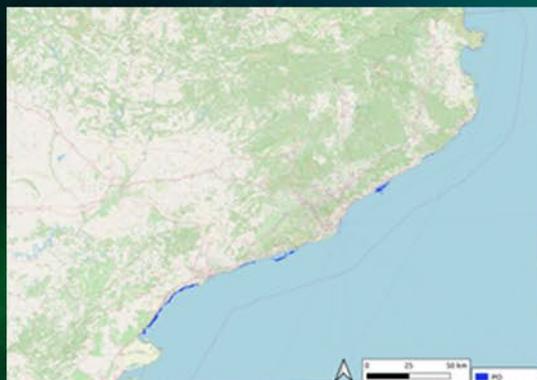


📍 Sentinel-2 tiles a procesar
del área de interés
23 tiles



📍 Batimetría del área
de interés
(EMODNET, 100m de resolución)

Resultados: datos *in situ*



Andalucía:

Mezcla de datos de los años 2014, 2019, 2020
Contiene información de diferentes especies (PO, CN, ZM, ZN)
Contiene información de diferentes estados de las praderas (mata muerta, en regresión, en fondo mixto)
Mucho detalle

Cataluña:

Contiene información de diferentes especies (PO, ZM, CN, ...)
Mezcla de diferentes resoluciones espaciales
Actualizado a agosto 2022

Valencia:

Contiene información de diferentes especies (PO, CN)
Contiene información de diferentes estados de las praderas (en degradación, en fondo mixto y óptimo)
Detalle moderado

Murcia:

No disponible

Islas Baleares:

Contiene información de diferentes especies (> 10)
Contiene información de diferentes estados de las praderas (rizoma muerta)
Mucho detalle



Resultados: estadística de procesado de imágenes

Costa Peninsular Mediterránea (sin incluir las Islas Baleares)

1168 imágenes disponibles antes de corrección atmosférica
42 % imágenes rechazadas antes de corrección atmosférica (nubes)

679 imágenes corregidas de corrección atmosférica. Después de corrección,
9 % buenas imágenes
26 % parcialmente usables
65 % no usables (reflejo solar, olas, turbulencia, nubes altas)

1679 imágenes

1343 (80%) rechazadas
252 (15%) calidad media
82 (5%) buena calidad

Islas Baleares

511 imágenes disponibles antes de corrección atmosférica
59 % imágenes rechazadas antes de corrección atmosférica (nubes)

210 imágenes corregidas de corrección atmosférica. Después de corrección,
10 % buenas imágenes
36 % parcialmente usables
54 % no usables (reflejo solar, olas, turbulencia, nubes altas)



Resultados: Obtención de Cartografía



RGB IMAGE

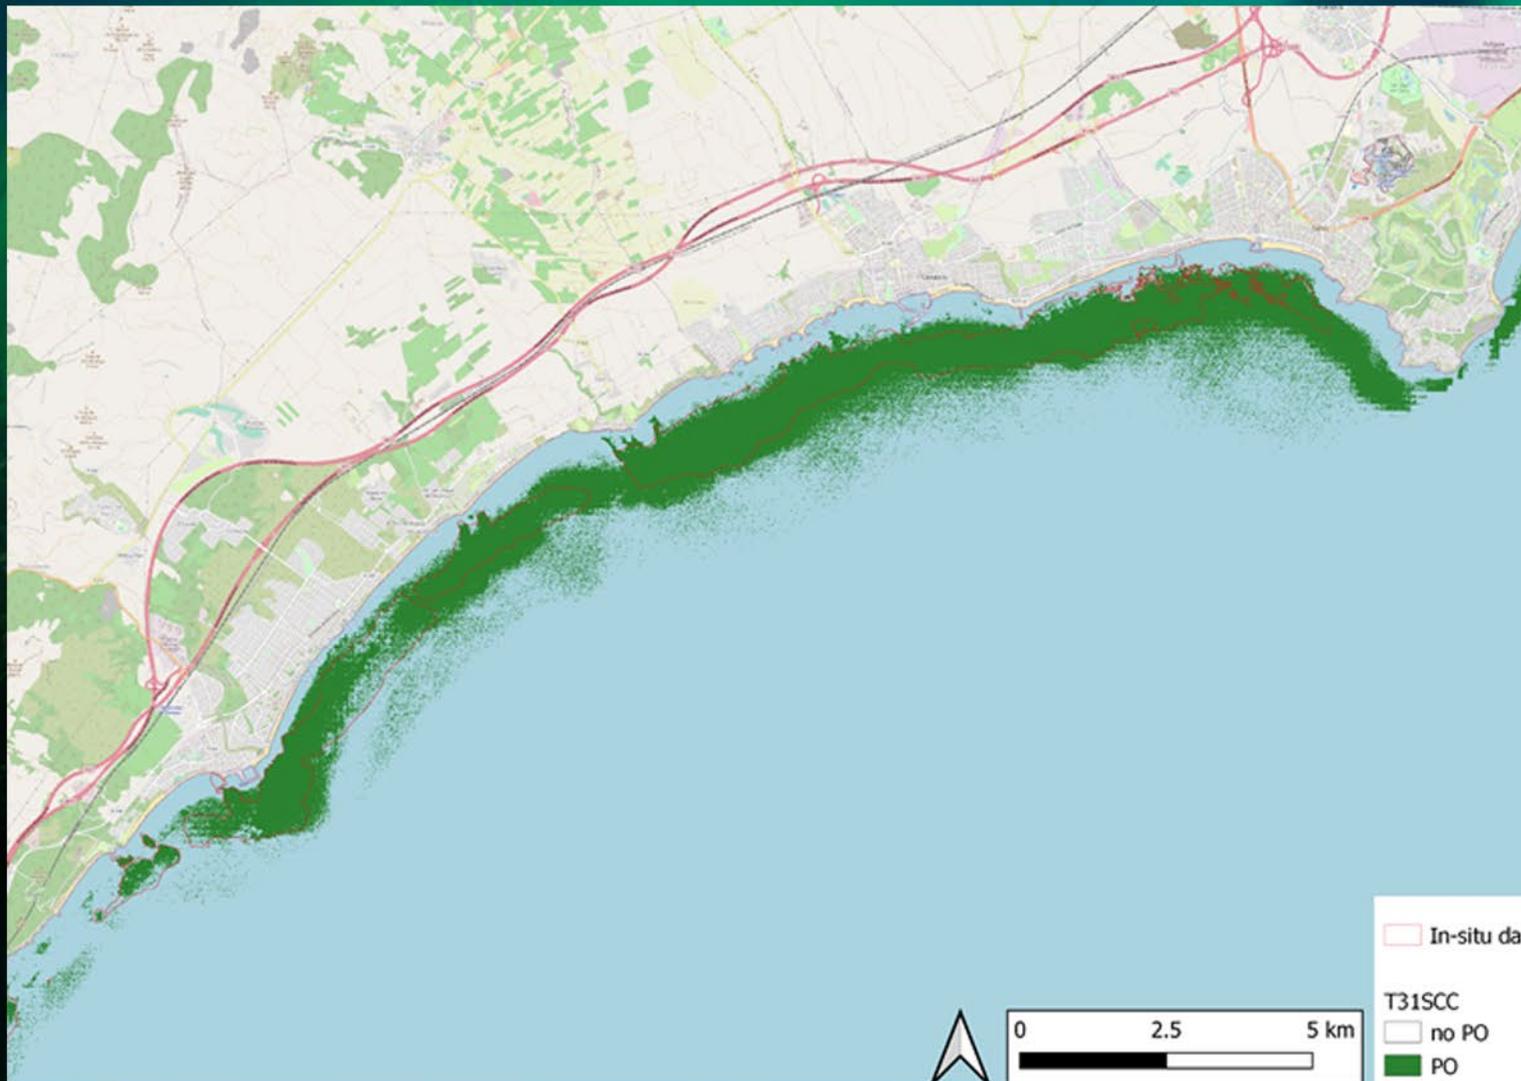


RGB IMAGE + *in situ*



Resultados: Obtención de Cartografía

 **Cataluña**



Datos de salida
de la Red Neuronal
sin entrenar con
datos *in situ* del
área de interés



Resultados: Obtención de Cartografía

 **Cataluña**



Datos de salida de la Red Neuronal entrenada con datos *in situ* del área de interés



Resultados: T30SWF (Andalucía) y T31SCC (Islas Baleares)

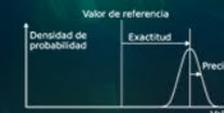
T30SWF - Andalucía

T30SWF	Tamaño_muestra = 93699647
	c_matriz = $\begin{bmatrix} 99.4 & 0.1 \\ 0.28 & 0.21 \end{bmatrix}$
	Exactitud = 1.0
	Precisión_positiva = 0.68 Precisión_negativa = 1.0
	Exhaustividad_positiva = 0.43 Exhaustividad_negativa = 1.0
	f1_positiva = 0.53 f1_negativa = 1.0



		Valores de Predicción	
		Non-PO	PO
Valores Reales	Non-PO	Verdaderos Negativos (TN)	Falsos Positivos (FP)
	PO	Falsos Negativos (FN)	Verdaderos Positivos (TP)

La Matriz de Confusión es una herramienta que permite la visualización del desempeño de un algoritmo que se emplea en aprendizaje supervisado.



Métricas

Precisión = $TP / (TP + FP)$
como de seguros estamos de lo que estamos midiendo

Exactitud = $(TP + TN) / (TP + FP + FN + TN)$
como de alejados estamos del valor real

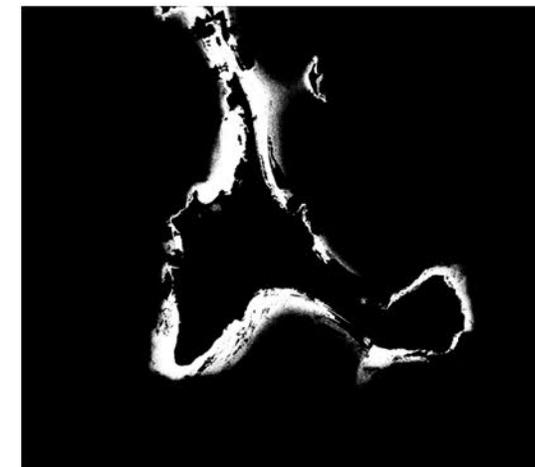
Exhaustividad Positiva = $TP / (TP + FN)$ Tasa de verdaderos positivos
Exhaustividad Negativa = $TN / (TN + FP)$ Tasa de verdaderos negativos

Información disponible en la memoria tile a tile para los 23 tiles que conforman la región de interés de este proyecto.

Información sobre métricas de calidad se genera como fichero de metadatos (xml) asociado a cada tile.

T31SCC - Islas Baleares

T31SCC	Tamaño_muestra = 8244817
	c_matriz = $\begin{bmatrix} 89.77 & 0.45 \\ 3.63 & 6.15 \end{bmatrix}$
	Exactitud = 0.96
	Precisión_positiva = 0.93 Precisión_negativa = 0.96
	exhaustividad_positiva = 0.63 exhaustividad_negativa = 0.99
	f1_positiva = 0.75 f1_negativa = 0.98



Resultados: Islas Baleares, Cataluña, Valencia, Murcia y Andalucía

Islas Baleares

Tamaño_muestra = 544260288

c_matriz = $\begin{bmatrix} 98.73 & 0.19 \\ 0.19 & 0.90 \end{bmatrix}$

Exactitud = 1.0

Precisión_positiva = 0.83
Precisión_negativa = 1.0

Exhaustividad_positiva = 0.82
Exhaustividad_negativa = 1.0

f1_positiva = 0.83
f1_negativa = 1.0



Cataluña

Tamaño_muestra = 509742900

c_matriz = $\begin{bmatrix} 99.77 & 0.11 \\ 0.06 & 0.06 \end{bmatrix}$

Exactitud = 1.0

Precisión_positiva = 0.36
Precisión_negativa = 1.0

Exhaustividad_positiva = 0.51
Exhaustividad_negativa = 1.0

f1_positiva = 0.43
f1_negativa = 1.0



Valencia

Tamaño_muestra = 330020082

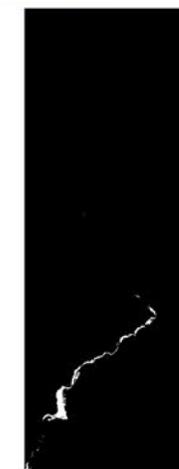
c_matriz = $\begin{bmatrix} 98.87 & 0.45 \\ 0.48 & 0.20 \end{bmatrix}$

Exactitud = 0.99

Precisión_positiva = 0.31
Precisión_negativa = 1.0

Exhaustividad_positiva = 0.29
Exhaustividad_negativa = 1.0

f1_positiva = 0.3
f1_negativa = 1.0



**Información disponible
región a región para las 5 regiones
de interés de este proyecto.**

**La región con resultados de menor fiabilidad es la de Valencia,
Datos *in-situ* de Valencia con menor nivel de detalle
Región con mucha turbidez
Identificación de otras especies
y la de mayor, la región de las Islas Baleares.**



Resultados: Post-procesado y Versiones de Cartografía de PO

Post-procesado

Limpieza de píxeles en zonas de tierra y aguas profundas (> 30m, según batimetría empleada)
Eliminación de artefactos

Cartografía

Dos versiones proporcionadas (V01 y V02) en formato Shapefile

V01 proporcionada por *tile*

V02 proporcionada por región

La versión V02 incluye un filtrado de ruido (filtro de mediana con ventana móvil 3x3)

La versión V02 incluye un fichero de metadatos en formato xml (estándar ISO19115:2003/Cor 1 2006 y cumple directrices NEM (Núcleo Español de Metadatos) e INSPIRE)

La versión V02 incluye la cartografía correspondiente al estudio temporal del Cabo de la Nao



Resultados: Resumen

En general, la Precisión positiva obtenida está entre 10% y 93% mientras que la Exhaustividad positiva está en el rango 10% a 70%.

Para el caso de las regiones, la Precisión positiva obtenida está entre 31% y 83% mientras que la Exhaustividad positiva está en el rango 30% a 82%.

La región que proporciona los mejores resultados es la de las Islas Baleares y la que proporciona los peores es la región de Valencia.

Se han elaborado y aplicado 5 modelos. 2 modelos se descartaron, y el resto se emplearon para clasificar los 23 tiles. Los tres modelos empleados se han elaborado con datos *in situ* de 3 tiles: T3ISCC (Islas Baleares), T3ITCF (Cataluña) y T3OSWF (Almería).

Las regiones de Murcia y Valencia, mejorarán con el uso de datos *in situ* de las correspondientes regiones.

No solo la calidad de los datos *in situ* afecta al resultado final, si no también la calidad de los datos satelitales.



Estudio de series temporales de cartografía de PO

El caso del Cabo de la Nao (Valencia)

Resultados: Estudio de series temporales de cartografía de PO

Región piloto para el desarrollo de herramientas que permitan llevar a cabo un estudio de evolución temporal.

Zona seleccionada: Cabo de la Nao y San Antonio en Alicante

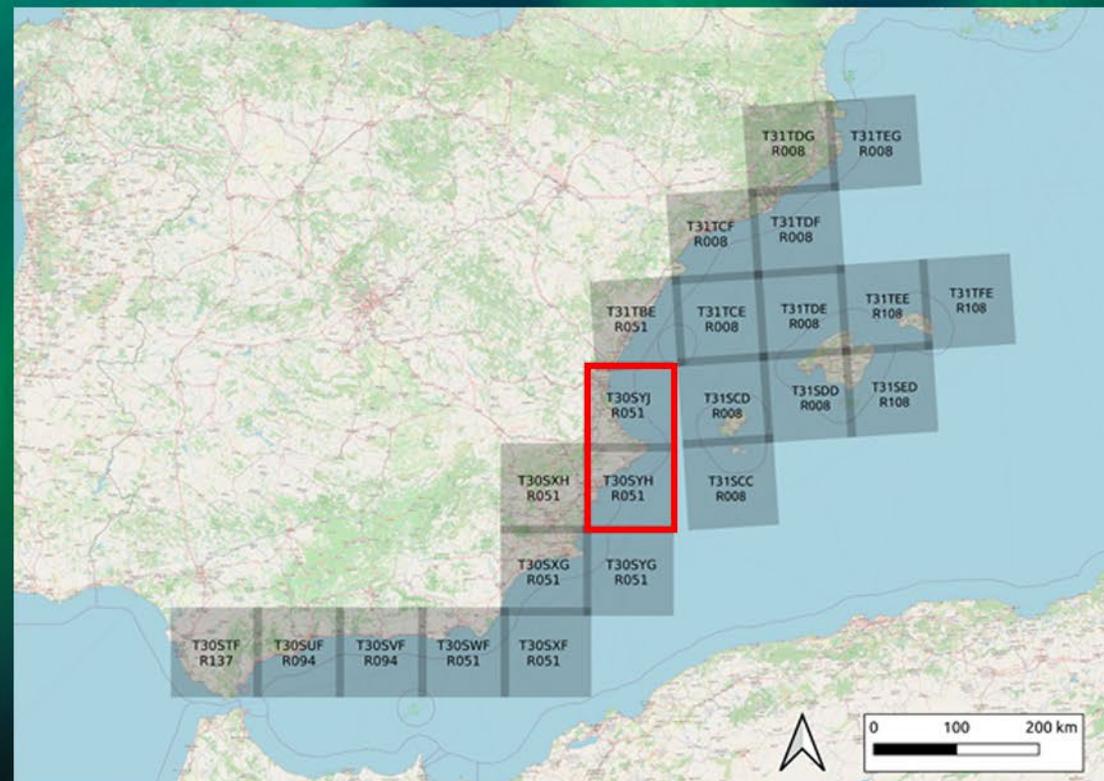
Análisis de los tiles de Sentinel-2: R05I T30SYJ y R05I T30SYH.

Descarga de todas las imágenes para 2015 - 2021

Control de calidad

CA

Elaboración de modelo y entrenamiento con de datos *in situ* de la región de interés (proporcionados de la región de Valencia)



Resultados: Estudio de series temporales de cartografía de PO

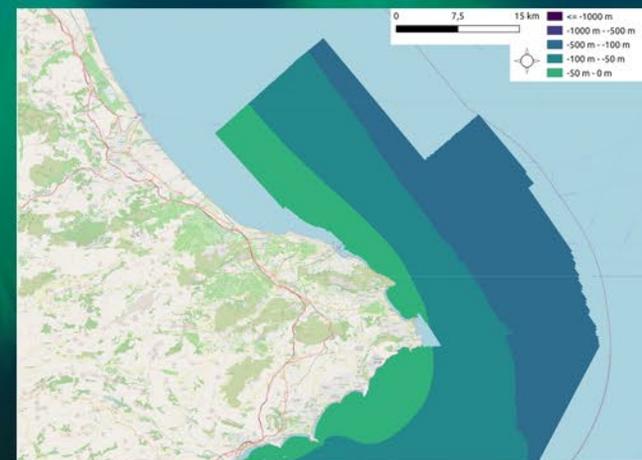
Cabo de la Nao:

332 imágenes corregidas de corrección atmosférica. Después de corrección,
 6.6 % buenas imágenes
 14.8 % parcialmente usables
 78.6 % no usables (reflejo solar, olas, turbulencia, nubes altas)

Batimetría del área de interés de EMODNET, 100m de resolución.

Datos *in-situ* proporcionados por el MITECO (*Fanerógamas marinas para el Decreto 64 2022*), los cuales aparecen actualizados con fecha 2022.

Modelo: datos RGB año 2020 de T30SYH



Batimetría (Fuente MAPA con una resolución de 5m)



Datos *in-situ* presencia PO (Fuente MITECO)

Año	Número de imágenes disponibles	Calidad del stacking
2015	3	baja
2016	5	baja
2017	7	media
2018	5	baja
2019	5	baja
2020	5	media
2021	7	media

Stack de imágenes por año

Resultados: Estudio de series temporales de cartografía de PO



Comparación
Satelite vs *In-situ*



Cabo de la Nao
2015-2021



Precisión Positiva: 56-90%
Exhaustividad Positiva: 43-78%

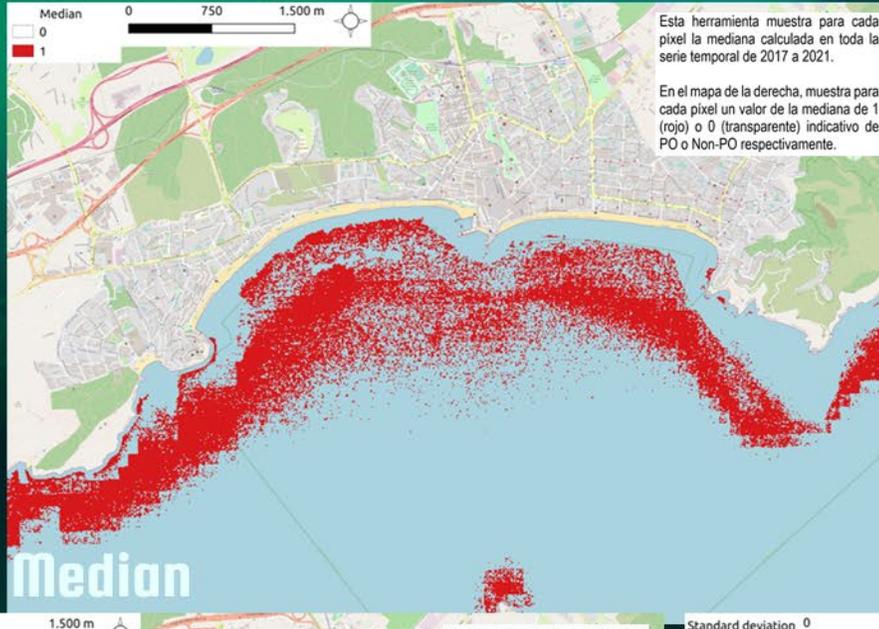
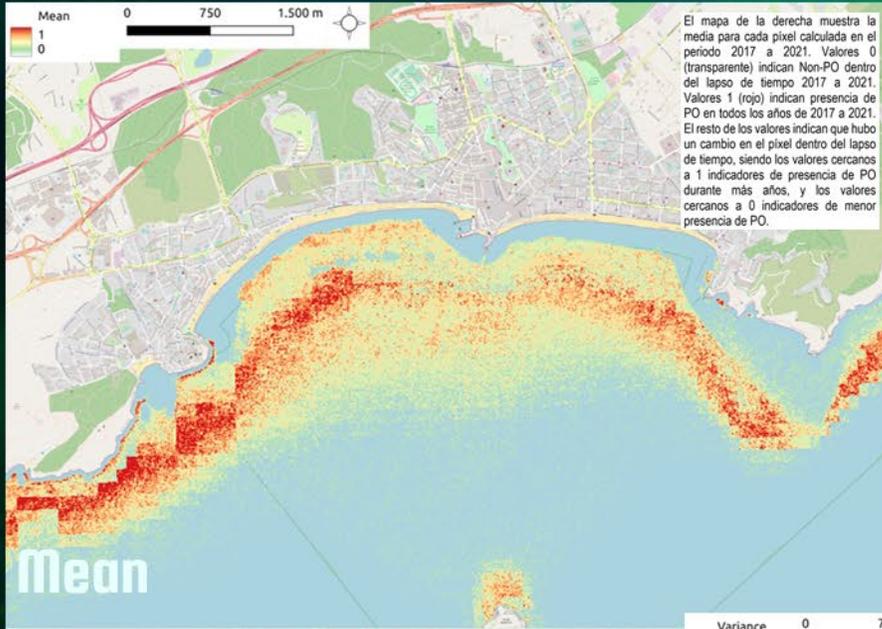
(2018 peor año, 2020 mejor año)

nn
Predicción Correcta

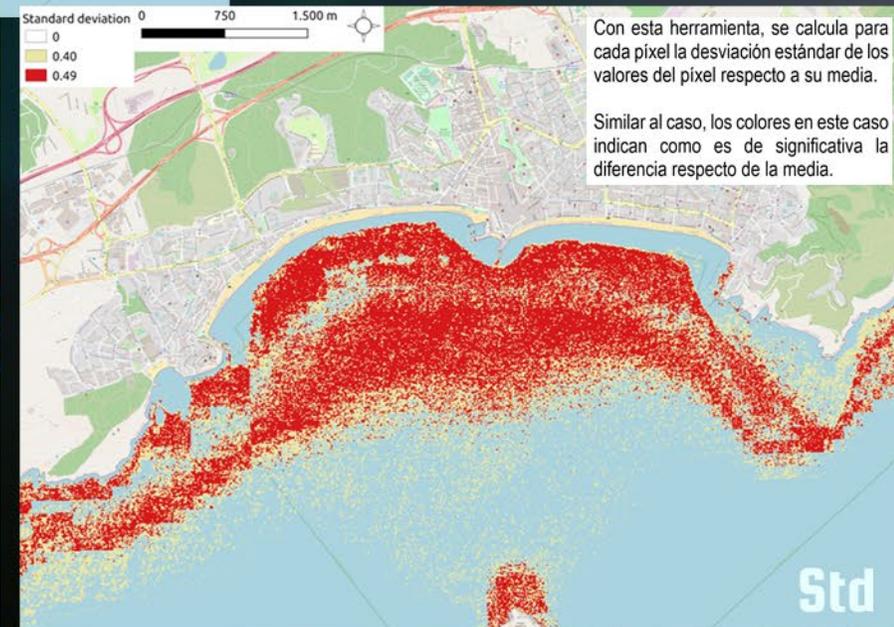
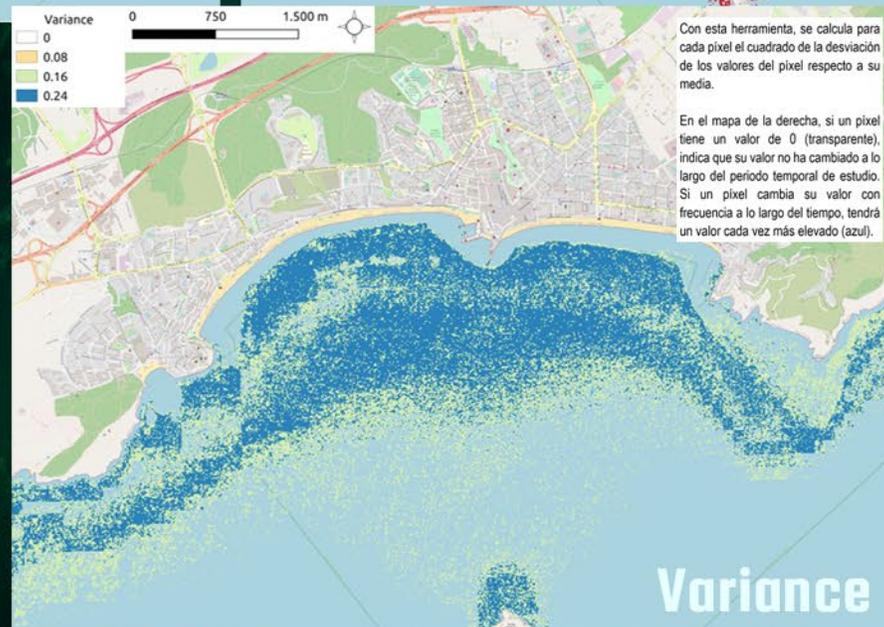
nn
Falla en predecir
No PO

nn
Falla en predecir
PO

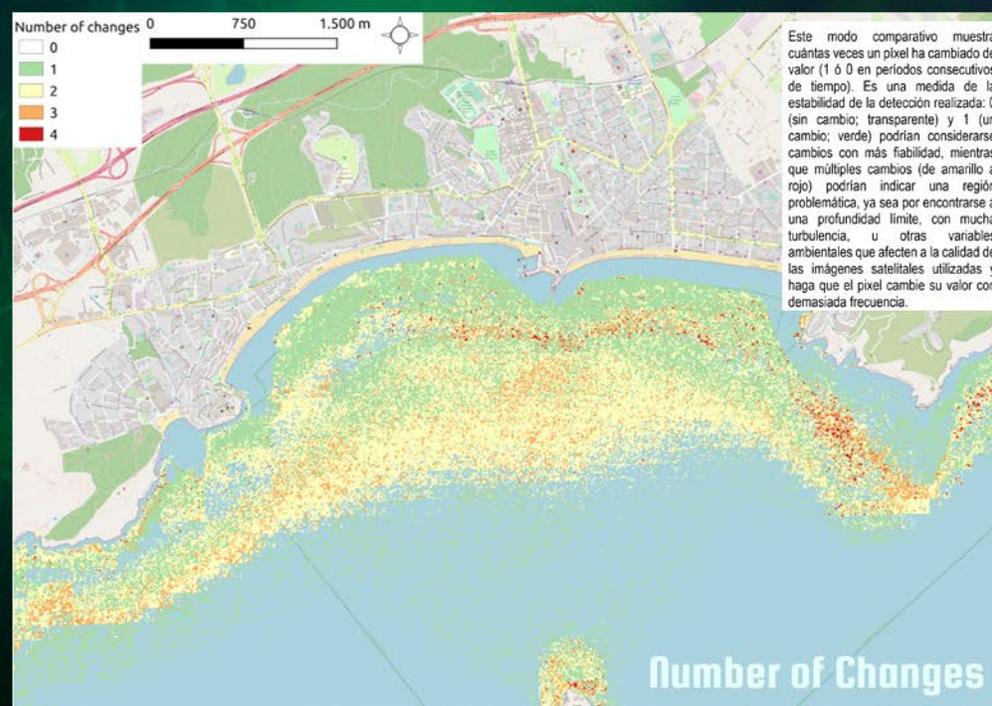
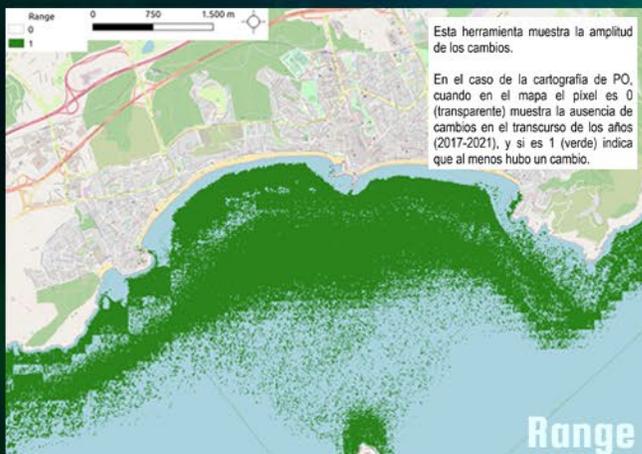
Resultados: Estudio de series temporales de cartografía de PO, el caso de Benidorm



Estimación y cuantificación de los cambios observados entre los años 2017 a 2021



Resultados: Estudio de series temporales de cartografía de PO, el caso de Benidorm

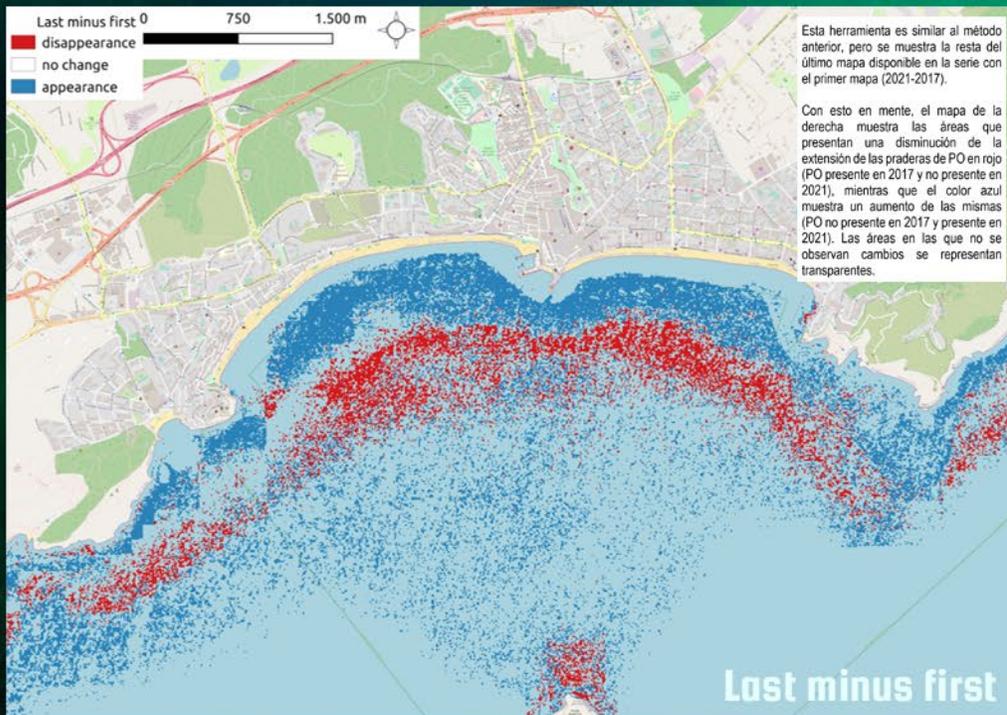


Estimación y cuantificación de los cambios observados entre los años 2017 a 2021



Estabilidad de la detección
0 y 1 píxeles de mayor fiabilidad
> 1 píxeles problemáticos

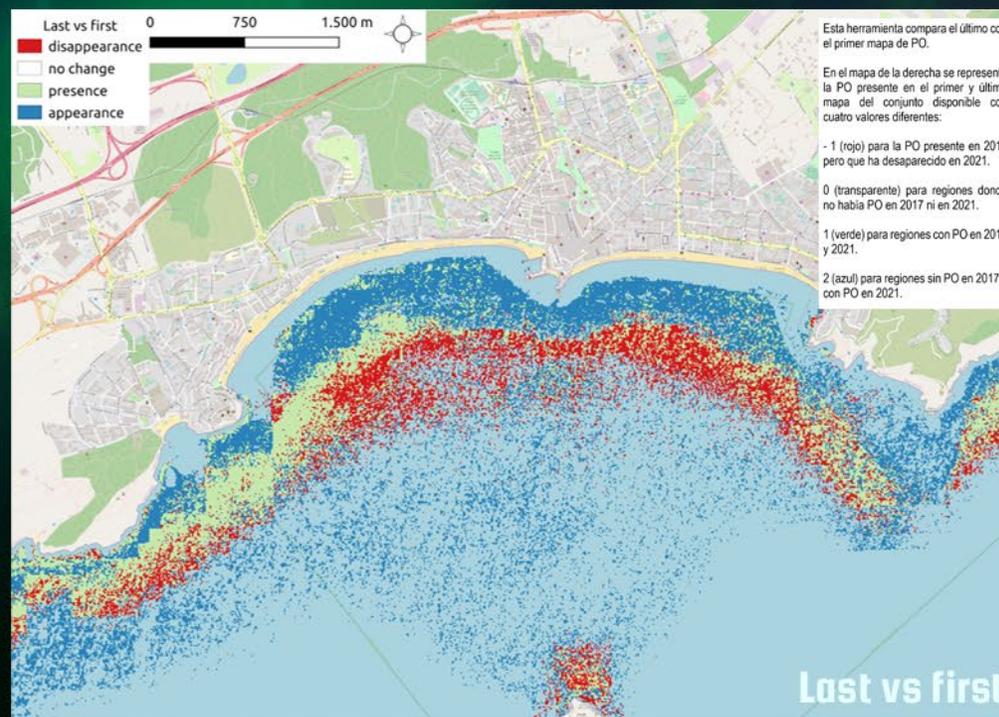
Resultados: Estudio de series temporales de cartografía de PO, el caso de Benidorm



Zonas significativas de cambio entre 2017 a 2021

Rojo indica desaparición de PO
Azul indica aparición de PO

Estimación y cuantificación de los cambios observados entre los años 2017 a 2021



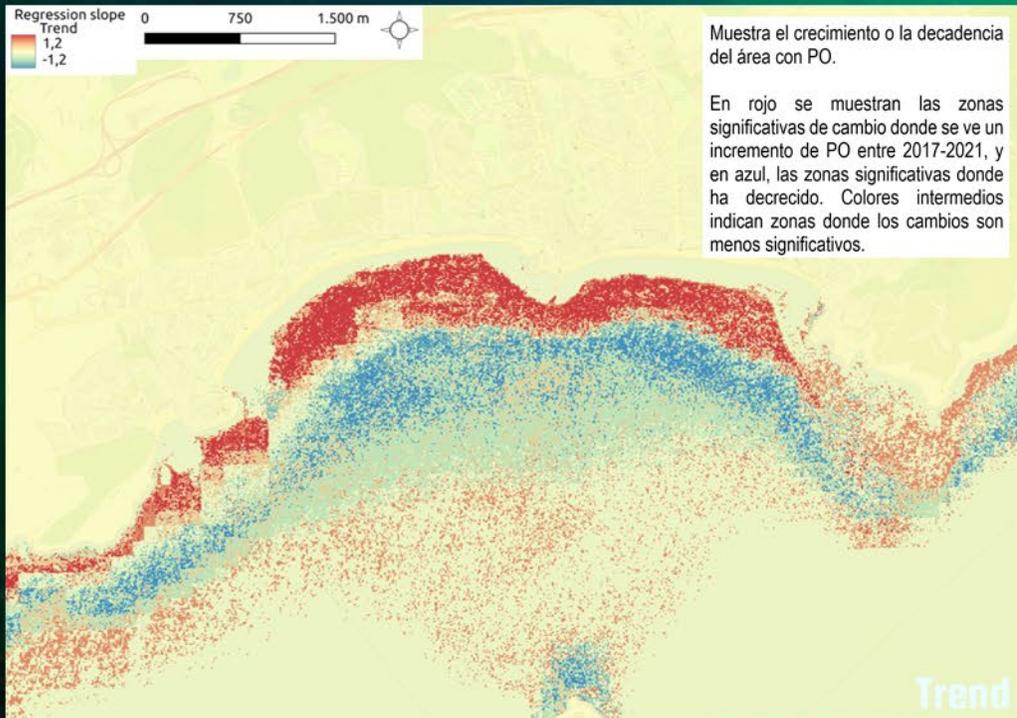
Rojo PO en 2017 No PO en 2021

Verde PO en 2017 PO en 2021

Azul No PO en 2017 PO en 2021



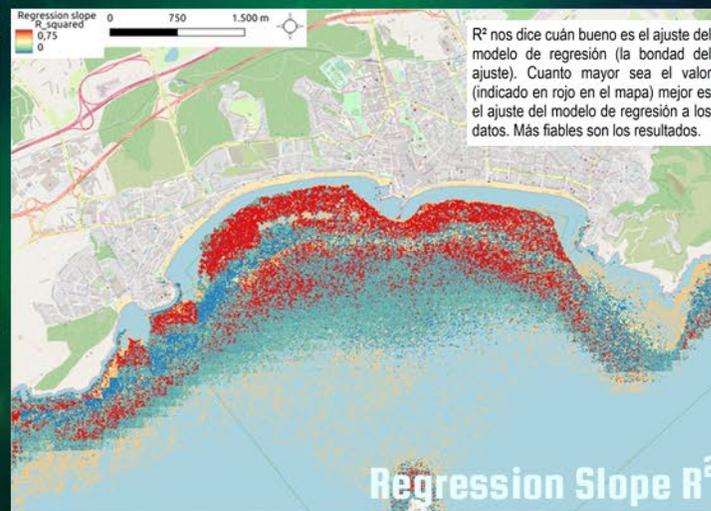
Resultados: Estudio de series temporales de cartografía de PO, el caso de Benidorm



Bondad del ajuste: en rojo se muestran las zonas donde el modelo de regresión ajusta mejor los datos

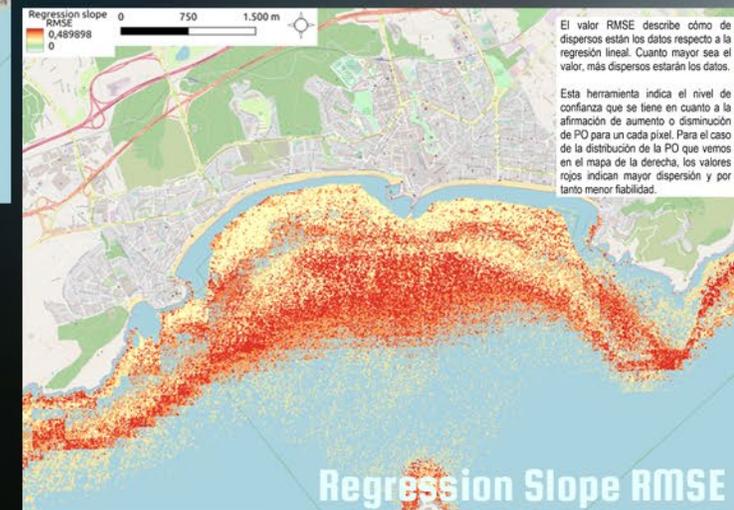
Zonas significativas de cambio entre 2017 a 2021

Rojo indica un incremento
Azul indica un decrecimiento

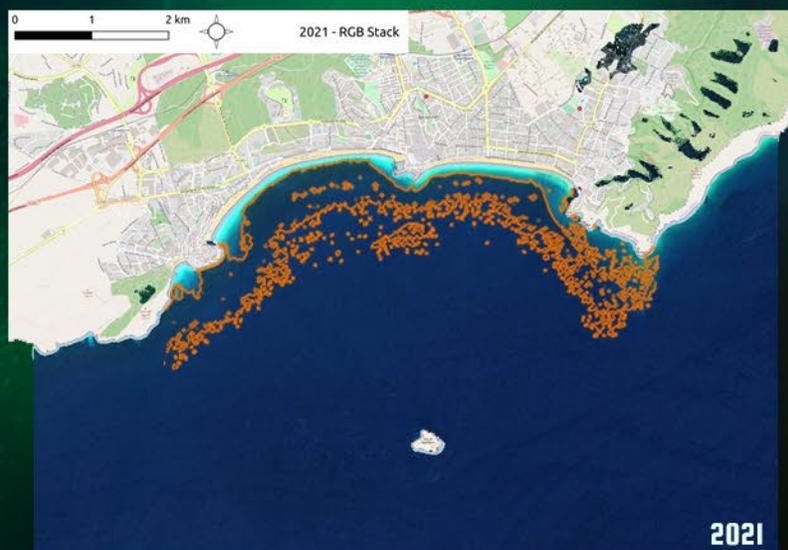
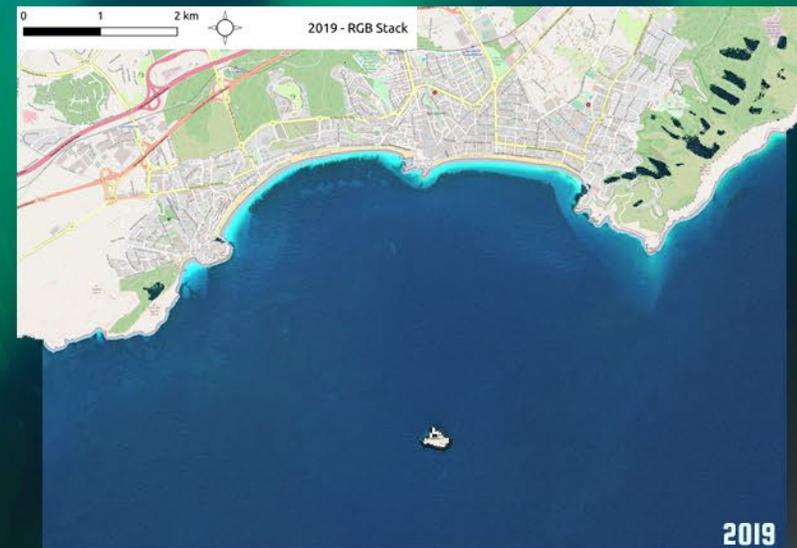
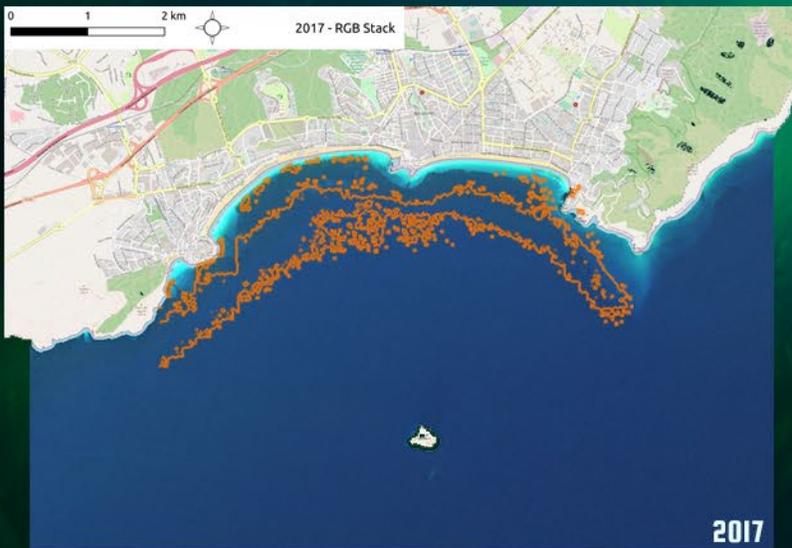


Dispersión respecto a la regresión: valores rojos indican mayor dispersión y por tanto menor fiabilidad

Estimación y cuantificación de los cambios observados entre los años 2017 a 2021



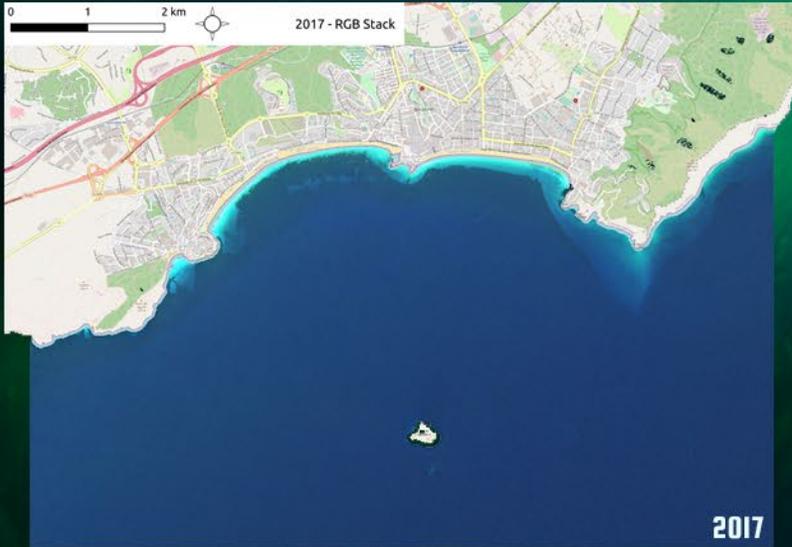
Resultados: Estudio de series temporales de cartografía de PO, el caso de Benidorm



Stack de imágenes para los años 2017 a 2021.



Resultados: Estudio de series temporales de cartografía de PO, el caso de Benidorm



La calidad de las imágenes de *stack* depende de la calidad de las imágenes individuales

Modelo desarrollado con imágenes de 2020. El contraste de las imágenes impacta la clasificación

El *stack* se hace *tile a tile*. Podría ser que aunque el *stack* sea de calidad, la subzona de estudio podría no ser óptima

La calibración de las imágenes llevada a cabo por la ESA varía a lo largo del tiempo

Stack de imágenes



Resultados: Estudio de series temporales de cartografía de PO, el caso de Benidorm

Resumen y Conclusiones

Se han implementado estadísticas que muestran tasas de cambio temporales, crecimiento y decrecimiento en la extensión de las praderas de PO

En el periodo 2017-2021;

1. Observamos una disminución de la extensión de las praderas en aguas más profundas
2. Observamos la aparición de PO cerca de la costa

Las imágenes RGB no parecen confirmar el punto 2. La imagen de 2017 muestra PO cerca de la costa

El modelo ha sido entrenado con datos de 2020 que podría no ser óptimo para 2017



QUASAR

Conclusiones

El estudio demuestra el potencial de emplear técnicas de teledetección satelital en combinación con técnicas de Inteligencia Artificial basada en redes neuronales para el cartografiado y seguimiento de las praderas de PO en entornos costeros.

El estudio ha permitido evaluar los distintos procesos, herramientas y mecanismos que hay que poner en marcha para la generación de cartografía de PO en regiones muy extensas de manera uniforme y automática y con bajo coste.

La clasificación y la cartografía resultante son altamente dependientes de la región de estudio, sobre todo, de factores como turbidez, turbulencia y calidad de las aguas.

Se han implementado estadísticas que muestran tasas de cambio temporales, crecimiento y decrecimiento en la extensión de las praderas de PO. Estas herramientas pueden servir para monitorizar la evolución temporal de las praderas de PO. Será la combinación de varias de estos metodos los que ofrezcan una mejor interpretación de los resultados observados. Es necesaria la validación de los resultados e interpretaciones con datos sobre el terreno.

Obstáculos

Las imágenes satelitales no siempre están libres de nubes u otros efectos atmosféricos que dificultan su procesamiento y pueden afectar al resultado final. Para mitigar este problema, en lugar de rechazar tiles enteros, se podría rechazar únicamente las zonas afectadas de la imagen.

La batimetría empleada en este estudio, aunque de libre acceso, tiene una resolución espacial 10 veces inferior a las imágenes de Sentinel-2.

Se hace necesario para el entrenamiento y validación del modelo de clasificación la existencia de datos *in situ*. Esto no siempre es posible para una región dada.

Trabajo Futuro

Datos:

Imágenes satelitales: mayor aprovechamiento de las imágenes satelitales

Empleo de imágenes satelitales comerciales de mayor resolución. Para ciertas regiones de interés, el uso de estas imágenes podría aportar una cartografía de mayor resolución y calidad.

Obtención de datos batimétricos y datos in-situ de mayor resolución espacial.

Metodología:

Mejora de la técnica de generación de stacks de imágenes satelitales. En algunas regiones se hace complicado alcanzar un número ideal de imágenes para realizar el stacking debido a la mala calidad de las mismas. Esto se podría mitigar aprovechando aquellas zonas de la imagen que no se vean afectadas.

Realizar mejoras en la red neuronal incluyendo bandas espectrales adicionales de Sentinel-2 permitiendo aumentar los criterios de clasificación y no proporcionar únicamente resultados binarios.

Dada la gran extensión de terreno a cubrir en este trabajo, sería necesario la generación de un modelo global de clasificación.

Clasificación de estado de las praderas (densidad, estado evolutivo ...).

Estudio de evolución temporal extendido a toda la costa Mediterránea.



www [HTTPS://QUASARSR.COM](https://quasarsr.com)

f [HTTPS://FACEBOOK.COM/QUASARSR](https://facebook.com/quasarsr)

 [HTTPS://TWITTER.COM/QUASAR_SR](https://twitter.com/quasar_sr)

 [HTTPS://WWW.INSTAGRAM.COM/QUASAR_SR/](https://www.instagram.com/quasar_sr/)

You Tube

Linked in [HTTPS://ES.LINKEDIN.COM/COMPANY/QUASAR-SCIENCE-RESOURCES](https://es.linkedin.com/company/quasar-science-resources)

 CONTACT@QUASARSR.COM

 +34 91 8197120

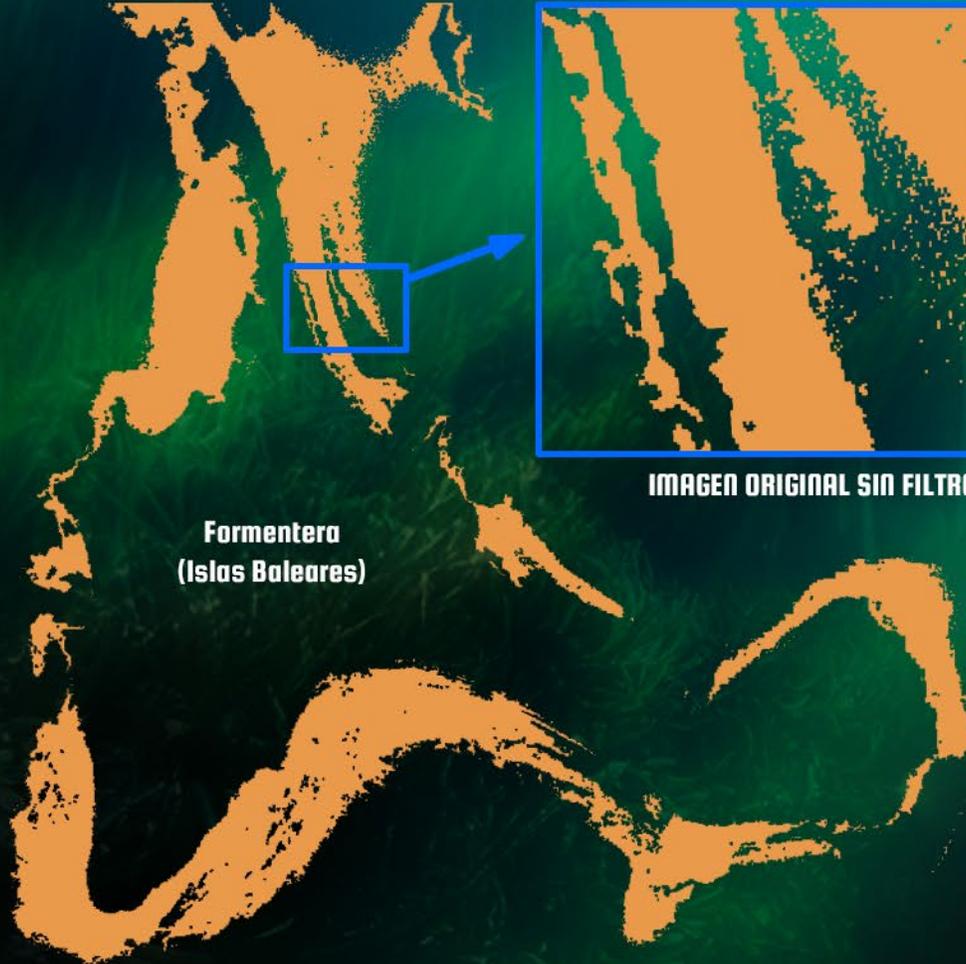
 EDIFICIO CEUDAS, CTRA. DE LA CORUÑA KM 22.300,
28232 LAS ROZAS DE MADRID, MADRID (SPAIN)

ENHANCE YOUR RESEARCH

Material Extra



Metodología: Filtrado de Ruido



Formentera
(Islas Baleares)

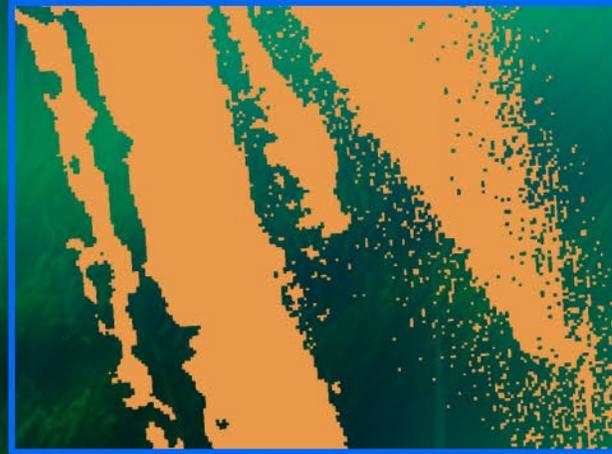
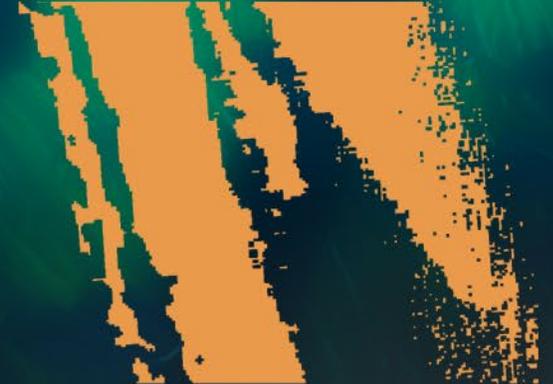


IMAGEN ORIGINAL SIN FILTRO DE RUIDO



GDAL Sieve



PCA 94%



Filtro Mediana



Filtro Bilateral

GDAL Sieve

Elimina n píxeles aislados

PCA

Reduce el número de componentes maximizando la varianza

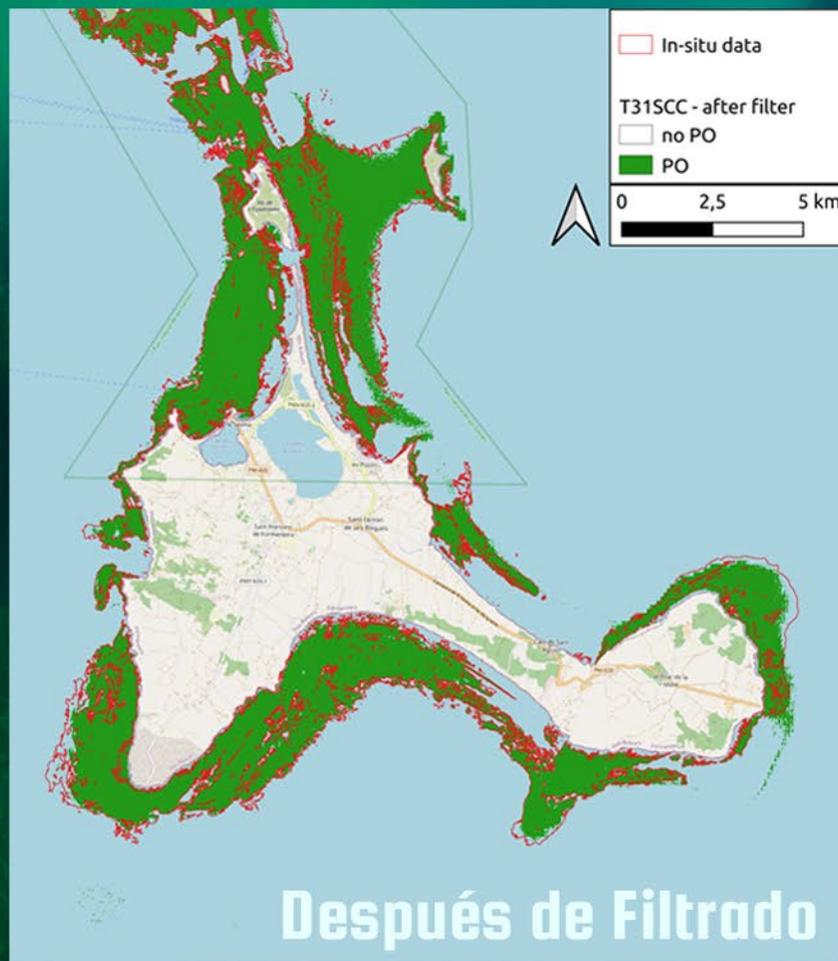
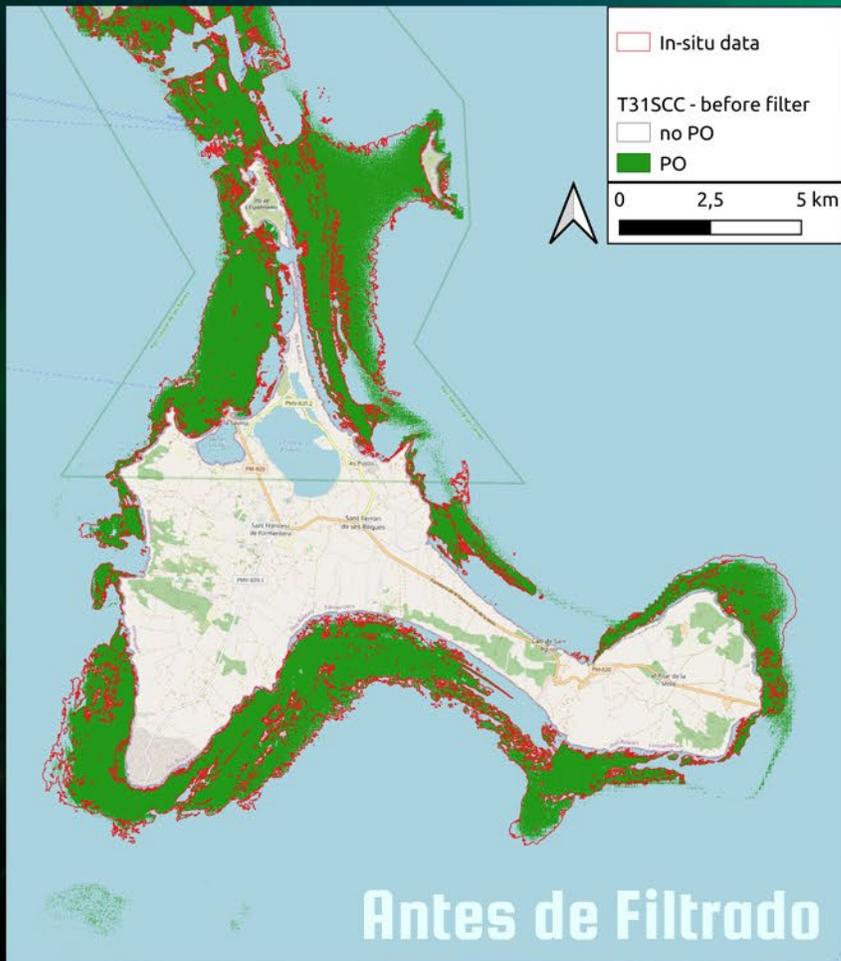
Filtro Mediana

Calcula la mediana sobre una ventana móvil

Filtro Bilateral

Suavizado manteniendo los bordes

Resultados: Filtrado de Ruido



Resultados de calidad para el caso de Formentera (T31SCC) antes y después de aplicar el filtrado de ruido.

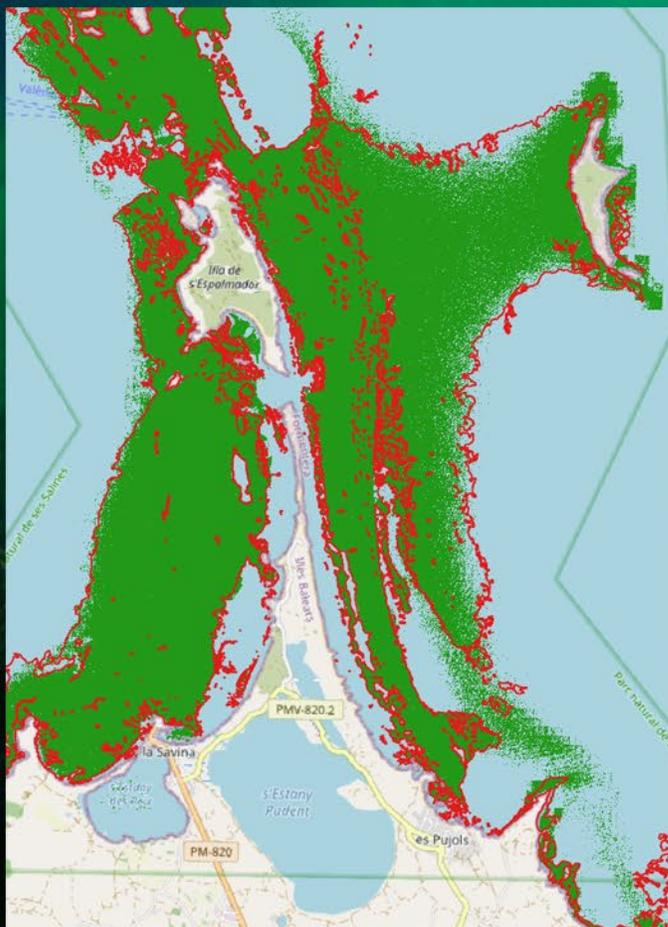
Filtro de mediana ventana móvil 3x3

	before filter	after filter
sample_size	9051714	9051714
c_matrix - TN	90.15	90.24
c_matrix - FP	0.91	0.82
c_matrix - FN	0.98	0.89
c_matrix - TP	7.96	8.05
accuracy	0.98	0.98
precision_positiv	0.90	0.91
precision_negati	0.99	0.99
recall_positive	0.89	0.90
recall_negative	0.99	0.99
f1_positive	0.89	0.90
f1_negative	0.99	0.99

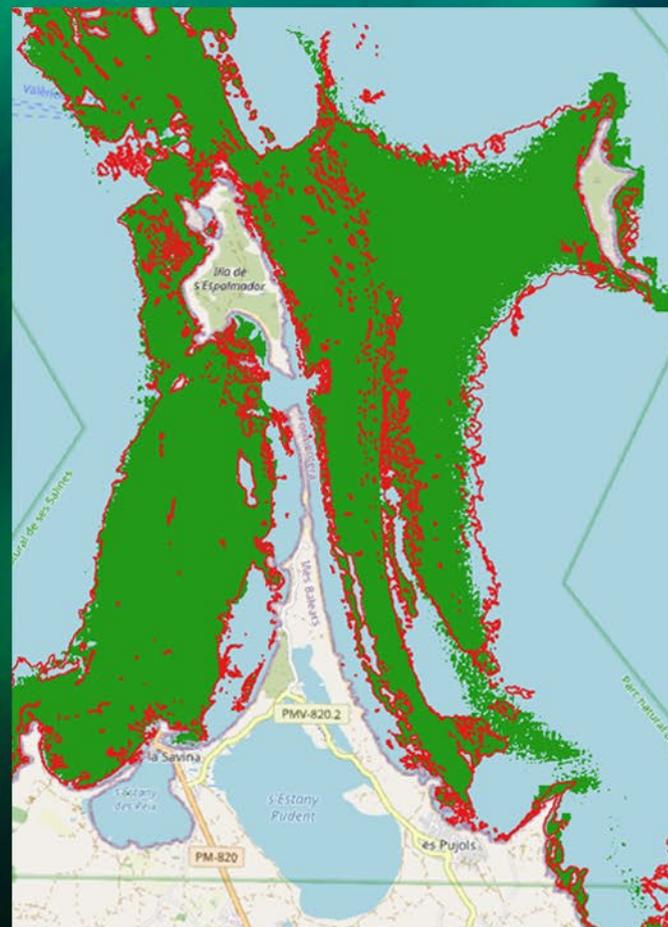
Las diferencias son pequeñas, pero va en el sentido de mejorar los píxeles que son correctamente identificados (TN y TP)

Resultados: Filtrado de Ruido

Formentera



Antes de Filtrado



Después de Filtrado

Resultados de calidad para el caso de Formentera (T31SCC) antes y después de aplicar el filtrado de ruido.

Filtro de mediana ventana móvil 3x3

	before filter	after filter
sample_size	9051714	9051714
c_matrix - TN	90.15	90.24
c_matrix - FP	0.91	0.82
c_matrix - FN	0.98	0.89
c_matrix - TP	7.96	8.05
accuracy	0.98	0.98
precision_positiv	0.90	0.91
precision_negati	0.99	0.99
recall_positive	0.89	0.90
recall_negative	0.99	0.99
f1_positive	0.89	0.90
f1_negative	0.99	0.99

Las diferencias son pequeñas, pero va en el sentido de mejorar los píxeles que son correctamente identificados (TN y TP)