



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Politécnica Superior de Gandia

Evolución temporal de la lámina de agua del Marjal de La Safor mediante imágenes Sentinel-2

Trabajo Fin de Máster

Máster Universitario en Evaluación y Seguimiento Ambiental de Ecosistemas Marinos y Costeros

AUTOR/A: Oñate Fuster, Ana María

Tutor/a: Estornell Cremades, Javier

Cotutor/a: Marti Gavila, Jesus

CURSO ACADÉMICO: 2022/2023

Resumen

Los humedales son uno de los ecosistemas más importantes y productivos del mundo, ya que proporcionan una amplia variedad de servicios ecosistémicos, pero desafortunadamente se han visto sometidos a diferentes factores de amenaza, principalmente de origen antrópico. El objetivo principal de este estudio es cartografiar la lámina de agua libre del Marjal de La Safor utilizando imágenes satelitales Sentinel-2 y realizar una comparación en el periodo analizado entre los años 2017 y 2022. Para ello se desarrollaron modelos de clasificación empleando técnicas de aprendizaje automático, concretamente el algoritmo *Random Forest*, los cuales mostraron resultados óptimos en términos de fiabilidad global e índice kappa, con valores máximos de 0.91 y 0.88, respectivamente. De las seis fechas estudiadas, la mayor superficie inundada de agua fue de 57.32 ha el 10 de mayo de 2022 y la menor de 36.6 ha el 20 de mayo de 2020. Sin embargo, no se observó una alta correlación entre la precipitación y la superficie de lámina libre de agua en el periodo analizado, debido a que el proceso hidrológico de este humedal es complejo e intervienen otros factores, tanto climáticos y geomorfológicos como de origen antrópico. La monitorización de la evolución espacial y temporal de la lámina libre de agua del Marjal de La Safor, es de gran importancia para la conservación y gestión de dicho humedal.

Palabras clave: *Sentinel-2, humedal, Random Forest*

Abstract

Wetlands are one of the most important and productive ecosystems in the world, as they provide a wide variety of ecosystem services, but unfortunately they have been subjected to different threat factors, mainly of anthropogenic origin. The main objective of this study is to map the free water layer of Safor wetland using Sentinel-2 satellite images and to make a comparison in the period analysed between 2017 and 2022. For this purpose, classification models were developed using machine learning techniques, specifically the Random Forest algorithm, which showed optimal results in terms of overall accuracy and kappa index, with maximum values of 0.91 and 0.88, respectively. Of the six dates studied, the highest flooded surface was 57.32 ha on 10 May 2022 and the lowest was 36.6 ha on 20 May 2020. However, no high correlation was observed between precipitation and the surface of the free water layer in the period analysed, due to the fact that hydrological process of this wetland is complex and other factors intervene, both climatic and geomorphological as well as anthropogenic. The monitoring of the spatial and temporal evolution of the free water layer in the Safor wetland is important for the conservation and management of this wetland.

Keywords: *Sentinel-2, wetland, Random Forest*

ÍNDICE

1. INTRODUCCIÓN.....	3
1.1. Definición, distribución e importancia de los humedales	3
1.2. Principales factores de amenaza de los humedales.....	6
1.3. Estrategias de conservación.....	8
1.4. Antecedentes	10
2. OBJETIVOS	12
3. MATERIAL Y MÉTODOS	13
3.1. Área de estudio.....	13
3.2. Imágenes y software	16
3.3. Índices	18
3.4. Análisis exploratorio de las variables	19
3.5. Clasificación supervisada y <i>Random Forest</i>	20
3.6. Evaluación	22
4. RESULTADOS	23
5. DISCUSIÓN.....	31
6. CONCLUSIONES.....	34
7. LÍNEAS FUTURAS.....	34
8. OBJETIVOS DE DESARROLLO SOSTENIBLE	34
9. REFERENCIAS	36
ANEXO I. CÓDIGO	I

ÍNDICE DE FIGURAS

Figura 1. Mapa de los Sitios RAMSAR..	4
Figura 2. Delimitación de la zona de estudio.	13
Figura 3. Precipitación mensual durante el periodo de estudio.	15
Figura 4. Precipitación anual durante el periodo de estudio.	15
Figura 5. Precipitación desde inicio de año hasta la fecha de las imágenes de estudio. ...	15
Figura 6. Imágenes clasificadas.	24
Figura 7. Matrices de confusión de los modelos.	25
Figura 8. Valores de precisión derivados de las matrices de confusión.	26
Figura 9. Masas de agua clasificadas en cada modelo del periodo de estudio.	30

ÍNDICE DE TABLAS

Tabla 1. Características de las bandas de Sentinel-2.	17
Tabla 2. Características de las bandas de las ortofotos proporcionadas por el Instituto Cartográfico Valenciano.	18
Tabla 3. Fechas de las ortofotos e imágenes Sentinel-2 para el entrenamiento y clasificación.	21
Tabla 4. Número de puntos empleados en el cálculo de las métricas de evaluación.	22
Tabla 5. Matriz de correlación entre bandas.	23
Tabla 6. Resumen de las métricas de evaluación de cada modelo.	28
Tabla 7. Superficies de la lámina libre de agua calculadas.	29
Tabla 8. Relación del trabajo con los Objetivos de Desarrollo Sostenible de la Agenda 2030.	35

1. INTRODUCCIÓN

1.1. Definición, distribución e importancia de los humedales

Los humedales se pueden definir como “áreas donde el agua es el principal factor que controla el medio ambiente y la vida vegetal y animal asociada” (Zedler y Kercher, 2005). Sin embargo, el término humedal es un concepto muy amplio el cual recibe una gran cantidad de definiciones. Según la Convención de Ramsar (1971), tratado intergubernamental y principal marco mundial para la protección ambiental de los humedales, se define a los humedales como: “extensiones de marismas, pantanos y turberas, o superficies cubiertas de aguas, sean éstas de régimen natural o artificial, permanentes o temporales, estancadas o corrientes, dulces, salobres o saladas, incluidas las extensiones de agua marina cuya profundidad en marea baja no exceda de seis metros”.

Además, la Convención estableció un Sistema Ramsar de Clasificación de Tipos de Humedales que identifica 42 tipos agrupados en tres categorías: continentales, marinos y costeros, y artificiales. Concretamente existen 20 tipos de humedales continentales, 12 marinos y costeros, y 10 artificiales (Ramsar Convention on Wetlands, 2016). De esta forma, una zona húmeda específica se identifica con una de las tres categorías principales de humedal según la predominancia, aunque es frecuente que presente más de un tipo al mismo tiempo (Pena *et al.*, 2019).

Los humedales se distribuyen por todos los continentes y zonas climáticas, desde los trópicos hasta la tundra (Kingsford *et al.*, 2016; Hu *et al.*, 2017). En la figura 1 se muestran los humedales designados como Sitio Ramsar, es decir humedales considerados de importancia internacional por el Convenio de Ramsar. Sin embargo, existen muchos otros que no gozan de esta figura de protección y por lo tanto no aparecen reflejados en el mapa.

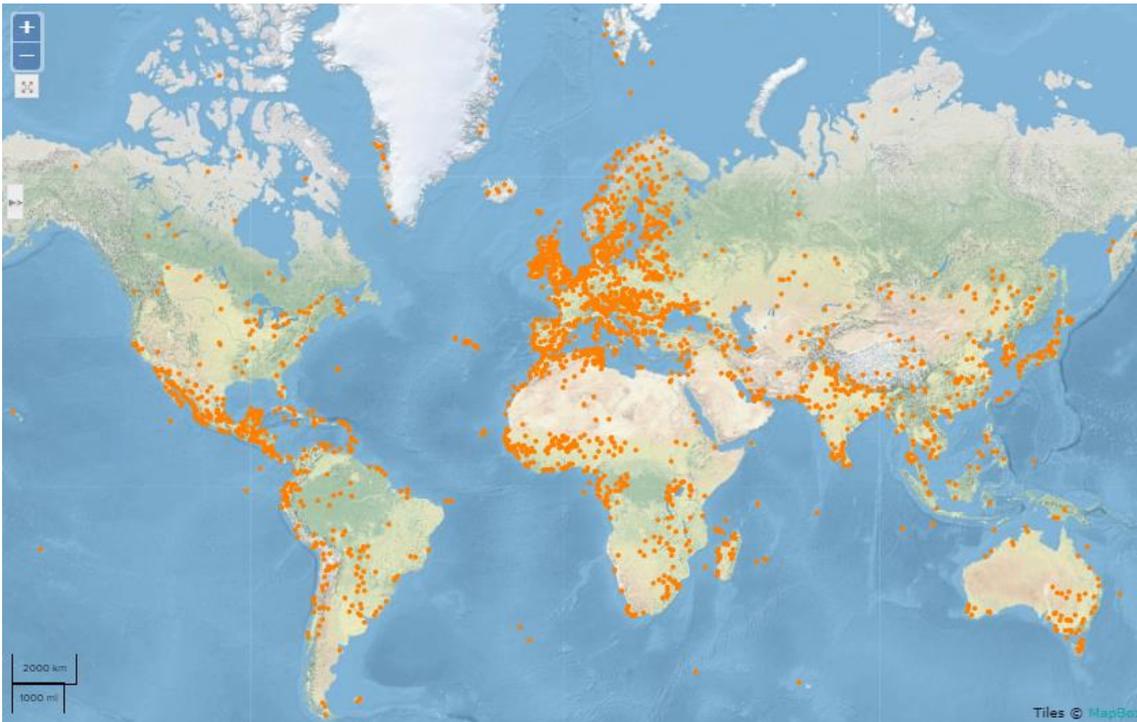


Figura 1. Mapa de los Sitios RAMSAR. Fuente: Servicio de Información sobre Sitios Ramsar (2023).

Los humedales son uno de los ecosistemas más importantes y productivos del mundo (Smardon, 2009; Mitsch y Gosselink., 2015). Albergan una elevada biodiversidad animal y vegetal, ya que proporcionan hábitats para una gran variedad de plantas, aves y peces, entre otros, incluidas especies amenazadas y en peligro de extinción (Hu *et al.*, 2017). Además, la composición y estructura de los diferentes humedales varía notablemente entre unos y otros, dependiendo de los factores abióticos y bióticos característicos (Kingsford *et al.*, 2016).

Los humedales proporcionan una amplia variedad de servicios ecosistémicos. Cabe resaltar que estos ecosistemas no solo brindan servicios indirectos a los seres humanos, sino también valores económicos directos (Xu *et al.*, 2019). A continuación, se mencionan algunos de los servicios ecosistémicos:

- Mejora y mantenimiento de una buena calidad del agua, ya que pueden actuar como sistemas de filtrado, consiguiendo eliminar nutrientes, principalmente nitrógeno y fósforo, sedimentos y contaminantes, como por ejemplo pesticidas procedentes de la actividad agrícola (Vymazal, 2014; Pena *et al.*, 2020b).
- Actúan como una reserva importante de agua dulce y fuente de reposición de aguas subterráneas (Pena *et al.*, 2020a; Pena *et al.*, 2020b).
- Almacenamiento de sedimentos (Gallant, 2015).

- Ayudan al control de inundaciones, gracias a su capacidad de retención, evitando el encharcamiento de los cultivos y áreas urbanas contiguas (Mitsch y Gosselink, 2000; Ramsar Convention Secretariat, 2016; Pena *et al.*, 2020b).
- Estabilización de las costas y control de la erosión, defensa contra la intrusión marina, y protección contra eventos meteorológicos como tormentas (Costanza *et al.*, 2014; Ramsar Convention on Wetlands, 2016; Pena *et al.*, 2020a; Pena *et al.*, 2020b).
- Mitigación y adaptación al cambio climático (Pena *et al.*, 2020b).
- Ayudan a regular el clima global y regional. Por un lado, de forma directa a través de la evapotranspiración, ya que los humedales intercambian agua, calor y energía con la atmósfera (Marshall *et al.*, 2004; Ramsar Convention on Wetlands, 2016). Por otro lado, de forma indirecta al participar en el ciclo biogeoquímico mediante la captura y emisión de gases de efecto invernadero (Hu *et al.*, 2017; Convención de Ramsar sobre los Humedales, 2018).
- Secuestro y almacenamiento de carbono (Verhoeven, 2014). Los humedales son el principal sumidero de carbono y fuente natural de metano (CH₄), por lo que sus características, como por ejemplo tipo, área, y patrones de inundación, son importantes para calcular las emisiones de gases de efecto invernadero (Hu *et al.*, 2017; Convención de Ramsar sobre los Humedales, 2018)
- Impulsan el ciclo de nutrientes y la conservación de la composición de la atmósfera. Los humedales absorben e incorporan nitrógeno y fósforo, es decir actúan como sumidero de nutrientes (Frazer y Keddy, 2005). También contribuyen a otras partes del ciclo del nitrógeno mediante la liberación de nitrógeno molecular a la atmósfera después de la desnitrificación (Kingsford *et al.*, 2016).
- Suministro de alimentos (Gallant, 2015). Los humedales brindan tanto alimentos a los seres humanos como una fuente de agua esencial para el riego de cultivos, la ganadería y la acuicultura (Convención de Ramsar sobre los Humedales, 2022). Algunos humedales artificiales, como los campos de arroz y estanques, adquieren una importancia significativa al proporcionar alimentos básicos como el arroz o el marisco (crustáceos y moluscos) y pescado (Kingsford *et al.*, 2016).
- Proporcionan hábitat para la vida silvestre y un hábitat crítico para las especies migratorias continentales e intercontinentales (Webb *et al.*, 2010).
- Los humedales son importantes para la recreación, la educación y los valores culturales (Kingsford *et al.*, 2016).

1.2. Principales factores de amenaza de los humedales

A lo largo de la historia, los humedales se han visto sometidos a diferentes factores de amenaza, ya sean de origen natural o antrópico. La desaparición y degradación de los humedales es un hecho que ha ocurrido a escala global (Kingsford *et al.*, 2016) y que se ha visto intensificado en los últimos años como consecuencia del modelo de desarrollo socioeconómico actual y el rápido crecimiento de la población, poco sostenible en la franja costera (Hu *et al.*, 2017).

Los humedales son considerados como uno de los ecosistemas más amenazados por las actividades antropogénicas (Sebastiá *et al.*, 2014; Zhao *et al.*, 2016; Pena *et al.*, 2020a; Pena *et al.*, 2020b), produciéndose una gran degradación o pérdida de estos debido a impactos directos e indirectos (Xu *et al.*, 2019).

Además, los cambios en el área y la distribución de los humedales provocan efectos negativos en los hábitats y biodiversidad, como por ejemplo cambios en la distribución y composición de especies, en las rutas migratorias, en la estructura de las comunidades y en las relaciones bióticas interespecíficas (Erwin, 2009; Hu *et al.*, 2017), pero también generan impactos negativos para los seres humanos (Xu *et al.*, 2019). Los principales factores de amenaza se pueden clasificar según el origen en:

a) Amenazas de origen natural:

- Variabilidad climática y fenómenos meteorológicos extremos como cambios en los patrones de temperatura y precipitación, tormentas, terremotos, etc. (Quesada y Mora, 2017; Convención de Ramsar sobre los Humedales, 2018).
- Enfermedades. Existen microorganismos patógenos que pueden causar daños en las poblaciones de especies animales y vegetales (Convención de Ramsar sobre los Humedales, 2018).

b) Amenazas de origen antrópico:

- Directas:
 - o Extracción y desvío agua. La extracción de agua de los humedales continentales, con el propósito de utilizarla en actividades agrícolas, industriales y domésticas, puede generar diferentes efectos adversos como la destrucción de características ecológicas y el impacto en aguas subterráneas (Convención de Ramsar sobre los Humedales, 2018). Además, en los humedales costeros uno de los problemas de la extracción de agua dulce es la salinización, la cual también puede darse

por la intrusión de agua salada a causa del aumento del nivel del mar, provocando por ejemplo la disminución de la vegetación debido al incremento de la salinidad (Herbert *et al.*, 2015).

- Contaminación. La basura marina y los desechos urbanos causan daños a los humedales costeros. La gran mayoría de estos, son residuos plásticos que no solo generan impactos físicos, sino también toxicológicos debido a los productos químicos asociados a estos materiales (Beaman y Bergeron, 2016). Por otra parte, las actividades agrícolas, industriales y domésticas liberan contaminantes, como por ejemplo pesticidas, lo cual provoca una reducción de la biodiversidad y productividad de los humedales (Convención de Ramsar sobre los Humedales, 2018).
- Pesca. La sobrepesca, el uso de artes de pesca destructivos, y la introducción de especies exóticas pueden disminuir las poblaciones y la diversidad, cambiar la estructura trófica y conducir a la degradación de los ecosistemas (Welcomme *et al.*, 2010).
- Extracción de arenas y gravas. Esta actividad destruye las comunidades bentónicas e indirectamente afecta a la calidad del agua y a la supervivencia de otras especies a causa de la turbidez producida por los sedimentos en suspensión (Convención de Ramsar sobre los Humedales, 2018).

- Indirectas:

- Intensificación del cambio climático. Eventual aumento del nivel del mar, cambios en el volumen y caudal de las masas de agua, aumento de la temperatura, regresión de la línea de costa, cambios en la distribución e intensidad de los eventos naturales extremos, aumento de las especies invasoras, etc. (Finlayson *et al.*, 2017).
- Aumento de la población. Urbanización, sobre todo en zonas costeras, aumento de la generación de residuos y emisiones de gases de efecto invernadero, y aumento de la demanda de infraestructuras, productos industriales y agua (Convención de Ramsar sobre los Humedales, 2018).
- Transporte de sedimentos. El transporte hacia los humedales puede incrementar debido a la erosión resultante de cambios en el uso de la tierra, lo cual puede alterar las características de un cuerpo de agua, por ejemplo, aumentando la turbidez, y consecuentemente influir en la disminución de las poblaciones de fauna y flora acuáticas (Gallant, 2015).

Por otro lado, en algunos casos, la aportación de sedimentos a los humedales puede disminuir debido a la construcción de presas y diques (Pena *et al.*, 2023). Estas infraestructuras reducen el flujo y disminuyen la productividad en estos ambientes, lo cual puede causar efectos negativos en la salud y el equilibrio de los ecosistemas (Convención de Ramsar sobre los Humedales, 2018).

- Introducción de especies exóticas e invasoras. Las condiciones que se dan en los humedales, en ocasiones favorecidas por otros impactos, ayudan al desarrollo de especies oportunistas (Zedler y Kercher, 2004). Las especies exóticas pueden ser introducidas de forma intencionada o involuntaria, y llegar a establecerse en ese nuevo hábitat, convirtiéndose en especies exóticas invasoras y provocando daños como: alteración de las comunidades y del ecosistema, competición, desplazamiento y depredación de las especies autóctonas. Como consecuencia, las especies nativas pueden sufrir una regresión e incluso extinguirse (Capdevila-Argüelles *et al.*, 2013).
- Eutrofización. El exceso de nutrientes, procedente tanto de fuentes puntuales (aguas residuales e industriales) como difusas (agricultura y acuicultura), puede causar la proliferación de microalgas o fitoplancton, lo cual reducirá la cantidad de luz que penetra habitualmente y por lo tanto la tasa fotosintética, con la consecuente disminución de la biomasa y productividad de estos ecosistemas (Wenger *et al.*, 2015).

1.3. Estrategias de conservación

La conservación de los humedales costeros es fundamental debido a su importancia ecológica y socioeconómica, y a las amenazas a las que se ven sometidos. La protección y restauración de estos ecosistemas requiere un enfoque integrado que involucre a gobiernos, a la comunidad científica, organizaciones ambientales y comunidades locales (Ramsar Convention on Wetlands, 2016). La implementación de políticas y legislaciones sólidas, y la creación de áreas protegidas, son algunas de las estrategias clave para asegurar la supervivencia de los humedales costeros. Además, es esencial el monitoreo y aumentar la conciencia social sobre la importancia de estos ecosistemas. La conservación y regeneración de los humedales a nivel global se puede llevar a cabo en diferentes aspectos:

a) Gestión y política

En primer lugar, una de las opciones para controlar el área total de los humedales es establecer límites, logrando de esta forma implantar diferentes áreas protegidas, las cuales facilitan la gestión de estos ecosistemas y proporcionan una protección eficaz (Zheng *et al.*, 2012).

Por otra parte, se puede llevar a cabo un control de la cantidad total de contaminantes vertidos en los humedales procedentes de la agricultura, ganadería, industria, aguas residuales domésticas, etc. (Xu *et al.*, 2019). Además, otra medida que se puede adoptar es el control y ayuda a la reproducción y conservación de las especies endémicas o en peligro de extinción. También es de interés realizar predicciones climáticas con la suficiente antelación para poder ver los posibles efectos del cambio climático y que dé tiempo a actuar (Xu *et al.*, 2019).

b) Monitoreo

El monitoreo es un proceso que consiste en medir el cambio en las características ecológicas de un humedal durante un periodo de tiempo determinado. Se puede llevar a cabo mediante la observación de campo, recolección de material vegetal o empleando diferentes tecnologías (Ramsar Convention on Wetlands, 2016). Monitorizar la dinámica espacial y temporal de las láminas de agua es de vital importancia para la gestión del agua y la conservación de la biodiversidad asociada a estos ecosistemas (Pena *et al.*, 2020a). Una de las tecnologías efectivas para monitorear los humedales es la teledetección, ya que permite realizar un seguimiento preciso de la evolución espacio-temporal de los humedales (Xu *et al.*, 2019).

c) Restauración

El proceso de restauración de humedales degradados consiste en una serie de acciones planificadas y ejecutadas con el objetivo de revertir o mitigar los impactos negativos causados por actividades humanas o eventos naturales en el ecosistema. La restauración busca recuperar la estructura, función y biodiversidad del humedal, así como restablecer sus servicios ecológicos para beneficio tanto de la vida silvestre como de las comunidades humanas que dependen de ellos (Wortley *et al.*, 2013). En este proceso de restauración se debe respetar las características naturales de los ecosistemas, evitando la interferencia humana excesiva, para que puedan aprovechar su capacidad de autorrecuperación (Mitsch y Gosselink, 2015).

d) Concienciación

Involucrar activamente a la población y educar sobre la importancia y protección de los humedales, es esencial. La concienciación social puede fomentar el apoyo y la colaboración en las actividades de restauración y asegurar un enfoque más sostenible para su conservación a largo plazo (Convención de Ramsar sobre los Humedales, 2018). Esto se puede lograr a través de diversas acciones, como promover actividades de protección de humedales para diferentes públicos. Asimismo, es crucial difundir información sobre la conservación de los humedales mediante los medios de comunicación y establecer una sólida base de educación científica sobre humedales en las reservas de estos entornos (Xu *et al.*, 2019). Además, es necesario impulsar y apoyar la investigación científica relacionada con los humedales. Mediante estudios e investigaciones dedicadas a la protección y restauración de los humedales, se puede mejorar significativamente la gestión y conservación de estos hábitats en un nivel más elevado (Xu *et al.*, 2019).

1.4. Antecedentes

El análisis de la evolución espacio-temporal de los humedales es de gran interés debido a la importancia ecológica y socioeconómica que tienen estos ecosistemas.

La teledetección es una herramienta valiosa para estudiar los humedales, ya que permite obtener información a gran escala y a lo largo del tiempo de los cuerpos de agua mediante imágenes satelitales (Pena *et al.*, 2023). Por lo tanto, la teledetección sirve para la detección y seguimiento de humedales. En este caso, el monitoreo de inundaciones de las masas de agua permite investigar la dinámica del balance hídrico. Esto es de gran relevancia para la conservación y restauración de los humedales, ya que proporciona información sobre la evolución espacial y temporal de la lámina libre de agua en estos ecosistemas (Doña, 2016).

Sin embargo, el desarrollo de índices y algoritmos de teledetección efectivos para identificar la presencia de agua bajo la vegetación, suelos húmedos o zonas de agua poco profundas ha sido un reto, ya que, como se ha comentado anteriormente, las masas de agua de los humedales experimentan grandes fluctuaciones espaciales y temporales (Ozesmi y Bauer, 2002; Pena *et al.*, 2020a), y por ende su firma espectral puede ser altamente dinámica. (Zhang *et al.*, 2022).

Los datos de teledetección de los satélites Landsat se han utilizado ampliamente. Sin embargo, se ha observado que, en algunos casos, dichos satélites pueden presentar deficiencias a la hora de monitorizar humedales debido a que la resolución espacial de Landsat es de 30 metros, lo cual dificulta el monitoreo de cuerpos de agua pequeños. Además, la precisión de la clasificación de la superficie de agua varía según el tamaño y forma de la lámina libre de agua (Pena *et al.*, 2023). Por ello se propone el uso de imágenes Sentinel-2, ya que la resolución espacial es mayor, concretamente de 10 metros, lo cual puede mejorar significativamente el rango de monitoreo, especialmente en zonas de menor tamaño que no pueden ser cubiertas por Landsat (Pena *et al.*, 2023), como es el caso de las presentes en el área de estudio.

Por otra parte, a partir de dichas imágenes de teledetección, se pueden extraer píxeles que corresponden a áreas inundadas a través de diferentes metodologías.

En estudios previos para detectar las masas de agua en humedales y estudiar su evolución espacio-temporal se emplea la umbralización de índices de agua. Algunos de los índices más utilizados son el índice de diferencia de agua normalizado (NDWI), el índice de diferencia de agua normalizado modificado (MNDWI), el índice de Vegetación de diferencia normalizada (NDVI), el índice de humedad de diferencia normalizado (NDMI) y el índice de extracción de agua automatizado (AWEI) (Soltani *et al.*, 2021; Zhang *et al.*, 2022). Por ejemplo, esta técnica se observa con imágenes Sentinel-2 en el estudio realizado por Pena *et al.* (2019) en el Marjal de La Safor, Pena *et al.* (2020a) en cuatro humedales costeros de la Comunidad Valenciana, y Pena *et al.* (2023) en el Parque Nacional de las Tablas de Daimiel, siendo NDWI el índice de mayor rendimiento para extraer superficies de agua en los tres estudios.

Esta metodología consiste en definir un umbral apropiado para los índices de agua, para que los píxeles de la imagen se puedan clasificar en agua o no agua, y de esta forma poder identificar las superficies de agua y cartografiar las condiciones de inundación de los humedales (Pena *et al.*, 2020a). Esta técnica presenta ventajas como la simplicidad, velocidad de procesamiento, ya que permite analizar grandes volúmenes de datos, y adaptabilidad, es decir puede aplicarse a diferentes índices de agua. Además, estos son más reproducibles y generalizables (Pena *et al.*, 2023)

Sin embargo, también presenta inconvenientes, ya que la definición de un valor umbral puede resultar en clasificaciones inexactas, especialmente en áreas con variaciones en la reflectancia relacionadas con las diferentes propiedades del agua o de la tipología de los suelos, lo que puede llevar a la inclusión de áreas no acuáticas o la exclusión de áreas acuáticas, dependiendo del umbral seleccionado. Además, como los humedales

son ecosistemas muy variables espacial y temporalmente, dificulta la definición de un umbral único que funcione para otras situaciones. (Soltani *et al.*, 2021; Pena *et al.*, 2023).

En el presente estudio se emplean técnicas de *machine learning* (aprendizaje automático) en lugar de umbralización de índices de agua. Recientemente los algoritmos de aprendizaje automático han adquirido un mayor interés en la clasificación de imágenes de humedales (Maxwell *et al.*, 2018). Como ejemplo de estudios previos, Doña (2016) compararon diferentes métodos de aprendizaje automático, optando por el algoritmo genético como método para estimar el área inundada a partir de imágenes Landsat. Kordelas *et al.* (2018) desarrollaron un enfoque no supervisado para estimar la extensión de las áreas inundadas a partir de datos Sentinel-2 corregidos radiométricamente. Huang *et al.* (2018) propusieron un enfoque de árbol de clasificación automático para clasificar la extensión de agua superficial a partir usando Sentinel-1. Zhang *et al.* (2022) utilizaron SVM como algoritmo de aprendizaje automático para clasificar el estado de inundación en humedales con imágenes de Sentinel-2.

Esta metodología de aprendizaje automático representa una mejora respecto a la umbralización de índices de agua, ya que al utilizar algoritmos y modelos entrenados para distinguir las diferentes clases permite un análisis más preciso de la información contenida en las imágenes satelitales y se ajusta a las características específicas de cada humedal. Según diferentes estudios previos, el aprendizaje automático permite clasificar imágenes satelitales de forma eficiente y eficaz, ya que son capaces de procesar datos de grandes dimensiones y cartografiar clases con características complejas (Maxwell *et al.*, 2018). En la actualidad los algoritmos de *machine learning* se han impuesto a los métodos paramétricos, debido a que mejoran la precisión de clasificación por teledetección.

2. OBJETIVOS

El objetivo principal de este estudio es cartografiar la lámina de agua libre del Marjal de La Safor utilizando imágenes satelitales Sentinel-2 y realizar una comparación en el periodo analizado entre los años 2017 y 2022. Para lograr este objetivo general, se plantearon una serie de objetivos específicos que se relatan a continuación: comprobar la viabilidad de las imágenes Sentinel-2 para este estudio y la calidad de los modelos calculados haciendo uso de métodos de aprendizaje automático, concretamente del algoritmo *Random Forest*. Asimismo, se analizó la relación entre la precipitación y la superficie de lámina libre de agua en el periodo analizado.

3. MATERIAL Y MÉTODOS

3.1. Área de estudio

El Marjal de La Safor (al sur de la provincia de Valencia, España) se extiende por los municipios de Gandía, Xeresa, Xeraco y Tavernes de la Valldigna, con una superficie de 1.244,86 hectáreas (Generalitat Valenciana, s.f.). En este caso, la zona de estudio se centra únicamente en la parte del marjal que discurre paralelo a la carretera Nazaret-Oliva dirección Gandía-Xeraco (Figura 2) que incluye el paraje Les Galerases, área natural que contiene las zonas inundadas de mayor superficie de este humedal.

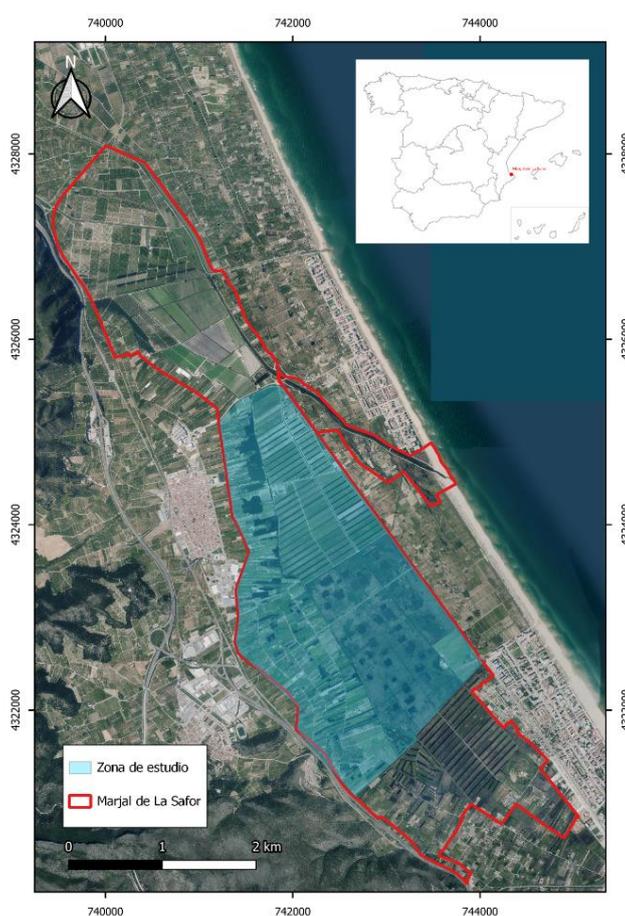


Figura 2. Delimitación de la zona de estudio. Sistema de referencia de las coordenadas UTM utilizadas en el mapa: ETRS89 (siglas en inglés de European Terrestrial Reference System 1989).

Los humedales costeros son ecosistemas dinámicos y diversos que se encuentran en la transición entre los ambientes acuáticos marinos y terrestres (Maynard y Wilcox, 1997; Hu *et al.*, 2017). Este humedal costero se encuentra amparado por diferentes figuras de protección, tanto a nivel europeo, siendo Zona de Especial Protección para las Aves (ZEPA) y Lugar de Interés Comunitario (LIC) con código ES5233030, como a

nivel autonómico, formando parte del Catálogo Valenciano de Zonas Húmedas (Generalitat Valenciana, s.f.).

El origen de este marjal se remonta a la formación de una barra o restinga arenosa que se creó en dirección norte-sur debido a las corrientes marinas longitudinales, y también a las corrientes transversales que contribuyeron al transporte de sedimentos hacia la costa, lo que resultó en el cierre de un brazo de mar. Inicialmente, se trataba de un humedal costero de agua marina, pero con el paso del tiempo esta fue reemplazada por agua dulce procedente de acuíferos continentales, y al mismo tiempo, los sedimentos transportados desde los relieves fueron colmatando la depresión inicial (Alonso *et al.*, 2012).

Como se ha comentado en el párrafo anterior, el humedal de la Safor está separado del mar por una barra de arena, concretamente de unos diez kilómetros de longitud. La entrada de agua dulce procede principalmente de las aguas subterráneas de los acuíferos kársticos que alimentan el acuífero detrítico de la Plana de Gandia-Denia sobre el cual se asienta el humedal (Sebastiá *et al.*, 2014). Además, cabe mencionar que la sedimentación no ha colmatado completamente la depresión debido a la alta tasa de subsidencia o hundimiento geológico que existe en esta zona del golfo de Valencia (Alonso *et al.*, 2012).

Actualmente, este humedal se sitúa en una zona muy llana, cuya cota está por debajo del nivel del mar, dando lugar a superficies inundadas permanentemente, conocidas como surgencias o *ullals*, y otras áreas en las que el nivel de inundación es variable a causa de la pluviometría, entre otros factores (Alonso *et al.*, 2012; Pena *et al.*, 2020a; Pena *et al.*, 2020b).

Por otra parte, en la figura 3 se muestran los datos de precipitación mensual durante el periodo de estudio, observándose una estacionalidad marcada, con mayores precipitaciones en otoño, seguidas de las de primavera, y fuertes sequías durante el verano. En el segundo gráfico (Figura 4), se muestra la precipitación anual acumulada, siendo el periodo con mayor sequía el comprendido entre mayo de 2017 y mayo de 2018 con tan solo 317 mm. Por el contrario, el periodo más lluvioso estudiado es el comprendido entre mayo de 2018 y mayo de 2019 con más de 1100 mm acumulados. En la figura 5 se observa la precipitación acumulada desde inicio de año hasta la fecha de las imágenes de estudio, observándose una mayor acumulación de precipitación entre enero y mayo de 2022 (528 mm), y mínima entre enero y junio de 2018 (198 mm). Todos los datos han sido registrados por la estación meteorológica Gandia-Marxuquera, siendo esta la más próxima a la zona de estudio.

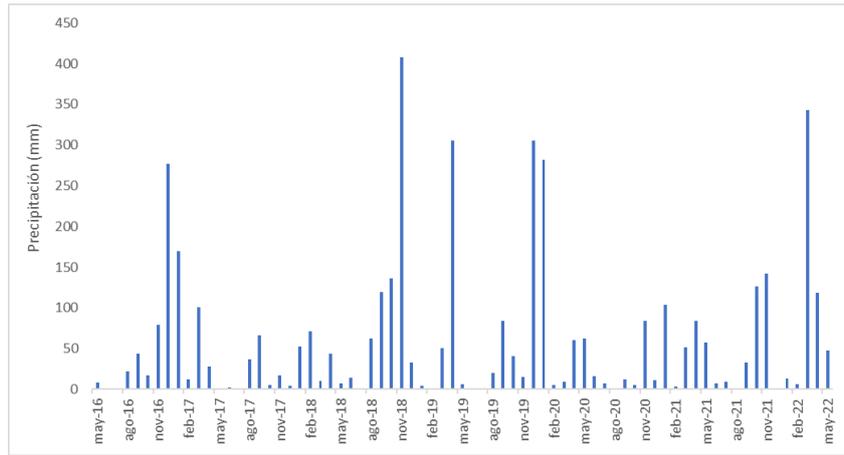


Figura 3. Precipitación mensual durante el periodo de estudio. Fuente: SiAR (Elaboración propia).

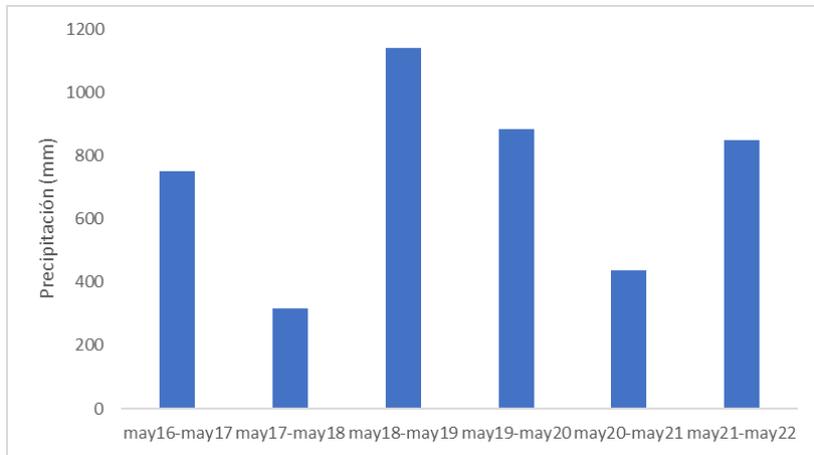


Figura 4. Precipitación anual durante el periodo de estudio. Fuente: SiAR (Elaboración propia).

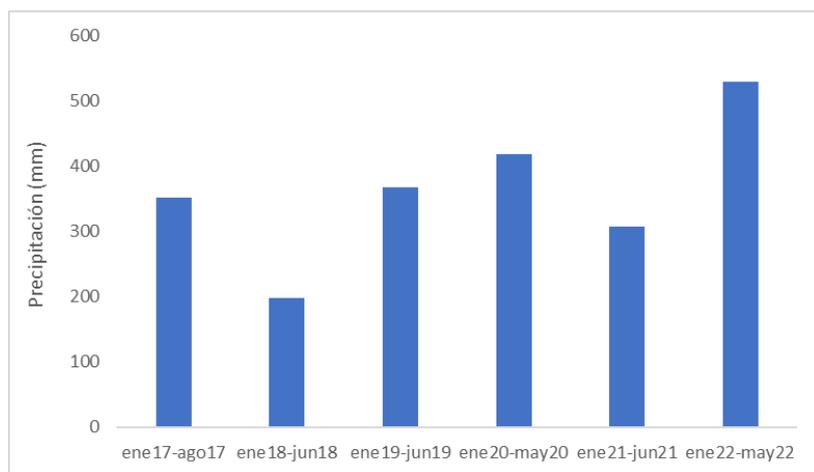


Figura 5. Precipitación desde inicio de año hasta la fecha de las imágenes de estudio. Fuente: SiAR (Elaboración propia).

En cuanto a los usos del suelo, a partir de la década de los setenta, el humedal de la Safor ha experimentado cambios significativos en su paisaje debido a intensas transformaciones agrícolas (Sebastiá *et al.*, 2014). En la actualidad se trata principalmente de un humedal natural, caracterizado por la presencia de láminas de agua, vegetación palustre, y cultivos de cítricos, hortalizas y flores ornamentales (Pena *et al.*, 2019; Pena *et al.* 2020b; Generalitat Valenciana, s.f.).

El Marjal de La Safor es considerado uno de los humedales costeros de agua dulce mejor preservados en la Comunidad Valenciana, debido a la gran cantidad y excelente calidad del suministro de agua disponible (Sebastiá *et al.*, 2012; Pena *et al.*, 2019). Contiene los siguientes hábitats incluidos en la Directiva 92/43/CEE, los cuales tienen un excelente o buen estado de conservación: lagos eutróficos naturales con vegetación *Magnopotamion* o *Hydrocharition*, lagos distróficos naturales, ríos mediterráneos de caudal permanente con *Paspalo-Agrostidion* y cortinas vegetales ribereñas con *Salix* y *Populus alba*, prados mediterráneos de hierbas altas y juncos, y turberas calcáreas de *Cladium meriscus* y *Carex davalliana* (Generalitat Valenciana, s.f.).

Además, en este espacio natural se puede encontrar una población de samaruc (*Valencia hispanica*), especie endémica de la Comunidad Valenciana, y muchos tipos de aves, tanto de paso como viviendo de forma permanente (Alonso *et al.*, 2012). Asimismo, tal y como se ha mencionado anteriormente, una de las amenazas a las que se ven sometidos los humedales es la introducción de especies exóticas. En el Marjal de La Safor se encuentra el galápagos de florida (*Trachemys scripta*), especie exótica la cual afecta a la integridad del humedal (Alonso *et al.*, 2012).

3.2. Imágenes y software

Los análisis se llevaron a cabo mediante el uso de imágenes satelitales Sentinel-2 corregidas atmosféricamente con nivel de procesado 2A, utilizando la plataforma de procesado de imágenes en la nube Google Earth Engine.

Sentinel-2 (S2) es una misión de imágenes multispectrales que presenta un tiempo de revisita corto, concretamente de 5 días, y una alta resolución espacial, proporcionando datos adecuados para evaluar el estado y el cambio de la cubierta de agua, la vegetación y el suelo (Zhang *et al.*, 2022), entre otras aplicaciones, y por lo tanto resultando de gran utilidad para el objeto de estudio.

Este satélite (S2), lanzado por la Agencia Espacial Europea (ESA) en 2015, lleva incorporado un instrumento multispectral (MSI) que mide la radiación reflejada de la Tierra en 13 bandas espectrales que operan a lo largo del espectro visible e infrarrojo (Zhang *et al.*, 2022). En la tabla 1 se observan dichas bandas, junto con su longitud de onda y resolución espacial.

Tabla 1. Características de las bandas de Sentinel-2. Fuente: Google Earth Engine (2023).

Nombre	Descripción	Longitud de onda (nm)	Resolución espacial (m)
B1	Aerosol	444	60
B2	Azul	497	10
B3	Verde	560	10
B4	Rojo	665	10
B5	Infrarrojo cercano (NIR)	704	20
B6	Infrarrojo cercano (NIR)	740	20
B7	Infrarrojo cercano (NIR)	782	20
B8	Infrarrojo cercano (NIR)	835	10
B8A	Infrarrojo cercano (NIR)	865	20
B9	Vapor de agua	945	60
B10	Cirrus	1373	60
B11	Infrarrojo de onda corta (SWIR 1)	1614	20
B12	Infrarrojo de onda corta (SWIR 2)	2202	20

La plataforma de Google Earth Engine (GEE) permite utilizar imágenes Sentinel-2 con dos niveles de procesado, el nivel 1C (“COPERNICUS/S2”) y el nivel 2A (“COPERNICUS/S2_SR”). En el presente estudio únicamente se empleó el nivel 2A (L2A), el cual contiene la reflectancia superficial ortorrectificada corregida atmosféricamente (BOA, *Bottom Of Atmosphere reflectances*).

El análisis realizado consistió en extraer la superficie de la lámina libre de agua en el periodo comprendido entre agosto de 2017 y mayo de 2022. Este periodo de tiempo fue elegido en base a las fechas de disponibilidad de imágenes de Sentinel-2 L2A que están disponibles desde el 28 de marzo de 2017 hasta la actualidad.

Para procesar las imágenes de Sentinel-2 se utilizó Google Earth Engine (GEE), una plataforma de análisis y procesamiento de datos geoespaciales desarrollada por Google que destaca por su alta capacidad computacional, es decir procesar grandes volúmenes

de datos de forma eficiente en la nube, y disponer de una gran variedad de imágenes satelitales sin necesidad de descargarlas localmente (Gorelick *et al.*, 2017; Roca *et al.*, 2022)

Además, el código se desarrolló en Jupyter Notebook empleando el lenguaje de programación de Python. Esto fue posible utilizando la API de GEE, la cual permite acceder a dicha plataforma directamente desde Jupyter para hacer uso de diferentes funciones y algoritmos que ofrece GEE, logrando procesar y analizar imágenes de Sentinel-2.

Por otra parte, para la selección de muestras de aprendizaje se utilizó el software QGIS versión 3.22.16, un Sistema de Información Geográfica (SIG) de código abierto que permite visualizar y analizar datos geoespaciales. Las muestras se seleccionaron sobre las ortofotos de mayor resolución espacial (Tabla 2) comprendidas en el periodo de estudio establecido, concretamente: 18 de agosto de 2017, 13 de junio de 2018, 15 de junio de 2019, 6 de mayo de 2020, 15 de mayo de 2021 y 11 de mayo de 2022. Estas ortofotos son imágenes anuales de toda la Comunidad Valenciana proporcionadas por el Instituto Cartográfico Valenciano (ICV) con una resolución espacial de 0.25 metros y cuatro bandas espectrales.

Tabla 2. Características de las bandas de las ortofotos proporcionadas por el Instituto Cartográfico Valenciano. Fuente: Morell et al. (2020).

Nombre	Descripción	Longitud de onda (nm)	Resolución espacial (m)
B1	Rojo	620	0.25
B2	Verde	530	0.25
B3	Azul	430	0.25
B4	Infrarrojo cercano (NIR)	720	0.25

3.3. Índices

Con la finalidad de añadir otras variables, además de las bandas iniciales de Sentinel-2, se calcularon dos índices espectrales para cada una de las imágenes de Sentinel-2 empleadas en este estudio.

El Índice de Agua de Diferencia Normalizada (NDWI, *Normalized Difference Water Index*) propuesto McFeeters (1996). Este índice permite detectar superficies de agua presentes en la zona de estudio. El NDWI (1) fue diseñado para maximizar la reflectancia del cuerpo de agua en la banda verde (B3) y minimizar la reflectancia de la

masa de agua en la banda del infrarrojo cercano (B8). Los resultados pueden oscilar entre -1 y +1, correspondiendo los valores positivos con el agua, mientras que los valores negativos o cero corresponden con el suelo y la vegetación (McFeeters, 1996).

$$NDWI = \frac{B3 - B8}{B3 + B8} \quad (1)$$

Siendo B3 la reflectividad de la banda 3 (560 nm) de Sentinel-2 y B8 la reflectividad de la banda 8 (835 nm). No obstante, en otros estudios en los que se utilizó este índice para determinar láminas libres de agua se encontró que valores negativos mayores a -0,30 obtuvieron buenos resultados en la determinación de estas superficies (Pena *et al.*, 2020a, 2023).

También se calculó el Índice de Humedad de Diferencia Normalizada (NDMI, *Normalized Difference Moisture Index*) (2), el cual detecta los niveles de humedad en la vegetación combinando la reflectancia del infrarrojo cercano (B8) con la del infrarrojo de onda corta (B11). Los resultados pueden oscilar entre -1 y +1, correspondiendo los valores menores con un bajo contenido de agua en la vegetación lo cual puede indicar estrés hídrico, y los valores mayores corresponden con un alto contenido de agua (Taloor *et al.*, 2021).

$$NDMI = \frac{B8 - B11}{B8 + B11} \quad (2)$$

Siendo B8 la reflectividad de la banda 8 (835 nm) de Sentinel-2 y B11 la reflectividad de la banda 11 (1614 nm).

3.4. Análisis exploratorio de las variables

Con el objetivo de reducir la dimensionalidad de los datos con alta correlación, se realizó un análisis exploratorio de correlación entre las diferentes bandas de Sentinel-2 con una resolución espacial de 10 metros (B2, B3, B4, B8) y 20 metros (B5, B6, B7, B8A, B11 y B12) y los índices seleccionados (NDWI y NDMI).

Este análisis se basó en la construcción de una matriz de correlación que muestra las relaciones lineales entre las diferentes variables espectrales. Esta matriz permite identificar la intensidad y dirección de la correlación entre cada par de variables. Los valores cercanos a 1 indican una alta correlación positiva, es decir las variables tienden a cambiar juntas en la misma dirección. En cambio, los valores próximos a -1 indican una alta correlación negativa, lo que significa que las variables tienden a cambiar en direcciones opuestas. Los valores cercanos a 0 indican una correlación débil o nula.

3.5. Clasificación supervisada y *Random Forest*

Para llevar a cabo el análisis de la evolución de la lámina libre de agua presente en la zona de estudio, se utilizó el método de clasificación supervisada con *Random Forest*, algoritmo propuesto por Breiman (1999) que sirve para identificar diferentes clases de cobertura del suelo en un área determinada. Esta técnica combina el uso de algoritmos de aprendizaje automático con datos espectrales, en este caso, de las imágenes Sentinel-2, permitiendo clasificar y asignar etiquetas a píxeles individuales en función de sus características espectrales (Morell *et al.*, 2020).

La clasificación supervisada se basa en la selección de muestras de aprendizaje, es decir objetos cuya clase es conocida. El software utiliza estas muestras de entrenamiento para reconocer las diferentes clases asociando a cada píxel una de las clases previamente definidas y aplicándolas a la imagen completa. El resultado es una nueva imagen cuyos valores de píxel representan una clase.

Estas muestras se seleccionaron en función del conocimiento previo de la zona de estudio obteniéndose mediante el uso de imágenes de alta resolución. Concretamente, en este caso, se seleccionaron puntos representativos para cada clase presente en la zona de estudio sobre las ortofotos del ICV comprendidas entre 2017 y 2022.

Tal y como se ha mencionado, este método permite especificar los tipos de clases deseados, por lo que se decidió establecer cinco clases en función de las coberturas representativas de la zona de estudio, siendo estas: agua, carrizo-cañas, cítricos, herbáceas y suelo sin vegetación.

Inicialmente se propuso establecer 200 puntos para cada clase, pero al comenzar a analizar las diferentes ortofotos de la zona de estudio, se observó que en el caso de los cítricos y las herbáceas la superficie no era lo suficientemente amplia como para ubicar determinado número de puntos, es decir no existía suficiente representación de esas clases. En el caso del agua, clase objeto de estudio, a pesar de existir una amplia superficie de láminas libres de agua, muchas de ellas eran superficies inferiores a 10 metros y por ello, debido a la resolución espacial de Sentinel-2, se decidió no establecer puntos en esas zonas, ya que podía generar resultados no deseados en la clasificación. Por estos motivos, finalmente se ajustó el número de puntos a 100, de forma que las cinco clases quedasen estandarizadas.

Por lo tanto, los datos sobre el terreno se recopilaron a partir de las ortofotos del ICV. Se seleccionó un conjunto total de 500 puntos (100 de agua, 100 de carrizo, 100 de

cítricos, 100 de herbáceas y 100 de suelo sin vegetación) para cada uno de los modelos calculados. El conjunto de datos original se segmentó aleatoriamente utilizando 350 puntos de entrenamiento y 150 puntos de validación aproximadamente.

A continuación, una vez definidas las muestras de aprendizaje y elegido el número de bandas según el análisis exploratorio de correlación entre bandas comentado en el apartado anterior, se procedió a entrenar el algoritmo de *Random Forest*, un método de aprendizaje automático (*machine learning*) que consiste en crear múltiples árboles de decisión independientes y combinar sus resultados para utilizarlos en la clasificación final de la variable de interés (Belgiu y Drăgu, 2016). Cada árbol de decisión se entrena usando una porción aleatoria del conjunto de datos de entrenamiento y utiliza diferentes características espectrales para tomar decisiones de clasificación, en este caso el 70% de los datos se destinaron al entrenamiento del modelo y el 30% restante se reservó para la validación del mismo. Durante el proceso de entrenamiento, *Random Forest* aprende las relaciones entre las características espectrales de los píxeles y las clases de cobertura del suelo asociadas. Cada modelo fue entrenado con 500 puntos y 100 árboles de decisión, y el número de variables seleccionadas para el cálculo de cada uno de los árboles de decisión fue de 3.

Una vez entrenados los modelos, se procedió a clasificar cada una de las imágenes Sentinel-2 más próximas a las fechas de las ortofotos de cada uno de los años del periodo de estudio (Tabla 3).

Tabla 3. Fechas de las ortofotos e imágenes Sentinel-2 para el entrenamiento y clasificación.

Modelo	Ortofoto	Sentinel-2
Modelo 2017	18/08/2017	14/08/2017
Modelo 2018	13/06/2018	15/06/2018
Modelo 2019	15/06/2019	15/06/2019
Modelo 2020	06/05/2020	20/05/2020
Modelo 2021	15/05/2021	14/06/2021
Modelo 2022	11/05/2022	10/05/2022

Para evaluar la bondad de los mapas de clasificación se calculó la matriz de confusión para cada uno de los modelos. Esta matriz se utilizó para calcular las métricas explicadas en el siguiente apartado. A continuación, se calculó la superficie de agua de las imágenes clasificadas.

3.6. Evaluación

Las métricas para evaluar la precisión del modelo de clasificación fueron la fiabilidad global y el índice Kappa. La combinación de ambas métricas permite obtener una evaluación más completa de la capacidad del modelo para realizar clasificaciones precisas.

La fiabilidad global es una métrica que permite evaluar la precisión global del modelo. Se calcula dividiendo el número de muestras correctamente clasificadas por el total de muestras en el conjunto de prueba.

El índice Kappa es una métrica más robusta debido a que tiene en cuenta tanto las clasificaciones correctas como las incorrectas, además de considerar el acuerdo entre las clasificaciones observadas y las esperadas por azar. El cálculo del índice Kappa consiste en comparar la matriz de confusión del modelo, la cual muestra el número de clasificaciones correctas e incorrectas para cada clase, con una matriz que refleja el acuerdo esperado por azar. El resultado es un valor que oscila entre -1 y 1, donde un valor cercano a 1 indica una alta correlación entre las clasificaciones observadas y esperadas, mientras que un valor cercano a 0 o negativo indica un rendimiento similar al azar (Cohen, 1960). Por lo tanto, cuanto mayor sea el valor del índice Kappa, mejor será el rendimiento del modelo.

Para el cálculo de estas métricas, se empleó un número de puntos concreto para cada uno de los modelos, tal y como se muestra en la tabla 4. Estos puntos no han sido utilizados en el proceso de entrenamiento del modelo, ya que la matriz de confusión, a partir de la cual se calculan estas métricas de evaluación del modelo, se lleva a cabo con los datos de validación.

Tabla 4. Número de puntos empleados en el cálculo de las métricas de evaluación.

Modelo	Número de puntos
Modelo 2017	149
Modelo 2018	167
Modelo 2019	157
Modelo 2020	137
Modelo 2021	142
Modelo 2022	140

4. RESULTADOS

En primer lugar, en la tabla 5 se observa que las bandas 5 y 11 presentan una alta correlación con el resto de las bandas, con coeficientes superiores a 0.7. Esto indica que ambas bandas contienen información espectral similar a otras bandas del sensor, lo que podría generar un sobreajuste del modelo de clasificación.

Por otro lado, las bandas 6 y 7 presentan una alta similitud entre ellas (Tabla 5), lo que, al igual que en el caso anterior, sugiere que pueden estar proporcionando información redundante en la clasificación.

Tabla 5. Matriz de correlación entre bandas.

	TC	B11	B12	B8A	NDWI	B2	B3	B4	B5	B6	B7	B8	NDMI
TC	1.000000	0.854979	0.841610	0.688565	-0.429444	0.761747	0.835370	0.759434	0.858709	0.709698	0.686868	0.687989	0.221494
B11	0.854979	1.000000	0.959590	0.795330	-0.553591	0.779076	0.865055	0.792027	0.945531	0.804911	0.783183	0.772066	0.195178
B12	0.841610	0.959590	1.000000	0.631558	-0.334154	0.867501	0.893920	0.879433	0.918758	0.653319	0.621778	0.612845	-0.004108
B8A	0.688565	0.795330	0.631558	1.000000	-0.878102	0.430768	0.643516	0.422967	0.806885	0.995786	0.995695	0.979968	0.695920
NDWI	-0.429444	-0.553591	-0.334154	-0.878102	1.000000	-0.063166	-0.287345	-0.053781	-0.503475	-0.848507	-0.869147	-0.883019	-0.823274
B2	0.761747	0.779076	0.867501	0.430768	-0.063166	1.000000	0.948854	0.983789	0.822009	0.465396	0.430267	0.436224	-0.079591
B3	0.835370	0.865055	0.893920	0.643516	-0.287345	0.948854	1.000000	0.947486	0.933908	0.677734	0.645703	0.655325	0.160423
B4	0.759434	0.792027	0.879433	0.422967	-0.053781	0.983789	0.947486	1.000000	0.833586	0.457452	0.420450	0.427874	-0.106484
B5	0.858709	0.945531	0.918758	0.806885	-0.503475	0.822009	0.933908	0.833586	1.000000	0.834962	0.806323	0.795453	0.281507
B6	0.709698	0.804911	0.653319	0.995786	-0.848507	0.465396	0.677734	0.457452	0.834962	1.000000	0.996452	0.977712	0.680968
B7	0.686868	0.783183	0.621778	0.995695	-0.869147	0.430267	0.645703	0.420450	0.806323	0.996452	1.000000	0.980279	0.706204
B8	0.687989	0.772066	0.612845	0.979968	-0.883019	0.436224	0.655325	0.427874	0.795453	0.977712	0.980279	1.000000	0.758717
NDMI	0.221494	0.195178	-0.004108	0.695920	-0.823274	-0.079591	0.160423	-0.106484	0.281507	0.680968	0.706204	0.758717	1.000000

En función de estos resultados, se toma la decisión de no incluir las bandas 5, 7 y 11 en el proceso de entrenamiento del modelo. Como se ha mencionado en el apartado anterior, esta selección se ha realizado con el objetivo de reducir la dimensionalidad de los datos y evitar la introducción de información redundante. Además, al mantener una diversidad de bandas que presenten una menor correlación entre sí, se espera que el modelo pueda capturar de manera más efectiva las características distintivas de las clases de interés y, en última instancia, mejorar el rendimiento de la clasificación.

Por lo tanto, el número total de variables empleadas en cada uno de los modelos es de nueve, concretamente siete bandas y dos índices espectrales (NDWI y NDMI). Las bandas de Sentinel-2 empleadas en este estudio son las cuatro que tienen una resolución espacial de 10 metros (B2, B3, B4, B8), y tres bandas con una resolución espacial de 20 metros, concretamente B6, B8A, y B12.

A continuación, en la figura 6 se muestran las imágenes clasificadas de cada una de las fechas del periodo de estudio y en la figura 8 los valores de precisión, es decir fiabilidad global del usuario y productor, derivados de la matriz de confusión (Figura 7).

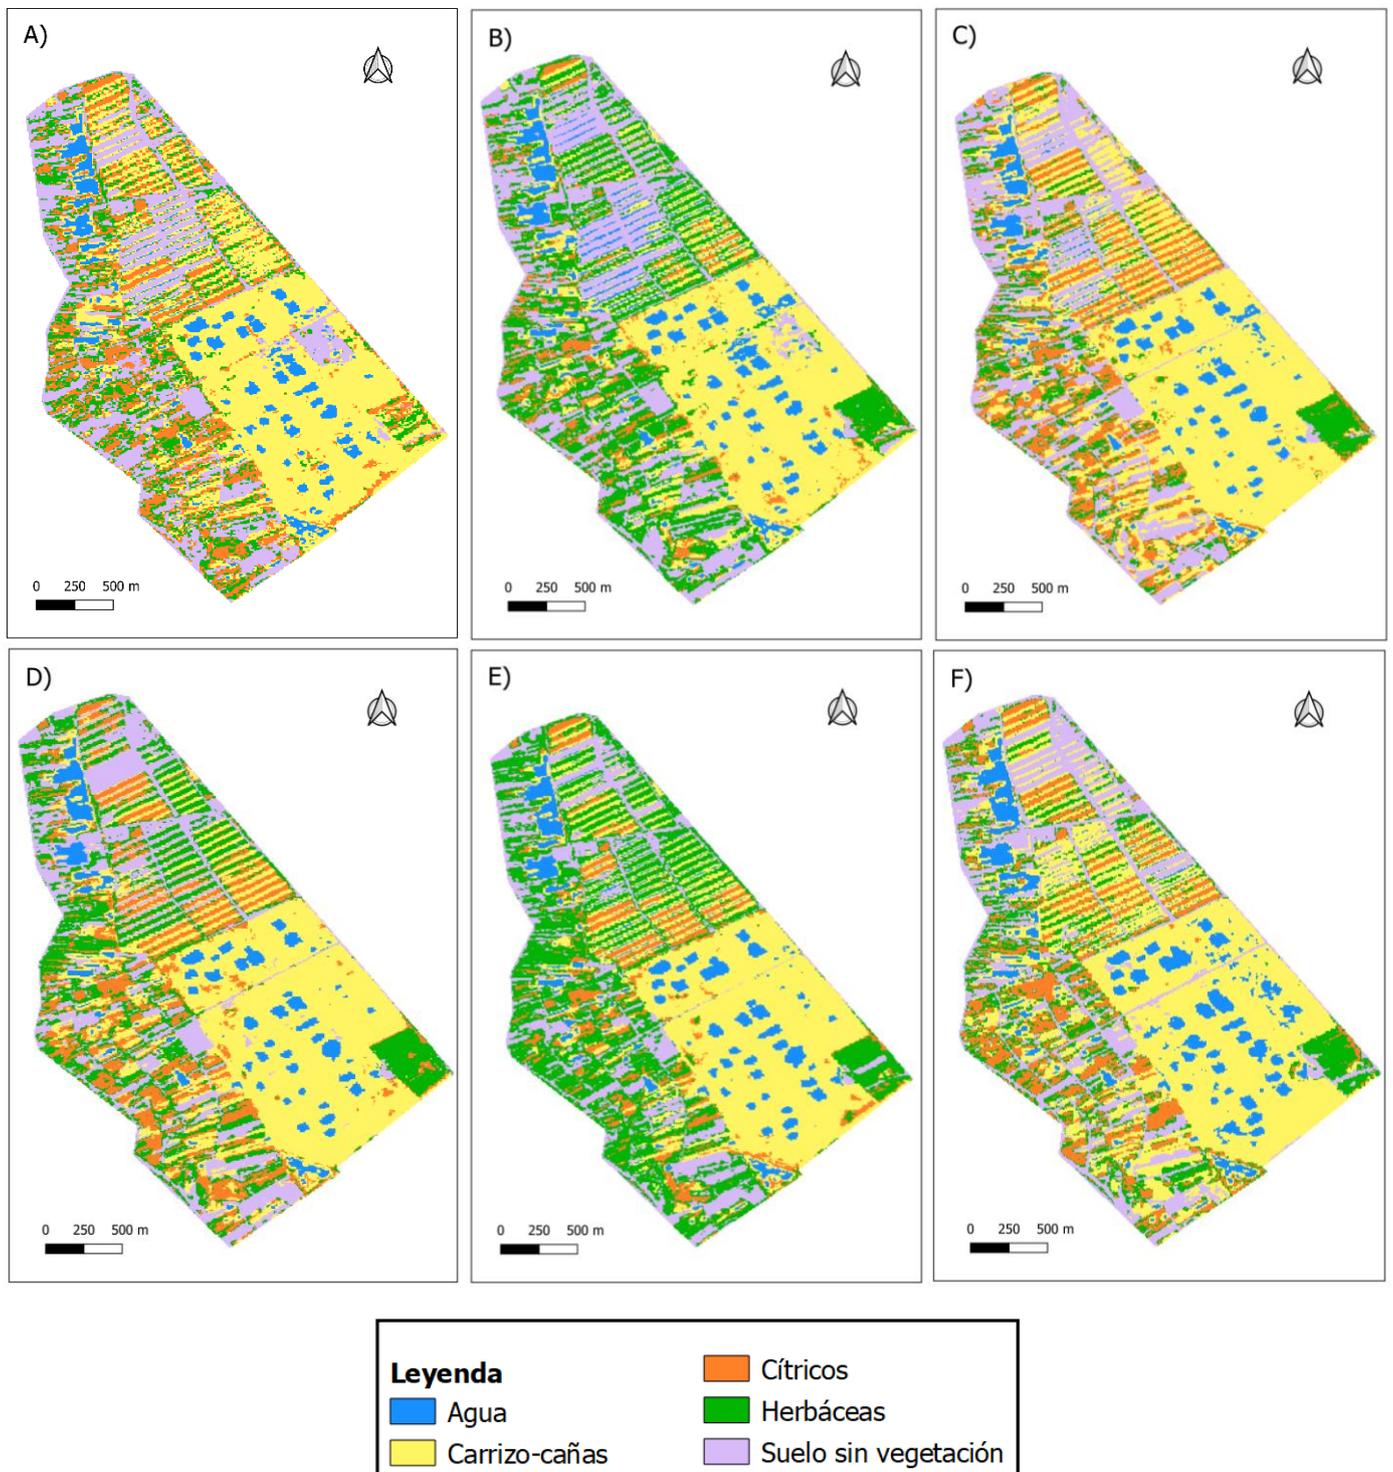


Figura 6. Imágenes clasificadas. A) Modelo 2017. B) Modelo 2018. C) Modelo 2019. D) Modelo 2020. E) Modelo 2021. F) Modelo 2022.

Modelo 2017	Agua	Carrizo-cañas	Cítricos	Herbáceas	Suelo sin vegetación
Agua	31	0	0	0	1
Carrizo-cañas	0	21	0	2	0
Cítricos	0	4	20	3	2
Herbáceas	0	1	5	29	1
Suelo sin vegetación	0	0	1	1	27

Modelo 2018	Agua	Carrizo-cañas	Cítricos	Herbáceas	Suelo sin vegetación
Agua	35	0	0	0	0
Carrizo-cañas	0	29	1	2	1
Cítricos	0	1	25	9	0
Herbáceas	0	0	4	28	0
Suelo sin vegetación	0	0	0	0	32

Modelo 2019	Agua	Carrizo-cañas	Cítricos	Herbáceas	Suelo sin vegetación
Agua	34	0	0	0	0
Carrizo-cañas	0	18	1	3	0
Cítricos	0	2	33	6	0
Herbáceas	0	0	3	22	1
Suelo sin vegetación	0	0	0	0	34

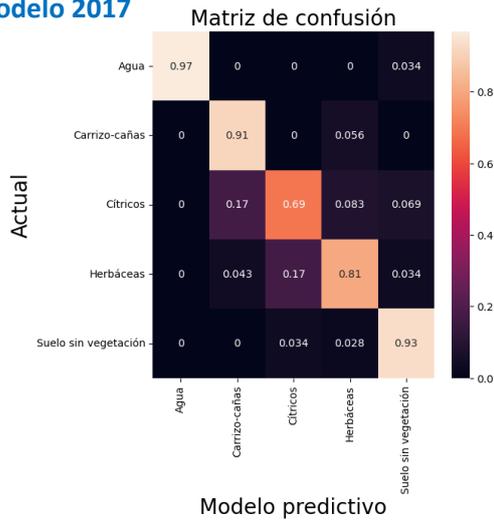
Modelo 2020	Agua	Carrizo-cañas	Cítricos	Herbáceas	Suelo sin vegetación
Agua	24	0	0	0	0
Carrizo-cañas	0	25	2	0	0
Cítricos	0	2	21	5	1
Herbáceas	0	1	3	25	0
Suelo sin vegetación	0	0	0	0	28

Modelo 2021	Agua	Carrizo-cañas	Cítricos	Herbáceas	Suelo sin vegetación
Agua	33	1	0	0	0
Carrizo-cañas	0	25	1	0	0
Cítricos	0	0	17	5	1
Herbáceas	0	0	2	22	2
Suelo sin vegetación	0	0	0	4	29

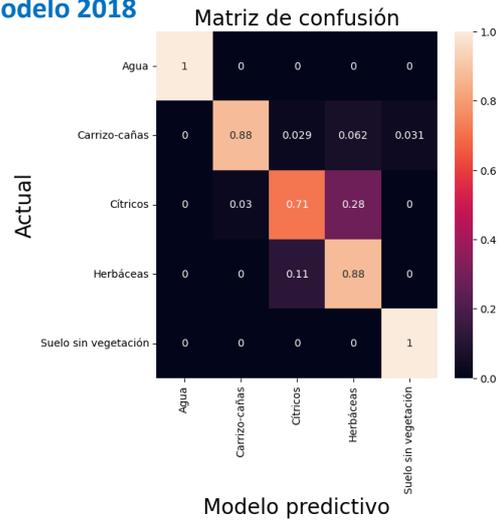
Modelo 2022	Agua	Carrizo-cañas	Cítricos	Herbáceas	Suelo sin vegetación
Agua	33	0	0	0	0
Carrizo-cañas	1	14	0	0	0
Cítricos	0	1	31	1	0
Herbáceas	0	3	6	25	1
Suelo sin vegetación	0	0	0	0	24

Figura 7. Matrices de confusión de los modelos.

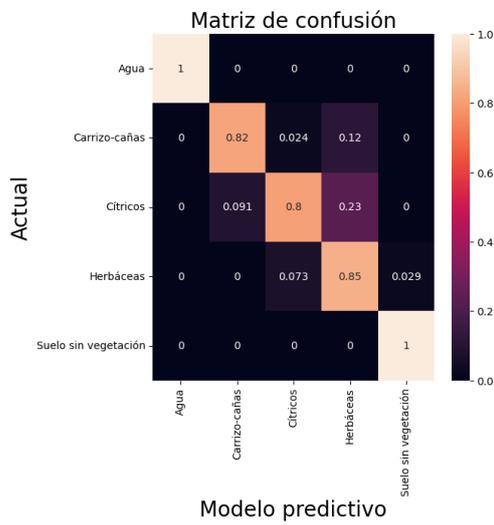
Modelo 2017



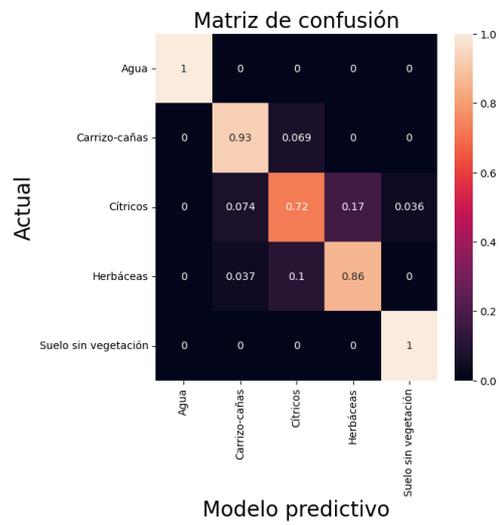
Modelo 2018



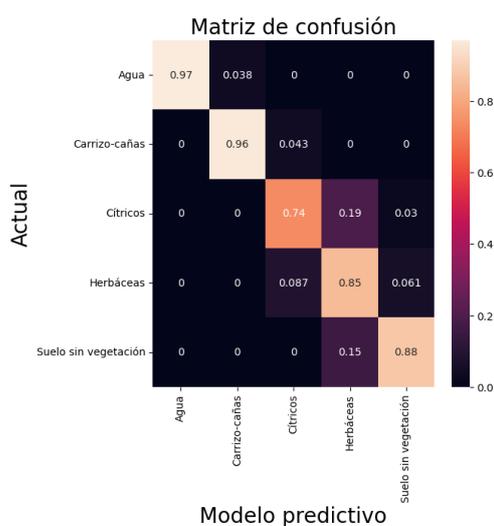
Modelo 2019



Modelo 2020



Modelo 2021



Modelo 2022

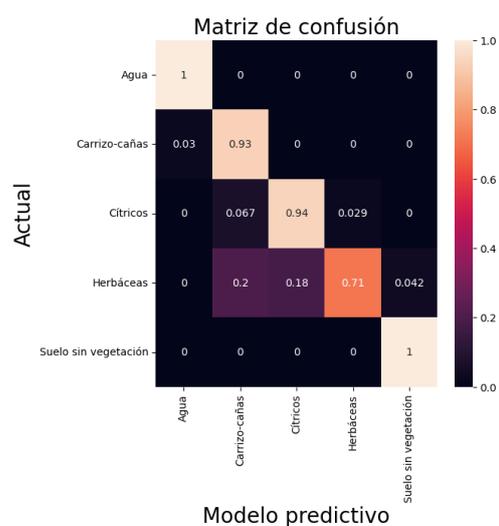


Figura 8. Valores de precisión derivados de las matrices de confusión.

En el modelo realizado para 2017, la clase agua fue clasificada con una elevada precisión (97%). En cuanto al resto de clases, también muestran buenos resultados, con una precisión del 91% para la clase carrizo-cañas, 81% para la clase herbáceas y 93% para la clase de suelo sin vegetación. Sin embargo, la clase cítricos fue la que obtuvo una menor precisión, concretamente del 69%.

La clase agua fue detectada correctamente en el modelo de 2018, con una precisión del 100%, al igual que la clase de suelo sin vegetación, es decir todas las muestras pertenecientes a dichas clases fueron identificadas y clasificadas correctamente por el modelo. En cuanto al resto de clases, también muestran buenos resultados, con una precisión del 88% para la clase carrizo-cañas y herbáceas, y un 71% para la clase cítricos, siendo esta última la que obtuvo una menor precisión.

En el modelo realizado para 2019, la clase agua y suelo sin vegetación se detectaron con elevada precisión (100%). En cuanto al resto de clases, también muestran muy buenos resultados, todas con una precisión entorno al 80% concretamente con una precisión del 82% para la clase carrizo-cañas, 80% para la clase cítricos y 85% para la clase herbáceas.

La clase agua y suelo sin vegetación se cartografiaron correctamente con una precisión del 100% en el modelo realizado para 2020. En cuanto al resto de clases, también muestran buenos resultados, con una precisión del 93% para la clase carrizo-cañas, 86% para la clase herbáceas y 72% para la clase cítricos, siendo esta la que obtuvo una menor precisión.

En el modelo realizado para 2021, la clase agua y carrizo-cañas fueron clasificadas con una elevada precisión, 97% y 96%, respectivamente. En cuanto al resto de clases, también muestran buenos resultados, con una precisión del 85% para la clase herbáceas, 88% para la clase suelo sin vegetación y 74% para la clase cítricos, siendo esta última la que obtuvo una menor precisión.

En el modelo realizado para 2022, las clases agua y suelo sin vegetación se obtuvieron también para este año con máxima precisión (100%). En cuanto al resto de clases, también muestran muy buenos resultados, con una precisión de más del 90% para las clases carrizo-cañas y cítricos. Sin embargo, la clase herbáceas fue la que obtuvo una menor precisión, concretamente del 71%.

Las clases agua y suelo sin vegetación fueron fácilmente detectables por todos los modelos, con precisiones del 100% o cercanas. La distinción entre la clase cítricos y la clase herbáceas fue más imprecisa debido a una respuesta espectral similar. Sin

embargo, las precisiones que obtienen están entorno al 70%. En cuanto a la clase carrizo-cañas, las precisiones son intermedias entre los dos casos comentados.

En general, los resultados obtenidos de la matriz de confusión demuestran que el modelo de clasificación basado en *Random Forest* es efectivo en la identificación y clasificación de las diferentes clases, especialmente en la clase de interés para este estudio como lo es la clase agua. Los altos valores de precisión para la mayoría de las clases destacan la calidad y eficacia del modelo, lo cual indica que es una buena herramienta para analizar la evolución de la lámina libre de agua en el periodo de tiempo definido.

En la tabla 6 se muestran los resultados obtenidos de las métricas empleadas para evaluar la calidad del modelo.

Tabla 6. Resumen de las métricas de evaluación de cada modelo

	Fiabilidad global	Índice Kappa
Modelo 2017	0.86	0.82
Modelo 2018	0.89	0.86
Modelo 2019	0.90	0.87
Modelo 2020	0.90	0.87
Modelo 2021	0.89	0.86
Modelo 2022	0.91	0.88

Estas métricas permiten evaluar el rendimiento general del modelo. En este caso los resultados muestran que se trata de buenos modelos, ya que presentan valores altos tanto de fiabilidad global como de índice kappa. Los resultados de fiabilidad global son óptimos, con un valor medio de 0.89 y valor máximo de 0.91 en el modelo de 2022. Los resultados del Índice Kappa muestran un valor promedio de 0.86, siendo también el valor máximo el correspondiente al año 2022, concretamente de 0.88. Por el contrario, en ambas métricas el modelo de 2017 muestra valores inferiores, con un 0.86 de fiabilidad global y 0.82 para el índice kappa.

A continuación, en la tabla 7 se muestra la superficie de la lámina libre de agua calculada para cada una de las fechas comprendidas en el periodo de estudio. De las seis fechas estudiadas, la mayor superficie inundada de agua fue de 57,32 ha el 10 de mayo de 2022 y la menor de 36,6 ha el 20 de mayo de 2020.

Tabla 7. Superficies de la lámina libre de agua calculadas.

Modelo	Superficie de agua (hectáreas)
Modelo 2017	43.00
Modelo 2018	53.83
Modelo 2019	41.48
Modelo 2020	36.60
Modelo 2021	48.41
Modelo 2022	57.32

En la figura 9 se muestran los mapas de las masas de agua clasificadas en cada uno de los modelos del periodo de estudio. En ellos se observa la superficie de agua permanente como algunas pequeñas acequias y rasas, y la zona más variable correspondiente a la zona húmeda de vegetación palustre (turberas y prados), evidenciando la eficacia de Sentinel-2 para mapear cuerpos de agua de pequeño tamaño y dinámicos (Pena *et al.*, 2019).

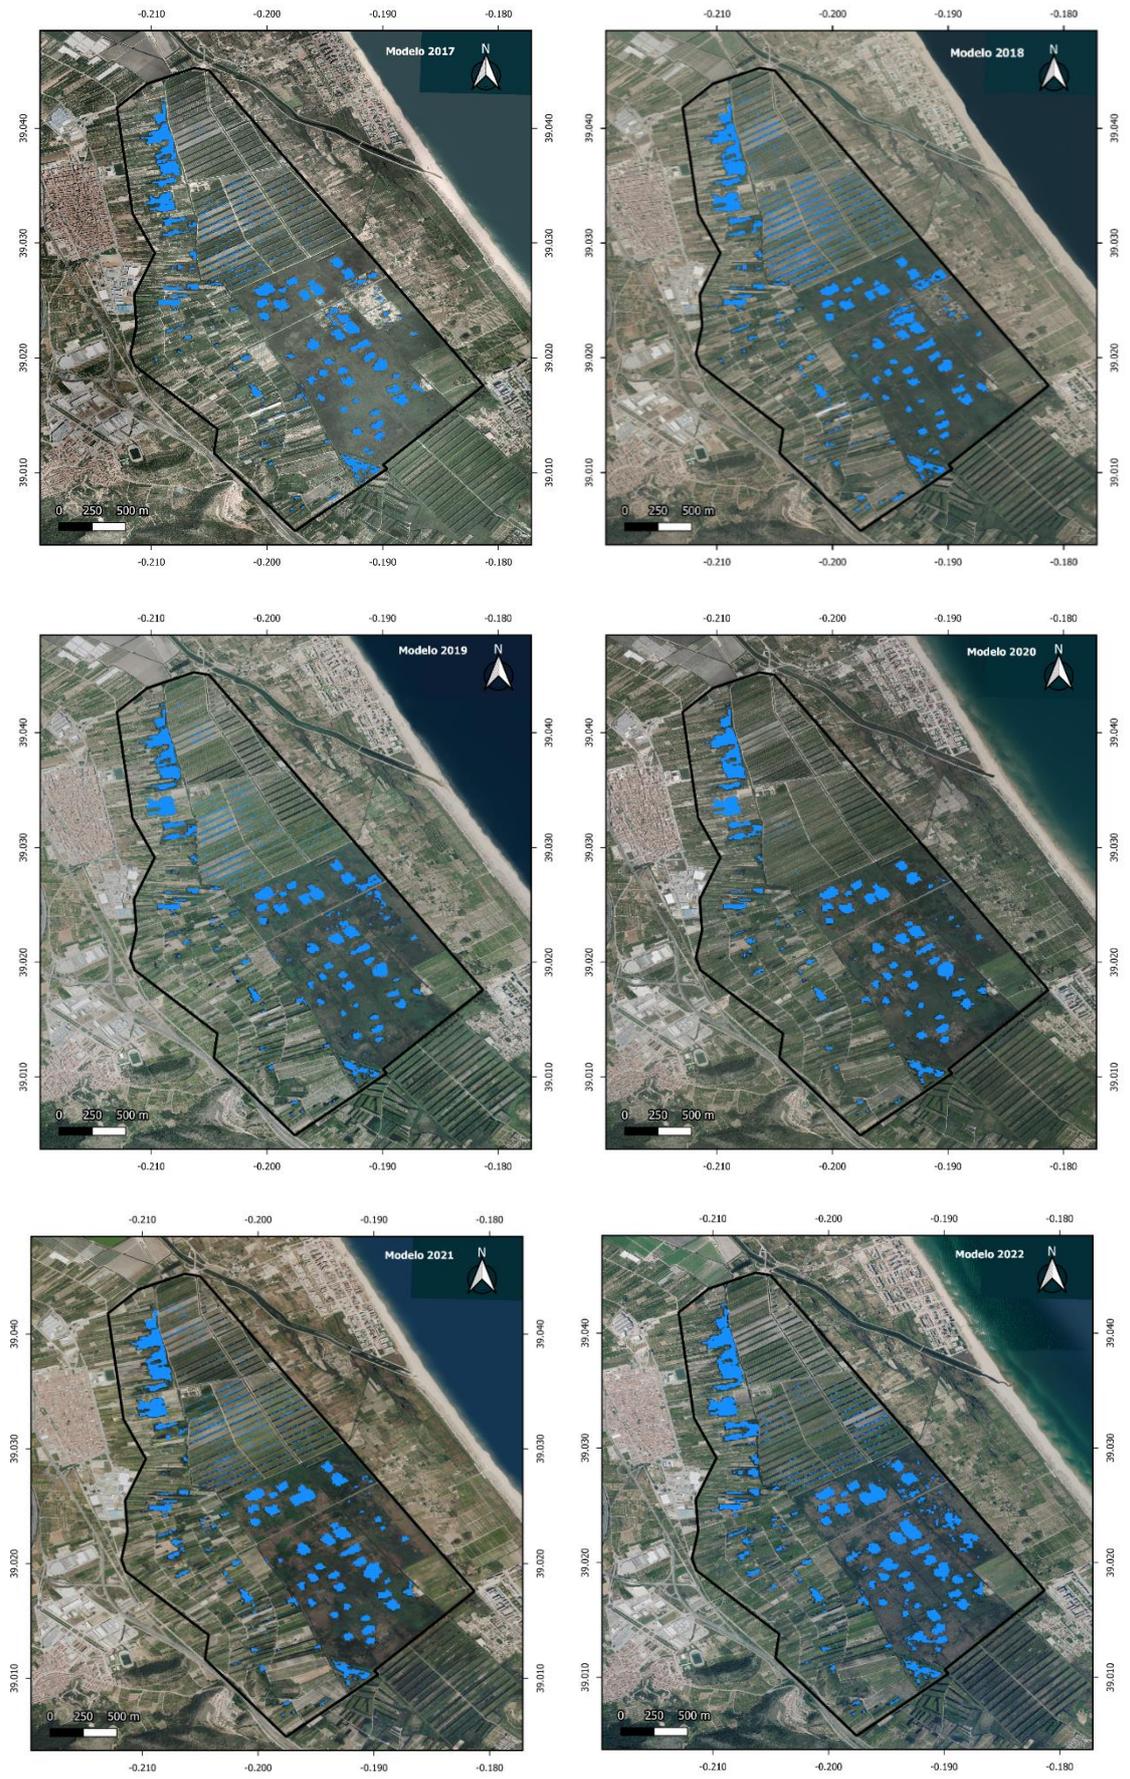


Figura 9. Masas de agua clasificadas en cada modelo del periodo de estudio.

5. DISCUSIÓN

Las imágenes Sentinel-2 han demostrado ser eficaces para cartografiar cuerpos de agua de pequeñas dimensiones en la zona de estudio del Marjal de La Safor (Pena *et al.*, 2019; Pena *et al.*, 2020a). Además, todas las clasificaciones muestran buenos resultados, observándose en las matrices de confusión precisiones para la clase agua del 100% o próximas, como en el caso del modelo de 2017 con un 97%. Sin embargo, a pesar de estos buenos resultados de la matriz de confusión y de la mejora de la resolución espacial de Sentinel-2 respecto a las imágenes Landsat vista en estudios previos, se observa que en los mapas de clasificación hay masas de agua que no quedan cartografiadas. Esto es debido a que algunas masas de agua tienen una geometría en la que alguno de los lados es inferior a 10 metros, siendo más notable en el caso de las acequias y rasas situadas al norte de la zona de estudio, y por lo tanto como la máxima resolución espacial de Sentinel-2 es de 10 metros no se pueden detectar a partir de estas imágenes.

Como resultados preliminares los modelos realizados con el algoritmo de aprendizaje automático *Random Forest*, son óptimos tal y como muestran las métricas de evaluación. Sin embargo, sería necesario comprobar la transferibilidad de los diferentes modelos entrenados aplicándolos a otras fechas de imágenes Sentinel-2.

Por otra parte, la variación espacial y temporal de la superficie de la lámina libre de agua puede ser elevada debido a diferentes procesos hidrológicos, como por ejemplo la precipitación y evapotranspiración, pero también a actividades humanas (Jin *et al.*, 2017). Como se ha comentado anteriormente, la principal entrada de agua procede del vertido de aguas subterráneas de los acuíferos kársticos que alimentan el acuífero detrítico (Sebastiá *et al.*, 2014) sobre el cual se asienta el humedal objeto de estudio. Es decir, las precipitaciones causan la recarga del acuífero kárstico, lo cual provoca un incremento en el flujo de agua hacia el acuífero detrítico y consecuentemente un aumento del nivel freático (Pena *et al.*, 2019).

Además, el área del humedal está limitada al norte por el río San Nicolás y al sur por el río Vaca. El primero desemboca en el Puerto de Gandía y solo transporta grandes volúmenes de agua durante episodios de precipitaciones intensas. Su flujo es continuo únicamente en los últimos 1,5 km debido a los aportes de agua dulce procedentes del Marjal de La Safor (Sebastiá *et al.*, 2012). Respecto al río Vaca, este desemboca directamente en el mar y tiende a inundar ocasionalmente el humedal a causa de las tormentas típicas del clima mediterráneo (Sebastiá *et al.*, 2013).

Respecto a la pluviometría en el Marjal de La Safor, una vez comparados los datos de precipitación registrados por la estación meteorológica Gandia-Marxuquera (Figura 3, 4 y 5) con los datos de la superficie de la lámina libre de agua obtenidos a partir de los diferentes modelos calculados (Tabla 7), se ha observado en algunos casos la relación entre ambos conjuntos de datos, es decir en algunos periodos en los que se registra un mayor nivel de precipitación, también se aprecia una expansión de la superficie de agua inundada. Sin embargo, es importante destacar que esta correlación no es consistente en todos los casos, ya que los periodos de máxima precipitación no siempre corresponden con un aumento directo de la superficie de la lámina libre de agua. Por lo tanto, estos datos son insuficientes para determinar si existe una relación fuerte entre la precipitación y la superficie de agua, ya que, a pesar de tratarse de diferentes años, todas las imágenes de estudio corresponden a la misma época del año, entre mayo y agosto. Para realizar un análisis más detallado y representativo, sería interesante disponer de datos trimestrales o mensuales de todos los años del periodo de estudio escogido. De esta forma, disponiendo de un suficiente número de datos, se podría calcular un índice de correlación y obtener conclusiones robustas desde un punto de vista estadístico.

Además, paralelamente a los procesos hidrológicos naturales, cabe destacar que en el Marjal de La Safor la regulación artificial de la superficie inundada es importante, ya que, en ocasiones, después de los episodios de lluvia, el agua subterránea es bombeada al mar para disminuir el nivel freático y evitar la asfixia de las raíces de los cítricos (Sebastiá *et al.*, 2012). En este humedal existen aproximadamente 14 pozos para abastecimiento urbano de aguas potables y riego de cultivos (Sebastiá *et al.*, 2014), aunque algunos de ellos solo están en funcionamiento durante la época estival, coincidiendo con la temporada alta de turismo (Sebastiá *et al.*, 2012; Pena *et al.*, 2019). Estas actuaciones antrópicas explican que no exista una fuerte correlación positiva entre la precipitación y la superficie de agua (Pena *et al.* 2019), ya que es posible que, a pesar de haber un aumento de la precipitación, el agua esté siendo destinada a otros usos.

Por lo tanto, a pesar de que la variabilidad climática tiene un efecto directo en la distribución del agua (Varghese *et al.*, 2021), es decir que la superficie de la lámina libre de agua depende en gran medida de la precipitación y evapotranspiración, esta también se ve modificada por las actividades antropogénicas (Pena *et al.*, 2020a).

Al realizar una comparación entre los resultados obtenidos en este trabajo mediante *machine learning* con los obtenidos en estudios previos mediante umbralización de índices de agua en el área del Marjal de la Safor, como por ejemplo el realizado por

Pena *et al.* (2020a), se observa que en este caso los resultados son ligeramente mejores en términos de fiabilidad global e índice kappa. El valor más alto de fiabilidad global e índice kappa en el estudio de Pena *et al.* (2020a) fue 0.89 y 0.77, respectivamente, y en este trabajo es de 0.91 y 0.88. Además, el algoritmo *Random Forest* empleado en el presente estudio permite realizar clasificaciones con alta precisión y trabajar de forma rápida con una alta dimensionalidad de datos (Belgiu y Drăgu, 2016; Maxwell *et al.*, 2018). Sin embargo, los estudios previos muestran que se pudo aplicar un mismo umbral sobre el índice de agua a otras fechas con resultados aceptables. En este sentido sería necesario explorar metodologías que permitan aplicar los modelos obtenidos en este trabajo a otras fechas, lo cual puede ser complejo debido a la variabilidad espectral que presentan las cubiertas de la zona de estudio. No obstante, la metodología aplicada en este trabajo se podría aplicar seleccionando muestras sobre la imagen Sentinel-2 desde GEE y de esta manera poder realizar una monitorización temporal.

Por último, cabe destacar que a pesar de que los seis modelos muestren buenos resultados, estos datos preliminares no son suficientes para confirmar el tipo de evolución espacial y temporal de la lámina libre de agua de este humedal. Para ello sería necesario disponer de un mayor número de datos y aplicar los modelos calculados a imágenes promedio de cada mes, lo cual queda fuera del alcance de este trabajo preliminar. Además, sería necesario un mayor número de datos para poder observar una evolución clara y valorar mejor cuales son los causantes del aumento o descenso de la superficie de la lámina libre de agua, y de esta forma poder proporcionar datos a los profesionales encargados de la gestión del humedal y contribuir a su conservación.

6. CONCLUSIONES

En función de los resultados obtenidos, se pueden sacar las siguientes conclusiones. En primer lugar, la resolución espacial de las imágenes Sentinel-2 permite cartografiar masas de agua de pequeño tamaño y por lo tanto detectar la evolución espacial y temporal de la lámina libre de agua del Marjal de La Safor, lo cual es de gran importancia para la conservación y gestión sostenible de dicho humedal. En segundo lugar, todos los modelos de clasificación basados en el algoritmo *Random Forest* son efectivos en la identificación y clasificación de la clase agua, clase de interés para este estudio, y muestran resultados óptimos en términos de fiabilidad global e índice kappa, concretamente entre 0.82 y 0.91. Por último, no se observa una alta correlación entre la precipitación y la superficie de las masas de agua, ya que el proceso hidrológico de este marjal es complejo e intervienen otros factores, tanto climáticos y geomorfológicos como de origen antrópico.

7. LÍNEAS FUTURAS

Para contribuir a la mejora del presente trabajo, sería necesario realizar nuevos estudios futuros en los que se utilizarían imágenes de otros periodos del año para monitorizar las cubiertas que presentan alta variabilidad espectral comprobando la transferibilidad de los modelos calculados en este estudio o mediante la calibración sobre las propias imágenes Sentinel-2, lo cual puede realizarse de forma rápida, con el fin de analizar eficazmente la evolución de la lámina libre de agua. Asimismo, sería de interés realizar estudios utilizando imágenes Sentinel-1 para poder detectar la lámina de agua situada bajo las zonas con vegetación, aparte de la lámina libre de agua.

8. OBJETIVOS DE DESARROLLO SOSTENIBLE

El análisis de la evolución espacial y temporal de la lámina libre de agua del Marjal de La Safor a través de técnicas de teledetección puede estar relacionado con algunos de los Objetivos de Desarrollo Sostenible (ODS):

ODS 6. Agua limpia y saneamiento: El seguimiento de la lámina libre de agua y detección temprana de cambios puede ayudar en la gestión y conservación de este recurso esencial, contribuyendo al objetivo de garantizar la disponibilidad y gestión sostenible del agua y el saneamiento.

ODS 11. Ciudades y comunidades sostenibles: El Marjal de La Safor, al igual que otros humedales, está ubicado cerca de zonas urbanas. El estudio de la evolución de la lámina libre de agua puede proporcionar información sobre la planificación territorial y la expansión urbana, lo cual es relevante para promover la gestión sostenible de las ciudades, asegurando el acceso a servicios básicos y la conservación de áreas naturales.

ODS 13. Acción por el clima: Los humedales ayudan a la mitigación del cambio climático al actuar como sumideros de carbono. El estudio de cambios en la lámina libre de agua puede indicar alteraciones en los procesos de almacenamiento y liberación de carbono, lo que a su vez causa impactos en la regulación climática.

ODS 15. Vida de ecosistemas terrestres: La evolución de la lámina libre de agua está relacionada con la salud del ecosistema del Marjal de La Safor. El monitoreo de estos cambios puede ayudar a la conservación de la biodiversidad y a la prevención de la degradación del ecosistema.

ODS 17. Alianzas para lograr los objetivos: Este estudio puede requerir la colaboración entre instituciones científicas, gubernamentales y locales. La información recopilada puede ser compartida con el fin de tomar decisiones de conservación y desarrollo sostenible, promoviendo alianzas efectivas para alcanzar los ODS.

Tabla 8. Relación del trabajo con los Objetivos de Desarrollo Sostenible de la Agenda 2030.

Objetivos de Desarrollo Sostenible	Alto	Medio	Bajo	No procede
ODS 1. Fin de la pobreza.				X
ODS 2. Hambre cero.				X
ODS 3. Salud y bienestar.				X
ODS 4. Educación de calidad.				X
ODS 5. Igualdad de género.				X
ODS 6. Agua limpia y saneamiento.	X			
ODS 7. Energía asequible y no contaminante.				X
ODS 8. Trabajo decente y crecimiento económico.				X
ODS 9. Industria, innovación e infraestructuras.				X
ODS 10. Reducción de las desigualdades.				X
ODS 11. Ciudades y comunidades sostenibles.		X		
ODS 12. Producción y consumo responsables.				X
ODS 13. Acción por el clima.		X		
ODS 14. Vida submarina.				X
ODS 15. Vida de ecosistemas terrestres.	X			
ODS 16. Paz, justicia e instituciones sólidas.				X
ODS 17. Alianzas para lograr objetivos.		X		

9. REFERENCIAS

- Beaman, J., y Bergeron, C. (2016). State of the Science White Paper: A Summary of Literature on the Chemical Toxicity of Plastics Pollution to Aquatic Life and Aquatic-Dependent Wildlife. *United States Environmental Protection Agency (EPA)*, 822-R-16-009. <https://www.epa.gov/sites/production/files/2016-12/documents/plastics-aquatic-life-report.pdf>
- Belgiu, M., y Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Breiman, L. (1999). *Random Forests—Random Features*, Technical Report 567, Statistics Department, University of California: Berkeley, USA.
- Capdevila-Argüelles, L., Zilletti, B., y Suárez Álvarez, V. Á. (2013). Causas de la pérdida de biodiversidad: Especies Exóticas Invasoras Causes of biodiversity loss: Invasive Alien Species. *Memorias de La Real Sociedad Española de Historia Natural*, 10, 55–75.
- Cohen, J. (1960). A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 20(1), 37–46. <https://doi.org/10.1177/001316446002000104>
- Convención de Ramsar sobre los Humedales. (2018). *Perspectiva Mundial Sobre los Humedales: Estado de los humedales del mundo y de los servicios que prestan a las personas*. Secretaría de La Convención de Ramsar: Gland, Suiza. https://www.ramsar.org/sites/default/files/flipbooks/ramsar_gwo_spanish_web.pdf
- Convención de Ramsar sobre los Humedales. (2022). Los humedales y la agricultura : impactos de las prácticas agrícolas y vías hacia la sostenibilidad. *Convencion de Ramsar*.
- Costanza, R., de Groot, R., Sutton, P., van der Ploeg, S., Anderson, S. J., Kubiszewski, I., Farber, S., y Turner, R. K. (2014). Changes in the global value of ecosystem services. *Global Environmental Change*, 26(1), 152–158. <https://doi.org/10.1016/j.gloenvcha.2014.04.002>
- Doña, C. (2016). *Monitoring water quality and hydrological patterns of wetlands using recent techniques in remote sensing*. Tesis doctoral, Universitat de València.
- Erwin, K. L. (2009). Wetlands and global climate change: The role of wetland restoration

- in a changing world. *Wetlands Ecology and Management*, 17(1), 71–84. <https://doi.org/10.1007/s11273-008-9119-1>
- Finlayson, C. M., Capon, S. J., Rissik, D., Pittock, J., Fisk, G., Davidson, N. C., Bodmin, K. A., Papas, P., Robertson, H. A., Schallenberg, M., Saintilan, N., Edyvane, K., y Bino, G. (2017). Policy considerations for managing wetlands under a changing climate. *Marine and Freshwater Research*, 68(10), 1803–1815. <https://doi.org/10.1071/MF16244>
- Generalitat Valenciana (s.f.): *Marjal de La Safor*. Disponible en: <https://mediambient.gva.es/es/web/biodiversidad/marjal-de-la-safor> [Consulta: 24-06-2023]
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., y Moore, R. (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>
- Herbert, E. R., Boon, P., Burgin, A. J., Neubauer, S. C., Franklin, R. B., Ardon, M., Hopfensperger, K. N., Lamers, L. P. M., Gell, P., y Langley, J. A. (2015). A global perspective on wetland salinization: Ecological consequences of a growing threat to freshwater wetlands. *Ecosphere*, 6(10), 1–43. <https://doi.org/10.1890/ES14-00534.1>
- Hu, S., Niu, Z., y Chen, Y. (2017). Global Wetland Datasets: a Review. *Wetlands*, 37(5), 807–817. <https://doi.org/10.1007/s13157-017-0927-z>
- Jin, H., Huang, C., Lang, M. W., Yeo, I. Y., y Stehman, S. V. (2017). Monitoring of wetland inundation dynamics in the Delmarva Peninsula using Landsat time-series imagery from 1985 to 2011. *Remote Sensing of Environment*, 190, 26–41. <https://doi.org/10.1016/j.rse.2016.12.001>
- Kingsford, R. T., Basset, A., y Jackson, L. (2016). Wetlands: conservation's poor cousins. *Aquatic Conservation: Marine and Freshwater Ecosystems*, 26(5), 892–916. <https://doi.org/10.1002/aqc.2709>
- Marshall, C. H., Pielke, R. A., y Steyaert, L. T. (2004). Has the conversion of natural wetlands to agricultural land increased the incidence and severity of damaging freezes in south Florida? *Monthly Weather Review*, 132(9), 2243–2258. [https://doi.org/10.1175/1520-0493\(2004\)132<2243:HTCONW>2.0.CO;2](https://doi.org/10.1175/1520-0493(2004)132<2243:HTCONW>2.0.CO;2)
- Maxwell, A. E., Warner, T. A., y Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote*

- Sensing*, 39(9), 2784–2817. <https://doi.org/10.1080/01431161.2018.1433343>
- Mitsch, W. J., y Gossilink, J. G. (2000). The value of wetlands: Importance of scale and landscape setting. *Ecological Economics*, 35(1), 25–33. [https://doi.org/10.1016/S0921-8009\(00\)00165-8](https://doi.org/10.1016/S0921-8009(00)00165-8)
- Mitsch, W.J. y Gosselink, J.G. (2015). *Wetlands*, John Wiley & Sons: New York, USA.
- Ozesmi, S. L., y Bauer, M. E. (2002). Satellite remote sensing of wetlands. *Wetlands Ecology and Management*, 10(5), 381–402. <https://doi.org/10.1023/A:1020908432489>
- Pena, J., Sebastiá, M. T., y Estornell, J. (2019). "Análisis por teledetección de superficies de agua altamente variables en zonas húmedas", en: Ruiz, L.A., Estornell, J., Calle, A., y Antuña, J.C. *Teledetección: hacia una visión global del cambio climático*. Ediciones Universidad de Valladolid, 473-476.
- Pena, J., Estornell, J., Aguilar, J., y Sebastiá, M. T. (2023). Remote Sensing Temporal Reconstruction of the Flooded Area in "Tablas de Daimiel" Inland Wetland 2000–2021. *Sensors*, 23(8). <https://doi.org/10.3390/s23084096>
- Pena, J., Sebastiá, M. T., Estornell, J., y Aguilar, J. A. (2020a). Sentinel-2 application to the surface characterization of small water bodies in Wetlands. *Water*, 12(5), 1487. <https://doi.org/10.3390/w12051487>
- Pena, J., Sebastiá, M. T., Aguilar, J. A., Estornell, J., Sanchis, J. A., Morell, S., y Altur, V. (2020b). Sentinel-2 analysis of flooded areas: Applied case study - La safor wetland, spain. *WIT Transactions on Ecology and the Environment*, 242, 63–70. <https://doi.org/10.2495/WP200061>
- Quesada, A., y Mora, A. (2017). Impactos ambientales y variabilidad climática en el humedal de San Vito, Coto Brus, Costa Rica. *Revista de Ciencias Ambientales*, 51(1), 16. <https://doi.org/10.15359/rca.51-1.2>
- Ramsar Convention on Wetlands. (2016). *An Introduction to the Convention on Wetlands, 7th ed. (previously The Ramsar Convention Manual)*. Ramsar Convention Secretariat: Gland, Switzerland.
- Roca, M., Navarro, G., García, J., y Caballero, I. (2022). Monitoring Sand Spit Variability Using Sentinel-2 and Google Earth Engine in a Mediterranean Estuary. *Remote Sensing*, 14(10), 1–19. <https://doi.org/10.3390/rs14102345>
- Sebastiá, M. T., Altur, V., y Sanchis, J. A. (2014). Wetland planning: Current problems

- and environmental management proposals at supra-municipal scale (Spanish Mediterranean Coast). *Water*, 6(3), 620–641. <https://doi.org/10.3390/w6030620>
- Smardon, R.C. (2009). *Sustaining the Worlds Wetlands: Setting Policy and Resolving Conflicts*, Springer: New York, USA.
- Soltani, K., Amiri, A., Zeynoddin, M., Ebtehaj, I., Gharabaghi, B., y Bonakdari, H. (2021). Forecasting monthly fluctuations of lake surface areas using remote sensing techniques and novel machine learning methods. *Theoretical and Applied Climatology*, 143(1–2), 713–735. <https://doi.org/10.1007/s00704-020-03419-6>
- Taloor, A. K., Drinder Singh Manhas, y Chandra Kothiyari, G. (2021). Retrieval of land surface temperature, normalized difference moisture index, normalized difference water index of the Ravi basin using Landsat data. *Applied Computing and Geosciences*, 9, 100051. <https://doi.org/10.1016/j.acags.2020.100051>
- Verhoeven, J. T. A. (2014). Wetlands in Europe: Perspectives for restoration of a lost paradise. *Ecological Engineering*, 66, 6–9. <https://doi.org/10.1016/j.ecoleng.2013.03.006>
- Vymazal, J. (2014). *The Role of Natural and Constructed Wetlands in Nutrient Cycling and Retention on the Landscape*, Springer International Publishing: Switzerland.
- Webb, E. B., Smith, L. M., Vrtiska, M. P., y Lagrange, T. G. (2010). Effects of Local and Landscape Variables on Wetland Bird Habitat Use During Migration Through the Rainwater Basin. *Journal of Wildlife Management*, 74(1), 109–119. <https://doi.org/10.2193/2008-577>
- Welcomme, R. L., Cowx, I. G., Coates, D., Béné, C., Funge-Smith, S., Halls, A., y Lorenzen, K. (2010). Inland capture fisheries. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 365(1554), 2881–2896. <https://doi.org/10.1098/rstb.2010.0168>
- Wortley, L., Hero, J. M., y Howes, M. (2013). Evaluating ecological restoration success: A review of the literature. *Restoration Ecology*, 21(5), 537–543. <https://doi.org/10.1111/rec.12028>
- Xu, T., Weng, B., Yan, D., Wang, K., Li, X., Bi, W., Li, M., Cheng, X., y Liu, Y. (2019). Wetlands of international importance: Status, threats, and future protection. *International Journal of Environmental Research and Public Health*, 16(10). <https://doi.org/10.3390/ijerph16101818>
- Zedler, J. B., y Kercher, S. (2004). Causes and consequences of invasive plants in

- wetlands: Opportunities, opportunists, and outcomes. *Critical Reviews in Plant Sciences*, 23(5), 431–452. <https://doi.org/10.1080/07352680490514673>
- Zedler, J. B., y Kercher, S. (2005). Wetland resources: Status, trends, ecosystem services, and restorability. *Annual Review of Environment and Resources*, 30, 39–74. <https://doi.org/10.1146/annurev.energy.30.050504.144248>
- Zhang, L., Hu, Q., y Tang, Z. (2022). Using Sentinel-2 Imagery and Machine Learning Algorithms to Assess the Inundation Status of Nebraska Conservation Easements during 2018–2021. *Remote Sensing*, 14(17). <https://doi.org/10.3390/rs14174382>
- Zhao, Q., Bai, J., Huang, L., Gu, B., Lu, Q., y Gao, Z. (2016). A review of methodologies and success indicators for coastal wetland restoration. *Ecological Indicators*, 60, 442–452. <https://doi.org/10.1016/j.ecolind.2015.07.003>
- Zheng, Y. M., Zhang, H. Y., Niu, Z. G., y Gong, P. (2012). Protection efficacy of national wetland reserves in China. *Chinese Science Bulletin*, 57(10), 1116–1134. <https://doi.org/10.1007/s11434-011-4942-9>