

Universidad de Huelva

Departamento de Ciencias Agroforestales



Evaluación de la ocurrencia de medusas en la costa andaluza mediante datos de ciencia ciudadana

**Memoria para optar al grado de doctor
presentada por:**

Jairo Castro Gutiérrez

Fecha de lectura: 28 de noviembre de 2025

Bajo la dirección de los doctores:

Carlos Gutiérrez Estrada

José Carlos Báez Barrionuevo

Huelva, 2025



EVALUACIÓN DE LA OCURRENCIA DE MEDUSAS EN LA COSTA ANDALUZA MEDIANTE DATOS DE CIENCIA CIUDADANA

TESIS DOCTORAL

Jairo Castro Gutiérrez



Directores:

Dr. Juan Carlos Gutiérrez Estrada

Dr. José Carlos Báez Barrionuevo



CSIC

CONSEJO SUPERIOR DE INVESTIGACIONES CIENTÍFICAS



Huelva, 2025



EVALUACIÓN DE LA OCURRENCIA DE MEDUSAS EN LA COSTA ANDALUZA MEDIANTE DATOS DE CIENCIA CIUDADANA

MEMORIA DE TESIS DOCTORAL

Jairo Castro Gutiérrez

DIRIGIDA POR

Dr. Juan Carlos Gutiérrez Estrada

Dr. José Carlos Báez Barrionuevo

PROGRAMA DE DOCTORADO

Ciencia y Tecnología Industrial y Ambiental

UNIVERSIDAD DE HUELVA

Huelva, 2025



Universidad de Huelva



CSIC

CONSEJO SUPERIOR DE INVESTIGACIONES CIENTÍFICAS



INSTITUTO
ESPAÑOL DE
OCEANOGRAFÍA

El Doctor Juan Carlos Gutiérrez Estrada, Profesor Titular de Universidad del Departamento de Ciencias Agroforestales de la Universidad de Huelva, y el Doctor José Carlos Báez Barrionuevo, Científico Titular del Centro Oceanográfico de Málaga del Instituto Español de Oceanografía (IEO-CSIC).

HACEN CONSTAR

Que la presente memoria titulada “EVALUACIÓN DE LA OCURRENCIA DE MEDUSAS EN LA COSTA ANDALUZA MEDIANTE DATOS DE CIENCIA CIUDADANA”, presentada por Jairo Castro Gutiérrez para optar al grado de doctor, ha sido realizada bajo su tutorización y dirección, respectivamente, y, dada la idoneidad del trabajo, cumple las condiciones exigidas para su presentación, por lo que autorizan su lectura y defensa.

Para que así conste a los efectos oportunos, firman la presente en Huelva a 1 de julio de 2025.

Fdo.: Dr. Juan Carlos Gutiérrez Estrada

Fdo.: Dr. José Carlos Báez Barrionuevo

*Dpto. Ciencias Agroforestales,
Escuela Técnica Superior de Ingeniería,
Universidad de Huelva*

*Centro Oceanográfico de Málaga,
Instituto Español de Oceanografía
(IEO-CSIC)*

La realización de la presente Tesis Doctoral se ha llevado a cabo dentro del Departamento de Ciencias Agroforestales de la Universidad de Huelva, formando parte del Grupo de Investigación “Análisis y Planificación del Medio Natural” (RNM315) en el Área de Conocimiento de Tecnologías del Medio Ambiente.

*“Si he podido ver más lejos,
es porque voy sentado a hombros de Gigantes.”*

— Isaac Newton

AGRADECIMIENTOS

Cuando descubrí el mundo de la investigación, soñaba con aportar mi pequeña pincelada al gran lienzo de la historia de la ciencia. Empecé un camino de esfuerzo y aprendizaje, donde comprendí que cada hallazgo se construye sobre el conocimiento previo, y que el trabajo individual solo adquiere sentido dentro de una comunidad que guía, apoya y comparte un propósito común. Ahora, al ver esta etapa finalizada, miro atrás y reconozco que este camino nunca ha sido un viaje en solitario. Desde el principio, he tenido la suerte de contar con personas que me han acompañado, guiado y apoyado. Este trabajo es también el reflejo de su ayuda, confianza y enseñanzas. Por ello, quiero dedicarles unas líneas como muestra de mi más sincero agradecimiento.

En primer lugar, quiero dar las gracias a los directores de esta Tesis Doctoral, el Dr. Juan Carlos Gutiérrez y el Dr. José Carlos Báez. Sus comentarios, revisiones, apoyo y guía a lo largo de estos años han sido indispensables para que esta tesis siguiera adelante, tanto a nivel académico como profesional. Decía Isaac Newton: *“Si he podido ver más lejos, es porque voy sentado a hombros de Gigantes”*. Mi carrera investigadora comenzó a crecer el día en que el Dr. José Carlos Báez me propuso un Trabajo de Fin de Máster en el que, en un acto de valentía, decidimos que se llevaría a cabo utilizando el lenguaje de programación *R*, en aquel entonces prácticamente desconocido para mí. Gracias a aquella decisión, cuando aún era un estudiante indeciso y entusiasmado por todas las ramas disciplinarias de las ciencias marinas, encontré mi camino. Sus llamadas ofreciendo oportunidades laborales hacen temblar al más tranquilo, pero qué afortunado soy de formar parte de esa lista telefónica. Más adelante, el Dr. Juan Carlos Gutiérrez me ofreció mi primera oportunidad laboral en la ciencia y la de realizar una Tesis Doctoral, algo que siempre había considerado para unos pocos elegidos con beca. Juan Carlos apostó por mí y me dio la posibilidad de realizarla, dejándome claro durante todas las crisis de estos tres años que la tesis no solo podía continuar, sino que debía hacerlo. No ha habido un solo día en que no me haya esforzado por estar a la altura de la confianza que depositó en mí. Nunca podré agradecerle lo suficiente el haber ido más allá de su papel como jefe y director, para ser también mentor y referente. Mis directores de tesis son mis Gigantes.

Quiero agradecer también a la Dra. Remedios Cabrera. Reme es una de esas personas extraordinariamente capaces en todo aquello que se propone. Es una persona luchadora, cuyo ejemplo inspira y convence de que puedes conseguir todo lo que te

propongas. Aunque podría expresarle mis agradecimientos por las clases que me dio, su tutorización en el TFM o por haberme dado la oportunidad de trabajar junto a ella, tengo algo mucho más importante que agradecerle: Reme fue la primera profesora que confió en mí. Aquel primer día de Máster quedará para siempre grabado en mi memoria por darme la oportunidad de colaborar con ella con una confianza que ningún profesor antes había depositado en mí, y que ha continuado a lo largo de estos años. Gracias a Reme pasé de sentirme un estudiante anónimo, un número de expediente, a sentirme un futuro investigador. No hay suficientes “artículos de 48 horas” que puedan compensar todos sus consejos cuando más lo necesité y todo el esfuerzo que ha depositado en aquel estudiante anónimo para que hoy sea Doctor.

Me gustaría también agradecer a la Dra. Inmaculada Pulido, por haber velado por mí durante y tras mi estancia en Huelva. Prometo que me he leído todos sus correos en los que siempre había un curso con un precio desorbitado y no asumible para aquellos pobres doctorandos sin beca como yo. Aunque no hiciera ninguno de ellos, cada vez que llegaba uno de esos correos era inevitable sentirse agradecido de que en su memoria apareciera mi nombre.

Cómo no extender estos agradecimientos al Dr. Víctor Sanz. Víctor es una de las personas con mayor entusiasmo por la Ciencia y por aprender que he visto nunca. Era capaz de permanecer una hora entera averiguando por qué dos funciones diferentes de *R* que hacen la misma tarea daban resultados dispares (a las 14:00h de la tarde y habiendo quedado para comer). La magnitud de su entusiasmo me motivó a superarme siempre para intentar estar a la altura de lo que se espera de un doctorando. Víctor para mí es un ejemplo académico a seguir y sus éxitos los celebro como si fueran míos.

Agradecimientos a la Dra. Pilar Hernández, por el apoyo científico y personal que me ofreció durante mi contrato con la FAO. La conocí de casualidad en un proyecto relacionado con el estudio de delfines y acabó siendo una de las artífices del gran proyecto de medusas que permitió la finalización de esta Tesis. Además, gracias a Pilar conocí a la Dra. Mar Bosch-Belmar, a quien extiendo estos agradecimientos, no solo por su calidad como profesional, sino también por su calidad humana. Solo conocía a Mar de citar sus trabajos, pero tuve el placer de conocerla y me demostró que es tan buena persona como investigadora, brindándome toda la ayuda posible para que mi estancia en Palermo, además de hacerse realidad, fuera lo más cómoda posible.

Agradecer también a todos mis compañeros del Departamento de Biología de la Universidad de Cádiz: Ángel, Belquior, Carlos y Jessica, por el equipo tan unido y competente que hicimos. Aquel equipo que formamos, y que espero que volvamos a formar, fue un sueño hecho realidad. Aquello de “*trabaja de algo que te guste y no volverás a trabajar el resto de tu vida*” se hizo posible también gracias a ellos. Especial mención a Ángel, que llegó a mi vida como un alumno de TFM y terminó convirtiéndose en uno de mis mejores amigos y compañeros. Ángel es de esas personas a las que puedes confiar cualquier tarea sabiendo que superará con creces cualquier expectativa, y tener a alguien así a tu lado es un verdadero privilegio.

No puedo olvidarme de mis compañeros de la Universidad de Huelva, Alejandro Garrocho y Samuel López, quienes me mostraron el potencial científico que tiene una colaboración entre las ciencias marinas y la ingeniería. Dimos ejemplo de lo que significa la colaboración multidisciplinar en el ámbito académico, y solo podía haber sido posible gracias a que había gente tan competente y tan buenos compañeros como ellos. Gracias por convencerme de que debía aprender *Python*. Fui fiel defensor de *R* hasta que me convencisteis... ¡y qué razón teníais!

Me gustaría agradecer también a aquellos profesores que años atrás contribuyeron al científico que soy hoy. Al profesor Joaquín Rodríguez, quien inició una reacción en cadena de acontecimientos al darme aquella primera clase de Biología, permitiéndome dar una respuesta tan prematura a esa pregunta tan difícil de “¿*Qué quieres ser de mayor?*”. También quiero agradecer a la profesora Elena Armstrong, quien me enseñó algo que no se suele enseñar en las aulas: comunicar. Qué agradecido estuve durante toda mi trayectoria universitaria de haber recibido todas aquellas críticas tan finas de cómo se hace una exposición y cómo mantener una buena comunicación con el oyente. Y cómo olvidarme de Chema Villares, quien me enseñó a amar y comprender las matemáticas, permitiendo que todos los desafíos matemáticos que me encontré después en la carrera fueran más sencillos de entender y superar.

También quiero agradecer a Censi Martín, por su extraordinario trabajo en el diseño de la portada y los elementos gráficos de esta Tesis Doctoral. Su atención al detalle, su creatividad y su profesionalidad han hecho que cada aspecto visual de este trabajo esté a la altura de lo que siempre quise.

De un modo extra-científico, hay personas que han contribuido a quien soy hoy. Gracias a Alex Raventós y Francisco Pardo por darme su apoyo cuando lo he necesitado. Mis amigos han estado siempre, pase lo que pase y a la distancia que nos separara. Su apoyo ha sido incondicional, aunque su forma de demostrarlo fuera más parecida a un guantazo a tiempo que a una palmadita en la espalda. Ellos me han dado las críticas más destructivas y constructivas a la vez, con una sinceridad tan dura que solo puede venir del cariño.

Un agradecimiento especial a Sara, mi compañera de vida. Ella ha vivido la parte más dura de este doctorado y ha estado presente apoyándome en esos momentos en los que el barco hacía aguas por todas partes, siendo la mejor consejera que he podido tener para salir a flote. Sara llegó a mi vida para reordenar mi prioridades, para enseñarme lo bonito que es disfrutar de las cosas imperceptibles a simple vista, y a darme una nueva definición de lo que es el amor y la confianza. Ella es mi tierra firme cuando tiemblo y mi viento a favor cuando sueño. Gracias por ser la mejor persona que podía encontrarme en la vida.

Por último, quiero expresar mi más profundo agradecimiento a mi familia: a mis padres, Rafael y María, y a mi hermana Celia. Ellos han sido quienes han asumido el verdadero sacrificio detrás de esta Tesis Doctoral. Gracias a su esfuerzo, apoyo y generosidad he podido permitirme el lujo de acceder a una educación superior. Ellos han priorizado siempre mi futuro, han apoyado cada una de mis decisiones ofreciéndome el mejor consejo posible, y han creído en mí, incluso en los momentos de mayor incertidumbre. Si en algún momento sienten orgullo por mis logros, deben saber que aún mayor es el orgullo que siento por formar parte de nuestra familia. Todo lo que he conseguido se lo debo, en gran parte, a ellos.

A todos ellos, los que de una forma u otra han sido parte de este camino, mi más sincero agradecimiento por ayudarme y acompañarme a llegar hasta aquí. Esta Tesis Doctoral es, en esencia, un testimonio colectivo de su impacto en mi vida, y sus huellas están indeleblemente impresas en cada página de este trabajo.

*A mis padres,
con el alma y con el corazón.*



ÍNDICES

ÍNDICE DE CONTENIDOS

RESUMEN	1
ABSTRACT	5
INTRODUCCIÓN GENERAL	9
El mar de Alborán	11
Los afloramientos de medusas: amenaza ecológica y socioeconómica	12
La costa andaluza y la presencia de medusas	12
Ciencia ciudadana ante la escasez de datos.....	15
Referencias	17
HIPÓTESIS DE PARTIDA Y OBJETIVOS	23
JUSTIFICACIÓN E INNOVACIÓN DE LA TESIS DOCTORAL.....	27
CAPÍTULO I.....	31
Resumen	33
Abstract	35
1.1. ¿Qué es una medusa?	37
1.1.1. Filo <i>Cnidaria</i>	38
1.1.2. Características morfológicas.....	40
1.1.3. Ciclo de vida y reproducción.....	43
1.1.4. Ecología trófica y relación entre especies	46
1.1.5. Especies más frecuentes en el mar de Alborán.....	48
1.2. Presencia de medusas en diferentes áreas del Mediterráneo.....	53
1.3. Factores que impulsan las proliferaciones de medusas.....	57
1.3.1. Factores ambientales	57
1.3.1.1. Forzamiento físico	58
1.3.1.2. Forzamiento de parámetros fisicoquímicos.....	59
1.3.1.3. Forzamiento biológico.....	62
1.3.1.4. Forzamiento climático	62
1.3.2. Factores antrópicos	63
1.4. Impacto socioeconómico y gestión	66
1.4.1. Efectos negativos en diferentes sectores económicos costeros	66
1.4.1.1. Interacción con la pesca.....	66

1.4.1.2.	<i>Impacto en la acuicultura y la industria costera.....</i>	67
1.4.1.3.	<i>Impacto negativo en el turismo y la salud humana.....</i>	68
1.4.2.	Estrategias de gestión: Desafíos y oportunidades.....	71
1.4.2.1.	<i>Las medusas como recurso.....</i>	75
1.4.2.2.	<i>Pesquerías y acuicultura de medusas.....</i>	77
1.5.	Avances metodológicos y tecnológicos en el estudio de las medusas	78
1.5.1.	Innovaciones en las técnicas de muestreo y monitorización	81
1.5.1.1.	<i>Ciencia ciudadana.....</i>	82
1.6.	Modelización y análisis de datos	82
1.6.1.	Modelización de <i>Pelagia noctiluca</i> en el Mediterráneo.....	83
1.7.	Brechas de conocimiento y futuras líneas de investigación	86
1.8.	Conservación y gestión de las medusas en el mar de Alborán.....	88
1.8.1.	Estrategias de conservación y gestión basadas en la evidencia.....	88
1.8.2.	Integración de la investigación en políticas y decisiones de gestión.....	89
1.9.	Conclusiones.....	91
1.10.	Referencias	93
CAPÍTULO II	117	
Resumen	119	
Abstract	121	
2.1. Introducción	123	
2.1.1.	Ciencia ciudadana.....	123
2.2. Material y métodos	130	
2.2.1.	Área de estudio	130
2.2.2.	Recopilación de datos: Aplicación Infomedusa.....	131
2.2.3.	Preprocesamiento de datos y codificación <i>one-hot</i>	134
2.2.4.	Redes neuronales artificiales	136
2.2.4.1.	<i>Elementos básicos de una RNA</i>	<i>137</i>
2.2.4.2.	<i>El Perceptrón Multicapa (MLP).....</i>	<i>141</i>
2.2.4.3.	<i>Selección de hiperparámetros</i>	<i>144</i>
2.2.5.	Análisis de factores ambientales.....	146
2.2.5.1.	<i>Modelos GAMM</i>	<i>147</i>
2.3. Resultados	149	
2.3.1.	Perceptrón Multicapa (MLP).....	150

2.3.2.	Efecto de los factores ambientales en la presencia de medusas	151
2.4.	Discusión.....	156
2.4.1.	La ciencia ciudadana para monitorear medusas	157
2.4.2.	Impacto de los factores ambientales estudiados	160
2.4.3.	Limitaciones de este estudio.....	163
2.5.	Conclusiones.....	165
2.6.	Referencias	167
CAPÍTULO III		181
Resumen		183
Abstract		185
3.1.	Introducción	187
3.2.	Material y métodos	191
3.2.1.	Área de estudio	191
3.2.2.	Datos de avistamientos de medusas	192
3.2.3.	Datos ambientales.....	193
3.2.4.	Preprocesamiento de datos y análisis exploratorio.....	194
3.2.4.1.	<i>Análisis exploratorio de datos ambientales</i>	195
3.2.5.	Modelos MaxEnt	197
3.2.5.1.	<i>Fundamentos teóricos y matemáticos de MaxEnt</i>	197
3.2.5.2.	<i>Proceso de modelización</i>	200
3.2.5.3.	<i>Evaluación de los modelos MaxEnt</i>	201
3.2.5.4.	<i>Validación de los modelos MaxEnt utilizando datos de ausencia</i>	202
3.3.	Resultados	203
3.3.1.	Análisis exploratorio de variables ambientales	204
3.3.2.	Modelos MaxEnt	207
3.3.3.	Análisis de importancia de las variables ambientales	208
3.3.4.	Mapas de distribución de probabilidad de ocurrencia de medusas	211
3.3.5.	Validación de los modelos MaxEnt utilizando datos de ausencia	212
3.4.	Discusión.....	214
3.4.1.	Principales variables ambientales y su efecto en <i>Pelagia noctiluca</i>	215
3.4.2.	Efecto de otras variables ambientales.....	220
3.5.	Conclusiones.....	223
3.6.	Referencias	225

CAPÍTULO IV	237
Resumen	239
Abstract	241
4.1. Introducción	243
4.2. Material y métodos	246
4.2.1. Área de estudio	246
4.2.2. Datos de abundancia relativa de medusas	247
4.2.3. Datos ambientales.....	249
4.2.4. Análisis estadísticos.....	250
4.2.4.1. <i>Inteligencia Artificial Explicable</i>	250
4.2.4.2. <i>Lógica difusa (Fuzzy logic)</i>	252
4.2.4.3. <i>Metodología propuesta de un sistema basado en reglas difusas..</i>	255
4.2.4.4. <i>Validación del FRBS mediante comparación con modelos GAM</i>	256
4.3. Resultados	259
4.3.1. Conjunto 1 de playas	259
4.3.2. Conjunto 2 de playas	262
4.3.3. Conjunto 3 de playas	265
4.3.4. Conjunto 4 de playas	268
4.3.5. Conjunto 5 de playas	271
4.4. Discusión.....	274
4.4.1. Comparativa entre los resultados de lógica difusa y GAM.....	275
4.4.2. Implicaciones para una gestión adaptativa de medusas.....	276
4.5. Conclusiones.....	281
4.6. Referencias	283
CONCLUSIONES	293
ANEXOS	297

ÍNDICE DE TABLAS

Tabla 0-1. Evolución de la contribución relativa de la pesca y el turismo al Producto Interior Bruto (PIB) de la Comunidad Autónoma de Andalucía (2013-2023). Fuente: Consejería de Turismo, Regeneración, Justicia y Administración Local; y Consejería de Agricultura, Pesca, Agua y Desarrollo Rural.	13
Tabla II-1. Resumen de iniciativas de ciencia ciudadana relacionadas con la monitorización de medusas llevadas a cabo en el Mar Mediterráneo. Nota: El asterisco (*) significa que el proyecto se llevó a cabo en el marco más amplio del Programa JellyWatch del CIESM.....	126
Tabla II-2. Resumen de las localidades y número de playas abarcadas por cada conjunto de playas.	131
Tabla II-3. Resumen de resultados de los 10 mejores modelos generados por el algoritmo de optimización de ajuste de hiperparámetros mediante GridSearchCV con las 63 combinaciones únicas. La clasificación de modelos se ordena a partir del mejor modelo (#1) en términos de sensibilidad de la clase minoritaria (Clase 1). Ausencia de medusas (Clase 0); Presencia de medusas (Clase 1). Clave: Unidad lineal rectificadora (ReLU, <i>Rectified Linear Unit</i>); Sigmoide (Sig); Precisión (P); Sensibilidad (S); <i>F1-score</i> (F1).	150
Tabla II-4. Valores medios de las variables ambientales temperatura de la superficie del mar (SST, °C), dirección del viento (°x10) y velocidad del viento (km/h) en los diferentes grupos de playas. Para cada variable ambiental, las medias con diferentes letras minúsculas en superíndice (a, b, c, d, e, f) indican diferencias estadísticamente significativas entre los grupos ($p < 0,05$). Por ejemplo, una letra diferente junto al valor de la SST para cada conjunto de playas indica que estos valores son estadísticamente diferentes entre sí. Los conjuntos de playas 6 y 7 se excluyeron del análisis ambiental dado el escaso volumen de datos generados por los usuarios sobre avistamiento de medusas.	153
Tabla III-1. Resumen mensual de los comentarios enviados a través de la aplicación Infomedusa a lo largo de 2019, informando de la presencia o ausencia de medusas en el litoral andaluz, así como los registros específicos del litoral andaluz del mar de Alborán durante los meses de verano (junio-septiembre). Se desglosan los valores por meses, incluyendo el número total de comentarios publicados, los que informan de la presencia de medusas y los que informan de su ausencia. Clave: AND, datos obtenidos en toda la costa de Andalucía; ALB, datos obtenidos en el litoral andaluz del mar de Alborán en el verano de 2019.	204
Tabla III-2. Variables ambientales que contribuyeron de forma significativa (valor absoluto de la carga $> 0,2$) en al menos uno de los tres primeros Componentes Principales (CP). En negrita se destacan los valores de carga absolutos superiores a 0,2.	205
Tabla III-3. Porcentaje de contribución (%C) e importancia por permutación (%P) de las variables ambientales en los modelos MaxEnt de cada uno de los meses analizados.	209
Tabla III-4. Resultados de la coincidencia entre las predicciones MaxEnt y las observaciones de ausencia por mes.	213
Tabla IV-1. Descripción de las estaciones meteorológicas de las que se obtuvieron los datos ambientales utilizados en este capítulo y los conjuntos de playas y municipios cubiertos por cada estación.	249

Tabla IV-2. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 1 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada <i>et al.</i> (2021) como valores de entrada para las variables de dirección y velocidad del viento.....	261
Tabla IV-3. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 2 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada <i>et al.</i> (2021) como valores de entrada para las variables de dirección y velocidad del viento.....	264
Tabla IV-4. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 3 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada <i>et al.</i> (2021) como valores de entrada para las variables de dirección y velocidad del viento.....	267
Tabla IV-5. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 4 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada <i>et al.</i> (2021) como valores de entrada para las variables de dirección y velocidad del viento.....	270
Tabla IV-6. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 5 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada <i>et al.</i> (2021) como valores de entrada para las variables de dirección y velocidad del viento.....	273

ÍNDICE DE FIGURAS

Figura I-1. Fotografía de la medusa clavel (<i>Pelagia noctiluca</i>), una especie de <i>Scyphozoa</i> caracterizada por su campana semitransparente con tonalidades rosadas y manchas violáceas. Sus tentáculos largos y urticantes, junto con los lóbulos orales franjeados, son rasgos distintivos que facilitan su identificación. Fotografía tomada por Juan Carlos Sáez.	37
Figura I-2. Cladograma del filo <i>Cnidaria</i> , representando las relaciones filogenéticas entre sus clases principales y su relación con el grupo hermano Bilateria.....	39
Figura I-3. Esquema del plan corporal de un pólipo (a la izquierda del lector) y de una medusa (a la derecha del lector), señalando y comparando algunas de sus estructuras corporales. Adaptado de Berzins <i>et al.</i> (2021).	40
Figura I-4. Ciclo de vida de una medusa del género <i>Rhizostoma</i> (clase <i>Scyphozoa</i>). Presenta una alternancia de generaciones entre la fase sexual (medusa) y la fase asexual (pólipo). La medusa adulta (7) es la etapa sexual, que libera gametos al agua. Tras la fecundación, se forma una larva plánula (1), que se fija al sustrato y se transforma en un pólipo primario (2). Este pólipo crece hasta convertirse en un pólipo completamente desarrollado (3), el cual se reproduce asexualmente mediante estrobilación (3a). Durante este proceso, el pólipo forma una estructura segmentada llamada estróbila (4), que libera discos en forma de éfiras (5) (etapas juveniles tempranas). Las éfiras evolucionan a meta-éfiras (6), medusas juveniles con lóbulos tentaculares. Finalmente, tras madurar, alcanzan la etapa de medusa adulta (7), cerrando el ciclo. Adaptado de Fuentes <i>et al.</i> (2011).	44
Figura I-5. Ciclo de vida de la especie de medusa <i>Pelagia noctiluca</i> (clase <i>Scyphozoa</i>) caracterizado por la ausencia de una fase de pólipo sésil. Los adultos realizan el desove, liberando gametos al agua. Tras la fecundación, los huevos fertilizados se desarrollan rápidamente en plánulas (larvas ciliadas). Estas larvas, en lugar de asentarse como pólipos, experimentan una metamorfosis directa a éfiras (etapas juveniles), con tiempos de desarrollo influenciados por la temperatura: 76 horas a 23°C o 92 horas a 14°C. Las éfiras muestran rasgos distintivos, como lóbulos marginales desarrollados, una boca con bordes orales definidos y rhopalía (estructuras sensoriales) desarrollada. Finalmente, las éfiras maduran como juveniles y luego como adultos, completando un ciclo de vida predominantemente pelágico. Este ciclo, sin fase bentónica de pólipo, permite a <i>P. noctiluca</i> una rápida colonización de aguas abiertas. Adaptada de Canepa <i>et al.</i> (2014).	45
Figura I-6. Medusa del género <i>Rhizostoma</i> sirviendo como refugio para peces de la especie <i>Boops boops</i> . Fotografía tomada por Óscar Morillas.....	48
Figura I-7. Imágenes de diferentes especies de medusas tomadas en las aguas de la costa de Andalucía (sur de España). (A) <i>Pelagia noctiluca</i> , tomada por Juan Carlos Sáez, (B) <i>Cotylorhiza tuberculata</i> , tomada por Juan José Domenech, (C) <i>Rhizostoma pulmo</i> , tomada por Miguel C. Padial, (D) <i>Physalia physalis</i> , tomada por Óscar Morillas, y (E) <i>Rhizostoma luteum</i> , tomada por Juan José Domenech.	52
Figura I-8. Barco retirando medusas cerca de la costa de Málaga (sur de España). Esta medida protocolaria es utilizada por diversas playas españolas para retirar los enjambres de medusas cuando aparecen en gran número y suponen un riesgo para la salud de los usuarios de las playas en temporadas	

estivales. Extraído de: https://www.surinenglish.com/local/201806/22/authorities-remove-tonnes-jellyfish-20180622094131-v.html	72
Figura I-9. Diseño de la bandera de advertencia de medusas implantada en las playas españolas.	73
Figura II-1. Área de estudio abarcada en este estudio. Los distintos conjuntos de playas se indican con recuadros rojos. Las localidades cubiertas por cada conjunto de playas se muestran en la Tabla II-2.....	130
Figura II-2. Interfaz de la aplicación Infomedusa. A la izquierda, se muestra la información de la playa Burriana, en Nerja (Málaga). A la derecha, se muestra la sección de “Mensajes”, donde los usuarios Jenifer y Xexu han comentado sobre la ausencia de medusas y su experiencia durante su visita a esta playa.	132
Figura II-3. Resumen gráfico del proceso de tratamiento de cada comentario j para la obtención del vector de entrada tras la codificación <i>one-hot</i>	135
Figura II-4. Diagrama del modelo básico de una neurona artificial, la unidad fundamental en redes neuronales artificiales. Las entradas ($x_1, x_2, \dots, x_n$) corresponden a las señales de entrada, que pueden provenir de datos externos o de otras neuronas. Los pesos asociados ($w_1, w_2, \dots, w_n$) se multiplican por su entrada correspondiente (x_i) y ajustan su contribución al resultado final. La suma ponderada se calcula multiplicando cada entrada (x_i) por su peso asociado (w_i) más el sesgo (θ), que es un término constante que permite desplazar la función de activación para mejorar la flexibilidad del modelo. La función de activación transforma la suma ponderada en una salida que puede ser lineal o no lineal (ver Figura II-5). Por último, la salida (y) es el resultado final de la neurona, que puede transmitirse a otras neuronas o capas en una red.	138
Figura II-5. Ecuación y gráficos de cuatro funciones de activación diferentes.....	139
Figura II-6. Arquitectura de una Red Neuronal Artificial con una capa de entrada compuesta de tres neuronas, dos capas ocultas compuestas de cuatro neuronas cada una, y una capa de salida con dos neuronas.	140
Figura II-7. Diagrama de flujo de la información de entrada a la red, desde la codificación <i>one-hot</i> hasta el proceso de configuración de los diferentes hiperparámetros establecidos en el Perceptrón Multicapa.....	145
Figura II-8. Frecuencia de comentarios de usuarios de la aplicación Infomedusa que mencionan explícitamente la presencia de medusas (barra naranja, etiquetada como 1) o su ausencia (barra azul, etiquetada como 0) para cada conjunto de playas.....	149
Figura II-9. Gráficos de densidad del núcleo para las variables de temperatura superficial del mar (SST), dirección del viento y velocidad del viento en cada conjunto de playas. Cada fila de gráficos corresponde a un conjunto de playas, mientras que cada columna representa una de las variables ambientales. Para cada gráfico se representan dos distribuciones: una para la presencia de medusas (en naranja, indicada como 1) y otra para la ausencia de medusas (en azul, indicada como 0).	152
Figura II-10. Efectos suavizados de las variables ambientales sobre la presencia de medusas. Las zonas sombreadas azules representan el intervalo de confianza del 95%.....	155
Figura III-1. Mapa de la costa mediterránea andaluza, destacando el área de estudio con una línea discontinua roja que se extiende desde el estrecho de Gibraltar en el oeste hasta Pulpí en el este en	

la frontera con la Región de Murcia. El mapa muestra los patrones generales de circulación superficial en los 200 m superiores del mar de Alborán, dominados por el Chorro del Atlántico (AJ, <i>Atlantic Jet</i>), que forma dos importantes giros anticiclónicos: el Giro Occidental del mar de Alborán (WAG, <i>Western Alboran Gyre</i>) y el Giro Oriental del mar de Alborán (EAG, <i>Eastern Alboran Gyre</i>). Entre estos dos sistemas se encuentra el Giro Ciclónico Central (CCG, <i>Central Cyclonic Gyre</i>), de menor tamaño.	192
Figura III-2. Diagrama de flujo que ilustra el proceso de obtención, procesado y preparación tanto de los datos de ocurrencia de medusas como de los datos ambientales para su integración en el modelo MaxEnt.	197
Figura III-3. Distribución espacial de la densidad de presencia de medusas a lo largo de la costa mediterránea andaluza de junio a septiembre de 2019, basada en los informes de usuarios de Infomedusa. Los valores de densidad representan el número de informes de presencia de avistamientos por cuadrícula.	207
Figura III-4. Curvas ROC de los modelos MaxEnt de junio a septiembre de 2019.	208
Figura III-5. Curvas de respuesta de las principales variables ambientales que influyen en la probabilidad prevista de presencia de medusas de junio a septiembre de 2019. Cada panel muestra la respuesta de una variable específica a lo largo de los cuatro meses estudiados. Las líneas rojas representan junio, las azules julio, las verdes agosto y las negras septiembre.	211
Figura III-6. Mapas de probabilidad de aparición de medusas predichos por MaxEnt de junio a septiembre de 2019 para la costa mediterránea andaluza.	212
Figura III-7. Superposición de áreas de baja probabilidad predichas por MaxEnt y áreas de alta densidad de ausencia observadas para cada mes. La columna de la izquierda representa las zonas en las que el modelo MaxEnt predijo una baja probabilidad de presencia de medusas (rojo). La columna central muestra las zonas con alta densidad de ausencia observada según los informes de los usuarios de Infomedusa (azul). La columna de la derecha destaca el solapamiento espacial entre ambos conjuntos de datos, donde las predicciones de baja probabilidad de MaxEnt coinciden con altas densidades de ausencia observadas (verde). La zona costera del área de estudio se muestra en blanco, mientras que las aguas mar adentro se representan en azul claro.	213
Figura IV-1. Ubicación de las principales ciudades que agrupan los conjuntos de playas. Los colores de los marcadores reflejan la pertenencia a cada conjunto de playas: Conjunto 1 (azul), playas de la ciudad de Málaga; Conjunto 2 (gris), playas de Nerja a Rincón de la Victoria; Conjunto 3 (verde), playas de Torremolinos a Fuengirola; Conjunto 4 (rojo), playas de Marbella; Conjunto 5 (amarillo), playas de Manilva a Estepona. Asimismo, se muestran los límites de la Costa del Sol al oeste (La Línea de la Concepción) y al este (Maro-Cerro Gordo). Las líneas punteadas en azul, rojo y verde representan respectivamente la Costa del Sol Occidental, la Costa del Sol Oriental y la zona de la capital.	247
Figura IV-2. Funciones de pertenencia para los conjuntos difusos “Escaso” (línea verde), “Moderado” (línea azul) y “Abundante” (línea roja) en función del número diario de medusas (eje X). El eje Y representa el grado de pertenencia.	253
Figura IV-3. Ejemplo de regla difusa gráfica <i>IF-THEN</i> (SI-Entonces).	255

Figura IV-4. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 1 de playas, correspondiente a las playas de la ciudad de Málaga.	259
Figura IV-5. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 1 de playas.	260
Figura IV-6. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada <i>et al.</i> (2021) correspondientes al Conjunto 1 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la presencia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h). Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).	261
Figura IV-7. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 2 de playas, correspondiente a las playas comprendidas entre Nerja y Rincón de la Victoria.	262
Figura IV-8. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 2 de playas.	263
Figura IV-9. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada <i>et al.</i> (2021) correspondientes al Conjunto 2 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la abundancia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h). Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).	263
Figura IV-10. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 3 de playas, correspondiente a las playas comprendidas entre Torremolinos y Fuengirola.	265
Figura IV-11. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 3 de playas.	266
Figura IV-12. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada <i>et al.</i> (2021) correspondientes al Conjunto 3 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la abundancia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h). Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).	266
Figura IV-13. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 4 de playas, correspondiente a las playas de Marbella.	268
Figura IV-14. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 4 de playas.	269
Figura IV-15. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada <i>et al.</i> (2021) correspondientes al Conjunto 4 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la abundancia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h).	

Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).....	269
Figura IV-16. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 5 de playas, correspondiente a las playas comprendidas entre Manilva y Estepona.	271
Figura IV-17. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 5 de playas.	272
Figura IV-18. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada <i>et al.</i> (2021) correspondientes al Conjunto 5 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la abundancia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h). Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).....	272



RESUMEN

RESUMEN

En la presente Tesis Doctoral se ha llevado a cabo un análisis integral sobre las proliferaciones de medusas en la costa andaluza mediterránea a partir de datos de ciencia ciudadana no dirigida y técnicas de inteligencia artificial y modelización ecológica.

El primer capítulo ofrece una revisión del conocimiento científico disponible sobre las medusas en el mar de Alborán, con especial atención a la especie *Pelagia noctiluca*, centrándose en los principales aspectos biológicos y ecológicos, los factores que influyen en sus eventos de aparición, así como en los impactos ecológicos y socioeconómicos que generan.

El segundo capítulo aplica redes neuronales artificiales Perceptrón Multicapa, para clasificar automáticamente los comentarios de los usuarios de la aplicación móvil Infomedusa con información sobre presencia o ausencia de medusas durante 2019. En estos análisis se alcanzó una precisión del 96% en la clasificación, destacando la efectividad del aprendizaje automático en el procesamiento de comentarios basados en lenguaje natural procedentes de ciencia ciudadana.

En el tercer capítulo se utiliza el modelo de distribución de especies MaxEnt para predecir las zonas con mayor y menor probabilidad de presencia de medusas, combinando los reportes de los ciudadanos con variables ambientales con y sin desfase temporal. Los resultados muestran que la profundidad de la capa de mezcla en abril es el factor ambiental más determinante, con contribuciones superiores al 70%.

En el cuarto capítulo se evalúa la utilidad de la lógica difusa como herramienta de inteligencia artificial explicable para modelar la aparición de enjambres de medusas en las playas de la Costa del Sol analizando el efecto a corto plazo de la dirección y velocidad del viento. Los resultados muestran que los vientos perpendiculares favorecen los varamientos en la zona centro-oriental, mientras que los paralelos lo hacen en la zona occidental, ofreciendo una base sólida para una gestión costera adaptativa.

En conjunto, los hallazgos presentados ofrecen un punto de partida para el diseño de sistemas de monitoreo más robustos y estrategias de gestión que integren la variabilidad ambiental y la participación ciudadana en la planificación costera.

Palabras clave: Medusas; Ciencia ciudadana; Redes Neuronales Artificiales; MaxEnt; Lógica difusa; Mar de Alborán; Gestión costera adaptativa.



ABSTRACT

ABSTRACT

In the present Doctoral Thesis, a comprehensive analysis has been conducted on jellyfish proliferations along the Mediterranean coast of Andalusia, based on unstructured citizen science data and techniques from artificial intelligence and ecological modelling.

*The first chapter provides a review of the available scientific knowledge on jellyfish in the Alboran Sea, with particular emphasis on the species *Pelagia noctiluca*. It focuses on key biological and ecological aspects, the drivers influencing their appearance events, as well as the ecological and socio-economic impacts they cause.*

The second chapter applies Multilayer Perceptron artificial neural networks to automatically classify user comments from the mobile application Infomedusa containing information on jellyfish presence or absence during 2019. These analyses achieved a classification accuracy of 96%, highlighting the effectiveness of machine learning in processing natural language-based comments derived from citizen science.

The third chapter employs the MaxEnt species distribution model to predict areas with higher and lower probabilities of jellyfish presence, combining citizen reports with environmental variables both with and without time lag. Results indicate that the depth of the mixed layer in April is the most influential environmental factor, contributing to over 70%.

The fourth chapter assesses the usefulness of fuzzy logic as an explainable artificial intelligence tool to model the occurrence of jellyfish swarms on the beaches of the Costa del Sol, analysing the short-term effects of wind direction and speed. The results show that perpendicular winds favour strandings in the central-eastern area, while parallel winds do so in the western area, providing a solid foundation for adaptive coastal management.

Taken together, the findings presented offer a starting point for the design of more robust monitoring systems and management strategies that integrate environmental variability and citizen engagement in coastal planning.

Keywords: *Jellyfish; Citizen science; Artificial Neural Networks; MaxEnt; Fuzzy logic; Alboran Sea; Adaptive coastal management.*



INTRODUCCIÓN GENERAL

El mar de Alborán

El nombre del mar Mediterráneo, derivado del latín *Mare medi terraneum*, se traduce como “mar en medio de la tierra”, reflejando perfectamente su posición geográfica. Esta cuenca se erige como el mar cerrado más grande (con 2.969.000 kilómetros cuadrados) y profundo del planeta (con una profundidad media de 1.460 metros y un máximo de 5.267 metros).

El mar Mediterráneo, situado entre tres continentes, Europa, Asia y África, ha sido central en la historia de la civilización humana. Se caracteriza por sus singulares condiciones oceanográficas (Coll *et al.*, 2010), que funcionan como una cuenca de concentración. En su extremo más occidental, delimitado entre el estrecho de Gibraltar y una línea imaginaria que une Almería (España) y Orán (Argelia), se encuentra el mar de Alborán, una región especialmente dinámica debido al intercambio constante de aguas entre el océano Atlántico y el mar Mediterráneo. Esta región está influenciada por tres masas de agua principales (Sánchez-Garrido y Nadal, 2022): dos de origen atlántico (el agua superficial atlántica y el agua central del Atlántico norte), que pueden distinguirse en su extremo occidental; y por aguas mediterráneas más cálidas y salinas que se forman en las cuencas del Mediterráneo occidental y oriental. La formación y circulación de estas masas de agua son resultado de las condiciones climáticas regionales a lo largo de diferentes áreas del Mediterráneo (Pinardi y Masetti, 2000).

Desde un punto de vista ecológico, el mar de Alborán se considera un punto caliente de biodiversidad, albergando una gran variedad de vida marina. Sus aguas son el hogar de miles de especies, algunas endémicas que no se encuentran en ninguna otra parte del mundo (Báez *et al.*, 2021). Como muchas otras zonas del Mediterráneo, el mar de Alborán enfrenta múltiples desafíos, incluidos problemas ambientales como la contaminación, la sobrepesca y los impactos del cambio climático (Coll *et al.*, 2010), que ponen en riesgo tanto sus ecosistemas marinos como los medios de subsistencia de poblaciones vinculadas a la costa (Valdés *et al.*, 2021).

Los afloramientos de medusas: amenaza ecológica y socioeconómica

Entre estas amenazas, una de particular relevancia es el incremento en la frecuencia y la magnitud de las proliferaciones de medusas durante los últimos dos siglos (Purcell *et al.*, 2007; Brotz y Pauly, 2012; Condon *et al.*, 2012). Estas proliferaciones suelen corresponder especialmente a la especie más destacada en el Mediterráneo, la medusa clavel *Pelagia noctiluca* (Forsskål, 1775) (Brotz y Pauly, 2012). Estudios previos han mostrado una periodicidad de 12 años en la aparición de enjambres de esta especie (Goy *et al.*, 1989). Sin embargo, investigaciones más recientes señalan que, desde la década de 1990, este patrón ha cambiado, siendo en la actualidad las proliferaciones de medusas prácticamente anuales (La Spada *et al.*, 2002; Daly Yahia *et al.*, 2010; Kogovšek *et al.*, 2010; Licandro *et al.*, 2010). Aun así, algunos estudios matizan la visión de un incremento generalizado de estos afloramientos, indicando que la escasez de datos históricos y la interacción de múltiples factores ecológicos complican su confirmación (Fernández-Álías *et al.*, 2024).

Estos eventos no solo afectan a la biodiversidad y la salud de los ecosistemas marinos, sino que también tienen importantes implicaciones socioeconómicas (Ghermandi *et al.*, 2015; Nunes *et al.*, 2015; Mghili *et al.*, 2022a, b). Las medusas, al proliferar en grandes cantidades, pueden perjudicar a las actividades pesqueras y turísticas, afectando así la economía de las comunidades costeras. Además, su presencia masiva puede ser un indicador de desequilibrios ecológicos subyacentes en el mar de Alborán (Mills, 2001). En estos casos, la ausencia de depredadores naturales de medusas, frecuentemente a causa de actividades humanas, ha sido un factor clave que contribuye a dichos desequilibrios (Lynam *et al.*, 2006; Richardson *et al.*, 2009; Purcell, 2012).

La costa andaluza y la presencia de medusas

Al norte del mar de Alborán se encuentra la costa mediterránea andaluza. El crecimiento económico de Andalucía ha tenido como pilar fundamental su relación con el mar, especialmente a través de la pesca y el turismo. Desde tiempos remotos, la actividad pesquera ha marcado la cultura, la economía y la identidad de las comunidades costeras andaluzas. Con el paso de los siglos, la pesca pasó a ser considerada patrimonio cultural, abarcando tanto bienes materiales (por ejemplo, embarcaciones o utensilios), como

manifestaciones inmateriales, entre ellas celebraciones y costumbres ligadas al oficio. Por otro lado, el turismo ha contribuido a diversificar y reforzar la relevancia económica de la pesca. Muchas localidades costeras han apostado por rutas turísticas que giran en torno al legado pesquero, de modo que visitantes de diferentes orígenes pueden descubrir las tradiciones marineras, probar la gastronomía local y participar en distintas actividades culturales relacionadas con el mar. Al valorar y promocionar este acervo cultural, el patrimonio pesquero se convierte en un recurso económico sostenible, logrando armonizar la protección de la herencia cultural con el progreso de la región (Jiménez de Madariaga, 2016).

No obstante, la pesca y el turismo tienen relevancias económicas muy diferentes en el conjunto del Producto Interior Bruto (PIB) de Andalucía. Aunque el sector pesquero es clave para el sostenimiento de las comunidades costeras, su aportación al PIB es proporcionalmente menor que la del turismo, que en los últimos años roza anualmente en torno al 13% de la economía andaluza, salvo en 2020, cuando descendió notablemente en el contexto de la pandemia del COVID-19. Por su parte, la pesca suele mantener una contribución muy estable, próxima al 0,2%. En la Tabla 0-1 se muestra la serie histórica de la contribución de ambos sectores al PIB andaluz durante los años 2013-2023, obtenida a partir de datos de la Consejería de Turismo, Regeneración, Justicia y Administración Local y de la Consejería de Agricultura, Pesca, Agua y Desarrollo Rural.

Tabla 0-1. *Evolución de la contribución relativa de la pesca y el turismo al Producto Interior Bruto (PIB) de la Comunidad Autónoma de Andalucía (2013-2023). Fuente: Consejería de Turismo, Regeneración, Justicia y Administración Local; y Consejería de Agricultura, Pesca, Agua y Desarrollo Rural.*

Año	Pesca (% del PIB)	Turismo (% del PIB)
2013	0,208	12,8
2014	0,212	12,6
2015	0,216	13,1
2016	0,232	13,9
2017	0,234	12,8
2018	0,227	12,6
2019	0,241	13,1
2020	0,251	5,4
2021	0,277	6,5
2022	0,280	9,0
2023	0,281	10,1

Concretamente, el turismo de sol y playa (también conocido como turismo 3S) constituye un pilar esencial de la economía andaluza, donde una parte considerable de los visitantes busca sol, mar y arena (*Sun, Sea and Sand*) (Bernier *et al.*, 2014; Tugcu, 2014). Sin embargo, las proliferaciones de medusas pueden llegar a reducir las visitas turísticas y ocasionar pérdidas millonarias en este sector recreativo (Ghermandi *et al.*, 2015). En el caso de la Costa del Sol, por ejemplo, se han reportado miles de picaduras en temporadas veraniegas, lo que ha forzado a cerrar playas temporalmente y a desplegar redes o planes nacionales de acción para contener el problema (Purcell *et al.*, 2007; Ghermandi *et al.*, 2015). Estos eventos no solo afectan a la imagen turística del destino, sino que también incrementan los costes en personal de vigilancia, primeros auxilios e infraestructura de protección. Por otro lado, la reciente proliferación de la macroalga invasora *Rugulopteryx okamurae* supone un problema similar, ya que obliga a realizar costosas tareas de retirada y limpieza de playas, afectando igualmente la experiencia y la satisfacción del visitante (García-Gómez *et al.*, 2020; Moreno-Ostos *et al.*, 2021; Figueroa *et al.*, 2025). Aunque una comunicación de riesgos clara y estrategias de mitigación pueden disminuir la percepción negativa de los visitantes, el riesgo real y potencial de encontrar medusas (o algas invasoras) sigue influyendo en la elección de destino y la satisfacción de los turistas, con implicaciones para la economía local tanto a corto como a largo plazo.

Históricamente, la investigación sobre distribución de poblaciones de medusas en el mar Mediterráneo ha sido limitada, lo que refleja una tendencia general a subestimar su importancia en los estudios marinos. Esta omisión se debe en gran medida a dificultades metodológicas y a la percepción de las medusas como elementos secundarios en los ecosistemas marinos (Brotz *et al.*, 2012). Si se pretende preservar la salud a largo plazo de este ecosistema marino y garantizar la seguridad de sus usuarios, es necesario comprender mejor los procesos que desencadenan estos eventos de aparición, así como desarrollar estrategias efectivas para predecir su ocurrencia y mitigar sus impactos.

Ciencia ciudadana ante la escasez de datos

La participación ciudadana en la recopilación de datos ofrece una valiosa oportunidad para cubrir extensas zonas costeras que sería costoso o poco práctico vigilar mediante programas o campañas científicas (Marambio *et al.*, 2021). Las iniciativas de ciencia ciudadana se han convertido en una herramienta esencial para el seguimiento de las poblaciones de medusas, aprovechando la participación colectiva del público para recopilar datos valiosos sobre vastas zonas marinas. Este enfoque colaborativo no sólo democratiza el proceso de investigación científica, sino que también amplía significativamente el alcance y la escala de las observaciones, permitiendo la captura en tiempo real de las fluctuaciones en las poblaciones de medusas y sus patrones de distribución (Dobson *et al.*, 2023).

En Andalucía, un ejemplo de participación ciudadana en la ciencia marina relacionada con las medusas es el trabajo llevado a cabo por la Fundación Aula del Mar Mediterráneo (anteriormente Aula del Mar de Málaga), una entidad dedicada a la conservación, investigación y divulgación del medio marino. En 2013, junto con la Diputación de Málaga, crearon la aplicación móvil para teléfonos inteligentes “Infomedusa”, que permite a la ciudadanía reportar avistamientos de medusas en tiempo real. Con esta herramienta, la población puede no solo compartir información sobre la presencia y abundancia de medusas en diferentes puntos de la costa, sino también intercambiar experiencias e información sobre el estado de las playas. Sin embargo, la primera versión de la aplicación Infomedusa funcionaba como un foro abierto en el que los usuarios, además de informar sobre la presencia de medusas, compartían comentarios relacionados con las condiciones de la playa y otros aspectos de su experiencia en la playa, por lo que puede ser considerada una aplicación móvil no dirigida a ciencia ciudadana.

La convergencia de la ciencia de datos con técnicas incluidas dentro del campo de la Inteligencia Artificial (IA) como el aprendizaje profundo (*Deep learning*) ofrecen herramientas para manejar el gran volumen y la diversidad de comentarios generados en plataformas como Infomedusa. Estas herramientas permiten procesar, filtrar y clasificar automáticamente menciones específicas sobre medusas (Tang *et al.*, 2015; Young *et al.*, 2018). Con la ayuda de algoritmos de procesamiento del lenguaje natural y redes neuronales computacionales, es posible extraer información relevante de textos

heterogéneos y a gran escala (Zhang, 2000; Hovy, 2022; Mukhamediev *et al.*, 2022), lo que contribuye a convertir un foro abierto y no dirigido a la obtención de datos científicos en una fuente valiosa de información. Estas soluciones basadas en IA y ciencia de datos sientan las bases para un análisis más eficiente y robusto que refuerza la utilidad de la ciencia ciudadana en la investigación de medusas.

Asimismo, comprender la compleja relación entre las medusas y el medio ambiente es crucial para entender, predecir, y gestionar a tiempo las posibles proliferaciones de medusas en las zonas costeras. Se ha demostrado que la presencia de medusas en las costas está influida por diversos factores ambientales (Purcell, 2005; Canepa *et al.*, 2014), destacando especialmente aquellos relacionados con condiciones físicas y fisicoquímicas del ambiente marino, y la influencia del viento a nivel regional, que afecta el transporte y la acumulación de estos organismos cerca de la costa. Por lo tanto, una mejor comprensión de los efectos combinados de las variables ambientales sobre los afloramientos de medusas puede contribuir a unas estrategias de gestión y mitigación más eficaces para hacer frente a su impacto sobre los ecosistemas costeros y las actividades humanas.

De esta forma, en la presente Tesis Doctoral se propone abordar la monitorización de medusas desde enfoques complementarios que integran ciencia ciudadana e inteligencia artificial, con el fin de mejorar la comprensión y la gestión de estas proliferaciones. Para ello, en el Capítulo I se ofrece una revisión bibliográfica detallada sobre la biología, ecología y el impacto socioeconómico de las medusas, así como de las metodologías de gestión más destacadas. En el Capítulo II, se emplean técnicas de aprendizaje profundo para el análisis automático de comentarios procedentes de la aplicación Infomedusa, optimizando la extracción de información relativa a la presencia de medusas. El Capítulo III aplica modelos de distribución de especies MaxEnt que incorporan variables ambientales para tratar de entender cuáles tienen una mayor influencia en la presencia de enjambres de estos organismos, mientras que el Capítulo IV introduce un sistema basado en lógica difusa que aporta una visión explicable y más interpretable de la dinámica de aparición a corto plazo de las medusas en las costas. Con ello, se ofrece un marco integral que combina la participación ciudadana con herramientas avanzadas de ciencia de datos para la gestión y el estudio de las medusas en la costa andaluza.

Referencias

- Báez, J. C., Camiñas, J. A., Vázquez, J. T., Malouli Idrissi, M. 2021. Introduction: Thinking the Future from Now. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli Idrissi (Eds.), *Alboran Sea-Ecosystems and Marine Resources* (pp. 1-10). Springer International Publishing.
- Bernier, E. T., Sánchez, R. R., Díaz, B. R. 2014. La crisis económica en el sector turístico. Un análisis de sus efectos en la Costa del Sol. *Revista de análisis turístico* 18, 11-18.
- Brotz, L., Cheung, W. W. L., Kleisner, K., Pakhomov, E., Pauly, D. 2012. Increasing jellyfish populations: trends in large marine ecosystems. *Hydrobiologia* 690(1), 3-20.
- Brotz, L., Pauly, D. 2012. Jellyfish populations in the Mediterranean Sea. *Acta Adriatica* 53(2), 213-232.
- Canepa, A., Fuentes, V., Sabatés, A., Piraino, S., Boero, F., Gili, J. M. 2014. *Pelagia noctiluca* in the Mediterranean Sea. En K. Pitt, C. Lucas (Eds.), *Jellyfish blooms* (pp. 237-266). Springer.
- Coll, M., Piroddi, C., Steenbeek, J., Kaschner, K., Ben Rais Lasram, F., Aguzzi, J., Ballesteros, E., Bianchi, C. N., Corbera, J., Dailianis, T., Danovaro, R., Estrada, M., Frogalia, C., Galil, B. S., Gasol, J. M., Gertwagen, R., Gil, J., Guilhaumon, F., Kesner-Reyes, K., Kitsos, M.-S., Koukouras, A., Lampadariou, N., Laxamana, E., López-Fe de la Cuadra, C. M., Lotze, H. K., Martin, D., Mouillot, D., Oro, D., Raicevich, S., Rius-Barile, J., Saiz-Salinas, J. I., San Vicente, C., Somot, S., Templado, J., Turon, X., Vafidis, D., Villanueva, R., Voultsiadou, E. 2010. The biodiversity of the Mediterranean Sea: estimates, patterns, and threats. *PLoS ONE* 5(8), e11842.
- Condon, R. H., Graham, W. M., Duarte, C. M., Pitt, K. A., Lucas, C. H., Haddock, S. H. D., Sutherland, K. R., Robinson, K. L., Dawson, M. N., Decker, M. B., Mills, C. E., Purcell, J. E., Malej, A., Mianzan, H., Uye, S., Gelcich, S., Madin, L. P. 2012. Questioning the rise of gelatinous zooplankton in the world's oceans. *Bioscience* 62(2), 160-169.

- Daly-Yahia, M. N., Batistić, M., Lučić, D., Fernández De Puellas, M. L., Licandro, P., Malej, A., Molinero, J. C., Siokou-Frangou, I., Zervoudaki, S., Prieto, L., Goy, J., Yahia-Kéfi, O. D. 2010. Are the outbreaks of *Pelagia noctiluca* more frequent in the Mediterranean basin? *ICES Cooperative Research Report* 300, 8-14.
- Dobson, J. Y., Fonfría, E. S., Palacios, R., Blasco, E., Bordehore, C. 2023. Citizen science effectively monitors biogeographical and phenological patterns of jellyfish. *Ocean & Coastal Management* 242, 106668.
- Fernández-Álías, A., Marcos, C., Pérez-Ruzafa, A. 2024. The unpredictability of scyphozoan jellyfish blooms. *Frontiers in Marine Science* 11, 1349956.
- Figuerola, F. L., Vega, J., Flórez-Fernández, N., Mazón, J., Torres, M. D., Domínguez, H., Pereira, L. 2025. Challenges and opportunities of the exotic invasive macroalga *Rugulopteryx okamurae* (Phaeophyceae, Heterokontophyta). *Journal of Applied Phycology*, 1-17.
- García-Gómez, J. C., Sempere-Valverde, J., González, A. R., Martínez-Chacón, M., Olaya-Ponzone, L., Sánchez-Moyano, E., Ostalé-Valriberas, E., Megina, C. 2020. From exotic to invasive in record time: The extreme impact of *Rugulopteryx okamurae* (Dictyotales, Ochrophyta) in the strait of Gibraltar. *Science of the Total Environment* 704, 135408.
- Ghermandi, A., Galil, B., Gowdy, J., Nunes, P. A. 2015. Jellyfish outbreak impacts on recreation in the Mediterranean Sea: welfare estimates from a socioeconomic pilot survey in Israel. *Ecosystem services* 11, 140-147.
- Goy, J., Morand, P., Etienne, M. 1989. Long-term fluctuations of *Pelagia noctiluca* (Cnidaria, Scyphomedusa) in the western Mediterranean Sea. Prediction by climatic variables. *Deep Sea Research* 36(2), 269-279.
- Hovy, D. 2022. *Text analysis in Python for social scientists: prediction and classification*. Cambridge University Press.
- Jiménez de Madariaga, C. 2016. Pesca, cultura y turismo. En *Cultura y pesca: actas de las I Jornadas de Patrimonio Cultural Pesquero* (pp. 17-33). Universidad de Huelva.

- Kogovšek, T., Bogunović, B., Malej, A. 2010. Recurrence of bloom-forming scyphomedusae: wavelet analysis of a 200-year time series. En J. E. Purcell, D. L. Angel (Eds.), *Jellyfish Blooms: New Problems and Solutions*. Springer.
- La Spada, G., Marino, A., Sorrenti, G. 2002. *Pelagia noctiluca* “Blooming” in the Strait of Messina: preliminary studies on the applicability of two methods for isolating nematocytes. *Marine Ecology* 23(1), 220-227.
- Licandro, P., Conway, D. V. P., Daly-Yahia, M. N., Fernandez de Puellas, M. L., Gasparini, S., Hecq, J. H., Tranter, P., Kirby, R. R. 2010. A blooming jellyfish in the northeast Atlantic and Mediterranean. *Biology letters* 6(5), 688-691.
- Lynam, C. P., Gibbons, M. J., Axelsen, B. E., Sparks, C. A., Coetzee, J., Heywood, B. G., Brierley, A. S. 2006. Jellyfish overtake fish in a heavily fished ecosystem. *Current Biology* 16(13), R492-R493.
- Marambio, M., Canepa, A., Lòpez, L., Gauci, A. A., Gueroun, S. K., Zampardi, S., Boero, F., Kéfi-Daly Yahia, O., Daly Yahia, M. N., Fuentes, V., Deidun, A. 2021. Unfolding jellyfish bloom dynamics along the Mediterranean basin by transnational citizen science initiatives. *Diversity* 13(6), 274.
- Mghili, B., Analla, M., Aksissou, M. 2022a. Medusae (Scyphozoa and hydrozoa) from the Moroccan Mediterranean coast: abundance and spatiotemporal dynamics and their economic impact. *Aquatic Ecology* 56(1), 213-226.
- Mghili, B., Analla, M., Aksissou, M. 2022b. Estimating the economic damage caused by jellyfish to fisheries in Morocco. *African Journal of Marine Science* 44(3), 271-277.
- Mills, C. E. 2001. Jellyfish blooms: are populations increasing globally in response to changing ocean conditions? *Hydrobiologia* 451, 55-68.
- Moreno-Ostos, E., Figueroa, F. L., Mercado, J., Castillo, P. S., Bañares, E., Franco, F. I., Recuna, M., Noriega, J., Alarcón, F. 2021. Un esfuerzo de integración para contribuir a la gestión de la invasión del alga *Rugulopteryx okamurae* en las costas de Andalucía: el Foro Alga Invasora. *Ecosistemas* 30(1), 2132-2132.
- Mukhamediev, R. I., Popova, Y., Kuchin, Y., Zaitseva, E., Kalimoldayev, A., Symagulov, A., Levashenko, V., Abdoldina, F., Gopejenko, V., Yakunin, K., Muhamedijeva,

- E., Yelis, M. 2022. Review of Artificial Intelligence and Machine Learning Technologies: Classification, Restrictions, Opportunities and Challenges. *Mathematics* 10(15), 2552.
- Nunes, P. A., Loureiro, M. L., Piñol, L., Sastre, S., Voltaire, L., Canepa, A. 2015. Analyzing beach recreationists' preferences for the reduction of jellyfish blooms: Economic results from a stated-choice experiment in Catalonia, Spain. *PLoS ONE* 10(6), e0126681.
- Pinardi, N., Masetti, E. 2000. Variability of the large scale general circulation of the Mediterranean Sea from observations and modelling: a review. *Palaeogeography, Palaeoclimatology, Palaeoecology* 158(3-4), 153-173.
- Purcell, J. E. 2005. Climate effects on formation of jellyfish and ctenophore blooms: a review. *Journal of the Marine Biological Association of the United Kingdom* 85(3), 461-476.
- Purcell, J. E. 2012. Jellyfish and ctenophore blooms coincide with human proliferations and environmental perturbations. *Annual Review of Marine Science* 4(1), 209-235.
- Purcell, J. E., Uye, S.-I., Wen-Tseng, L. 2007. Anthropogenic causes of jellyfish blooms and their direct consequences for humans: a review. *Marine Ecology Progress Series* 350, 153-174.
- Richardson, A. J., Bakun, A., Hays, G. C., Gibbons, M. J. 2009. The jellyfish joyride: causes, consequences and management responses to a more gelatinous future. *Trends in Ecology & Evolution* 24(6), 312-322.
- Sanchez-Garrido, J. C., Nadal, I. 2022. The Alboran Sea circulation and its biological response: A review. *Frontiers in Marine Science* 9, 933390.
- Tang, D., Qin, B., Liu, T. 2015. Document modeling with gated recurrent neural network for sentiment classification. En *Proceedings of the 2015 conference on empirical methods in natural language processing* (pp. 1422-1432). Association of Computational Linguistics.

- Tugcu, C. T. 2014. Tourism and economic growth nexus revisited: A panel causality analysis for the case of the Mediterranean Region. *Tourism Management* 42, 207-212.
- Valdés, L., Camiñas, J. A., Suárez-de Vivero, J. L., Báez, J. C. 2021. Sustainable development and Blue growth in the Alboran Sea: enabling ocean health and ecosystem services through ocean science and equitable governance. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli Idrissi (Eds.), *Alboran Sea-Ecosystems and Marine Resources* (pp. 797-818). Springer International Publishing.
- Young, T., Hazarika, D., Poria, S., Cambria, E. 2018. Recent trends in deep learning based natural language processing. *IEEE Computational Intelligence Magazine* 13(3), 55-75.
- Zhang, G. P. 2000. Neural networks for classification: a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 30(4), 451-462.



HIPÓTESIS DE PARTIDA Y OBJETIVOS

HIPÓTESIS DE PARTIDA Y OBJETIVOS

Se considera como hipótesis de partida de la presente Tesis Doctoral que la proliferación de medusas en la costa andaluza está fuertemente condicionada por factores ambientales. Además, se prevé que la integración de datos aportados por la ciudadanía y el uso de técnicas de modelado avanzado permite modelar de forma eficaz la aparición de estas proliferaciones, contribuyendo de manera significativa a la gestión y mitigación de sus impactos.

Así, el objetivo principal de esta Tesis Doctoral consiste en evaluar y modelizar la influencia de diversos factores ambientales en la dinámica poblacional de las medusas a corto y medio plazo, empleando metodologías que combinen aportaciones de la ciencia ciudadana con enfoques de modelaje basados en inteligencia artificial. De esta forma, se busca proporcionar herramientas que faciliten una gestión costera sostenible y efectiva ante futuros escenarios de variabilidad climática.

Para lograr este objetivo principal, se establecen los siguientes objetivos específicos (OE):

- OE 1. Realizar una revisión exhaustiva de la literatura científica relacionada con la ecología de las medusas y su papel en los ecosistemas marinos del norte del mar de Alborán, abordando sus posibles impactos sociales y económicos en el área de estudio.
- OE 2. Desarrollar y validar un sistema de clasificación de comentarios de usuarios basado en técnicas de aprendizaje automático, tomando como insumo los datos procedentes de aplicaciones de ciencia ciudadana, así como relacionar la información de estos comentarios con variables ambientales locales para entender la influencia de estos sobre la presencia de medusas.
- OE 3. Aplicar modelos de distribución de especies basados en el principio de máxima entropía que integren información ambiental satelital (con y sin desfase temporal), con objeto de identificar las zonas con mayor probabilidad de sufrir proliferaciones de medusas en base a determinadas condiciones oceanográficas.
- OE 4. Implementar un sistema explicable basado en lógica difusa, capaz de estimar la abundancia relativa de medusas y de ofrecer un sistema de alerta temprana para la toma de decisiones a corto plazo en la gestión costera.

A faint, light gray illustration of a jellyfish is centered in the background. It has a rounded, bell-shaped top and several long, thin, wavy tentacles hanging down. The illustration is positioned behind the title text.


JUSTIFICACIÓN E INNOVACIÓN DE LA TESIS DOCTORAL

JUSTIFICACIÓN E INNOVACIÓN DE LA TESIS DOCTORAL

El papel creciente de las medusas en los ecosistemas costeros, junto con su notable impacto socioeconómico, hace urgente el desarrollo de metodologías que permitan comprender, anticipar y gestionar la aparición de sus proliferaciones. Aún existe controversia en cuanto a los factores que influyen en la aparición de enjambres de estos organismos, pero cada vez se acumulan más evidencias de que la aparición y persistencia de afloramientos de medusas dependen de múltiples variables ambientales (viento, corrientes, temperatura, etc.). La profundización en el estudio de la dinámica de poblaciones de medusas está limitada por la escasez de datos históricos de estos organismos. Esta carencia de información se explica, en gran medida, porque históricamente las medusas han sido consideradas componentes secundarios en los programas de monitoreo, de modo que su presencia solía pasar inadvertida o no se registraba de manera sistemática. Como consecuencia, los datos disponibles suelen ser fragmentarios y dispersos, dificultando el análisis de su dinámica poblacional a lo largo del tiempo.

Este panorama justifica la necesidad de una Tesis Doctoral que integre enfoques novedosos para el análisis de datos ambientales y biológicos, aprovechando asimismo la participación ciudadana. La recolección de información masiva a través de aplicaciones móviles abre nuevas vías para recabar datos de manera continua y a bajo coste, posibilitando la monitorización en tiempo real de las costas. Sin embargo, dichas fuentes generan volúmenes de datos heterogéneos que requieren técnicas analíticas robustas. Por ello, el empleo de metodologías basadas en la Inteligencia Artificial y de modelos de distribución de especies ofrece la capacidad de procesar, sintetizar y modelar de forma eficaz estos grandes conjuntos de información.

El carácter innovador de esta investigación radica, por tanto, en conjugar la ciencia ciudadana con enfoques computacionales avanzados, para así aislar e identificar los principales factores que impulsan los afloramientos de medusas. Este tipo de estrategia no solo impulsa la elaboración de escenarios predictivos más precisos, sino que también contribuye a generar herramientas de gestión y alerta temprana orientadas a la toma de decisiones en un contexto de creciente variabilidad ambiental y climática. De este modo, la Tesis Doctoral se convierte en un aporte valioso tanto para la investigación básica en ecología marina como para la planificación y la gobernanza costera a diferentes escalas.



CAPÍTULO I

ESTADO DEL ARTE DEL ESTUDIO DE
MEDUSAS EN EL MAR DE ALBORÁN:
BIOLOGÍA, ECOLOGÍA, IMPACTOS
SOCIOECONÓMICOS Y AVANCES EN
SU ESTUDIO

Resumen

Esta revisión sintetiza el conocimiento actual sobre la ecología de las medusas y sus impactos socioeconómicos en el mar de Alborán, ofreciendo una visión general de los principales factores que impulsan las proliferaciones de medusas y los retos que suponen para las comunidades costeras. Comienza contextualizando el mar de Alborán como una zona de transición entre el Atlántico y el Mediterráneo, destacando los principales taxones de medusas, en particular *Pelagia noctiluca*, e identificando una persistente carencia de metodologías de monitoreo estandarizadas a largo plazo. La revisión de la literatura examina los factores ambientales (por ejemplo, temperatura, salinidad, características oceanográficas) y antrópicos (como la sobrepesca, la eutrofización y el cambio climático) implicados en la dinámica de las floraciones, así como el papel trófico que desempeñan las medusas dentro de las redes alimentarias marinas.

Desde el punto de vista metodológico, este estudio combina una evaluación exhaustiva de publicaciones científicas revisadas por pares, informes de proyectos y estudios de caso de distintas regiones del Mediterráneo, evaluando tanto técnicas clásicas de muestreo como enfoques emergentes como la teledetección y la ciencia ciudadana. Al integrar estos hallazgos, la revisión pone de manifiesto las importantes repercusiones socioeconómicas de las proliferaciones de medusas, que van desde pérdidas en pesca y acuicultura hasta impactos en el turismo y la salud pública.

La revisión concluye destacando futuras líneas de investigación, en particular el desarrollo de marcos de gestión adaptativa, la mejora de los protocolos de monitoreo y la exploración del potencial de las medusas como recurso. Asimismo, subraya la necesidad de adoptar un enfoque más coordinado y basado en el ecosistema para comprender y gestionar estas proliferaciones en el mar de Alborán.

Palabras clave: Enjambres de medusas; Factores ambientales; Factores antrópicos; Gestión ecosistémica; Mar de Alborán; Monitorización de medusas; *Pelagia noctiluca*.

Abstract

*This review synthesises current knowledge on jellyfish ecology and socio-economic impacts in the Alboran Sea, offering insights into key drivers of jellyfish proliferations and the challenges they pose to coastal communities. It begins by contextualising the Alboran Sea as a transition zone between the Atlantic and the Mediterranean, highlighting the main jellyfish taxa, particularly *Pelagia noctiluca*, and identifying a persistent gap in long-term, standardised monitoring methodologies. The literature review examines environmental (e.g. temperature, salinity, oceanographic features) and anthropogenic (e.g. overfishing, eutrophication, climate change) drivers implicated in bloom dynamics, as well as the trophic roles jellyfish fulfil within marine food webs.*

Methodologically, this study combines an extensive assessment of peer-reviewed publications, project reports, and case studies from different Mediterranean regions, evaluating both classical sampling techniques and emergent approaches such as remote sensing and citizen science. By integrating these findings, the review reveals the significant socio-economic repercussions of jellyfish blooms, ranging from fisheries and aquaculture losses to implications for tourism and public health.

The revision concludes by outlining future lines of research, particularly the development of adaptive management frameworks, refined monitoring protocols, and an exploration of jellyfish as a potential resource, and underscores the need for a more coordinated, ecosystem-based approach to understanding and managing these proliferations in the Alboran Sea.

Keywords: *Jellyfish blooms; Environmental drivers; Anthropogenic drivers; Ecosystem-based management; Alboran Sea; Jellyfish monitoring; *Pelagia noctiluca*.*

1.1. ¿Qué es una medusa?

Cuando los habitantes y visitantes de la costa andaluza piensan en una medusa, la imagen más frecuente suele ser la de *Pelagia noctiluca* (Forsskal, 1775) (Figura I-1). Esta especie, considerada la más habitual en el Mediterráneo occidental (Pastor-Prieto *et al.*, 2021; Gutiérrez-Hernández y Rubio Gómez, 2023), se avista con regularidad entre febrero y octubre, formando enjambres masivos de más de cien individuos por metro cúbico (Zavodnik, 1987; Malej, 1989). Dichos enjambres llegan a persistir durante días o semanas, con repercusiones en la salud pública, el turismo y otros sectores costeros. Para comprender estos fenómenos de aparición de estos organismos, es esencial comprender primero qué define a una medusa, sus rasgos morfológicos y sus ciclos de vida, para así poder situar el papel de *P. noctiluca* en un contexto más amplio del filo *Cnidaria*.



Figura I-1. Fotografía de la medusa clavel (*Pelagia noctiluca*), una especie de *Scyphozoa* caracterizada por su campana semitransparente con tonalidades rosadas y manchas violáceas. Sus tentáculos largos y urticantes, junto con los lóbulos orales franjeados, son rasgos distintivos que facilitan su identificación. Fotografía tomada por Juan Carlos Sáez.

Para hablar de medusas es fundamental comenzar situando estos organismos en el reino animal. Estos seres pertenecen al grupo del macrozooplancton gelatinoso, una categoría que abarca diversas formas de vida acuática con una característica en común: una consistencia predominantemente gelatinosa.

Pertenecientes al filo *Cnidaria*, las medusas poseen una historia evolutiva notablemente antigua, con registros fósiles que datan del Precámbrico, lo que las ubica entre los animales más antiguos que aún persisten en la Tierra. Aunque compartimos con ellas la presencia de una matriz extracelular, las medusas difieren significativamente de los vertebrados. Algunos cordados como los tunicados también forman parte del macrozooplancton gelatinoso, al igual que otros grupos, como los organismos del filo *Ctenophora* (o medusas peine). Todos estos grupos constituyen la mayor parte del macrozooplancton gelatinoso y, en conjunto, conforman lo que los angloparlantes definen como “*jellyfish*” (Boero, 2013).

1.1.1. Filo *Cnidaria*

El filo *Cnidaria* comprende más de 10.000 especies, incluyendo animales acuáticos como medusas, corales, anémonas de mar e hidras que se distribuyen por todo el mundo y han poblado los mares durante más de 500 millones de años (Durán-Fuentes *et al.*, 2018; Killi y Mariottini, 2018; WoRMS, 2023). Su nombre se debe a la presencia de unas células únicas llamadas “cnidocitos”. Estos cnidocitos se encuentran agrupados a lo largo de la superficie de los tentáculos y contienen un orgánulo capsular proteico conocido como nematocisto, que alberga veneno y un filamento hueco enrollado a modo de arpón, capaz de descargarse con aceleraciones extremadamente rápidas de hasta 5 millones de g¹ debido a presiones osmóticas muy elevadas (Purcell *et al.*, 2001; Nüchter *et al.*, 2006; Collins, 2009). La función principal de estas células es la protección y la captura de presas, aunque también pueden ser utilizadas para la locomoción (Tardent, 1978; Technau *et al.*, 2015). El nematocisto se extruye rápidamente tras activarse, proceso que se desencadena por una combinación de estímulos químicos y táctiles procedentes de la víctima (Purcell *et al.*, 2001), inyectando el veneno en la presa o el atacante (Mariottini y Pane, 2010). Si bien el nematocisto es el más conocido de estos orgánulos, existen otros tipos como los espirocistos y los ptiocistos, que difieren en la forma de la cápsula, el filamento y el estilete (Collins, 2009; Fautin, 2009; Technau *et al.*, 2015). El veneno de los cnidarios varía según la especie, pero generalmente está compuesto sobre todo por proteínas, péptidos y otras sustancias de interés farmacológico (Mariottini y Pane, 2010).

¹ La aceleración de descarga de los nematocistos ha sido medida mediante cámaras de ultra-alta velocidad, registrando valores de hasta 5,410,000 g en *Hydra* y otros cnidarios (Nüchter *et al.*, 2006).

Los cnidarios presentan dos formas morfológicas diferentes que pueden adoptar según la etapa de su ciclo de vida: la fase de pólipo, caracterizada por un estilo de vida sésil, y la fase de medusa, adaptada al desplazamiento mediante natación o flotación (Technau *et al.*, 2015). Algunos cnidarios exhiben ambas formas en su ciclo de vida, mientras que otros solo presentan una de ellas. Pueden encontrarse tanto en colonias como de forma solitaria, variando en tamaño desde formas microscópicas hasta grandes formaciones arrecifales y medusas de varios metros de diámetro con tentáculos que superan los 20 metros de longitud (Brusca *et al.*, 2016). Los cnidarios se separaron relativamente pronto en la historia evolutiva de los metazoos (Marques y Collins, 2004) y el filo se divide en varios clados (Figura I-2):




Figura I-2. Cladograma del filo Cnidaria, representando las relaciones filogenéticas entre sus clases principales y su relación con el grupo hermano Bilateria.

1. **Anthozoa**, que incluye corales, anémonas de mar y plumas de mar. Los miembros de *Anthozoa* son únicos porque solo presentan la fase de pólipo en su ciclo de vida y destacan por formar importantes estructuras arrecifales en los océanos. Los antozoos constituyen el grupo más numeroso entre los cnidarios, con al menos 7.200 especies descritas (Barbosa Santos *et al.*, 2020).
2. **Medusozoa**, que agrupa especies con una fase de medusa prominente en su ciclo de vida (Durán-Fuentes *et al.*, 2018). Este clado se subdivide, a su vez, en varios grupos: (i) **Scyphozoa**, comúnmente llamadas medusas verdaderas o típicas, se centran principalmente en la fase de medusa y se distinguen por su tamaño y morfología; (ii)

- Hydrozoa**, que incluye tanto la forma de medusa como la de pólipo, con ejemplos como las hidras y la carabela portuguesa (*Physalia physalis*); (iii) **Cubozoa**, conocidas como cubomedusas, famosas por sus picaduras sumamente venenosas; y (iv) **Staurozoa**, un grupo menos conocido que incluye medusas con forma de estrella.
3. El grupo **Myxozoa**, que inicialmente no se clasificaba dentro de los cnidarios y ha sido reubicado en este filo gracias a estudios genéticos recientes. Este grupo peculiar consiste principalmente en parásitos de peces y otros animales, tanto acuáticos como terrestres (Atkinson *et al.*, 2018).
 4. **Polypodiozoa**, un clado pequeño y parásito, conocido por infectar a determinados crustáceos (Novosolov *et al.*, 2022).

1.1.2. Características morfológicas

En el ámbito de los cnidarios, las medusas presentan una morfología altamente especializada y adaptada a la vida pelágica. En esta sección, se analizan las estructuras fundamentales de las medusas, que abarcan la umbrela, los tentáculos provistos de cnidocitos, la mesoglea, y las capas gastrodérmica y epidérmica (Figura I-3).




Figura I-3. Esquema del plan corporal de un pólipo (a la izquierda del lector) y de una medusa (a la derecha del lector), señalando y comparando algunas de sus estructuras corporales. Adaptado de Berzins *et al.* (2021).

Los cnidarios se caracterizan por ser organismos diblásticos, compuestos únicamente por dos capas celulares primarias: (i) el ectodermo, y (ii) el endodermo o gastrodermis. A diferencia de los organismos bilaterales, que desarrollan una tercera capa embrionaria denominada mesodermo, los cnidarios carecen de esta estructura. En estos organismos, tanto el ectodermo como el endodermo consisten en tejidos epiteliales monocapa que mantienen su estructura a lo largo de todo el desarrollo y ciclo de vida. Separando dichas capas embrionarias se encuentra la mesoglea, una sustancia gelatinosa no celular (Burton, 2008). Esta matriz extracelular, presente en todos los animales, desempeña un papel crucial en las medusas, ya que conforma la mayor parte de su estructura y les confiere la textura gelatinosa tan característica (Boero, 2013). La mesoglea es secretada por las células epiteliales y está compuesta de laminina, fibronectina y colágeno IV, elementos muy similares a la membrana basal de los organismos bilaterales. Aproximadamente el 96% del volumen corporal de una medusa es agua, y cerca del 40% corresponde a líquido extracelular (Wright y Purcell, 1997). Al ser osmoconformistas, las medusas mantienen un equilibrio osmótico entre el líquido extracelular de la mesoglea y el agua circundante (Wright y Purcell 1997; Kogovšek *et al.*, 2014). Esta adaptación, junto con su composición mayoritariamente de agua, sales y un bajo contenido orgánico en proporción a su tamaño, las diferencia del zooplancton constituido por crustáceos.

Morfológicamente, los cnidarios presentan un cuerpo similar a un saco con una única abertura que comunica con una cavidad gastrovascular, la cual funciona como boca y ano a la vez. El pólipo, la forma sésil, posee un cuerpo tubular o cilíndrico, con el extremo oral orientado hacia arriba y rodeado de tentáculos que son prolongaciones de la pared corporal. El extremo opuesto (aboral), se adhiere normalmente a sustratos sólidos, aunque ciertas especies pueden excavar en sedimentos blandos o encontrarse recubiertas por tejido conjuntivo o un exoesqueleto. En cambio, la medusa tiene una estructura en forma de campana denominada “umbrela”, con la parte convexa dirigida hacia arriba y la boca situada en el centro de la superficie cóncava inferior, de cuyos bordes cuelgan los tentáculos. La medusa se impulsa de forma eficiente mediante un movimiento pulsátil y coordinado de las células musculares situadas en la parte inferior de la umbrela. La forma y tamaño de la umbrela varían enormemente entre las diferentes especies de medusas, lo que evidencia la adaptación evolutiva a múltiples nichos ecológicos (Dawson y Hamner, 2009; Griffin *et al.*, 2019). Dichas variaciones incluyen diferencias en el diámetro de la

umbrella, en el grosor de la mesoglea, así como en la forma de los bordes de la campana, que en ciertas especies pueden presentar lobulaciones. La umbrella no solo sirve para la locomoción y protección física, sino que también contribuye a la captura de presas. La combinación entre la estructura de la umbrella y los tentáculos genera corrientes de agua que dirigen a los organismos más pequeños hacia los tentáculos.

La cavidad gastrovascular de los cnidarios suele dividirse mediante mesenterios (pliegues de mesoglea y capas gastrodermales) que proporcionan soporte estructural y aumentan la superficie de la gastrodermis. En muchas especies, los filamentos mesentéricos o gástricos situados en los bordes libres de los mesenterios cuentan con numerosos nematocistos y células productoras de enzimas, esenciales para la digestión de las presas (Technau *et al.*, 2015).

El tejido gonadal se localiza por lo general en las zonas mesogleales de los mesenterios en los pólipos o en el espacio gástrico de las medusas. En estas últimas, la mesoglea constituye la estructura de sostén principal, mientras que, en los pólipos, el agua contenida en el espacio gastrovascular actúa como esqueleto hidrostático. Carecen de estructuras diferenciadas para la respiración, excreción o circulación. La absorción de nutrientes puede darse por endocitosis de partículas alimenticias, por la absorción de compuestos orgánicos disueltos o mediante el aprovechamiento de compuestos orgánicos filtrados por dinoflagelados simbioses (Technau *et al.*, 2015).

La respiración y la excreción ocurren mediante intercambio directo a través de las membranas celulares, tanto por transporte pasivo como activo. No poseen un sistema nervioso centralizado, sino una red de células nerviosas llamada red nerviosa difusa. Algunas especies presentan ocelos sensibles a la luz, estatocistos para la detección de la gravedad y la orientación, además de fosas quimio-sensoriales primitivas (Martin, 2002).

Los tentáculos y brazos orales de las medusas son una característica notable y, a menudo, muy llamativa. En estos apéndices se encuentran sus células urticantes, cruciales para la depredación y responsables de picaduras a los usuarios de las playas (Beckmann y Özbek, 2012). La activación de estas células se da en uno de los movimientos biológicos más rápidos del mundo animal, que puede ocurrir en tan solo 700 nanosegundos (Nüchter *et al.*, 2006). Las medusas emplean dichas células para inmovilizar a sus presas y así alimentarse (Strychalski *et al.*, 2018), por lo que sus tentáculos y brazos orales resultan indispensables para su supervivencia (Miles y Battista, 2019).

1.1.3. Ciclo de vida y reproducción

El filo *Cnidaria* engloba una amplia gama de organismos marinos con estrategias de historia de vida muy diversas. Tradicionalmente, se ha descrito que estos organismos alternan dos fases morfológicas principales, la fase de pólipo y la fase de medusa. Sin embargo, es importante señalar que tanto la presencia como la predominancia de estas fases pueden variar de manera notable entre las diferentes clases de cnidarios. En concreto, mientras que en *Anthozoa* la fase de medusa está ausente, en *Medusozoa* sí se observa la alternancia entre ambas fases, reflejando la complejidad evolutiva y adaptativa de los cnidarios (Seipel y Schmid, 2006).

El ciclo de vida de una especie bentopelágica se caracteriza por la alternancia entre la fase de pólipo y la fase de medusa (Figura I-4). El ciclo comienza con la reproducción sexual, en la cual las medusas adultas, organismos pelágicos en su mayoría dioicos, liberan óvulos y espermatozoides al medio acuático, realizando así la fecundación externa. De este proceso surgen las larvas plánulas, pequeñas y móviles, capaces de desplazarse pasivamente con las corrientes oceánicas. Esta capacidad de dispersión de la plánula contribuye a la colonización de nuevos hábitats. Tras un periodo de dispersión, la plánula se asienta sobre un sustrato sólido y se transforma en pólipo. Los pólipos, al capturar partículas alimenticias y pequeños organismos con sus tentáculos, pueden crecer y reproducirse de manera asexual. La reproducción asexual en pólipos puede presentarse en diferentes modalidades, incluidas la gemación, en la que nuevos individuos se forman directamente a partir del cuerpo del pólipo, o la estrobilación, un proceso más complejo en el que el pólipo segmenta parte de su cuerpo para originar éfiras, futuras medusas jóvenes. Una vez liberadas, las éfiras atraviesan una serie de transformaciones morfológicas que las llevan a su forma adulta. Durante esta fase de medusa, los individuos maduran sexualmente y cierran el ciclo de vida al liberar gametos en el entorno, preparados para reiniciar el proceso reproductivo. Este ciclo, aunque en gran medida generalizable a los *Medusozoa*, presenta variaciones específicas de cada especie que pueden influir en su ecología y dinámica de poblaciones.




Figura I-4. Ciclo de vida de una medusa del género *Rhizostoma* (clase Scyphozoa). Presenta una alternancia de generaciones entre la fase sexual (medusa) y la fase asexual (pólipo). La medusa adulta (7) es la etapa sexual, que libera gametos al agua. Tras la fecundación, se forma una larva plánula (1), que se fija al sustrato y se transforma en un pólipo primario (2). Este pólipo crece hasta convertirse en un pólipo completamente desarrollado (3), el cual se reproduce asexualmente mediante estrobilación (3a). Durante este proceso, el pólipo forma una estructura segmentada llamada estróbila (4), que libera discos en forma de éfiras (5) (etapas juveniles tempranas). Las éfiras evolucionan a meta-éfiras (6), medusas juveniles con lóbulos tentaculares. Finalmente, tras madurar, alcanzan la etapa de medusa adulta (7), cerrando el ciclo. Adaptado de Fuentes et al. (2011).

Dado el enfoque y el objetivo de este capítulo, centrado en la dinámica de poblaciones y en los eventos de proliferación masiva de medusas, resulta fundamental poner el acento en el ciclo de vida de los Scyphozoa, concretamente el de la especie *P. noctiluca*. El ciclo de vida de la mayoría de los escifozoos se caracteriza por un ciclo metagenético que implica una sucesión de generaciones alternantes con separación temporal y espacial de los modos reproductivos (Ceh et al., 2015). Sin embargo, *P. noctiluca* es una especie de medusa holoplanctónica, cuyas larvas plánulas se desarrollan directamente en éfiras que posteriormente maduran hasta convertirse en medusas adultas (Lucas et al., 2012), lo cual la hace excepcional dentro de los escifozoos, ya que carece de fase pólipo. Los huevos fecundados se convierten en plánulas en un plazo de tres días,

para transformarse luego en éfiras planctónicas en un periodo aproximado de 92 horas (Rottini-Sandrini y Avian, 1983). La fase juvenil, con un diámetro de 8 mm, se caracteriza por el desarrollo de brazos orales y tentáculos marginales (Russell, 1970). Los adultos suelen presentar un diámetro de la campana superior a 35 mm (Rottini-Sandrini y Avian, 1991) (Figura I-5).




Figura I-5. Ciclo de vida de la especie de medusa *Pelagia noctiluca* (clase Scyphozoa) caracterizado por la ausencia de una fase de pólipo sésil. Los adultos realizan el desove, liberando gametos al agua. Tras la fecundación, los huevos fertilizados se desarrollan rápidamente en plánulas (larvas ciliadas). Estas larvas, en lugar de asentarse como pólipos, experimentan una metamorfosis directa a éfiras (etapas juveniles), con tiempos de desarrollo influenciados por la temperatura: 76 horas a 23°C o 92 horas a 14°C. Las éfiras muestran rasgos distintivos, como lóbulos marginales desarrollados, una boca con bordes orales definidos y rhopalia (estructuras sensoriales) desarrollada. Finalmente, las éfiras maduran como juveniles y luego como adultos, completando un ciclo de vida predominantemente pelágico. Este ciclo, sin fase bentónica de pólipo, permite a *P. noctiluca* una rápida colonización de aguas abiertas. Adaptada de Canepa et al. (2014).

Esta especie es dioica y su reproducción es exclusivamente sexual. El número de huevos que producen las hembras es proporcional a su tamaño, y siguen reproduciéndose incluso en condiciones desfavorables, lo que garantiza un posible crecimiento poblacional (Lilley et al., 2014). La reproducción parece ocurrir durante todo el año (Piccinetti-Manfrin et al., 1986), con picos en primavera y otoño en el mar de Alborán (Rottini-

Sandrini y Avian, 1991), aunque puede variar según la zona geográfica (Milisenda *et al.*, 2018). Estudios han demostrado que *P. noctiluca* muestra una marcada respuesta reproductiva frente a factores de estrés ambiental. En condiciones de laboratorio, se ha observado que estos organismos liberan gametos bajo situaciones de estrés, como la falta de alimento y los cambios en el ciclo de luz. Lilley *et al.* (2014) documentaron que las medusas desovan a diario cuando están estresadas, indicando un mecanismo fisiológico que dispara la liberación de gametos en respuesta a condiciones adversas. Esta adaptación garantiza la supervivencia y el éxito reproductivo de la especie incluso en entornos desfavorables. Además, algunos estudios han demostrado que, aunque puede experimentar un estrés fisiológico considerable por falta de alimento, *P. noctiluca* continúa produciendo y liberando gametos, subrayando su resistencia y estrategia reproductiva adaptativa (Lilley *et al.*, 2014; Milisenda *et al.*, 2014).

Estudios sobre la madurez gonadal en el Mediterráneo han determinado que los machos son fértiles con unos pocos meses de vida y un tamaño aproximado de 35 mm (Rosa *et al.*, 2013). La puesta en aguas costeras va seguida de una migración desde el talud continental entre los meses de marzo y mayo. Las éfiras suelen encontrarse más próximas a la superficie (Sabatés *et al.*, 2018) y pueden estar presentes hasta nueve meses al año (Lilley *et al.*, 2014). Durante el verano, las medusas descienden a mayores profundidades para evitar las altas temperaturas. En otoño, con la mezcla de la columna de agua debido al enfriamiento superficial, las medusas regresan a la superficie, un fenómeno asociado a su reproducción (Milisenda *et al.*, 2018).

1.1.4. Ecología trófica y relación entre especies

La investigación sobre la ecología trófica de las medusas es esencial para comprender el funcionamiento y la estructura de los ecosistemas marinos, así como para anticipar posibles repercusiones en la pesca y otras actividades económicas humanas (Hamilton, 2016; Milisenda *et al.*, 2018). Aunque durante décadas se las subestimó como componentes alimentarios de bajo valor nutricional, numerosos estudios han demostrado que las medusas pueden ejercer una influencia significativa en la circulación de materia y energía, en particular cuando las poblaciones de peces disminuyen y las medusas ocupan ese nicho ecológico (Mills, 2001; Purcell, 2009).

Las medusas suelen ser oportunistas y adaptan su dieta a la disponibilidad de presas, desde microzooplancton hasta larvas de peces y huevos (Purcell y Arai, 2001; Boero, 2013; Rosa *et al.*, 2013). Un ejemplo representativo es el de la especie *Pelagia noctiluca* en el Mediterráneo, que ilustra bien esta flexibilidad dietética. En épocas de mayor temperatura, puede alimentarse principalmente de copépodos, mientras que en periodos más fríos incorpora presas más ricas en nutrientes (Malej, 1989; Rottini-Sandrini y Avian, 1991). Debido a estas variaciones regionales y estacionales, los resultados de estudios sobre la dieta de una especie en una zona específica pueden no ser directamente extrapolables a otras áreas (Boero, 2013).

Por otra parte, se ha comprobado que las medusas desempeñan un papel notable en el ciclo trófico como presas de diversos depredadores. Pese a su elevado contenido de agua, especies como la tortuga laúd (*Dermochelys coriacea*) o el pez luna (*Mola mola*) pueden llegar a consumir grandes cantidades de medusas, sobre todo durante proliferaciones masivas (Hays *et al.*, 2018; Milisenda *et al.*, 2018). Estos organismos pueden ser una fuente de alimento cualitativamente importante para procesos fisiológicos como el crecimiento, la reproducción y el desarrollo de sus depredadores (Purcell, 1991; Milisenda *et al.*, 2018), ya que su rápida digestión compensa el bajo valor nutricional que contienen (Arai *et al.*, 2003). Aunque esta afirmación requiere confirmación experimental (debido a que los restos de medusas no suelen preservarse bien en los estómagos), técnicas como el análisis de isótopos estables ha evidenciado su importancia nutricional (Purcell, 1991). A pesar de que las observaciones *in situ* de la depredación de medusas son escasas (Milisenda *et al.*, 2014), los estudios de depredación de medusas han sido ampliamente documentados en diversas revisiones (Purcell y Arai, 2001; Doyle *et al.*, 2014), demostrándose que los depredadores de medusas pueden abarcar una amplia gama de organismos, desde larvas de peces hasta aves marinas (Catry *et al.*, 2004; Arai, 2005; Houghton *et al.*, 2006), e incluso otras medusas (Purcell, 1991).

Además, ciertas medusas pueden competir con especies piscícolas con valor comercial por el zooplancton, lo cual, en escenarios de sobreexplotación pesquera, podría exacerbar la reducción de los *stocks* (Brodeur *et al.*, 1999; Aubert *et al.*, 2018). Sin embargo, no todos los efectos son negativos: en algunos casos, ciertas especies como *Rhizostoma* y *Cotylorhiza* actúan como “viveros” al ofrecer refugio a estadios juveniles de peces, generando oportunidades tróficas para depredadores de niveles superiores (Tilves *et al.*, 2018a, b) (Figura I-6). Del mismo modo, algunas medusas son consumidas

por error por los depredadores cuando se dirigen hacia estos pequeños peces y crustáceos que a menudo viven sobre ellas o a su alrededor (Hays *et al.*, 2018). Estas interacciones subrayan la necesidad de tomar en consideración a las medusas en la gestión y conservación de los ecosistemas marinos, pues su impacto puede influir en la estabilidad y el equilibrio de la red trófica.



Figura I-6. Medusa del género *Rhizostoma* sirviendo como refugio para peces de la especie *Boops boops*. Fotografía tomada por Óscar Morillas.

1.1.5. Especies más frecuentes en el mar de Alborán

Pelagia noctiluca (Forsskål, 1775) (Figura I-7A) se considera la medusa más frecuente en el Mediterráneo occidental (Brotz y Pauly, 2012). Esta medusa autóctona con ciclo de vida holoplanctónico se observa con frecuencia de febrero a octubre, sobre todo en el mar de Alborán (Pastor-Prieto *et al.*, 2021; Gutiérrez-Hernández y Rubio Gómez, 2023). Su presencia se caracteriza por enjambres de gran magnitud, con repercusiones en la salud humana, el turismo, la pesca y la acuicultura marina. Se desplaza principalmente en la superficie y es capaz de formar enjambres densos de más de 100 medusas por metro cúbico que pueden persistir durante días o semanas (Zavodnik, 1987; Malej, 1989). Los estudios genéticos muestran poblaciones mixtas, pero las relaciones ecológicas y los impactos específicos de esta especie aún requieren más investigación. *P. noctiluca* se distribuye principalmente en aguas comprendidas entre la superficie y los 150 m de

profundidad, aunque durante el día también puede hallarse a 300 y 500 m (Mariottini *et al.*, 2008). Estas variaciones de profundidad podrían estar relacionadas con sus migraciones verticales diarias y con la disponibilidad de presas. Se ha observado que esta especie tiene un comportamiento migratorio nocturno, permaneciendo en aguas profundas durante el día y ascendiendo a la superficie por la noche (Axiak, 1984).

Aunque *P. noctiluca* se describe con mayor detalle en las secciones precedentes por su relevancia en la costa andaluza como se mencionó al inicio del capítulo, existen otras especies que también habitan el mar de Alborán y pueden presentar, en menor medida, impactos ecológicos y socioeconómicos (revisadas en Boero, 2013).

Entre estas otras especies importantes en este ecosistema marino se encuentra la medusa autóctona *Cotylorhiza tuberculata* (Macri, 1778) (Figura I-7B). Su campana, la cual puede alcanzar hasta 40 cm de diámetro, presenta en la superficie tubérculos prominentes responsables de su aspecto característico que recuerda a un huevo frito. Habita principalmente en el mar Mediterráneo y, en menor medida, en zonas adyacentes del Atlántico, donde desempeña un rol relevante como depredadora planctónica. Su dieta incluye pequeños organismos como zooplankton y larvas de peces (Aouititen *et al.*, 2024). Además, exhibe un complejo ciclo de vida anual que alterna fases sexuales y asexuales, con un periodo de estrobilación en primavera y verano que conduce a un rápido crecimiento. Las medusas producen larvas plánulas que se convierten en pólipos, los cuales pueden generar nuevas medusas mediante estrobilación. Su máxima abundancia se produce en el periodo estival (entre junio y septiembre), pudiendo prolongarse hasta el invierno (Boero, 2013). Aunque la fisiología ecológica y el comportamiento de esta especie están poco estudiados, su papel en los ecosistemas marinos es importante, ya que se ha sugerido que facilita el reclutamiento de peces juveniles (D'Ambra y Malej, 2015).

Rhizostoma pulmo (Macri, 1778) (Figura I-7C) es otra medusa autóctona cuyo ciclo de vida se inicia por estímulos relacionados con la temperatura, generando floraciones estacionales sobre todo en el mar Adriático y en el Jónico. Su dieta se basa fundamentalmente en diatomeas y desempeña un papel ecológico relevante al actuar como hospedador de transporte para algunas especies de cangrejos. Se han documentado efectos económicos y sanitarios, aunque sus picaduras son menos dañinas que las de *P. noctiluca*.

Entre las especies no autóctonas destaca *Physalia physalis* (Linnaeus, 1758) (Figura I-7D). Originaria de zonas tropicales y subtropicales, ocasionalmente ingresa al Mediterráneo a través del estrecho de Gibraltar. Su ciclo de vida es complejo, pues consiste en una colonia de organismos unisexuales con un sistema reproductivo singular. Esta especie es conocida por su potente veneno, que puede resultar letal, y desempeña un papel destacado en el ecosistema marino al depredar larvas de peces, por lo que podría tener un efecto significativo sobre la pesca comercial (Boero, 2013).

Rhizostoma luteum (Quoy & Gaimard, 1827) (Figura I-7E) fue reportada por primera vez en 1827 en el estrecho de Gibraltar (como *Orithya lutea*). En 2013, Prieto *et al.* (2013) publicaron el primer registro de *R. luteum* en los últimos 60 años. Contrariamente a su aparente rareza, *R. luteum* se ha identificado erróneamente en numerosas ocasiones, confundiéndola a menudo con *R. pulmo* y *Catostylus tagi* dado su parecido morfológico (Kienberger y Prieto, 2018). Estas confusiones, habituales durante las últimas dos décadas han ocultado la verdadera presencia de *R. luteum*. En la actualidad, su identificación se ha logrado gracias a iniciativas de ciencia ciudadana (Dobson *et al.*, 2023). *R. luteum* presenta una umbrella abovedada de coloración blanquecina con matices azulados y protuberancias de tonos rojizos. Sus brazos orales muestran zonas azuladas con franjas amarillas, terminando en ocho apéndices marrones oscuros. El margen de la umbrella se divide en lóbulos cortos y ovalados, y los segmentos próximos a la boca son más grandes y robustos. Se distribuye ampliamente en el Mediterráneo, el Atlántico y la costa africana occidental. Su umbrella es abovedada, de tonalidad blanquecina azulada con verrugas de color marrón rojizo, y sus brazos orales presentan tonos azulados con flecos amarillentos. Cuenta con 80 lóbulos marginales y una estructura particular en los brazos orales y el manubrio. Cabe resaltar las protuberancias en forma de frijol en cada foseta subgenital, que permiten diferenciarla de especies afines (Aouititen *et al.*, 2024).

Tras la revisión exhaustiva de Boero (2013), el conocimiento del ecosistema marino en el mar de Alborán ha evolucionado, evidenciando la presencia de otros organismos gelatinosos no contemplados originalmente (Gutiérrez-Hernández y Rubio Gómez, 2023). Entre ellos, se destaca la relevancia de especies que no figuraban en el análisis original, como *Chrysaora hysoscella* (Linnaeus, 1767), conocida como la medusa compás, que es una especie de *Scyphozoa* que habita en aguas costeras templadas y subtropicales del Atlántico y el Mediterráneo. Esta se distingue por su umbrella

hemisférica que puede alcanzar hasta 30 cm de diámetro, presentando marcas radiales pardas que recuerdan a una brújula. Sus tentáculos pueden superar el metro de longitud que emplean para capturar presas como pequeños peces y zooplancton. Su ciclo de vida incluye una fase planctónica y otra bentónica, lo que contribuye a su dispersión y abundancia en diversas áreas marinas (van Walraven *et al.*, 2020). Esta especie produce una picadura dolorosa en humanos, aunque no suele ser peligrosa.

La diversidad de medusas en el mar de Alborán va mucho más allá de las especies principales descritas en este capítulo. Investigaciones realizadas en sus aguas han identificado más de 24 especies de medusas, incluidas *Amphinema dinema*, *Corymorpha nutans*, *Euphysa aurata*, *Eucodonium brownei*, *Paragotoea bathybia*, *Podocorynoides minima*, *Lizzia blondina*, *Coryne eximia*, *Aequorea aequorea*, *Eucheilota paradoxa*, varias especies de *Clytia* (*Clytia hemisphaerica*, *Clytia mccradyi*), *Eutima gracilis*, *Eutima mira*, varias especies de *Obelia*, *Aglaurea hemistoma*, *Liriope tetraphylla*, *Rhopalonema velatum* y *Solmundella bitentaculata* (Touzri *et al.*, 2012; Benyoub *et al.*, 2023). Dada la intensa conectividad en las aguas superficiales de los océanos, es probable que en el futuro se sumen nuevas especies de medusas a la diversidad del mar de Alborán a medida que las comunidades planctónicas migren y se adapten a las cambiantes condiciones ambientales (Jönsson y Watson, 2016).




Figura I-7. Imágenes de diferentes especies de medusas tomadas en las aguas de la costa de Andalucía (sur de España). (A) *Pelagia noctiluca*, tomada por Juan Carlos Sáez, (B) *Cotylorhiza tuberculata*, tomada por Juan José Domenech, (C) *Rhizostoma pulmo*, tomada por Miguel C. Padial, (D) *Physalia physalis*, tomada por Óscar Morillas, y (E) *Rhizostoma luteum*, tomada por Juan José Domenech.

1.2. Presencia de medusas en diferentes áreas del Mediterráneo

Las proliferaciones de medusas han sido históricamente un fenómeno global y natural en los ecosistemas marinos tal como lo evidencia el registro fósil, que indica que estos eventos han ocurrido durante cientos de millones de años (Condon *et al.*, 2012; Marambio *et al.*, 2021). Es esencial definir qué entendemos por “proliferaciones”. De acuerdo con Lucas y Dawson (2014), una proliferación verdadera es un incremento significativo de la biomasa de medusas impulsado por condiciones ambientales favorables y por los ciclos reproductivos, a veces intensificados por actividades humanas. Esto contrasta con una proliferación aparente, que es un aumento local en el número de medusas debido a fenómenos físicos o químicos temporales, como corrientes o aportes de nutrientes, sin que exista un verdadero crecimiento poblacional. Por otro lado, un enjambre se refiere a una reagrupación densa de animales debida a su comportamiento. En un enjambre, los individuos no se distribuyen de manera uniforme ni mantienen una orientación específica. Por lo tanto, una presencia masiva de medusas, ya sea por agregación, proliferación o enjambre, es una característica notable de ciertos grupos diversos de escifozoos que representa ventajas evolutivas (Dawson y Hamner, 2009).

Concretamente, el mar Mediterráneo ha estado expuesto de manera constante a proliferaciones densas de diferentes especies de medusas a lo largo de la historia (Canepa *et al.*, 2014). A partir de una búsqueda bibliográfica exhaustiva de la literatura relacionada con la biota de *Pelagia noctiluca* en el Mediterráneo realizada por Goy *et al.* (1989), los autores revelaron que la primera proliferación registrada data de 1775 (Forsskål, 1775). Sin embargo, el interés por la dinámica de las proliferaciones de *P. noctiluca* no fue intensificado hasta inicios de la década de 1980, cuando una proliferación importante de esta especie afectó el Mediterráneo oriental, el mar Adriático y posteriormente el Mediterráneo occidental (Malej y Malej, 2004; Mariottini *et al.*, 2008). Desde entonces, los años de abundancia particularmente alta de esta especie pasaron a denominarse “años de *Pelagia*” (CIESM, 2001). En respuesta a este suceso, el Programa de las Naciones Unidas para el Medio Ambiente (UNEP, *United Nations Environmental Programme*), a través del Plan de Acción para el Mediterráneo (MAP, *Mediterranean Action Plan*), inició un proyecto para financiar investigación científica sobre medusas en el Mediterráneo. Estas actividades culminaron en dos talleres realizados en 1983 y 1987 (UNEP, 1984, 1991).

En los resultados de estos talleres y otras publicaciones se recopiló toda la información disponible sobre las proliferaciones de *P. noctiluca* en la región mediterránea. Entre 1775 y 1987 se registraron 55 proliferaciones de *P. noctiluca* con una periodicidad aproximada de 12 años, asociada a fluctuaciones climáticas (Goy *et al.*, 1989). Análisis más recientes en el Golfo de Túnez, las Islas Baleares y el mar de Liguria señalan un posible incremento en la frecuencia de las proliferaciones en el Mediterráneo occidental en épocas recientes (Daly-Yahia *et al.*, 2010; Bernard *et al.*, 2011). Sin embargo, este cambio en la periodicidad no parece reflejarse en el Mediterráneo oriental, ya que existen variaciones importantes en las tendencias de las poblaciones de medusas que pueden diferir ampliamente según la región específica (Brotz y Pauly, 2012). Kogovšek *et al.* (2010) reconstruyeron una serie temporal de 200 años en el norte del mar Adriático identificando proliferaciones notables alrededor de 1915, a inicios de la década de 1980, y entre 2004 y 2007. No obstante, estos autores no encontraron indicios de un cambio reciente en la periodicidad de las proliferaciones de *P. noctiluca*, aunque sí se observaron incrementos en otras especies de la región. En otras regiones como en el sur del Adriático o en el mar Egeo hay poca evidencia de un incremento general en la periodicidad de las proliferaciones (Daly-Yahia *et al.*, 2010). En un taller científico organizado en mayo de 2017 por la Sociedad para la Protección y el Desarrollo Sostenible del Golfo de Corinto, se informó que las proliferaciones de medusas en esta zona se repiten de forma cíclica cada 8-10 años, duran aproximadamente 2 años y están ocasionadas por la actividad humana (Komninos, 2019).

Algunos de los eventos más notorios de proliferaciones en años recientes han quedado reflejados en artículos de investigación. Por ejemplo, Bernard *et al.* (2011) destacaron un evento importante de proliferación de *P. noctiluca* ocurrido en la región occidental del Mediterráneo entre 1994 y 2008. Este período se caracterizó por una prolongada abundancia de medusas, interrumpida solo por unos pocos años (1997, 2001 y 2002) con abundancia muy baja, mientras que las abundancias más altas se observaron en 1999 y 2006. Asimismo, Prieto y Navarro (2013) documentaron varios episodios significativos de avistamientos de medusas en la costa andaluza. Destacan especialmente los eventos de 2007 y 2012 debido al elevado número de registros observados. En particular, en 2012 se produjo una llegada masiva de *P. noctiluca* desde el estrecho de Gibraltar hacia las costas de Málaga, coincidiendo con temperaturas relativamente bajas para esa época del año. En la costa opuesta, al sur del mar de Alborán, Aouititen *et al.*

(2021) registraron una proliferación importante de *P. noctiluca* en la playa de M'Diq, situada en la costa mediterránea noroccidental de Marruecos, cuyo inicio se remontó a 2011. Durante la temporada estival, que coincide con el periodo de proliferación y varamiento de medusas, se observaron fuertes repercusiones en las actividades económicas regionales. Paralelamente se han documentado proliferaciones inusuales de otras especies. En 2010, se registró una proliferación anómala de *Physalia physalis* a lo largo del mar Mediterráneo y del Atlántico nororiental, con colonias compuestas por más de 100.000 individuos (Prieto, 2018; Prieto, 2021).

Siguiendo a Boero (2013), a pesar del interés de algunos investigadores en documentar estos eventos, es probable que muchas proliferaciones de medusas no hayan sido detectadas. Este autor indica que pueden existir varias razones para esta ausencia de registros. Por ejemplo, las proliferaciones pueden ocurrir en zonas aisladas con alta concentración de medusas, pero sin la presencia de investigadores que las observen. Por otro lado, aunque las proliferaciones sean observadas, a menudo no se publican en revistas científicas porque no se consideran lo suficientemente relevantes. En otros casos, incluso cuando las proliferaciones se mencionan en trabajos científicos, suelen reseñarse de manera breve y anecdóticamente, lo que dificulta su rastreo en la literatura.

Los datos históricos sobre zooplancton gelatinoso no son suficientes para confirmar un incremento global, por lo que esta cuestión sigue generando controversia. Como señalan Pitt *et al.* (2018), las ideas científicas pueden distorsionarse debido a la citación selectiva y la amplificación, de modo que ciertas hipótesis logran amplia aceptación a pesar de basarse en evidencias limitadas, reforzando la percepción de un aumento global de medusas. Del mismo modo, el análisis de Sanz-Martín *et al.* (2016) reveló que la creencia de un incremento global de las poblaciones de medusas ha sido moldeada en gran medida por prácticas de citación defectuosas. De acuerdo con dichos autores, aproximadamente la mitad de las citas se consideran inadecuadas para respaldar afirmaciones sobre las tendencias en las poblaciones de medusas. Esta inclinación hacia la aseveración de un aumento poblacional podría haber generado una percepción errónea tanto en la comunidad científica como en la opinión pública. Fernández-Álías *et al.* (2024) cuestionaron aún más la percepción de un aumento general de las floraciones de medusas, haciendo hincapié en la imprevisibilidad de su aparición a pesar de más de tres décadas de investigación científica. Según los autores, aunque el número de especies que forman floraciones dentro de la clase *Scyphozoa* ha aumentado en la última década, esto no indica

necesariamente un aumento global de las poblaciones de medusas, sino más bien una consecuencia del aumento de los esfuerzos de investigación y de la mejora de la vigilancia. Los autores destacan que las series temporales a largo plazo revelan una considerable variabilidad interanual, incluidos años de ausencia inexplicable de medusas, lo que cuestiona la validez del marco conceptual que vincula directamente la degradación de los océanos con la proliferación de medusas.

Pese a las dificultades para recolectar datos históricos y la ambigüedad en las tendencias a largo plazo, es evidente que las proliferaciones de medusas forman parte natural de los ecosistemas marinos, con una notable presencia en el Mediterráneo y múltiples impactos sobre el ser humano y los servicios ecosistémicos (Bergamasco *et al.*, 2022). Tal y como subrayan Fernández-Alías *et al.* (2024), los factores que influyen en la formación de floraciones siguen siendo insuficientemente conocidos, lo que complica aún más los esfuerzos por establecer una tendencia definitiva en la dinámica de las poblaciones de medusas. Para comprender mejor estas dinámicas y predecir eventos futuros, es necesario examinar estos factores que influyen en la distribución y la abundancia de medusas. El conocimiento de estos factores no solo ayuda a explicar los patrones observados en el pasado, sino que también pueden proporcionar información útil para gestionar y mitigar los impactos de las proliferaciones de medusas en el presente y en el futuro.

1.3. Factores que impulsan las proliferaciones de medusas

Las medusas se caracterizan por sus proliferaciones súbitas y abundantes, y los factores que influyen en la distribución y la abundancia de las poblaciones de estos organismos son variados y complejos, incluyendo tanto una amplia gama de condiciones oceanográficas y climáticas como numerosas influencias antrópicas, desempeñando cada uno de ellos un papel significativo en la dinámica regional de estas poblaciones (Richardson *et al.*, 2009; Purcell, 2012).

En las secciones siguientes se exponen en detalle los factores que impulsan las proliferaciones de medusas, destacando su impacto crítico en las tendencias de *Pelagia noctiluca* en distintas zonas del Mediterráneo.

1.3.1. Factores ambientales

Según Purcell (2005), se ha ido reconociendo progresivamente la relación entre las variaciones climáticas y el tamaño de las poblaciones de medusas. Aunque existen pocos registros a largo plazo sobre la abundancia de medusas, estos resultan sumamente valiosos para correlacionar los cambios en su abundancia con variaciones climáticas. Las especies de medusas, debido a sus cortos tiempos de generación, parecen responder a las fuerzas climáticas sin un desfase temporal significativo. Sin embargo, aún no se han determinado de forma concluyente los factores que desencadenan la producción de medusas para la mayoría de las especies. Al parecer, estos factores incluyen una progresión estacional o una combinación de cambios ambientales en la temperatura, la salinidad, la disponibilidad de alimento y la luz, variando de una especie a otra (revisado en Purcell, 2005 y Canepa *et al.*, 2014). En este sentido, Canepa *et al.* (2014) propusieron una clasificación de los factores ambientales que impulsan las proliferaciones de *P. noctiluca* en cuatro categorías de forzamiento: físico, fisicoquímico, biológico y climático.

1.3.1.1. Forzamiento físico

En primer lugar, los factores físicos juegan un papel clave en la distribución espacial y acumulación de medusas, particularmente en zonas costeras donde la hidrodinámica puede favorecer su concentración sin implicar necesariamente un aumento poblacional real. Según la revisión de Canepa *et al.* (2014), en varias áreas del Mediterráneo las fuerzas físicas como la dirección y velocidad del viento, las corrientes y los efectos de mareas se han identificado como determinantes principales en la presencia y agregación de *Pelagia noctiluca*. Sabatés *et al.* (2010) subrayaron la relevancia de estas fuerzas físicas en la distribución de *P. noctiluca* en el noroeste del Mediterráneo. Sus investigaciones mostraron que la interacción entre las corrientes superficiales impulsadas por el viento y la geomorfología costera influye notablemente en la distribución y la abundancia de las poblaciones de medusas. El estudio hizo hincapié en cómo ciertas características costeras, tales como bahías y golfos, pueden actuar como zonas de retención donde las medusas se acumulan, impulsadas por los patrones de viento y corrientes. Asimismo, se observó que los cambios estacionales en la dirección y la intensidad del viento pueden provocar la aparición y desaparición periódicas de proliferaciones de medusas en áreas costeras específicas.

El índice de pendiente (*slope index*) ha sido reconocido ampliamente como un factor ambiental crucial para la proliferación de medusas, en particular para *P. noctiluca*. Diversos estudios han evidenciado que la proximidad a cañones submarinos, medida a través de este índice, desempeña un papel determinante en la concentración y agregación de poblaciones de medusas (Canepa *et al.*, 2014; Benedetti-Cecchi *et al.*, 2015; Marambio *et al.*, 2021; Bergamasco *et al.*, 2022). A menudo, a los cañones submarinos se les denomina “autopistas” debido a la circulación intensa de masas de agua, sedimentos y organismos, favoreciendo así movimientos activos y pasivos entre zonas someras y aguas profundas. Estas condiciones hidrodinámicas propician la formación de grandes proliferaciones, por lo que el índice de pendiente se erige como un predictor fiable de áreas con probabilidad de proliferación en diferentes regiones, como la costa septentrional de Cataluña, la costa de Túnez, el mar de Liguria, el estrecho de Sicilia y el sur del mar Tirreno. Por tanto, los cañones submarinos podrían funcionar como bombas de circulación que promueven el movimiento estacional de *P. noctiluca* entre aguas intermedias y superficiales, y viceversa.

En el contexto del mar de Alborán, Gutiérrez-Estrada *et al.* (2021) y Castro-Gutiérrez *et al.* (2022, 2024) demostraron que fuerzas físicas como la dirección y la velocidad del viento, junto con las corrientes superficiales, desempeñan un papel fundamental en la incidencia y distribución de medusas. Estos estudios evidenciaron que velocidades y direcciones de viento específicas ejercen un papel significativo en la presencia de medusas en las playas del norte del mar de Alborán. En la costa de Marruecos, Aouititen *et al.* (2019, 2021) obtuvieron conclusiones similares, donde la dirección del viento, sumada a la altura de las olas, puede favorecer la aparición de medusas en las playas.

Estos factores de forzamiento físico (dirección del viento, corrientes y estructuras frontales) son más característicos de una “proliferación aparente” que de una proliferación verdadera. En este caso, las medusas, que han perdido el control de su movimiento, se ven transportadas pasivamente por las corrientes y las olas. Más que reflejar un incremento poblacional debido a la reproducción, estas proliferaciones aparentes son producto de fenómenos físicos transitorios que redistribuyen las medusas hacia zonas donde las condiciones ambientales permiten su concentración temporal.

1.3.1.2. *Forzamiento de parámetros fisicoquímicos*

Más allá del papel del transporte físico, las condiciones fisicoquímicas del agua afectan directamente la fisiología, reproducción y supervivencia de las medusas y, por tanto, su capacidad real de proliferación. El efecto de variables fisicoquímicas en la supervivencia de las medusas ha sido objeto de numerosos estudios, tanto en campo como en laboratorio. Boero *et al.* (2016) llevaron a cabo una revisión detallada de estos factores, destacando que la temperatura del océano es determinante en la distribución y los ciclos de vida de las medusas. El calentamiento global ha facilitado la expansión de especies tropicales hacia latitudes más altas, desplazando a comunidades marinas templadas. Este proceso de tropicalización evidente en el Mediterráneo ha permitido que las especies de medusas tropicales prolonguen sus períodos reproductivos y se extiendan a nuevas áreas. Las medusas, gracias a su elevada tolerancia térmica, pueden adaptarse a diferentes condiciones, prolongando así sus ciclos reproductivos y mejorando su supervivencia en aguas templadas. No obstante, en regiones polares o de latitudes altas, el aumento de la

temperatura podría tener efectos negativos, al reducir la reproducción de especies nativas y facilitar la invasión de especies no autóctonas.

La temperatura del agua influye no solo en la distribución geográfica de las medusas, sino también en su rendimiento fisiológico (Bosch-Belmar *et al.*, 2020). Arai (1997), Purcell (2007) y Hubot *et al.* (2017) señalan que la temperatura regula el desarrollo de pólipos y medusas, así como la tasa de crecimiento de las medusas recién liberadas. Además, el calentamiento de las aguas puede elevar la supervivencia invernal de las medusas, resultando en mayores abundancias. En el caso de *P. noctiluca*, se ha observado mayor mortalidad de éfiras a temperaturas más bajas (Rottini-Sandrini, 1982; Avian *et al.*, 1991), mientras que su abundancia en el Mediterráneo ha aumentado, posiblemente debido a inviernos más suaves (Molinero *et al.*, 2005; Daly Yahia *et al.*, 2010). En estos entornos estacionales, las temperaturas frías marcan por lo general el final del ciclo de vida de las medusas adultas, pero si las temperaturas críticas se alcanzan más tarde en el año, esto podría prolongar su presencia y su período reproductivo (Canepa *et al.*, 2014; Milisenda *et al.*, 2018).

En el estrecho de Mesina, Rosa *et al.* (2013) identificaron varios factores clave que influyen en las proliferaciones de *P. noctiluca*. La temperatura superficial del mar desempeña un papel crucial ya que las temperaturas elevadas aceleran el crecimiento y la reproducción de esta especie, incrementando la frecuencia y la intensidad de las proliferaciones. Asimismo, la disponibilidad de presas, como los crustáceos, resulta fundamental para el crecimiento de las poblaciones de medusas. Las condiciones hidrodinámicas complejas de este área, que incluyen corrientes y afloramientos, potencian la disponibilidad de nutrientes, creando un ambiente propicio para la proliferación de medusas. La estacionalidad también influye, ya que las bajas temperaturas y ciertos patrones de corrientes en los meses de invierno se correlacionan con mayor abundancia de medusas.

La relación entre la alimentación, el metabolismo y la temperatura del agua en *P. noctiluca* ha sido demostrada previamente (Malej *et al.*, 1986; Morand *et al.*, 1987; Milisenda *et al.*, 2018). A temperaturas más bajas, estas medusas reducen su capacidad natatoria, lo que disminuye su potencial de búsqueda de alimento y alarga el tiempo de digestión de sus presas (Rottini-Sandrini y Avian, 1989). En contraste, a temperaturas más altas su metabolismo se acelera, aumentando su demanda alimenticia (Lilley *et al.*, 2014).

Otro factor determinante es la disminución de oxígeno disuelto en el agua, un fenómeno que se ve acentuado con el calentamiento de las aguas superficiales. A medida que el agua se calienta, su capacidad de retener oxígeno decrece, dando lugar a zonas hipóxicas donde muchos organismos marinos tienen dificultades para sobrevivir. Sin embargo, las medusas toleran bien la hipoxia en comparación con otras especies, lo que les brinda ventaja competitiva en entornos donde otros organismos no pueden prosperar (Boero *et al.*, 2016).

La acidificación oceánica constituye otro aspecto fundamental del forzamiento fisicoquímico detrás de las proliferaciones de medusas (Kroeker *et al.*, 2010; Gissi *et al.*, 2021). Aunque estos organismos no presentan estructuras calcificadas que pudieran verse afectadas directamente por la disminución del pH, la acidificación podría alterar funciones fisiológicas clave, como el desarrollo de los estatolitos, esenciales para el equilibrio y la orientación en algunas especies. Hasta el momento, no se han identificado efectos drásticos de la acidificación sobre la supervivencia global de las medusas, lo cual sugiere que, al menos a corto plazo, podrían ser menos vulnerables a este aspecto del cambio climático en comparación con otros organismos marinos (Richardson y Gibbons, 2008; Boero *et al.*, 2016). Otros estudios sugieren que la reducción del pH podría favorecer a las medusas perjudicando a los organismos calcificadores (Attrill *et al.*, 2007).

Se ha observado que la temperatura y la salinidad del entorno guardan una relación positiva con la presencia de *P. noctiluca*. Goy *et al.* (1989) concluyeron que las condiciones climáticas entre mayo y agosto, en particular baja precipitación, altas temperaturas y elevada presión atmosférica, están fuertemente correlacionadas con las proliferaciones de esta especie de medusa. De igual modo, Aouititen *et al.* (2021) hallaron una relación significativa entre la salinidad superficial del mar y las proliferaciones de *P. noctiluca* en la costa mediterránea noroccidental de Marruecos, señalando que mayores niveles de salinidad se asocian positivamente a incrementos en la presencia de medusas.

Por otra parte, Purcell (2012) identificó la eutrofización como uno de los principales impulsores de las proliferaciones de medusas. El incremento de nutrientes en las aguas costeras, a menudo derivado de la actividad humana, promueve el crecimiento de fitoplancton y zooplancton, que sirven de alimento a las medusas y les permiten crecer y reproducirse con mayor rapidez. Además, la eutrofización puede reducir el tamaño del zooplancton, circunstancia que beneficia a las medusas, ya que prefieren presas más pequeñas que los peces.

Vučetić (1984) propuso que concentraciones subletales de contaminación en aguas costeras del norte del Adriático habrían favorecido las proliferaciones de *P. noctiluca* desde 1977 a través de un proceso conocido como “hormesis”. Dicho proceso implica un aumento en la reproducción sexual y una estimulación de las tasas de crecimiento como respuesta a concentraciones bajas de contaminantes.

Finalmente, el calentamiento global también se ha señalado como un factor que beneficia a ciertas especies de medusas (Purcell *et al.*, 2007; Richardson *et al.*, 2009). El calentamiento global parece favorecer a algunas especies, puesto que el incremento de la temperatura superficial del mar puede intensificar la estratificación de la columna de agua, generando condiciones pobres en nutrientes que favorecen a los flagelados, al poder desplazarse hacia capas más profundas y ricas en nutrientes (Cushing, 1989). Estos entornos dominados por flagelados podrían resultar más beneficiosos para las medusas que para los peces.

1.3.1.3. Forzamiento biológico

La disponibilidad de alimento constituye uno de los factores determinantes de las proliferaciones de medusas, ya que un aumento en los recursos disponibles puede propiciar un crecimiento poblacional masivo (Hecq *et al.*, 2009; Milisenda *et al.*, 2018; Goldstein y Steiner, 2020). Factores a escala local, asociados a una elevada producción primaria, pueden incrementar la abundancia de crustáceos herbívoros, impulsar un mayor crecimiento y reproducción de *P. noctiluca* (Kogovšek *et al.*, 2010) y, en consecuencia, derivar en proliferaciones de esta especie (Boero, 2013; Milisenda *et al.*, 2018).

La disponibilidad de presas también repercute en la supervivencia larvaria y, por ende, en el éxito de las proliferaciones (Hecq *et al.*, 2009). No obstante, la abundancia de éfiras podría no vincularse directamente con la abundancia de adultos, tal como establecieron Bernard *et al.* (2011).

1.3.1.4. Forzamiento climático

A escala regional y global, los factores climáticos ejercen una influencia más amplia y sostenida en el tiempo, modulando tanto variables físicas como biológicas. El ecosistema pelágico del mar de Alborán es particularmente sensible a la influencia del clima

procedente del Atlántico norte y a patrones climáticos del hemisferio norte (Molinero *et al.*, 2005; Daly-Yahia *et al.*, 2010). Molinero *et al.* (2005) recalcaron el impacto significativo que ejercen los patrones climáticos a gran escala, en especial los del Atlántico norte, en las poblaciones de medusas en el Mediterráneo. Dicho estudio revela que la variabilidad climática interanual, impulsada por fenómenos macroclimáticos como la Oscilación del Atlántico Norte (NAO, *North Atlantic Oscillation*), desempeña un papel clave en la configuración de la abundancia de medusas. Las temperaturas más elevadas, las condiciones más secas y los cambios en la circulación atmosférica asociados a fases positivas de la NAO generan columnas de agua más estables, que favorecen las proliferaciones de medusas. Estas fuerzas climáticas inciden de manera indirecta en todo el ecosistema planctónico, reforzando la idea de que el cambio climático ejerce efectos profundos en los ecosistemas marinos. A partir de estas conclusiones, Bellido *et al.* (2020) reforzaron el vínculo entre los índices macroclimáticos y los enjambres de medusas, especialmente en el mar de Alborán. Su estudio encontró que la combinación de valores bajos de NAO y altos de Oscilación del Ártico (AO, *Arctic Oscillation*) durante el invierno conduce a un incremento de la temperatura superficial del mar, creando condiciones favorables para la proliferación de *P. noctiluca*.

En un estudio llevado a cabo en el noreste del mar de Alborán, Kienberger *et al.* (2016) no hallaron patrones meteorológicos ni oceanográficos específicos que explicaran la aparición diaria de *P. noctiluca*. No obstante, observaron que la abundancia de esta especie durante los meses de verano parecía estar relacionada con las condiciones climáticas invernales, tales como menor precipitación acumulada, índices NAO y AO positivos, temperaturas del aire más bajas y menor intensidad del viento y las olas. Aunque dichos resultados apuntan a una posible vinculación entre las condiciones climáticas invernales y las proliferaciones de medusas, los autores subrayan la necesidad de analizar series temporales más extensas para confirmar esta tendencia.

1.3.2. Factores antrópicos

Además de los factores naturales, diversas actividades humanas han sido propuestas como motores indirectos o amplificadores de las proliferaciones de medusas. Estos factores antrópicos pueden alterar el equilibrio ecológico y favorecer estados dominados por organismos gelatinosos. La idea de que los factores de estrés inducidos por la actividad

humana provocan proliferaciones masivas de medusas es común tanto en la literatura científica como en los medios de comunicación. La mayoría de las evidencias que respaldan la premisa de que las presiones antrópicas causan el aumento de estas proliferaciones se concentra en las revisiones de Purcell *et al.* (2007), Richardson *et al.* (2009) y Purcell (2012), cuyos trabajos han ejercido gran influencia y han generado una red de citas que puede considerarse, en ocasiones, sesgada (Pitt *et al.*, 2018).

Según Richardson *et al.* (2009), actividades humanas como la sobrepesca, la eutrofización, el cambio climático, la translocación de especies y la modificación de hábitats parecen estimular el incremento de las proliferaciones de medusas. Estas alteraciones en los ecosistemas pelágicos, históricamente dominados por peces, pueden derivar en un estado alternativo menos deseable, dominado por organismos gelatinosos, con repercusiones ecológicas, económicas y sociales de larga duración.

La sobrepesca puede ser considerada entre los impulsores más relevantes de la creciente presencia de medusas en los océanos y mares del mundo, incluido el Mediterráneo (Lynam *et al.*, 2006; Brotz y Pauly, 2012; Boero, 2013). La extracción masiva de peces, que compiten y depredan sobre las medusas, genera un espacio ecológico que permite la proliferación de estas últimas (Sabatés *et al.*, 2010). Aunque el informe *El estado de la pesca y la acuicultura en el Mediterráneo y el Mar Negro 2023* de la FAO indica una disminución en el estatus de sobreexplotación, aún subraya que el 60% de las poblaciones evaluadas en estas regiones continúan sobreexplotadas (FAO, 2023). Por tanto, no debe pasarse por alto el posible impacto de este problema continuo en las poblaciones de medusas. Un ejemplo se observa en las aguas de Israel, donde el incremento de la pesca de arrastre de fondo ha coincidido con una mayor incidencia de proliferaciones de medusas (Angel *et al.*, 2016).

La eutrofización, impulsada por la entrada de fertilizantes y aguas residuales a las aguas costeras, representa otro factor determinante (Purcell *et al.*, 2007). Este proceso incrementa la biomasa de fitoplancton, que a su vez puede favorecer las proliferaciones de medusas. Asimismo, las medusas muestran mayor tolerancia a condiciones hipóxicas resultantes de la descomposición bacteriana del fitoplancton que se deposita en el fondo, confiriéndoles ventaja respecto a otros organismos marinos (Richardson *et al.*, 2009). Un ejemplo de esta dinámica se dio en el mar Menor (sureste de España), donde tras la eutrofización, la construcción y la transformación extensiva del hábitat, se produjeron proliferaciones de medusas. El ecosistema cambió drásticamente con la sustitución de

praderas marinas por el alga invasora *Caulerpa prolifera*, y la introducción de ostras que proporcionaron sustrato adicional para los pólipos de medusas (Pagés, 2001).

Las translocaciones de especies, mayormente facilitadas por el transporte marítimo, también han contribuido a la expansión de medusas en nuevos entornos (Brotz y Pauly, 2012). Estos autores documentaron al menos 10 especies del filo *Cnidaria* clasificadas como invasoras en el Mediterráneo hasta la fecha de su estudio. Investigaciones más recientes ponen de manifiesto la persistencia del problema de zooplancton gelatinoso no autóctono en aguas europeas. Ejemplos destacados incluyen *Rhopilema nomadica* y *Cassiopea andromeda* en el mar Mediterráneo, *Gonionemus vertens* en las costas del norte de Europa y múltiples invasiones del ctenóforo *Mnemiopsis leidyi* en otros mares europeos, tal como indican Rinaldis *et al.* (2021).

La modificación de hábitats, en particular en zonas costeras, constituye otro factor que puede promover las proliferaciones de medusas. La construcción de infraestructuras como plataformas petrolíferas y estructuras de acuicultura proporciona nuevos sustratos para los pólipos de medusas, lo que puede incrementar la frecuencia de proliferaciones en estas áreas (Graham, 2001; Lo *et al.*, 2008; Richardson *et al.*, 2009). Además, la expansión urbanística en zonas costeras y las defensas frente a la subida del nivel del mar podrían aumentar el hábitat disponible para los pólipos.

A pesar de la creciente evidencia que apunta a la contribución de los factores antrópicos en el aumento de las proliferaciones de medusas, la relación entre estos y las proliferaciones no está totalmente confirmada (Pitt *et al.*, 2018). Buena parte de los estudios que sostienen dichas afirmaciones son de carácter correlacional, lo que dificulta determinar si estos factores son realmente la causa principal o si simplemente coinciden temporalmente. En ocasiones, las proliferaciones pueden formar parte de ciclos naturales, y no estar directamente inducidas por las actividades humanas (Graham *et al.*, 2001). Sin embargo, la interacción entre diversos factores antrópicos y naturales puede producir un bucle de retroalimentación que favorezca la proliferación continua de medusas. Este bucle de retroalimentación podría generar una modificación duradera de la estructura del ecosistema, en la que las medusas dominen sobre los peces (Richardson *et al.*, 2009).

1.4. Impacto socioeconómico y gestión

Las proliferaciones de medusas no son meramente eventos ecológicos, sino también fenómenos socioeconómicos con el potencial de afectar numerosos sectores. Las medusas desempeñan roles críticos en los servicios de regulación, apoyo, provisión y culturales (revisado en Doyle *et al.*, 2014 y Graham *et al.*, 2014). Con el aumento de las interacciones entre los humanos y los ecosistemas costeros, el contacto con proliferaciones de medusas también ha incrementado. En este contexto, es esencial evaluar cómo las medusas pueden afectar el bienestar humano, y también es útil analizar y comparar los costes y beneficios de las medusas (Graham *et al.*, 2014).

Esta sección resume algunos de los efectos perjudiciales que las medusas tienen sobre la sociedad, así como algunas estrategias para explotar este "escenario gelatinoso".

1.4.1. Efectos negativos en diferentes sectores económicos costeros

1.4.1.1. Interacción con la pesca

La interferencia física de las medusas en las pesquerías basadas en redes ha sido demostrada por diversos autores en todo el mundo, y las consecuencias económicas, aunque difíciles de cuantificar con precisión, son evidentes (Lucas *et al.*, 2014; Bosch-Belmar *et al.*, 2020). Entre los múltiples impactos negativos causados por las proliferaciones de medusas en el sector pesquero se encuentran la obstrucción y el desgarramiento de las redes de pesca, la reducción en la calidad de las capturas debido a lesiones, mortalidad o deterioro del pescado capturado, las picaduras a los pescadores cuando intentan retirar las medusas de las redes, el aumento del tiempo y la mano de obra debido a estas extracciones, y en algunos casos incluso el vuelco de embarcaciones pesqueras (Möller, 1980; Kideys *et al.*, 2005; Lynam *et al.*, 2005; Kawahara *et al.*, 2006; Purcell *et al.*, 2007; Daryanbard y Dawson, 2008; Uye, 2008; Dupont *et al.*, 2009; Dong *et al.*, 2010; Kim *et al.*, 2012; Quiñones *et al.*, 2013; Graham *et al.*, 2014; Báez *et al.*, 2022).

El mar Mediterráneo es la segunda región más afectada a nivel mundial por las medusas en términos de impacto en la pesca (Bosch-Belmar *et al.*, 2020). Según Bosch-Belmar *et al.* (2020), más del 50% de los problemas relacionados con las medusas en las operaciones pesqueras en el Mediterráneo fueron causados por las especies de escifozoos *Aurelia sp.* y *Rhopilema nomadica*, mientras que *Pelagia noctiluca* y *Rhizostoma pulmo*

representaron aproximadamente un 35% adicional de los reportes totales. En el norte del mar Adriático, los costes económicos estimados debido a la reducción de las capturas de la flota de arrastre ascendieron a 9,7 millones de dólares anuales, de los cuales más de 500.000 dólares se debieron al desplazamiento de actividades pesqueras (Palmieri *et al.*, 2014).

En el mar de Alborán, Mghili *et al.* (2022a, b) estimaron los costes económicos asociados con el impacto de las medusas en la pesca a lo largo de la costa marroquí de M'diq. Los pescadores en el área de estudio informaron haber sido afectados por la presencia de medusas, sufriendo colapsos de redes y picaduras al intentar retirarlas, lo que llevó a una disminución en las ganancias económicas durante la temporada de pesca. Las principales especies responsables fueron *P. noctiluca*, *Rhizostoma pulmo* y *Chrysaora hysoscella*, con daños directos anuales causados por estas especies que ascendieron a 3,26 millones de dólares. Además, el tiempo invertido en la reparación de redes afectadas por medusas ascendió a más de 1.783 horas de trabajo por persona cada año (Mghili *et al.*, 2022b).

1.4.1.2. Impacto en la acuicultura y la industria costera

Los efectos negativos de las proliferaciones de medusas no se limitan a las actividades pesqueras, sino que se extienden a todas las actividades económicas en el mar (Purcell *et al.*, 2007). Entre los negocios afectados se encuentran las operaciones de acuicultura y las plantas de energía o desalinización.

En 2021, la producción total de acuicultura en los países que bordean el Mediterráneo y el mar Negro fue de 3.299.000 toneladas, con un 24% originado por la acuicultura marina (FAO, 2023). Las proliferaciones de medusas pueden tener un impacto significativo en la acuicultura marina, ya que pueden entrar en las jaulas al ser empujadas por las corrientes y las olas a través de las redes, ya sea intactas o fragmentadas. Se han registrado múltiples interacciones entre medusas y peces en jaulas marinas, causando episodios de alta mortalidad en los peces (Rodger *et al.*, 2011; Purcell *et al.*, 2013). Diversas especies de medusas, como *Pelagia noctiluca* o *Aurelia aurita*, causan daños en la piel y branquias de los peces mediante la descarga de nematocistos, lo que provoca inflamación, toxicidad celular e infecciones secundarias (Helmholz *et al.*, 2010; Baxter *et al.*, 2011a). En casos severos, esto puede resultar en problemas respiratorios y

osmorregulatorios, cambios en el comportamiento y, eventualmente, la muerte. Mientras que los efectos de bajas densidades de medusas a menudo pasan desapercibidos, las mortalidades masivas están asociadas con especies conspicuas, como *P. noctiluca* (Marcos-López *et al.*, 2016).

El conocimiento científico sobre los impactos específicos de las medusas en la acuicultura en el mar de Alborán sigue siendo limitado. En el norte del mar de Alborán, se ha informado de proliferaciones de medusas que han tenido un impacto particularmente severo en las granjas de acuicultura de lubina (*Dicentrarchus labrax*), donde brotes de enfermedades branquiales vinculadas a la presencia de medusas han causado episodios de alta mortalidad y pérdidas económicas significativas (Baxter *et al.*, 2011b). Bosch-Belmar *et al.* (2017) informaron sobre dos granjas marinas en la costa mediterránea española que se vieron obligadas a reemplazar sus redes después de que enjambres de *P. noctiluca* fueran arrastrados por las corrientes y chocaran con las jaulas entre 2012 y 2014. Episodios similares se repitieron en estas mismas granjas durante 2016 y 2018 (Bosch-Belmar *et al.*, 2020).

En el caso de las plantas de energía costeras (eléctricas, nucleares y de carbón), los sistemas de refrigeración utilizan agua de mar para enfriar sus condensadores, además de servir como fuente de agua para plantas desalinizadoras. Esta agua de mar entra en la planta a través de un sistema ubicado a cientos de metros de la costa e inevitablemente captura flora y fauna marina, que se acumula en las rejillas de entrada antes de ingresar al sistema de enfriamiento (Purcell *et al.*, 2007; Lucas *et al.*, 2014). Sin embargo, este tipo de casos aún no ha sido documentado en el mar de Alborán.

1.4.1.3. Impacto negativo en el turismo y la salud humana

Europa es la región más visitada del mundo, habiendo recibido 700 millones de los 1.300 millones de viajeros globales registrados en 2023, lo que representa el 54% del total mundial (Organización Mundial del Turismo, 2024). El turismo de sol y playa, conocido como turismo de sol y playa, también conocido como turismo 3S (*Sun, Sea, and Sand*), ha sido fundamental en este crecimiento, consolidándose como una de las industrias más importantes a nivel mundial (Lekakou y Tzannatos, 2001; White *et al.*, 2006; Alipour *et al.*, 2020). En particular, el sur de Europa se ha convertido en un referente del turismo

masivo desde la segunda mitad del siglo XX, impulsado por la accesibilidad y la democratización de este tipo de turismo costero (Bujosa *et al.*, 2015).

En el mar de Alborán, la relación entre el turismo y el crecimiento económico varía entre las costas de España y Marruecos. En España, el turismo de sol y playa juega un papel esencial, con una correlación directa entre el crecimiento económico y los ingresos por turismo (Bernier *et al.*, 2014; Tugcu, 2014; Romero-Padilla *et al.*, 2020). En el norte de Marruecos, aunque el turismo ha sido una prioridad nacional desde 2001 y representa cerca del 11% del PIB, su impacto sobre el crecimiento económico es más limitado (Bouzahzah y El Menyari, 2013; El Menyari, 2021; Er-Ramy *et al.*, 2022).

Dada la importancia del turismo costero en la región, las proliferaciones de medusas representan una amenaza creciente tanto para la economía local como para la salud pública. Ghermandi *et al.* (2015) realizaron un estudio en el Mediterráneo y encontraron que las proliferaciones de medusas pueden reducir las visitas turísticas a las playas hasta en un 10,5% durante los episodios de proliferaciones, lo que representa pérdidas económicas de hasta 6,2 millones de euros para el sector recreativo. En el sur de España, las proliferaciones de medusas han generado impactos económicos significativos en zonas turísticas de la Costa del Sol. Según Cantarero-Prados *et al.* (2023), las playas de Málaga, Marbella y Torrox se encuentran entre las más afectadas por el alto riesgo de picaduras que representan las medusas, lo que lleva a una reducción en el número de turistas y a notables pérdidas económicas.

Casos similares han sido registrados en el norte de Marruecos, donde las proliferaciones han requerido tratamiento médico para más de 1.300 bañistas durante 2008 (Mghili *et al.*, 2022a). Aunque los estudios en el mar de Alborán aún son escasos, los patrones observados en todo el Mediterráneo indican que el impacto económico de estos eventos es significativo.

La intensidad de estos efectos ha llevado al desarrollo de estrategias defensivas. En 2006, se informó que más de 14.000 personas fueron tratadas por picaduras de medusa en las costas oriental y meridional de España (Purcell *et al.*, 2007). Otro ejemplo notable es el Mar Menor, donde grandes cantidades de *Cotylorhiza tuberculata* invadieron las lagunas de agua salada, obligando a las autoridades a retirar mil toneladas de medusas para proteger las actividades recreativas y turísticas. En 2007, al menos 30.000 personas fueron afectadas por picaduras de medusas en las costas españolas, lo que llevó a los

centros turísticos a implementar medidas defensivas para proteger sus playas. La Costa del Sol fue una de las áreas más afectadas, donde se establecieron redes y sistemas de alerta para evitar la entrada de medusas en las zonas de baño. En respuesta, España lanzó un "Plan Nacional contra las medusas", que incluía el despliegue de embarcaciones y redes para eliminar medusas del agua, así como el aumento del personal de salvavidas y primeros auxilios para atender a los bañistas afectados. A pesar de estas medidas, en 2012 los brotes de *Pelagia noctiluca* provocaron el cierre de playas a lo largo de la Costa del Sol, afectando gravemente la temporada turística de verano. En un solo fin de semana, más de mil bañistas en Málaga buscaron tratamiento tras ser picados, lo que llevó a la prohibición del acceso al agua en varias playas (Ghermandi *et al.*, 2015).

Por tanto, además del impacto económico, las medusas representan un riesgo para la salud de los bañistas. En comparación con hace 100 años, el impacto de las medusas en las actividades recreativas es mayor simplemente porque hay "más personas en el agua" (Prieto, 2018).

Los primeros informes sobre picaduras de *P. noctiluca* en bañistas fueron revisados por Mariottini *et al.* (2008) y posteriormente a mayor escala (CIESM, 2001; Nastasi, 2010; Bernard *et al.*, 2011). Generalmente, la picadura produce síntomas locales como dolor intenso, sensación de ardor, eritema, edema y vesículas (Ballesteros *et al.*, 2021). Las picaduras de *P. noctiluca* suelen causar lesiones cutáneas superficiales con dolor localizado que puede durar entre 1 y 2 semanas, aunque las complicaciones sistémicas o infecciones cutáneas son infrecuentes (Mariottini *et al.*, 2008).

Aunque todos los cnidarios tienen la capacidad de inyectar veneno, la mayoría son relativamente inofensivos para los humanos debido a la corta longitud de sus nematocistos o la baja toxicidad de sus toxinas (Cegolon *et al.*, 2013). Sin embargo, más allá del daño físico, las medusas influyen en la percepción del riesgo entre los turistas. Según Crowley-Cyr *et al.* (2022), este riesgo puede influir en sus decisiones, aunque no necesariamente los disuade de elegir destino costero. En el Mediterráneo, las proliferaciones de medusas pueden representar tanto desafíos económicos como reputacionales, afectando la experiencia de los bañistas (De Donno *et al.*, 2014). Crowley-Cyr *et al.* (2022) destacan así la importancia de una comunicación de riesgos clara y eficaz, ya que los mensajes de riesgo adecuados pueden influir en las percepciones de los turistas sin necesariamente modificar sus planes de viaje.

Del mismo modo, Cantarero-Prados *et al.* (2022) analizaron la vulnerabilidad del sector turístico ante la ocurrencia de enjambres de medusas en el sur de España. El estudio destaca que, si bien a corto plazo los enjambres de medusas pueden generar beneficios económicos inmediatos para los negocios locales, ya que los turistas buscan alternativas como bares y hoteles, a medio y largo plazo, los enjambres afectan gravemente al turismo, ya que muchos turistas optan por otros destinos para evitar la presencia de medusas.

La disposición de los turistas a pagar más por una experiencia segura también ha sido estudiada. Según Nunes *et al.* (2015), en España, los turistas que visitan destinos de playa están dispuestos a pagar un promedio de 3,20 € más si se les garantiza una baja probabilidad de encontrarse con medusas. En este contexto, la gestión de las medusas supone el desafío de equilibrar la seguridad de los visitantes con la experiencia turística, especialmente en destinos costeros altamente dependientes del turismo de sol y playa. La implementación de estrategias de comunicación adecuadas puede ayudar a mitigar la percepción negativa del riesgo y proteger la reputación de estos destinos turísticos.

Asimismo, las pérdidas económicas causadas por la presencia de medusas en las playas pueden mitigarse parcialmente mediante el monitoreo de sus poblaciones, el análisis estadístico de registros históricos y el desarrollo de modelos predictivos que permitan la implementación de medidas de control y la eliminación de especímenes que alcancen las playas (Ghermandi *et al.*, 2015; Bellido *et al.*, 2020; Castro-Gutiérrez *et al.*, 2022). Estas acciones, además de mejorar la seguridad, contribuyen a preservar la reputación de los destinos turísticos y a sostener su actividad económica.

1.4.2. Estrategias de gestión: Desafíos y oportunidades

A pesar de la incertidumbre sobre el aumento generalizado de las poblaciones de medusas, es fundamental tomar medidas en ecosistemas como el Mediterráneo, donde la evidencia indica incrementos en ciertas especies (Brotz y Pauly, 2012). Esto resalta la necesidad de implementar medidas de gestión que aborden proactivamente las proliferaciones de medusas, comenzando con la identificación del fenómeno y sus causas subyacentes para adoptar un enfoque integral y adaptativo.

Como señaló Boero (2013), las causas de estos eventos son múltiples y varían según la especie y la región, lo que complica su gestión. Cuando las causas de estos

fenómenos son difíciles de eliminar, la única alternativa es adaptarse a las nuevas condiciones. Dado que su presencia en las playas está asociada con picaduras y riesgos para los bañistas, la medida local más frecuente es su retirada de las zonas recreativas (Figura I-8) o el cierre de playas (Macías *et al.*, 2021).



Figura I-8. Barco retirando medusas cerca de la costa de Málaga (sur de España). Esta medida protocolaria es utilizada por diversas playas españolas para retirar los enjambres de medusas cuando aparecen en gran número y suponen un riesgo para la salud de los usuarios de las playas en temporadas estivales. Extraído de: <https://www.surinenglish.com/local/201806/22/authorities-remove-tonnes-jellyfish-20180622094131-v.html>

Estudios como los de Lucas *et al.* (2014) y Sagarminaga *et al.* (2024) han revisado diversas medidas de gestión de medusas y cómo algunas industrias las están implementando.

En el caso de la pesca, se han aplicado modificaciones en las técnicas de captura para evitar la captura accidental de medusas en áreas densamente pobladas por estos organismos, protegiendo así las redes y los equipos de pesca (Matsushita y Honda, 2006).

En el ámbito de la acuicultura, se han implementado diversas medidas físicas para reducir la entrada de medusas a las instalaciones y minimizar su impacto sobre la producción piscícola. Estas incluyen el uso de mallas de exclusión, coberturas protectoras alrededor de las jaulas y pantallas de burbujas que actúan como barreras dinámicas para evitar el contacto directo con los organismos. Estas soluciones buscan proteger a los peces

cultivados de posibles lesiones, estrés o mortalidad causados por la presencia de medusas en el entorno inmediato (Sagarminaga *et al.*, 2024).

Para proteger el turismo, se han implementado estrategias educativas y medidas de protección pública, como trajes de baño protectores y redes anti-medusas, minimizando así el impacto en el turismo costero. Estas redes anti-medusas han sido instaladas en ciertas regiones del mar Mediterráneo para crear áreas seguras y delimitadas para los bañistas (Piraino *et al.*, 2016). Además, se promueve la difusión de información pública sobre las condiciones del agua, lo que mejora la percepción y seguridad de los visitantes. En este contexto, el uso de banderas de advertencia sobre la presencia de medusas (Figura I-9) ha demostrado ser eficaz en localidades de la costa española, donde estas banderas se combinan con el código de colores estándar que indica el estado del mar (banderas verde/amarilla/roja). Esto permite alertar a los bañistas sobre la presencia de medusas y minimizar el contacto, especialmente cuando las especies presentes tienen toxicidad media o alta (Bordehore *et al.*, 2016; Dobson *et al.*, 2024).




Figura I-9. Diseño de la bandera de advertencia de medusas implantada en las playas españolas.

En este sentido, las iniciativas de ciencia ciudadana han demostrado ser una herramienta muy útil en los sistemas de alerta temprana sobre medusas, a través de señales de advertencia, carteles informativos y aplicaciones de monitoreo (Bellido *et al.*, 2020; Marambio *et al.*, 2021). Según el estudio de Ruiz-Frau (2023) en el Mediterráneo

occidental, este tipo de campañas pueden reducir hasta en un 83% la cantidad de turistas que evitan regresar a las mismas playas debido a la presencia de medusas.

Si bien las intervenciones locales pueden mitigar los síntomas, no abordan los factores que originan estas proliferaciones. Este tipo de gestión requiere una comprensión profunda del ecosistema y de las dinámicas que lo rigen, integrando tanto las especies afectadas como las condiciones ambientales que influyen en su proliferación. Boero (2013) y Richardson *et al.* (2009) sugieren que este enfoque adaptativo debe basarse en un monitoreo constante e investigación proactiva. Al integrar el estudio de las medusas en los programas de gestión ecosistémica, se pueden desarrollar estrategias más efectivas que incluyan la identificación temprana de proliferaciones y, cuando sea posible, la modificación de las condiciones que las desencadenan. Esta gestión basada en un conocimiento integral del ecosistema permite una respuesta más eficiente a los eventos naturales y contribuye a una mejor administración de los recursos marinos en general.

En el estudio realizado por Richardson *et al.* (2009), los autores proponen una serie de respuestas de gestión a corto y largo plazo dirigidas a prevenir que los ecosistemas cambien abruptamente hacia estados dominados por medusas, así como restaurar aquellos ecosistemas que ya han sido alterados. Entre estas estrategias se incluyen: el desarrollo de productos derivados de medusas para alimentación y medicina; el uso de redes de corte para destruir medusas en la columna de agua; la eliminación de estructuras artificiales duras como prevención de asentamientos; o el uso de agentes de biocontrol para los pólipos. Cada una de estas estrategias requiere considerar los beneficios esperados frente a los posibles riesgos y problemas asociados, buscando siempre un equilibrio entre intervenciones directas y la necesidad de un enfoque más holístico y sostenible en la gestión del medio marino.

Cabe señalar que ninguna de estas estrategias mencionadas es eficaz de manera aislada, por lo que para garantizar su efectividad se debe emplear una combinación de ellas junto con estrategias de gestión a largo plazo. Los esfuerzos de gestión tienden a volverse complejos e inciertos, por lo que adoptar un enfoque precautorio resalta la importancia de centrarse en la prevención en lugar de en el remedio. Medidas tempranas proactivas y coordinadas son esenciales para prevenir cambios extensivos en los ecosistemas pelágicos (Richardson *et al.*, 2009).

Implementar medidas de gestión preventiva para controlar la presencia de medusas en las costas es fundamental, dado que pueden minimizar los riesgos para los bañistas. Estas medidas incluyen el aumento de la vigilancia y los esfuerzos de monitoreo, la preparación de protocolos adecuados de respuesta y advertencia, y la concentración de las acciones de retirada de medusas durante períodos de mayor riesgo previsto. Esta estrategia involucra a una amplia gama de actores, entre los que se encuentran los servicios gubernamentales locales, regionales y nacionales, la Comisión Europea, el sector privado turístico, los pescadores, los operadores de acuicultura en alta mar, los clubes de buceo, los supervisores de áreas marinas protegidas, los socorristas, los marineros y los naturalistas entusiastas, todos los cuales desempeñan un papel vital en la gestión de las amenazas que representan las medusas (Macías *et al.*, 2021). Es importante comprender las características únicas de cada región del Mediterráneo y las preferencias de diferentes especies de medusas para desarrollar estrategias de gestión efectivas y específicas (Marambio *et al.*, 2021).

No obstante, no es inusual que especies que antes se consideraban indeseables se conviertan en recursos valiosos con el tiempo (Link, 2007; Nunoo *et al.*, 2009). A medida que las poblaciones de medusas han aumentado en ciertos ecosistemas, han surgido nuevas oportunidades comerciales. Además, si tales prácticas pueden ayudar a gestionar y reducir el número de una especie problemática, las ventajas son aún mayores. La sabiduría popular en esta situación podría resumirse en la frase: “*Si no puedes vencerlas... cómelas*” (Gibbons *et al.*, 2016). Esto abre la posibilidad de considerar a las medusas como un recurso valioso.

1.4.2.1. Las medusas como recurso

Se estima que la población mundial alcanzará los 9,7 mil millones en el año 2050, lo que incrementará la demanda alimentaria y podría cambiar las preferencias dietéticas globales (FAO, 2018). En este escenario las proliferaciones de medusas pueden ofrecer una alternativa alimentaria sostenible, beneficiando simultáneamente la gestión ecológica de estas especies (Bonaccorsi *et al.*, 2020). Aunque históricamente han sido mayormente consumidas en Asia, en Occidente aún existe desconocimiento y resistencia cultural hacia las medusas como alimento, a pesar de reconocerse al menos 35 especies comestibles, mayormente del orden Rhizostomae (Brotz y Pauly, 2017; Duarte *et al.*, 2022). Su bajo

contenido en grasas y calorías, junto con altos niveles de proteínas y minerales, las posicionan como una fuente nutricional atractiva, pero su introducción en dietas occidentales enfrenta desafíos relacionados con la seguridad alimentaria y aceptación cultural (Wong *et al.*, 2010; Bonaccorsi *et al.*, 2020; Torri *et al.*, 2020; Raposo *et al.*, 2022).

Además del consumo humano directo, las medusas tienen múltiples aplicaciones potenciales en diversos sectores productivos y científicos (Brotz y Pauly, 2017). En agricultura, se emplean como alimento para ganado, fertilizantes orgánicos y agentes insecticidas, reduciendo el uso de productos químicos sintéticos y mejorando la sostenibilidad agrícola. En acuicultura, las medusas ofrecen una alternativa eficaz y económica a la harina de pescado tradicional, beneficiando la producción sostenible de peces y moluscos. Sus propiedades gelatinizantes y emulsionantes son aprovechadas en el sector cosmético para crear productos naturales y biodegradables. En la ciencia de materiales, también se utilizan para producir polímeros absorbentes y aditivos sostenibles para cemento. Además, diversas especies de medusas han mostrado potencial en la investigación farmacéutica, al poseer compuestos bioactivos como anticoagulantes, antioxidantes y colágeno, relevantes en el desarrollo de tratamientos médicos innovadores (Brotz y Pauly, 2017).

En particular, la especie *Pelagia noctiluca* presenta gran interés por sus variadas aplicaciones. Aunque aún no está confirmada oficialmente como medusa comestible, ha sido identificada en mercados chinos como ingrediente en productos etiquetados incorrectamente, indicando tanto su potencial económico como problemas regulatorios en su comercialización (Armani *et al.*, 2013). Su utilidad en acuicultura como alimento alternativo para peces y moluscos ayuda a disminuir costos operativos y la dependencia de recursos pesqueros convencionales (Costa *et al.*, 2019). Asimismo, esta medusa es valorada por sus compuestos bioactivos en la industria farmacéutica y por su colágeno en la industria cosmética (Ayed *et al.*, 2012, 2016; Frazão *et al.*, 2017). Además, ha demostrado potencial para el biomonitoreo ambiental, siendo útil en la detección de contaminantes marinos como los microplásticos (Macali *et al.*, 2018).

1.4.2.2. Pesquerías y acuicultura de medusas

La importancia de las pesquerías de medusas ha crecido significativamente en los últimos años, expandiéndose desde su origen tradicional en Asia hacia otras regiones debido a factores como colapsos pesqueros locales y la demanda comercial internacional (Brotz y Pauly, 2017). Actualmente, al menos 19 países capturan aproximadamente 900.000 toneladas anuales de medusas mediante diversas técnicas tales como redes fijas, redes de deriva y nasas, entre otras (Purcell *et al.*, 2013; Behera *et al.*, 2020). Sin embargo, estas cifras están subestimadas por falta de registros adecuados, generando dificultades en la gestión sostenible de estos recursos (Brotz y Pauly, 2017). Además, la actividad pesquera de medusas está marcada por fuertes fluctuaciones interanuales en abundancia y biomasa, temporadas de pesca breves y desafíos relacionados con la falta de investigación y regulaciones apropiadas, lo que limita su implementación exitosa en muchas regiones (Kingsford *et al.*, 2000; Brotz, 2016; Duarte *et al.*, 2022).

La complejidad ecológica y biológica de las medusas plantea desafíos específicos para su gestión pesquera sostenible. Dado que las poblaciones de medusas responden dinámicamente a cambios ambientales y antrópicos, los modelos de gestión deben incorporar información local precisa y detallada (Gibbons *et al.*, 2016). Asimismo, debido a que las medusas cumplen roles importantes en los ecosistemas marinos, una extracción masiva podría generar efectos ecológicos adversos no deseados. Por tanto, es esencial desarrollar estrategias adaptativas que garanticen estabilidad económica a los pescadores, a la vez que protejan el equilibrio ecológico, considerando tanto periodos de alta como baja disponibilidad (Kingsford *et al.*, 2000; Kumawat *et al.*, 2023).

Ante la variabilidad en la disponibilidad natural de medusas, la acuicultura emerge como una solución para mantener un suministro constante y controlado (Purcell *et al.*, 2013). Desde los primeros avances en China durante la década de 1980, la producción en cautiverio ha demostrado ser rentable y efectiva para el repoblamiento, exhibiciones públicas, investigaciones científicas y aplicaciones comerciales (Ballesteros *et al.*, 2022; Duarte *et al.*, 2022). Aunque la especie más ampliamente cultivada es *Aurelia aurita*, los principios básicos de cría desarrollados se han extendido a otras especies. Sin embargo, el éxito reproductivo aún depende considerablemente de investigaciones específicas sobre condiciones de mantenimiento, dietas adaptadas a cada fase de desarrollo y sistemas acuícolas adecuados como los tanques Kreisel y Pseudo-Kreisel (Duarte *et al.*, 2022).

Debido a sus diversas aplicaciones potenciales, *Pelagia noctiluca* representa un modelo de especial interés para la acuicultura. Se ha demostrado que su cultivo es viable utilizando sistemas cerrados, temperaturas entre 9°C y 24°C y salinidad entre 33 y 38 PSU, con dietas específicas en función del estadio de desarrollo (Ballesteros *et al.*, 2022; Duarte *et al.*, 2022). Aunque tradicionalmente se recomienda una dieta que incluya presas gelatinosas, estudios recientes indican que es posible obtener buenos resultados sin estos recursos, simplificando significativamente el proceso de producción. La combinación de la pesquería sostenible con la acuicultura controlada puede transformar la percepción de las medusas de una amenaza ecológica en un recurso valioso, impulsando economías azules sostenibles y diversificadas (Ballesteros *et al.*, 2022; Duarte *et al.*, 2022).

1.5. Avances metodológicos y tecnológicos en el estudio de las medusas

La subrepresentación histórica de las medusas en la investigación marina, como detallan Brotz *et al.* (2012), se debe tanto a desafíos metodológicos como a un desinterés predominante en los estudios científicos. Las medusas eran consideradas ecológicamente irrelevantes y difíciles de estudiar (debido a su fragilidad y distribución irregular) en los estudios pesqueros y oceanográficos tempranos (Marambio *et al.*, 2021), por lo que en los protocolos de muestreo se recomendaba su exclusión y eliminación antes de los análisis (UNESCO, 1968). Estas metodologías reflejaban una percepción más amplia de las medusas como elementos insignificantes dentro de los ecosistemas marinos, una visión que ha persistido a pesar de la creciente evidencia en contra.

Sin embargo, la proliferación masiva de *Pelagia noctiluca* en el Mediterráneo oriental entre 1978 y 1981 marcó un punto de inflexión. A raíz de este evento, se organizó un simposio internacional sobre proliferaciones de medusas en Atenas, patrocinado por el Programa de las Naciones Unidas para el Medio Ambiente (UNEP, 1984). En respuesta a las directrices del Plan de Acción para el Mediterráneo (MAP, *Mediterranean Action Plan*), se estableció un programa de monitoreo sistemático. Este programa, implementado a través de una red de colaboración entre varias naciones mediterráneas afectadas por estas proliferaciones, buscó facilitar la recopilación y análisis de datos sobre este fenómeno ecológico (Bernard *et al.*, 2011).

A pesar del inicio de estos programas de monitoreo sistemático, aún persisten desafíos en la estandarización de metodologías para el monitoreo de medusas.

Organizaciones como la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO, *United Nations Educational, Scientific and Cultural Organization*) y programas previos como el *Global Ocean Ecosystem Dynamics* y el *U. S. Joint Global Ocean Flux Study* han reconocido la falta de enfoques estandarizados como un problema significativo (Knap *et al.*, 1996). Aunque se han logrado avances, como el informe metodológico del UNEP de 1991, que sentó las bases para futuros desarrollos, sigue existiendo una relativa escasez de publicaciones metodológicas en este campo de investigación. Además, la creación de una base de datos sobre la ocurrencia de medusas en el *Ocean Biogeographic Information System* (OBIS) y la formulación de políticas de intercambio de datos han sido pasos importantes (Prieto *et al.*, 2016). Sin embargo, el desafío continuo de la estandarización resalta la necesidad de esfuerzos sostenidos para mejorar la efectividad de los programas de monitoreo de medusas a nivel global (Prieto, 2018).

Actualmente, la recolección de datos de zooplancton gelatinoso suele estar orientada a proyectos específicos de corta duración o se lleva a cabo a través de programas de ciencia ciudadana, y rara vez se incluye en programas nacionales de monitoreo (Aubert *et al.*, 2018). En 2016, se celebró en Cádiz (España) un taller internacional organizado por el proyecto PERSEUS (Prieto *et al.*, 2016), en el que se reunió a la comunidad de investigadores de medusas de PERSEUS, junto con otros expertos internacionales y diversas partes interesadas involucradas en la investigación y gestión de las proliferaciones de medusas. Al evento asistieron 54 delegados de 15 países, incluidos representantes de ONGs internacionales como Oceana.

Para mejorar el monitoreo continuo de medusas y reducir la dependencia exclusiva de la ciencia ciudadana para la obtención de datos sobre distribución y abundancia, se estableció que es crucial contar con programas de monitoreo sólidos y sistemáticos, además de observaciones obligatorias. Las estrategias propuestas incluyen:

1. Definir el propósito del monitoreo: Determinar dónde, cuándo y con qué frecuencia se realizarán las observaciones.
2. Estandarizar metodologías: Crear y mantener un conjunto de protocolos de monitoreo estandarizados para garantizar la coherencia y comparabilidad de los datos recopilados.

3. Establecer programas de capacitación: Preparar a todos los participantes de los programas, tanto en ciencia ciudadana como en monitoreo sistemático, para que recojan datos de manera efectiva y confiable.
4. Armonizar y coordinar iniciativas de ciencia ciudadana: Se propuso que los proyectos de ciencia ciudadana no solo registren la presencia o ausencia de medusas, sino que también se estandaricen para alinearse mejor con los esfuerzos de monitoreo formal.
5. Incluir a diversos participantes: Se sugirió involucrar a pescadores, clubes de buceo, operadores de acuicultura en alta mar, supervisores de áreas marinas protegidas, socorristas, marineros y naturalistas entusiastas en los programas de observación. La simplicidad y consistencia de los protocolos de monitoreo son esenciales para facilitar la participación y asegurar la utilidad de los datos recopilados.
6. Crear una base de datos sobre la ocurrencia de medusas: Integrar y compartir datos en plataformas como OBIS (*Ocean Biogeographic Information System*) y establecer políticas claras de intercambio de datos.

Adicionalmente, Brodeur *et al.* (2016) proponen pequeños cambios en los protocolos y metodologías de muestreo existentes que permitirían recopilar medidas cuantitativas de la abundancia de medusas con costos y esfuerzo relativamente bajos, como la inclusión de sensores ópticos de arrastre, muestreo genómico durante perfiles de conductividad, temperatura y profundidad (CTD, *Conductivity, Temperature and Depth*), y la capacidad de documentar la ocurrencia y ubicación de medusas en formularios y bases de datos de encuestas. La inversión anual para el monitoreo básico de medusas incluiría la incorporación de nuevos datos en encuestas existentes, la capacitación del personal para identificar y enumerar especies de medusas, y el procesamiento, archivo y análisis de datos. Aunque esto puede parecer poco práctico para algunas encuestas, especialmente aquellas realizadas en embarcaciones pequeñas con tripulaciones científicas ya sobrecargadas, incluso estimaciones simples del peso o volumen de especies individuales serían beneficiosas para documentar tendencias.

Si bien el monitoreo de medusas puede presentar desafíos logísticos y requerir ajustes en los protocolos de muestreo, los riesgos de ignorar estos organismos son demasiado altos. Omitir el componente gelatinoso en los estudios de plancton, como

argumentan Boero y Mills (1997), es tan limitante como ignorar a los principales depredadores en los análisis de ecosistemas terrestres, subestimando su influencia en la dinámica trófica marina. Esta perspectiva subraya la necesidad de integrar componentes gelatinosos que desempeñan un papel crucial en el equilibrio de la estructura ecológica general del océano (Boero *et al.*, 2008).

Este enfoque resulta especialmente relevante si se consideran los costes económicos asociados con las proliferaciones masivas de medusas, que pueden oscilar entre cientos de miles y cientos de millones de dólares a nivel mundial (Brodeur *et al.*, 2016). Por lo tanto, el monitoreo sistemático de medusas no solo contribuiría al entendimiento científico de los ecosistemas marinos, sino que también podría mitigar los impactos económicos y sociales asociados con sus proliferaciones.

1.5.1. Innovaciones en las técnicas de muestreo y monitorización

Durante las últimas décadas, el monitoreo de medusas se ha llevado a cabo principalmente de forma manual, dependiendo de observaciones visuales directas en el campo para detectar, identificar y cuantificar especímenes (Martín-Abadal *et al.*, 2020). Sin embargo, el muestreo cuantitativo de medusas presenta importantes desafíos debido a su naturaleza frágil y a su distribución espacial heterogénea (Pastor-Prieto *et al.*, 2021). Comprender los mecanismos de transporte y agregación de medusas requiere muestreos a gran escala que combinen datos de abundancia con mediciones ambientales sincrónicas.

En respuesta a los desafíos que representan las medusas en los ecosistemas marinos y las zonas costeras, se han desarrollado e implementado nuevas tecnologías y estrategias para mejorar nuestras capacidades de monitoreo y facilitar intervenciones más efectivas para mitigar los impactos negativos de sus proliferaciones. Sagarminaga *et al.* (2024) han proporcionado una revisión detallada y actualizada de los métodos y programas de monitoreo existentes, explorando nuevas alternativas para la vigilancia de estos organismos marinos. Estos autores analizaron tanto las técnicas convencionales como las emergentes utilizadas en la investigación y gestión de las poblaciones de medusas entre los que destacaron las redes de muestreo, los registradores continuos de plancton (CPR, *Continuous Plankton Recorder*), el monitoreo de pólipos, los conteos visuales, métodos acústicos, teledetección aérea, métodos genéticos moleculares, y la ciencia ciudadana.

1.5.1.1. Ciencia ciudadana

La participación del público en la recolección de datos ofrece una oportunidad valiosa para cubrir extensas áreas costeras que serían costosas o inviables de monitorear mediante proyectos científicos convencionales (Marambio *et al.*, 2021). Las iniciativas de ciencia ciudadana se han convertido en una herramienta esencial para el monitoreo de las poblaciones de medusas, aprovechando la participación colectiva del público para recopilar datos valiosos en extensas áreas marinas. Este enfoque colaborativo no solo democratiza el proceso de investigación científica, sino que también expande significativamente el alcance y la escala de las observaciones, permitiendo la captura en tiempo real de fluctuaciones en las poblaciones de medusas y sus patrones de distribución (Dobson *et al.*, 2023).

Sin embargo, esta información puede verse afectada por sesgos espaciales y temporales, por lo que debe ser verificada por expertos para garantizar su calidad (Arazy y Malkinson, 2021). El concepto de ciencia ciudadana se verá en mayor profundidad en el Capítulo II de la presente Tesis Doctoral.

1.6. Modelización y análisis de datos

La modelización y el análisis de datos son herramientas fundamentales para comprender la dinámica poblacional de las medusas y predecir sus proliferaciones. Estos enfoques permiten integrar información de diversas fuentes, como datos ambientales, registros históricos y observaciones directas, para generar modelos que simulen el comportamiento y la distribución de las medusas en diferentes escalas espaciales y temporales (Pauly *et al.*, 2009).

Un ejemplo destacado es el proyecto EOJelly, que fue pionero en el uso de datos satelitales para modelar y predecir la presencia de medusas en playas del Mediterráneo occidental. Esta iniciativa estableció un concepto de prueba que demostró el potencial de la teledetección para anticipar eventos de proliferación de medusas. Posteriormente, el proyecto JELLYFOR se llevó a cabo en colaboración con varios municipios con el objetivo de evaluar la viabilidad de un sistema de predicción operacional basado en la observación terrestre. Estos proyectos evidenciaron que la integración de datos satelitales con modelos ambientales puede prever eficazmente la llegada de medusas a las zonas

costeras, facilitando así la gestión y mitigación de sus impactos en las comunidades locales.

1.6.1. Modelización de *Pelagia noctiluca* en el Mediterráneo

La modelización y el análisis de datos han sido herramientas clave para comprender la dinámica poblacional de *Pelagia noctiluca* en el Mediterráneo.

En el Mediterráneo occidental, Benedetti-Cecchi *et al.* (2015) analizaron los componentes deterministas y estocásticos que conducen a brotes de *P. noctiluca* en la costa catalana. Utilizando datos de abundancia recopilados a través de ciencia ciudadana en el Projecte Medusa entre 2007 y 2010, evaluaron la influencia de predictores espaciales y temporales en la ocurrencia de brotes. Los resultados mostraron que los brotes fueron más frecuentes en mayo y junio, disminuyendo en los meses siguientes, con una relación negativa con la temperatura superficial del mar. Además, identificaron que la advección costera y oceánica, impulsada por el flujo geostrofico, desempeñó un papel significativo en la concentración de medusas, especialmente cerca de cañones submarinos. Este estudio destacó la importancia de los procesos deterministas sobre los estocásticos en la generación de brotes, lo que sugiere que comprender los impulsores ambientales es crucial para anticipar eventos futuros.

Ottmann *et al.* (2021) aplicaron un enfoque analítico multiescalar combinando datos de abundancia de medusas de campañas oceanográficas en las Islas Baleares con un modelo físico-bioquímico acoplado para evaluar cómo los factores ambientales afectan la distribución tridimensional y la abundancia estacional de los primeros estadios de *P. noctiluca*. Encontraron que estas etapas permanecen principalmente por encima de la termoclina, donde las temperaturas son más cálidas. La distribución espacial mostró una correlación positiva con la concentración superficial de clorofila, y más del 90% de la variabilidad interanual en la abundancia se explicó por la productividad a escala de cuenca en junio. Concluyeron que inviernos y primaveras más cálidos, junto con floraciones primaverales prolongadas, aumentan las poblaciones de *P. noctiluca*, lo que podría explicar el incremento en brotes en las últimas décadas.

En el mismo área de estudio, El Rahi *et al.* (2020) desarrollaron un modelo basado en individuos (IBM, *Individual-Based Model*) para simular el ciclo de vida y el

movimiento de *P. noctiluca* desde el huevo fertilizado hasta la etapa adulta. Este modelo incorporó el conocimiento sobre el comportamiento y fisiología de la especie, así como datos de corrientes oceánicas y temperatura. Al comparar este modelo con otro más simple que omitía el comportamiento y la fisiología, encontraron que el IBM predijo de manera más efectiva los eventos de varamiento en el mar Balear. Esto resalta la importancia de incluir variables fisiológicas y de comportamiento en los modelos para mejorar su capacidad predictiva.

En el mar de Liguria, Ferraris *et al.* (2012) realizaron un monitoreo bimensual de la densidad superficial de *P. noctiluca* a lo largo de un transecto costero que se extendía hasta mar abierto. Sus observaciones revelaron que, durante el día, la presencia de medusas era escasa, mientras que por la noche se registraba una abundancia constante en zonas alejadas de la costa, disminuyendo notablemente dentro de los primeros 5 km. Estos resultados sugieren que las proliferaciones costeras podrían estar asociadas con el transporte de poblaciones oceánicas permanentes hacia la costa bajo condiciones hidrodinámicas específicas.

En el estrecho de Mesina, Bergamasco *et al.* (2022) investigaron la conectividad entre el archipiélago de las Islas Eolias y el estrecho adyacente mediante observaciones directas y modelos numéricos. Su estudio buscó determinar si el área alrededor del archipiélago actuaba como una zona fuente para *P. noctiluca*, con individuos transportados al estrecho a través de corrientes descendentes en cañones submarinos. Los resultados apoyaron la hipótesis de conectividad entre estos ecosistemas, indicando que las áreas costeras del archipiélago podrían ser óptimas para las etapas larvales.

En el mar de Alborán, Bellido *et al.* (2020) investigaron la incidencia de enjambres de medusas en la provincia de Málaga entre 2005 y 2018, utilizando informes de medios locales y datos de ciencia ciudadana recopilados mediante la aplicación móvil Infomedusa. Los autores analizaron el efecto de diferentes índices macroclimáticos, como la Oscilación del Atlántico Norte (NAO, *North Atlantic Oscillation*) y la Oscilación del Ártico (AO, *Arctic Oscillation*), sobre la variabilidad interanual en la incidencia de enjambres. Su estudio demostró que los años con incidencia media de medusas en verano estaban asociados con valores de AO y NAO del invierno previo que conducían a temperaturas superficiales del mar más altas.

Gutiérrez-Estrada *et al.* (2021) exploraron el uso de datos textuales de la aplicación Infomedusa, procesados mediante una red de transición aumentada, para modelar la relación entre la abundancia estimada de medusas en playas y las condiciones ambientales locales, específicamente la velocidad y dirección del viento. Sus Modelos Aditivos Generalizados (GAMs, *Generalized Additive Models*) explicaron entre el 37% y el 77% de la variabilidad en la abundancia de medusas estimada a partir de los datos de la aplicación.

Adicionalmente, los datos de Infomedusa también han sido utilizados por Castro-Gutiérrez *et al.* (2022, 2024), quienes demostraron que las técnicas de inteligencia artificial, particularmente las redes neuronales artificiales y la lógica difusa, pueden abordar eficazmente la escasez de datos sobre la incidencia de medusas en las áreas costeras del norte del mar de Alborán. Al emplear sistemas basados en reglas difusas y modelar los comentarios en lenguaje natural de los ciudadanos en la aplicación Infomedusa, confirmaron que factores ambientales locales, como la dirección y velocidad del viento, desempeñan un papel significativo en la ocurrencia de enjambres de medusas en esta región.

La integración de sistemas de inteligencia artificial con datos de aplicaciones de ciencia ciudadana como Infomedusa aprovecha la colaboración pública para comprender los factores climáticos que impulsan la proliferación costera de estos organismos gelatinosos. Dado que el plancton gelatinoso es transportado por las corrientes marinas, sería factible predecir que una floración observada en una parte del océano se desplazará hacia otra según las corrientes predominantes (Boero, 2013).

Más recientemente, de la Fuente Roselló *et al.* (2024) desarrollaron un modelo predictivo para identificar la susceptibilidad de las playas de la Costa del Sol a la llegada de enjambres de medusas, utilizando datos de la aplicación Infomedusa durante el periodo estival de 2015 a 2020. Su enfoque se basó en variables estructurales (como la orientación de la playa, la protección lateral o el ángulo de apertura) y circunstanciales (como la dirección del viento o la deriva litoral), aplicando regresión logística binaria para evaluar su influencia en la presencia de medusas. Aunque el modelo mostró una capacidad predictiva moderada, permitió identificar tipologías de playa más propensas a la llegada de estos organismos, destacando el papel de la orientación hacia el este o sur, la presencia de estructuras de protección y la exposición a corrientes de deriva mediterránea.

Estos estudios subrayan la importancia de combinar modelos físicos, biológicos y tecnológicos para comprender y anticipar la dinámica de las medusas en el Mediterráneo y, específicamente, en el mar de Alborán. La implementación de sistemas de alerta temprana basados en estos modelos puede facilitar la adopción de medidas preventivas y de mitigación por parte de las autoridades y comunidades costeras, asegurando una mejor gestión de los impactos ecológicos y socioeconómicos de las proliferaciones de medusas.

1.7. Brechas de conocimiento y futuras líneas de investigación

A pesar de los avances en la comprensión de la ecología de las medusas y sus impactos, persisten diversas lagunas de conocimiento que dificultan el desarrollo de estrategias de gestión integrales.

Una de las principales deficiencias es la escasez de datos a largo plazo y de alta resolución sobre las poblaciones de medusas en el mar de Alborán. Los registros históricos suelen ser esporádicos e inconsistentes, lo que dificulta la identificación de tendencias claras en la abundancia y distribución de medusas. Esta falta de datos impide evaluar si los aumentos observados en las proliferaciones de medusas forman parte de ciclos naturales o son impulsados por factores antropogénicos. Por lo tanto, es fundamental establecer programas de monitoreo estandarizados a largo plazo para generar conjuntos de datos confiables que permitan analizar tendencias.

Otra área que requiere mayor atención es el conocimiento detallado sobre los ciclos de vida de las medusas, en particular las primeras etapas de desarrollo de especies como *Pelagia noctiluca*. Aunque la fase de medusa está bien documentada, el conocimiento sobre las larvas plánulas y las éfiras, incluyendo sus tasas de supervivencia, mecanismos de dispersión y tolerancias ambientales, sigue siendo insuficiente. La investigación centrada en estas fases proporcionaría información clave sobre los factores que influyen en la dinámica poblacional y la formación de proliferaciones.

Las interacciones ecológicas entre las medusas y otros organismos marinos tampoco se comprenden completamente. Si bien se reconoce a las medusas como depredadores y presas dentro de los ecosistemas marinos, aún se desconoce en gran medida el impacto de su predación sobre larvas de peces y comunidades de zooplancton. Cuantificar sus tasas de depredación y su competencia con especies de peces es crucial

para evaluar su papel en la alteración de las redes tróficas y sus efectos sobre los recursos pesqueros.

El cambio climático introduce incertidumbres adicionales. Los efectos específicos del calentamiento oceánico, la acidificación y la hipoxia sobre la fisiología y el éxito reproductivo de las medusas son áreas donde el conocimiento sigue siendo limitado. Comprender cómo estos factores influyen en las poblaciones de medusas permitirá predecir la ocurrencia de proliferaciones bajo diferentes escenarios climáticos futuros.

Las influencias antropogénicas, como la sobrepesca, la modificación de hábitats y la contaminación, han sido señaladas como posibles impulsores de las proliferaciones de medusas, pero los mecanismos subyacentes no están completamente esclarecidos. Se necesita más investigación para cuantificar el impacto de estas actividades en la ecología de las medusas. Por ejemplo, estudios que examinen la relación entre la disminución de las poblaciones de peces y la proliferación de medusas podrían proporcionar información clave para la gestión sostenible de las pesquerías.

En cuanto a los impactos socioeconómicos, es necesario realizar evaluaciones económicas completas sobre las proliferaciones de medusas en las comunidades costeras. Cuantificar los costos directos e indirectos para la pesca, la acuicultura, el turismo y la salud pública permitirá comprender mejor las implicaciones económicas de estos eventos. Además, explorar las dimensiones sociales, como la percepción comunitaria y las respuestas adaptativas ante la presencia de medusas, puede contribuir a desarrollar estrategias de comunicación y gestión más efectivas.

Respecto a la utilización de medusas como recurso, existen lagunas de conocimiento sobre la viabilidad y sostenibilidad de su pesca y acuicultura. Es necesario investigar su valor nutricional, los posibles riesgos para la salud y la aceptación por parte de los consumidores para desarrollar mercados viables. Asimismo, evaluar las implicaciones ecológicas de la extracción de medusas es esencial para evitar consecuencias no deseadas en los ecosistemas marinos.

Las limitaciones tecnológicas en el monitoreo y la modelización también representan desafíos. Si bien se han logrado avances, mejorar la precisión y la resolución de los modelos predictivos sigue siendo una prioridad. La integración de datos multidisciplinarios, el fortalecimiento de las capacidades de teledetección y el desarrollo

de algoritmos más sofisticados pueden mejorar significativamente las capacidades de predicción.

Finalmente, se requiere investigación orientada a la formulación de políticas que cierre la brecha entre los hallazgos científicos y las acciones de gestión. Evaluar la efectividad de las medidas de gestión existentes y desarrollar estrategias adaptativas basadas en la evidencia científica garantizará que las políticas sean receptivas a las condiciones ambientales cambiantes y al conocimiento emergente.

1.8. Conservación y gestión de las medusas en el mar de Alborán

Los hallazgos de esta revisión han evidenciado la compleja interacción entre los factores ambientales, las actividades antropogénicas y las proliferaciones de medusas, destacando la necesidad de un enfoque holístico y basado en la evidencia para la conservación y gestión de los recursos marinos en el mar de Alborán.

1.8.1. Estrategias de conservación y gestión basadas en la evidencia

La implementación de estrategias de conservación efectivas requiere la integración de la investigación científica en los procesos de formulación de políticas y toma de decisiones. El desarrollo de modelos predictivos y sistemas de alerta temprana basados en indicadores ambientales puede facilitar la anticipación de eventos de proliferación de medusas. Estas herramientas permiten respuestas oportunas, favoreciendo la implementación de medidas de mitigación para proteger la pesca, la acuicultura y las actividades turísticas.

Las estrategias de gestión deben priorizar enfoques basados en el ecosistema que consideren el contexto ecológico más amplio. Esto incluye la regulación de las actividades pesqueras para evitar la sobreexplotación de los recursos que compiten con las medusas o que son sus depredadores. El fortalecimiento de las poblaciones de peces podría contribuir a restaurar los equilibrios ecológicos y reducir la probabilidad de que las medusas dominen la red trófica.

Abordar el problema de la eutrofización mediante una mejor gestión de residuos y la reducción del aporte de nutrientes es también una prioridad. La implementación de

regulaciones más estrictas sobre las descargas agrícolas e industriales puede mitigar la proliferación de medusas al limitar el exceso de nutrientes que favorecen su crecimiento.

En el sector acuícola, la adopción de mejores prácticas y la inversión en tecnologías de protección pueden minimizar las pérdidas provocadas por incursiones de medusas. Barreras físicas, monitoreo mejorado y protocolos de respuesta rápida pueden aumentar la resiliencia de las instalaciones acuícolas frente a este fenómeno.

Para la industria turística, el desarrollo de estrategias integrales de comunicación de riesgos es esencial. Proporcionar información precisa sobre la presencia de medusas, las medidas de seguridad y los protocolos de tratamiento puede ayudar a mitigar percepciones negativas y mantener la confianza de los turistas. Las inversiones en infraestructura, como la instalación de redes anti-medusas en zonas de baño, pueden mejorar la seguridad en las playas y reducir la incidencia de picaduras.

1.8.2. Integración de la investigación en políticas y decisiones de gestión

La gestión efectiva de las proliferaciones de medusas requiere la integración de los hallazgos científicos en los marcos normativos. La colaboración entre investigadores, responsables de políticas, actores industriales y comunidades locales es vital para garantizar que las estrategias de manejo estén fundamentadas en la evidencia científica más reciente y sean socialmente aceptables.

El establecimiento de grupos de trabajo interdisciplinarios o paneles asesores puede facilitar la traducción de la investigación en políticas concretas. Estos grupos pueden identificar áreas prioritarias de intervención, evaluar los impactos potenciales de las medidas propuestas y recomendar estrategias de gestión adaptativa en respuesta a condiciones cambiantes.

La promoción de la cooperación internacional es especialmente relevante dado el carácter transfronterizo de los ecosistemas marinos y las poblaciones de medusas. Los esfuerzos colaborativos pueden armonizar los programas de monitoreo, compartir datos y coordinar acciones de gestión en toda la región mediterránea.

Instrumentos de política, como la ordenación del espacio marítimo, pueden utilizarse para equilibrar los intereses de los distintos sectores mientras se conserva la biodiversidad marina. La designación de áreas protegidas o la implementación de cierres

temporales durante las temporadas de máxima proliferación de medusas pueden ayudar a mitigar los impactos sobre los ecosistemas vulnerables y las actividades económicas.

Invertir en programas de educación y divulgación pública puede mejorar la participación comunitaria y el apoyo a las iniciativas de gestión. Aumentar la concienciación sobre el papel ecológico de las medusas, los factores que contribuyen a su proliferación y la importancia de prácticas sostenibles pueden fomentar un sentido de responsabilidad colectiva y promover cambios de comportamiento que beneficien al medio marino.

Las medusas representan un componente esencial y dinámico del ecosistema marino del mar de Alborán. Su influencia en las redes tróficas, junto con los desafíos socioeconómicos que implican sus proliferaciones, subraya la necesidad imperativa de una vigilancia constante. El monitoreo continuo y la investigación sostenida son fundamentales para comprender plenamente la dinámica poblacional de estas especies y anticipar sus impactos.

Solo a través de un firme compromiso con la ciencia y la colaboración interdisciplinaria se podrán desarrollar estrategias de gestión efectivas que protejan tanto la biodiversidad marina como los intereses económicos y sociales de las comunidades costeras. De cara al futuro, es crucial que la investigación sobre medusas se integre coherentemente en las políticas de conservación y que se fortalezcan los esfuerzos para mitigar los efectos del cambio climático y las actividades humanas en el mar de Alborán. Este enfoque proactivo garantizará la sostenibilidad y resiliencia de este valioso ecosistema para las generaciones futuras.

1.9. Conclusiones

Esta revisión exhaustiva ha explorado el papel multifacético de las medusas en la región del mar de Alborán, destacando sus características biológicas, su importancia ecológica y los impactos socioeconómicos de sus proliferaciones.

El análisis biológico subrayó los complejos ciclos de vida de las medusas, destacando la naturaleza holoplanctónica de *P. noctiluca*, diferenciándola de otros escifozoos. Esta adaptación contribuye a su resiliencia y capacidad de crecimiento poblacional rápido bajo diferentes condiciones ambientales. Además, la revisión de su ecología trófica reveló que las medusas son depredadores activos y un componente significativo en las redes alimentarias marinas.

El estudio también destacó la presencia histórica de proliferaciones de medusas en el Mediterráneo, con registros que datan del siglo XVIII. Se observó un aparente aumento en la frecuencia e intensidad de estos eventos en las últimas décadas, aunque esta tendencia varía según la región. Los factores que impulsan estas proliferaciones son complejos e incluyen una combinación de factores ambientales e influencias antrópicas.

Una parte significativa del análisis se centró en los impactos socioeconómicos de las proliferaciones de medusas. Estos eventos afectan diversos sectores económicos, especialmente la pesca, la acuicultura y el turismo. Para mitigar estos impactos, se han implementado diversas estrategias de gestión, que van desde la remoción física de medusas en áreas recreativas hasta el desarrollo de campañas de educación pública y sistemas de alerta temprana. Sin embargo, estas medidas suelen abordar los síntomas en lugar de las causas subyacentes de las proliferaciones. En este contexto, se exploró el potencial de las medusas como recurso, resaltando oportunidades en la industria alimentaria, farmacéutica, agrícola y biotecnológica.

Los avances metodológicos y tecnológicos han mejorado significativamente la comprensión de la dinámica de las medusas. La innovación en técnicas de muestreo, teledetección, métodos moleculares e iniciativas de ciencia ciudadana ha fortalecido el monitoreo y la recopilación de datos. Además, el modelado y el análisis de datos, con el apoyo de inteligencia artificial y algoritmos predictivos, han proporcionado información valiosa sobre los factores ambientales que impulsan las proliferaciones y han facilitado el desarrollo de herramientas de predicción.

1.10. Referencias

- Alipour, H., Olya, H. G., Maleki, P., Dalir, S. 2020. Behavioral responses of 3S tourism visitors: Evidence from a Mediterranean Island destination. *Tourism Management Perspectives* 33, 100624.
- Angel, D. L., Edelist, D., Freeman, S. 2016. Local perspectives on regional challenges: jellyfish proliferation and fish stock management along the Israeli Mediterranean coast. *Regional Environmental Change* 16, 315-323.
- Aouititen, M., Bekkali, R., Nachit, D., Luan, X., Mrhraoui, M. 2019. Predicting jellyfish strandings in the Moroccan North-West Mediterranean coastline. *European Scientific Journal* 15(2), 72-84.
- Aouititen, M., Ravibhanu, A., Ang, S. C., Magabandi Mouanda, D. C., Luan, X. 2024. New records of two jellyfish species *Rhizostoma luteum* (Quoy and Gaimard 1827) and *Cotylorhiza tuberculata* (Macri 1778) in the Moroccan northwest Mediterranean coast. *Discover Life* 54, 5.
- Aouititen, M., Ravibhanu, A., Mrhraoui, M., Luan, X. F. 2021. Causes of outbreak *Pelagia noctiluca* in M'Diq beach, northwest Moroccan Mediterranean coastline. *Indian Journal of Ecology* 48(2), 519-523.
- Arai, M. N. 1997. *A functional biology of Scyphozoa*. Springer Science & Business Media.
- Arai, M. N. 2005. Predation on pelagic coelenterates: a review. *Journal of the Marine Biological Association of the United Kingdom* 85(3), 523-536.
- Arai, M. N., Welch, D. W., Dunsmuir, A. L., Jacobs, M. C., Ladouceur, A. R. 2003. Digestion of pelagic Ctenophora and Cnidaria by fish. *Canadian Journal of Fisheries and Aquatic Sciences* 60(7), 825-829.
- Arazy, O., Malkinson, D. 2021. A framework of observer-based biases in citizen science biodiversity monitoring: Semi-structuring unstructured biodiversity monitoring protocols. *Frontiers in Ecology and Evolution* 9, 1–13.
- Armani, A., Tinacci, L., Giusti, A., Castigliengo, L., Gianfaldoni, D., Guidi, A. 2013. What is inside the jar? Forensically informative nucleotide sequencing (FINS) of a short

- mitochondrial COI gene fragment reveals a high percentage of mislabeling in jellyfish food products. *Food Research International* 54(2), 1383-1393.
- Atkinson, D., Bartholomew, J.L., Lotan, T. 2018. Myxozoans: ancient metazoan parasites find a home in phylum Cnidaria. *Zoology* 129, 66-68.
- Attrill, M. J., Wright, J., Edwards, M. 2007. Climate-related increases in jellyfish frequency suggest a more gelatinous future for the North Sea. *Limnology and Oceanography* 52(1), 480-485.
- Aubert, A., Antajan, E., Lynam, C., Pitois, S., Pliru, A., Vaz, S., Thibault, D. 2018. No more reason for ignoring gelatinous zooplankton in ecosystem assessment and marine management: concrete cost-effective methodology during routine fishery trawl surveys. *Marine Policy* 89, 100-108.
- Avian, M., Rottini-Sandrini, L., Stravisi, F. 1991. The effect of seawater temperature on the swimming activity of *Pelagia noctiluca*. *Bollettino Di Zoologia* 58, 135-141.
- Axiak, V. 1984. Effect of decreasing light intensity on the activity of the scyphomedusa *Pelagia noctiluca* (Forsskål). En *UNEP: Workshop on Jellyfish Blooms in the Mediterranean* (pp. 121-127), 31 de octubre – 4 de noviembre de 1983. Atenas, Grecia.
- Ayed, Y., Dellai, A., Mansour, H. B., Bacha, H., Abid, S. 2012. Analgesic and antibutyrylcholinestrasic activities of the venom prepared from the Mediterranean jellyfish *Pelagia noctiluca* (Forsskål, 1775). *Annals of Clinical Microbiology and Antimicrobials* 11, 1-8.
- Ayed, Y., Sghaier, R. M., Laouini, D., Bacha, H. 2016. Evaluation of anti-proliferative and anti-inflammatory activities of *Pelagia noctiluca* venom in Lipopolysaccharide/Interferon- γ stimulated RAW264.7 macrophages. *Biomedicine & Pharmacotherapy* 84, 1986-1991.
- Báez, J. C., Pennino, M. G., Albo-Puigserver, M., Coll, M., Giraldez, A., Bellido, J. M. 2022. Effects of environmental conditions and jellyfish blooms on small pelagic fish and fisheries from the Western Mediterranean Sea. *Estuarine, Coastal and Shelf Science* 264, 107699.

- Ballesteros, A., Östman, C., Santín, A., Marambio, M., Narda, M., Gili, J. M. 2021. Cnidome and morphological features of *Pelagia noctiluca* (Cnidaria: Scyphozoa) throughout the different life cycle stages. *Frontiers in Marine Science* 8, 714503.
- Ballesteros, A., Páez, D., Santín, A., García, A., Martín, Y., Alonso, E., Jourdan, E., Gili, J. M. 2022. Successful culture of *Pelagia noctiluca* (Cnidaria: Scyphozoa) over time: a continuous supply of the holoplanktonic jellyfish for research and industrial applications. *Frontiers in Marine Science* 9, 911383.
- Barbosa Santos, T., Reimer, J. D., Acuña, F. H., Stampar, S. N. 2020. Diversity of feeding in Anthozoa (Cnidaria): A systematic review. *Diversity* 12(10), 405.
- Bastian, T., Haberlin, D., Purcell, J. E., Hays, G. C., Davenport, J., McAllen, R., Doyle, T. K. 2011. Large-scale sampling reveals the spatio-temporal distributions of the jellyfish *Aurelia aurita* and *Cyanea capillata* in the Irish Sea. *Marine Biology* 158, 2639-2652.
- Baxter E. J., Albinyana, G., Girons, A., Isern, M. M., García, A. B., Lopez, M., Canepa, A., Olariaga, A., Gili, J.-M., Fuentes, V. 2011b. Jellyfish-inflicted gill damage in marine-farmed fish: an emerging problem for the Mediterranean?. En *XIII Congreso Nacional de Acuicultura*, 21-24 de noviembre de 2011. Barcelona, España.
- Baxter, E. J., Rodger, H. D., McAllen, R., Doyle, T. K. 2011a. Gill disorders in marine-farmed salmon: investigating the role of hydrozoan jellyfish. *Aquaculture Environment Interactions* 1(3), 245-257.
- Beckmann, A., Özbek, S. 2012. The nematocyst: A molecular map of the cnidarian stinging organelle. *International Journal of Developmental Biology* 56(6-8), 577-582.
- Behera, P. R., Raju, S. S., Jishnudev, M. A., Ghosh, S., Saravanan, R. 2020. Emerging jellyfish fisheries along Central South East coast of India. *Ocean & Coastal Management* 191, 105183.
- Bellido, J. J., Baez, J. C., Souviron-Priego, L., Ferri-Yanez, F., Salas, C., López, J. A., Real, R. 2020. Atmospheric indices allow anticipating the incidence of jellyfish coastal swarms. *Mediterranean Marine Science* 21(2), 289-297.

- Benedetti-Cecchi, L., Canepa, A., Fuentes, V., Tamburello, L., Purcell, J. E., Piraino, S., Roberts, J., Boero, F., Halpin, P. 2015. Deterministic factors overwhelm stochastic environmental fluctuations as drivers of jellyfish outbreaks. *PLoS ONE* 10(10), e0141060.
- Benyoub, B., Kada, O., El Ouarghi, H., Mghili, B., Aknaf, A. 2023. Biodiversity and frequency of occurrence of jellyfish (*cnidaria*) in Al Hoceima Bay (North coast of Morocco, Alboran Sea). *E3S Web of Conferences* 364, 01003.
- Bergamasco, A., Cucco, A., Guglielmo, L., Minutoli, R., Quattrocchi, G., Guglielmo, R., Palumbo, F., Pansera, M., Zagami, G., Vodopivec, M., Malej, A., Granata, A. 2022. Observing and modeling long-term persistence of *P. noctiluca* in coupled complementary marine systems (Southern Tyrrhenian Sea and Messina Strait). *Scientific Reports* 12(1), 14905.
- Bernard, P., Berline, L., Gorsky, G. 2011. Long term (1981–2008) monitoring of the jellyfish *Pelagia noctiluca* (Cnidaria, Scyphozoa) on the French Mediterranean Coasts. *Journal of Oceanography, Research and Data* 4, 1-10.
- Bernier, E. T., Sánchez, R. R., Díaz, B. R. 2014. La crisis económica en el sector turístico. Un análisis de sus efectos en la Costa del Sol. *Revista de análisis turístico* 18, 11-18.
- Berzins, I. K., Yanong, R. P., LaDouceur, E. E., Peters, E. C. 2021. Cnidaria. En E. E. LaDouceur (Ed.), *Invertebrate Histology* (pp. 55-86). John Wiley & Sons.
- Boero, F. 2013. Review of jellyfish blooms in the Mediterranean and Black Sea. *General Fisheries Commission for the Mediterranean. Studies and Reviews* 92.
- Boero, F., Bouillon, J., Gravili, C., Miglietta, M. P., Parsons, T., Piraino, S. 2008. Gelatinous plankton: irregularities rule the world (sometimes). *Marine ecology progress series* 356, 299-310.
- Boero, F., Brotz, L., Gibbons, M. J., Piraino, S., Zampardi, S. 2016. Impacts and effects of ocean warming on jellyfish. En D. Laffoley, Baxter, J. M. (Eds.) *Explaining ocean warming: Causes, scale, effects and consequences* (pp. 213-237). IUCN.
- Boero, F., Mills, C. E. 1997. Agricultural versus ethological oceanography. *Trends in Ecology and Evolution* 12, 208-209.

- Bonaccorsi, G., Garamella, G., Cavallo, G., Lorini, C. 2020. A systematic review of risk assessment associated with jellyfish consumption as a potential novel food. *Foods* 9(7), 935.
- Bordehore, C., Alonso, C., Sánchez-Fernández, L., Canepa, A., Acevedo, M., Nogué, S., Fuentes, V. L. 2016. Lifeguard assistance at Spanish Mediterranean beaches: Jellyfish prevail and proposals for improving risk management. *Ocean & Coastal Management* 131, 45-52.
- Bosch-Belmar, M., Azzurro, E., Pulis, K., Milisenda, G., Fuentes, V., Kéfi-Daly Yahia, O., Micallef, A., Deidun, A., Piraino, S. 2017. Jellyfish blooms perception in Mediterranean finfish aquaculture. *Marine Policy* 76, 1-7.
- Bosch-Belmar, M., Milisenda, G., Basso, L., Doyle, T. K., Leone, A., Piraino, S. 2020. Jellyfish Impacts on Marine Aquaculture and Fisheries. *Reviews in Fisheries Science & Aquaculture* 29(2), 242-259.
- Bouzahzah, M., El Menyari, Y. 2013. International tourism and economic growth: the case of Morocco and Tunisia. *The Journal of North African Studies* 18(4), 592-607.
- Brodeur, R. D., Link, J. S., Smith, B. E., Ford, M. D., Kobayashi, D. R., Jones, T. T. 2016. Ecological and economic consequences of ignoring jellyfish: a plea for increased monitoring of ecosystems. *Fisheries* 41(11), 630-637.
- Brodeur, R. D., Mills, C. E., Overland, J. E., Walters G. E., Schumacher, J. D. 1999. Evidence for a substantial increase in gelatinous zooplankton in the Bering Sea, with possible links to climate change. *Fisheries Oceanography* 8, 296-306.
- Brotz, L. 2016. Jellyfish fisheries—a global assessment. En D. Pauly, D. Zeller (Eds.), *Global atlas of marine fisheries: a critical appraisal of catches and ecosystem impacts* (pp. 110-124). Island Press.
- Brotz, L., Cheung, W. W., Kleisner, K., Pakhomov, E., Pauly, D. 2012. Increasing jellyfish populations: trends in large marine ecosystems. En J. E. Purcell, H. Mianzan, J. R., Frost (Eds.), *Jellyfish Blooms IV: Interactions with humans and fisheries* (pp. 3-20). Springer.

- Brotz, L., Pauly, D. 2012. Jellyfish populations in the Mediterranean Sea. *Acta Adriatica* 53(2), 213-232.
- Brotz, L., Pauly, D. 2017. Studying jellyfish fisheries: toward accurate national catch reports and appropriate methods for stock assessments. En G. L. Mariottini (Ed.), *Jellyfish: Ecology, Distribution Patterns and Human Interactions* (pp. 313-329) Nova Publishers.
- Brusca, R. C., Moore, W., Shuster, S. M. (Eds.) 2016. Phylum Cnidaria. En *Invertebrates*, (3ª Ed., pp. 265-326). Oxford University Press.
- Bujosa, A., Riera, A., Pons, P. J. 2015. Sun-and-beach tourism and the importance of intra-destination movements in mature destinations. *Tourism Geographies* 17(5), 780-794.
- Burton, P. M. 2008. Insights from diploblasts: the evolution of mesoderm and muscle. *Journal of Experimental Zoology. Part B: Molecular and Developmental Evolution* 310(1), 5-14.
- Canepa, A., Fuentes, V., Sabatés, A., Piraino, S., Boero, F., Gili, J. M. 2014. *Pelagia noctiluca* in the Mediterranean Sea. En K. A. Pitt, C. H. Lucas (Eds.), *Jellyish Blooms* (pp. 237-266). Springer.
- Cantarero-Prados, F. J., de la Fuente Roselló, A., López, J. J. B. 2023. El impacto de las medusas en el uso recreativo de las playas. Un enfoque desde la perspectiva del riesgo. *Cuadernos Geográficos* 62(1), 300-318.
- Cantarero-Prados, F. J., De-la-Fuente-Roselló, A. L., Reyes-Corredera, S. J. 2022. Analysis of the vulnerability of tourism and leisure to jellyfish swarms on the eastern Costa del Sol. A multiscalar and multi-temporal perspective. *Revista de Estudios Andaluces* 44, 8-31.
- Castro-Gutierrez, J., Gutiérrez-Estrada, J. C., Aroba, J., Pulido-Calvo, I., Peregrín, A., Báez, J. C., Bellido, J. J., Souviron-Priego, L. 2022. Estimation of jellyfish abundance in the south-eastern Spanish coastline by using an explainable artificial intelligence model based on fuzzy logic. *Estuarine, Coastal and Shelf Science* 277, 108062.

- Castro-Gutiérrez, J., Gutiérrez-Estrada, J. C., Báez, J. C. 2024. Using artificial neural networks and citizen science data to assess jellyfish presence along coastal areas. *Journal of Applied Ecology* 61(9), 2244-2257.
- Catry, P., Phillips, R. A., Phalan, B., Silk, J. R., Croxall, J. P. 2004. Foraging strategies of grey-headed albatrosses *Thalassarche chrysostoma*: integration of movements, activity and feeding events. *Marine Ecology Progress Series* 280, 261-273.
- Cegolon, L., Heymann, W. C., Lange, J. H., Mastrangelo, G. 2013. Jellyfish stings and their management: a review. *Marine drugs* 11(2), 523-550.
- Ceh, J., Gonzalez, J., Pacheco, A., Riascos, J. M. 2015. The elusive life cycle of scyphozoan jellyfish – metagenesis revisited. *Scientific Reports* 5, 12037.
- CIESM (Commission Internationale pour l'Exploration Scientifique de la mer Méditerranée). 2001. Gelatinous Zooplankton Outbreaks: Theory and Practice. *CIESM Workshop Series* 14, 112.
- Collins, A. G. 2009. Recent insights into cnidarian phylogeny. *Smithsonian Contributions to the Marine Sciences* 38, 139-149.
- Condon, R. H., Graham, W. M., Duarte, C. M., Pitt, K. A., Lucas, C. H., Haddock, S. H. D., Sutherland, K. R., Robinson, K. L., Dawson, M. N., Decker, M. B., Mills, C. E., Purcell, J. E., Malej, A., Mianzan, H., Uye, S., Gelcich, S., Madin, L. P. 2012. Questioning the rise of gelatinous zooplankton in the world's oceans. *Bioscience* 62(2), 160-169.
- Costa, R., Capillo, G., Albergamo, A., Li Volsi, R., Bartolomeo, G., Bua, G., Ferracane, A., Savoca, S., Gervasi, T., Rando, R., Dugo, G., Spanò, N. 2019. A multi-screening Evaluation of the Nutritional and Nutraceutical Potential of the Mediterranean Jellyfish *Pelagia noctiluca*. *Marine drugs* 17(3), 172.
- Crowley-Cyr, L., Gershwin, L. A., Bremser, K., Abraham, V., Martin, M. J. M., Carreño, M., Wüst, K. 2022. Jellyfish risk communications: The effect on risk perception, travel intentions and behaviour, and beach tourism destinations. *Journal of Hospitality and Tourism Management* 51, 196-206.

- Cushing, D. H. 1989. A difference in structure between ecosystems in strongly stratified waters and in those that are only weakly stratified. *Journal of Plankton Research* 11(1), 1-13.
- D'Ambra, I., Malej, A. 2015. Scyphomedusae of the Mediterranean: state of the art and future perspectives. *Central Nervous System Agents in Medicinal Chemistry* 15(2), 81-94.
- Daly-Yahia, M. N., Batistić, M., Lučić, D., Fernández De Puellas, M. L., Licandro, P., Malej, A., Molinero, J. C., Siokou-Frangou, I., Zervoudaki, S., Prieto, L., Goy, J., Yahia-Kéfi, O. D. 2010. Are the outbreaks of *Pelagia noctiluca* more frequent in the Mediterranean basin? *ICES Cooperative Research Report* 300, 8-14.
- Daryanbard, R., Dawson, M. N. 2008. Jellyfish blooms: *Crambionella orsini* (Scyphozoa: Rhizostomeae) in the Gulf of Oman, Iran, 2002-2003. *Journal of the Marine Biological Association of the United Kingdom* 88(3), 477-483.
- Dawson, M. N., Hamner, W. M. 2009. A character-based analysis of the evolution of jellyfish blooms: adaptation and exaptation. *Hydrobiologia* 616, 193-215.
- De Donno, A., Idolo, A., Bagordo, F., Grassi, T., Leomanni, A., Serio, F., Guido, M., Canitano, M., Zampardi, S., Boero, F., Piraino, S. 2014. Impact of stinging jellyfish proliferations along south Italian coasts: Human health hazards, treatment and social costs. *International journal of environmental research and public health* 11(3), 2488-2503.
- de la Fuente Roselló, A., Perles Roselló, M. J., Cantarero Prados, F. J. 2024. A Predictive Analysis of Beach Susceptibility to Jellyfish Arrivals in Costa del Sol. *Journal of Marine Science and Engineering* 12(12), 2316.
- Dobson, J. Y., Fonfría, E. S., Flores-García, A., Bordehore, C. 2024. Epidemiology of jellyfish stings using the Sting Index to identify trends and support proactive management. *Ocean & Coastal Management* 256, 107308.
- Dobson, J. Y., Fonfría, E. S., Palacios, R., Blasco, E., Bordehore, C. 2023. Citizen science effectively monitors biogeographical and phenological patterns of jellyfish. *Ocean & Coastal Management* 242, 106668.

- Dong, Z., Liu, D., Keesing, J. K. 2010. Jellyfish blooms in China: dominant species, causes and consequences. *Marine Pollution Bulletin* 60(7), 954-963.
- Doyle, T. K., Hays, G. C., Harrod, C., Houghton, J. D. 2014. Ecological and societal benefits of jellyfish. En K. Pitt, C. Lucas (Eds.), *Jellyfish blooms* (pp. 105-127). Springer.
- Duarte, I. M., Marques, S. C., Leandro, S. M., Calado, R. 2022. An overview of jellyfish aquaculture: for food, feed, pharma and fun. *Reviews in Aquaculture* 14(1), 265-287.
- Dupont, N., Klevjer, T. A., Kaartvedt, S., Aksnes, D. L. 2009. Diel vertical migration of the deepwater jellyfish *Periphylla periphylla* simulated as individual responses to absolute light intensity. *Limnology and Oceanography* 54, 1765-1775.
- Durán-Fuentes, J., Gracia C. A., Osorio M. C., Cedeño-Posso, C. 2018. Aporte al conocimiento de las medusas (Cnidaria: Medusozoa) en el departamento del Atlántico, Colombia. *Revista De La Academia Colombiana De Ciencias Exactas, Físicas y Naturales* 42(162), 49-57.
- El Menyari, Y. 2021. Effect of tourism FDI and international tourism to the economic growth in Morocco: Evidence from ARDL bound testing approach. *Journal of Policy Research in Tourism, Leisure and Events* 13(2), 222-242.
- El Rahi, J., Weeber, M. P., El Serafy, G. 2020. Modelling the effect of behavior on the distribution of the jellyfish Mauve stinger (*Pelagia noctiluca*) in the Balearic Sea using an individual-based model. *Ecological Modelling* 433, 109230.
- Er-Ramy, N., Nachite, D., Anfuso, G., Williams, A. T. 2022. Coastal scenic quality assessment of Moroccan Mediterranean beaches: A tool for proper management. *Water* 14(12), 1837.
- FAO. 2018. *The future of food and agriculture – Alternative pathways to 2050*. Food and Agriculture of the United Nations.
- FAO. 2023. *The State of Mediterranean and Black Sea Fisheries 2023 – Special edition*. General Fisheries Commission for the Mediterranean.
- Fautin, D. G. 2009. Structural diversity, systematics, and evolution of cnidae, *Toxicon* 54(8), 0-1064.

- Fernández-Álías, A., Marcos, C., Pérez-Ruzafa, A. 2024. The unpredictability of scyphozoan jellyfish blooms. *Frontiers in Marine Science* 11, 1349956.
- Ferraris, M., Berline, L., Lombard, F., Guidi, L., Elineau, A., Mendoza-Vera, J. M., Lilley, M. K. S., Taillandier, V., Gorsky, G. 2012. Distribution of *Pelagia noctiluca* (Cnidaria, Scyphozoa) in the Ligurian Sea (NW Mediterranean Sea). *Journal of Plankton Research* 34(10), 874-885.
- Forsskål, P. 1775. *Descriptiones animalium, avium, amphibiorum, piscium, insectorum, vermium, quae in itinere orientale observavit Petrus Forsskål. Post mortem auctoris edidit Carsten Niebuhr*.
- Frazão, B., Campos, A., Osório, H., Thomas, B., Leandro, S., Teixeira, A., Vasconcelos, V., Antunes, A. 2017. Analysis of *Pelagia noctiluca* proteome reveals a red fluorescent protein, a zinc metalloproteinase and a peroxiredoxin. *The Protein Journal* 36, 77-97.
- Fuentes, V., Straehler-Pohl, I., Atienza, D., Franco, I., Tilves, U., Gentile, M., Acevedo, M., Olariaga, A., Gili, J.-M. 2011. Life cycle of the jellyfish *Rhizostoma pulmo* (Scyphozoa: Rhizostomeae) and its distribution, seasonality and inter-annual variability along the Catalan coast and the Mar Menor (Spain, NW Mediterranean). *Marine Biology* 158, 2247–2266.
- Ghermandi, A., Galil, B., Gowdy, J., Nunes, P. A. 2015. Jellyfish outbreak impacts on recreation in the Mediterranean Sea: welfare estimates from a socioeconomic pilot survey in Israel. *Ecosystem services* 11, 140-147.
- Gibbons, M. J., Boero, F., Brotz, L. 2016. We should not assume that fishing jellyfish will solve our jellyfish problem. *ICES Journal of Marine Science* 73(4), 1012-1018.
- Gissi, E., Manea, E., Mazaris, A. D., Frascchetti, S., Almpanidou, V., Bevilacqua, S., Coll, M., Guarnieri, G., Lloret-Lloret, E., Pascual, M., Petza, D., Rilov, G., Schonwald, M., Stelzenmüller, V., Katsanevakis, S. 2021. A review of the combined effects of climate change and other local human stressors on the marine environment. *Science of the Total Environment* 755(1), 142564.
- Goldstein, J., Steiner, U. K. 2020. Ecological drivers of jellyfish blooms – The complex life history of a ‘well-known’ medusa (*Aurelia aurita*). *Journal of Animal Ecology* 89(3), 910-920.

- Goy, J., Morand, P., Etienne, M., 1989. Long-term fluctuations of *Pelagia noctiluca* (Cnidaria, Scyphomedusa) in the western Mediterranean Sea. Prediction by climatic variables. *Deep Sea Research* 36(2), 269-279.
- Graham, W. M., Gelcich, S., Robinson, K. L., Duarte, C. M., Brotz, L., Purcell, J. E., Madin, L. P., Mianzan, H., Sutherland, K. R., Uye, S., Pitt, K. A., Lucas, C. H., Bøgeberg, M., Brodeur, R. D., Condon, R. H. 2014. Linking human well-being and jellyfish: ecosystem services, impacts, and societal responses. *Frontiers in Ecology and the Environment* 12(9), 515-523.
- Graham, W. M. 2001. Numerical increases and distributional shifts of *Chrysaora quinquecirrha* (Desor) and *Aurelia aurita* (Linné) (Cnidaria: Scyphozoa) in the northern Gulf of Mexico. *Hydrobiologia* 451, 97-111.
- Graham, W. M., Pagès, F., Hamner, W. M. 2001. A physical context for gelatinous zooplankton aggregations: a review. *Hydrobiologia* 451, 199-212.
- Griffin, D. C., Harrod, C., Houghton, J. D., Capellini, I. 2019. Unravelling the macro-evolutionary ecology of fish–jellyfish associations: life in the ‘gingerbread house’. *Proceedings of the Royal Society B* 286(1899), 20182325.
- Gutiérrez-Estrada, J. C., Pulido-Calvo, I., Peregrín, A., García-Gálvez, A., Báez, J. C., Bellido, J. J., Souviron-Priego, L., Sánchez-Laulhé, J. M., López, J. A. 2021. Integrating local environmental data and information from non-driven citizen science to estimate jellyfish abundance in Costa del Sol (southern Spain). *Estuarine, Coastal and Shelf Science* 249, 107112.
- Gutiérrez-Hernández, O., Rubio Gómez, A. 2023. Jellyfish Distribution and Abundance on the Southern Coast of the Iberian Peninsula. En M. L. De Lázaro Torres, R. De Miguel González (Eds.), *Sustainable Development Goals in Europe. Key Challenges in Geography*. Springer.
- Hamilton, G. 2016. The secret lives of jellyfish: long regarded as minor players in ocean ecology, jellyfish are actually important parts of the marine food web. *Nature* 531(7595), 432-435
- Hays, G. C., Doyle, T. K., Houghton, J. D. 2018. A paradigm shift in the trophic importance of jellyfish?. *Trends in Ecology & Evolution* 33(11), 874-884.

- Hecq, J. H., Goffart, A., Collignon, A., Piazza, S., Defreygne, P. S., Lejeune, P. 2009. La variabilité de la méduse *Pelagia noctiluca* (Forsskal, 1775) en Baie de Calvi (Corse) en relation avec l'environnement.
- Helmholz, H., Johnston, B., Ruhnau, C., Prange, A. 2010. Gill cell toxicity of northern boreal scyphomedusae *Cyanea capillata* and *Aurelia aurita* measured by an in vitro cell assay. *Hydrobiologia* 645, 223-234.
- Houghton, J. D., Doyle, T. K., Wilson, M. W., Davenport, J., Hays, G. C. 2006. Jellyfish aggregations and leatherback turtle foraging patterns in a temperate coastal environment. *Ecology* 87(8), 1967-1972.
- Hubot, N., Lucas, C. H., Piraino, S. 2017. Environmental control of asexual reproduction and somatic growth of *Aurelia* spp. (Cnidaria, Scyphozoa) polyps from the Adriatic Sea. *PLoS ONE* 12(6), e0178482.
- Jönsson, B. F., Watson, J. R. 2016. The timescales of global surface-ocean connectivity. *Nature communications* 7(1), 11239.
- Kawahara, M., Uye, S.-I., Ohtsu, K., Iizumi, H. 2006. Unusual population explosion of the giant jellyfish *Nemopilema nomurai* (Scyphozoa: Rhizostomeae) in East Asian waters. *Marine Ecology Progress Series* 307, 161-173.
- Kideys, A. E., Roohi, A., Bagheri, S., Finenko, G., Kamburska, L. 2005. Impacts of invasive ctenophores on the fisheries of the Black Sea and Caspian Sea. *Oceanography* 18(2), 76-85.
- Kienberger, K., Navarro, G., Prieto, L. 2016. High temporal resolution study all year round of *Pelagia noctiluca* in the NE Alboran Sea. En *5th International Jellyfish Bloom Symposium*, 30 de mayo - 3 de junio de 2016. Barcelona, España.
- Kienberger, K., Prieto, L. 2018. The jellyfish *Rhizostoma luteum* (Quoy & Gaimard, 1827): Not such a rare species after all. *Marine Biodiversity* 48, 1455-1462.
- Killi, N., Mariottini, G. L. 2018. Cnidarian jellyfish: ecological aspects, nematocyst isolation, and treatment methods of sting. En M. Kloc, J. Kubiak (Eds.), *Marine Organisms as Model Systems in Biology and Medicine. Results and Problems in Cell Differentiation* (Vol. 65, pp. 477-513). Springer.

- Kim, D.-H., Seo, J. N., Yoon, Y. D., Suh, Y.-S. 2012. Estimating the economic damage caused by jellyfish to fisheries in Korea. *Fisheries Science* 78, 1147-1152.
- Kingsford, M. J., Pitt, K. A. Gillanders, B. M. 2000. Management of jellyfish fisheries, with special reference to the Order Rhizostomeae. *Oceanography and Marine Biology* 38, 85-156.
- Knap, A. H., Michaels, A., Close, A. R., Ducklow, H., Dickson, A. G. 1996. Protocols for the joint global ocean flux study (JGOFS) core measurements. *JGOFS Report* 19.
- Kogovšek, T., Bogunović, B., Malej, A. 2010. Recurrence of bloom-forming scyphomedusae: wavelet analysis of a 200-year time series. *Hydrobiology* 212, 81-96.
- Kogovšek, T., Tinta, T., Klun, K., Malej, A. 2014. Jellyfish biochemical composition: importance of standardised sample processing. *Marine Ecology Progress Series* 510, 275-288.
- Komninos, A. 2019. Pro-social behaviour in crowdsourcing systems: Experiences from a field deployment for beach monitoring. *International Journal of Human-Computer Studies* 124, 93-115.
- Kroecker, K. J., Kordas, R. L., Crim, R. N., Singh, G. G. 2010. Meta-analysis reveals negative yet variable effects of ocean acidification on marine organisms. *Ecology letters*, 13(11), 1419-1434.
- Kumawat, T., Saravanan, R., Vinod, K., Jaiswar, A. K., Deshmukhe, G., Shenoy, L., Divu, D., Joshi, K. K., Gopalakrishnan, A. 2023. Jellyfish fisheries along the Gujarat coast, India: Status and challenges. *Marine Policy* 150, 105554.
- Lekakou, M., Tzannatos, E. 2001. Cruising and Sailing: A New Tourist Product for the Ionian Sea. *Volume in Honor of Emeritus Professor M. Rafael* (pp. 475-496). Universidad de El Pireo.
- Lilley, M. K. S., Elineau, A., Ferraris, M., Thiéry, A., Stemmann, L., Gorsky, G., Lombard, F., 2014. Individual shrinking to enhance population survival: quantifying the reproductive and metabolic expenditures of a starving jellyfish, *Pelagia noctiluca*. *Journal of Plankton Research* 36(6), 1585-1597.

- Link, J. S. 2007. Underappreciated species in ecology: “ugly fish” in the northwest Atlantic Ocean. *Ecological applications* 17(7), 2037-2060.
- Lo, W. T., Purcell, J. E., Hung, J. J., Su, H. M., Hsu, P. K. 2008. Enhancement of jellyfish (*Aurelia aurita*) populations by extensive aquaculture rafts in a coastal lagoon in Taiwan. *ICES Journal of Marine Science* 65(3), 453-461.
- Lucas, C. H., Dawson, M. N. 2014. What are jellyfishes and thaliaceans and why do they bloom? En K. Pitt, C. Lucas (Eds.), *Jellyfish Blooms* (pp. 9-44). Springer.
- Lucas, C. H., Gelcich, S., Uye, S.-I. 2014. Living with jellyfish: management and adaptation strategies. En K. Pitt, C. Lucas (Eds.), *Jellyfish blooms* (pp. 129-150). Springer.
- Lucas, C. H., Graham, W. M., Widmer, C. 2012. Jellyfish life histories: role of polyps in forming and maintaining scyphomedusa populations. *Advances in Marine Biology* 63, 133-196.
- Lynam, C. P., Gibbons, M. J., Axelsen, B. E., Sparks, C. A., Coetzee, J., Heywood, B. G., Brierley, A. S. 2006. Jellyfish overtake fish in a heavily fished ecosystem. *Current Biology* 16(13), R492-R493.
- Lynam, C. P., Heath, M. R., Hay, S. J., Brierley, A. S. 2005. Evidence for impacts by jellyfish on North Sea herring recruitment. *Marine Ecology Progress Series* 298, 157-167.
- Macali, A., Semenov, A., Venuti, V., Crupi, V., D’Amico, F., Rossi, B., Corsi, I., Bergami, E. 2018. Episodic records of jellyfish ingestion of plastic items reveal a novel pathway for trophic transference of marine litter. *Scientific Reports* 8(1), 6105.
- Macías, D., Prieto, L., García-Gorriz, E. 2021. A model-based management tool to predict the spread of *Physalia physalis* in the Mediterranean Sea. Minimizing risks for coastal activities. *Ocean & Coastal Management* 212, 105810.
- Malej, A., 1989. Behaviour and trophic ecology of the jellyfish *Pelagia noctiluca* (Forsskål, 1775). *Journal of Experimental Marine Biology and Ecology* 126, 259-270.
- Malej, A., Malej, A. 2004. Invasion of the Jellyfish *Pelagia noctiluca* in the Northern Adriatic: a non-success story. En H. Dumont, T. A. Shiganova, U. Niermann

- (Eds.), *Aquatic Invasions in the Black, Caspian, and Mediterranean Seas. Nato Science Series: IV: Earth and Environmental Sciences* 35 (pp. 273-285). Springer.
- Malej, A., Vuković, A., Vukovic, A., 1986. Some data on the metabolism of *Pelagia noctiluca* in the Gulf of Trieste. *Nova Thalassia* 8, 107-111.
- Marambio, M., Canepa, A., Lòpez, L., Gauci, A. A., Gueroun, S. K., Zampardi, S., Boero, F., Kéfi-Daly Yahia, O., Daly Yahia, M. N., Fuentes, V., Deidun, A. 2021. Unfolding jellyfish bloom dynamics along the Mediterranean basin by transnational citizen science initiatives. *Diversity* 13(6), 274.
- Marcos-López, M., Mitchell, S. O., Rodger, H. D. 2016. Pathology and mortality associated with the mauve stinger jellyfish *Pelagia noctiluca* in farmed Atlantic salmon *Salmo salar* L. *Journal of Fish Diseases* 39(1), 111-115.
- Mariottini, G. L., Giacco, E., Pane, L. 2008. The Mauve Stinger *Pelagia noctiluca* (Forsskål, 1775). Distribution, ecology, toxicity and epidemiology of stings. A review. *Marine Drugs* 6, 496-513.
- Mariottini, G. L., Pane, L. 2010. Mediterranean jellyfish venoms: A review on scyphomedusae. *Marine Drugs* 8(4), 1122-1152.
- Marques, A. C., Collins, A. G. 2004. Cladistic analysis of Medusozoa and cnidarian evolution. *Invertebrate Biology* 123(1), 23-42.
- Martin, V. J. 2002. Photoreceptors of cnidarians. *Canadian Journal of Zoology* 80(10), 1703-1722.
- Martin-Abadal, M., Ruiz-Frau, A., Hinz, H., Gonzalez-Cid, Y. 2020. Jellytoring: real-time jellyfish monitoring based on deep learning object detection. *Sensors* 20(6), 1708.
- Matsushita, Y., Honda, N. 2006. Method of designing and manufacturing JET (Jellyfish Excluder for Towed fishing gear) for various towed fishing gears. *Bulletin of Fisheries Research Agency* 16, 19-27.
- Mghili, B., Analla, M., Aksissou, M. 2022a. Medusae (Scyphozoa and hydrozoa) from the Moroccan Mediterranean coast: abundance and spatiotemporal dynamics and their economic impact. *Aquatic Ecology* 56(1), 213-226.

- Mghili, B., Analla, M., Aksissou, M. 2022b. Estimating the economic damage caused by jellyfish to fisheries in Morocco. *African Journal of Marine Science* 44(3), 271-277.
- Miles, J. G., Battista, N. A. 2019. Naut your everyday jellyfish model: exploring how tentacles and oral arms impact locomotion. *Fluids* 4(3), 169.
- Milisenda, G., Martinez-Quintana, A., Fuentes, V. L., Bosch-Belmar, M., Aglieri, G., Boero, F., Piraino, S. 2018. Reproductive and bloom patterns of *Pelagia noctiluca* in the Strait of Messina, Italy. *Estuarine, Coastal and Shelf Science* 201, 29-39.
- Milisenda, G., Rosa, S., Fuentes, V. L., Boero, F., Guglielmo, L., Purcell, J. E., Piraino, S. 2014. Jellyfish as prey: Frequency of predation and selective foraging of *Boops boops* (Vertebrata, Actinopterygii) on the Mauve Stinger *Pelagia noctiluca* (Cnidaria, Scyphozoa). *PLoS ONE* 9(4), e94600.
- Mills, C. E. 2001. Jellyfish blooms: are populations increasing globally in response to changing ocean conditions? *Hydrobiologia* 451, 55-68.
- Molinero, J. C., Ibanez, F., Nival, P., Buecher, E., Souissi, S. 2005. The North Atlantic climate and northwestern Mediterranean plankton variability. *Limnology and Oceanography* 50, 1213-1220.
- Möller, H. 1980. Population dynamics of *Aurelia aurita* medusae in the Kiel Bight, Germany (FRG). *Marine Biology* 60, 123-128.
- Morand, P., Carre, C., Biggs, D. C. 1987. Feeding and metabolism of the jellyfish *Pelagia noctiluca* (scyphomedusae, semaeostomae). *Journal of Plankton Research* 9(4), 651-665.
- Nastasi, A. 2010. Algal and jellyfish blooms in the Mediterranean and Black Sea: a brief review. En *General Fisheries Commission for the Mediterranean workshop on algal and jellyfish blooms in the Mediterranean and Black Sea*, 6-8 de octubre de 2010. Estambul, Turquía.
- Novosolov, M., Yahalomi, D., Chang, E. S., Fiala, I., Cartwright, P., Huchon, D. 2022. The phylogenetic position of the enigmatic, *Polypodium hydriforme* (Cnidaria, Polypodiozoa): insights from mitochondrial genomes. *Genome Biology and Evolution* 14(8), evac112.

- Nüchter, T., Benoit, M., Engel, U., Özbek, S., Holstein, T. W. 2006. Nanosecond-scale kinetics of nematocyst discharge. *Current Biology* 16(9), R316-R318.
- Nunes, P. A., Loureiro, M. L., Piñol, L., Sastre, S., Voltaire, L., Canepa, A. 2015. Analyzing beach recreationists' preferences for the reduction of jellyfish blooms: Economic results from a stated-choice experiment in Catalonia, Spain. *PLoS ONE* 10(6), e0126681.
- Nunoo, F. K. E., Boateng, J. O., Ahulu, A. M., Agyekum, K. A., Sumaila, U. R. 2009. When trash fish is treasure: the case of Ghana in West Africa. *Fisheries Research* 96(2-3), 167-172.
- Organización Mundial del Turismo. 2024. *UNWTO World Tourism Barometer* 22(1).
- Ottmann, D., Álvarez-Berastegui, D., Prieto, L., Balbín, R., Alemany, F., Fiksen, Ø., Gordo, A., Reglero, P. 2021. Abundance of *Pelagia noctiluca* early life stages in the western Mediterranean Sea scales with surface chlorophyll. *Marine Ecology Progress Series* 658, 75-88.
- Pagès, F. 2001. Past and present anthropogenic factors promoting the invasion, colonization and dominance by jellyfish of a Spanish coastal lagoon. En *Gelatinous zooplankton outbreaks: theory and practice*. CIESM Workshop Series 14 (pp. 69-71).
- Palmieri, M. G., Barausse, A., Luisetti, T., Turner, K. 2014. Jellyfish blooms in the Northern Adriatic Sea: Fishermen's perceptions and economic impacts on fisheries. *Fisheries Research* 155, 51-58.
- Pastor-Prieto, M., Bahamon, N., Sabatés, A., Canepa, A., Gili, J. M., Carreton, M., Company, J. B. 2021. Spatial heterogeneity of *Pelagia noctiluca* ephyrae linked to water masses in the Western Mediterranean. *PLoS ONE* 16(4), e0249756.
- Pauly, D., Graham, W., Libralato, S., Morissette, L., Deng Palomares, M. L. 2009. Jellyfish in ecosystems, online databases, and ecosystem models. *Hydrobiologia* 616, 67-85.
- Piccinetti-Manfrin, C., Piccinetti, C., Fiorentini, C. 1986. Distribuzione di *Pelagia noctiluca* in Adriatico negli anni 1983 e 1984. *Nova Thalassia* 8, 99-102.

- Piraino, S., Deidun, A., Fuentes, V., Daly-Yahia, M. N., Daly-Yahia, O., Marambio, M., Canepa, A., Olariaga, A., Gueroun, S. K. M., Aissi, M., Aglieri, G., Milisenda, G., Purcell, J. 2016. Are anti-jellyfish nets a useful mitigation tool for coastal tourism? Hindsight from the MED-JELLYRISK experience. En *5th International Jellyfish Bloom Symposium*. 30 de mayo - 3 de junio de 2016. Barcelona, España.
- Pitt, K. A., Lucas, C. H., Condon, R. H., Duarte, C. M., Stewart-Koster, B. 2018. Claims that anthropogenic stressors facilitate jellyfish blooms have been amplified beyond the available evidence: a systematic review. *Frontiers in Marine Science* 5, 451.
- Prieto, L. 2018. Diagnosis, prognosis, and management of jellyfish swarms. En E. Chassignet, A. Pascual, J. Tintoré, J. Verro (Eds.), *New Frontiers in Operational Oceanography* (pp. 737-758). GODAE OceanView.
- Prieto, L. 2021. *Physalia physalis* abundance on the shores in the Mediterranean Sea during 2010, 2013 and 2018 compiled by ICMAN (CSIC).
- Prieto, L., Armani, A., Macías, D. 2013. Recent strandings of the giant jellyfish *Rhizostoma luteum* Quoy and Gaimard, 1827 (Cnidaria: Scyphozoa: Rhizostomeae) on the Atlantic and Mediterranean coasts. *Marine Biology* 160, 3241-3247.
- Prieto, L., Deidun, A., Malej, A., Shiganova, T., Tirelli, V. 2016. *Coming to grips with the jellyfish phenomenon in the Southern European and other Seas: research to the rescue of coastal managers*. PERSEUS project.
- Prieto, L., Navarro, G. 2013. *Avistamientos de medusas en el litoral andaluz*. CSIC-Instituto de Ciencias Marinas de Andalucía (ICMAN).
- Purcell, J. E. 1991. A review of cnidarians and ctenophores feeding on competitors in the plankton. *Hydrobiologia* 216/217, 335-342.
- Purcell, J. E. 2005. Climate effects on formation of jellyfish and ctenophore blooms: a review. *Journal of the Marine Biological Association of the United Kingdom* 85(3), 461-476.
- Purcell, J. E. 2007. Environmental effects on asexual reproduction rates of the scyphozoan *Aurelia labiata*. *Marine Ecology Progress Series* 348, 183-196.


- Purcell, J. E. 2009. Extension of methods for jellyfish and ctenophore trophic ecology to large-scale research. *Hydrobiologia* 616, 23-50.
- Purcell, J. E. 2012. Jellyfish and ctenophore blooms coincide with human proliferations and environmental perturbations. *Annual Review of Marine Science* 4(1), 209-235.
- Purcell, J. E., Arai, M. N. 2001. Interactions of pelagic cnidarians and ctenophores with fish: a review. *Hydrobiologia* 451, 27-44.
- Purcell, J. E., Baxter, E. J., Fuentes, V. L. 2013. Jellyfish as products and problems of aquaculture. En G. Allan, G. Burnell (Eds.), *Advances in aquaculture hatchery technology* (pp. 404-430). Woodhead Publishing.
- Purcell, J. E., Graham, W. M., Dumont, H. J. (Eds.). 2001. *Jellyfish Blooms: Ecological and Societal Importance: Proceedings of the International Conference on Jellyfish Blooms*. Springer Science & Business Media.
- Purcell, J. E., Uye, S.-I., Wen-Tseng, L. 2007. Anthropogenic causes of jellyfish blooms and their direct consequences for humans: a review. *Marine Ecology Progress Series* 350, 153-174.
- Quiñones, J., Monroy, A., Acha, E. M., Mianzan, H. 2013. Jellyfish bycatch diminishes profit in an anchovy fishery off Peru. *Fisheries Research* 139, 47-50.
- Raposo, A., Alasqah, I., Alfheaid, H. A., Alsharari, Z. D., Alturki, H. A., Raheem, D. 2022. Jellyfish as food: A narrative review. *Foods* 11(18), 2773.
- Richardson, A. J., Bakun, A., Hays, G. C., Gibbons, M. J. 2009. The jellyfish joyride: Causes, consequences and management responses to a more gelatinous future. *Trends in Ecology & Evolution* 24(6), 312-322.
- Richardson, A. J., Gibbons, M. J. 2008. Are jellyfish increasing in response to ocean acidification?. *Limnology and Oceanography* 53(5), 2040-2045.
- Rinaldis, G., Leone, A., De Domenico, S., Bosch-Belmar, M., Slizyte, R., Milisenda, G., Santucci, A., Albano, C., Piraino, S. 2021. Biochemical characterization of *Cassiopea andromeda* (Forsskål, 1775), another red sea jellyfish in the Western Mediterranean Sea. *Marine Drugs* 19(9), 498.

- Rodger, H. D., Henry, L., Mitchell, S. O. 2011. Non-infectious gill disorders of marine salmonid fish. *Reviews in Fish Biology and Fisheries* 21, 423-440.
- Romero-Padilla, Y., Navarro-Jurado, E., Romero-Martínez, J. M. 2020. Destinos turísticos y capital creativo: el caso de la costa del sol en el sur de España. *Revista de Geografía Norte Grande* 77, 339-365.
- Rosa, S., Pansera, M., Granata, A., Guglielmo, L. 2013. Interannual variability, growth, reproduction and feeding of *Pelagia noctiluca* (Cnidaria: Scyphozoa) in the Straits of Messina (Central Mediterranean Sea): Linkages with temperature and diet. *Journal of Marine Systems* 111, 97-107.
- Rottini-Sandrini L. 1982. Effect of water temperature on the motility of *Pelagia noctiluca*. *Experientia* 38, 453-454.
- Rottini-Sandrini, L., Avian, M. 1983. Biological cycle of *Pelagia noctiluca*: morphological aspects of the development from planula to ephyra. *Marine Biology* 74(2), 169-174.
- Rottini-Sandrini, L., Avian, M. 1989. Feeding mechanism of *Pelagia noctiluca* (Scyphozoa: Semaestomeae); laboratory and open sea observations. *Marine Biology* 102, 49-55.
- Rottini-Sandrini, L., Avian, M. 1991. Reproduction of *Pelagia noctiluca* in the central and northern Adriatic Sea. *Hydrobiologia* 216, 197-202.
- Ruiz-Frau, A. 2023. Impacts of jellyfish presence on tourists' holiday destination choices and their willingness to pay for mitigation measures. *Journal of Environmental Planning and Management* 66(10), 2107-2125.
- Russell, F. S. 1970. *The Medusae of the British Isles (volume II): Pelagic Scyphozoa, with a supplement to the first volume of Hydromedusae*. Cambridge University Press.
- Sabatés, A., Pagès, F., Atienza, D., Fuentes, V., Purcell, J. E., Gili, J. M. 2010. Planktonic cnidarian distribution and feeding of *Pelagia noctiluca* in the NW Mediterranean Sea. *Hydrobiologia* 645, 153-165.
- Sabatés, A., Salat, J., Tilves, U., Raya, V., Purcell, J. E., Pascual, M., Gili, J.-M., Fuentes, V. L. 2018. Pathways for *Pelagia noctiluca* jellyfish intrusions onto the Catalan

- shelf and their interactions with early life fish stages. *Journal of Marine Systems* 187, 52-61.
- Sagarminaga, Y., Piraino, S., Lynam, C. P., Leoni, V., Nikolaou, A., Jaspers, C., Bosch-Belmar, M., Fumarola, L. M., Borja, Á., Spada, E., Amorim, E., Borrello, P., de Angelis, R., Leone, A., Montero, N., Ferrer, L., Holland, M. M., Doyle, T. K., Tsirtsis, G., Katsanevakis, S. 2024. Management of jellyfish outbreaks to achieve good environmental status. *Frontiers in Ocean Sustainability* 2, 1449190.
- Sanz-Martín, M., Pitt, K. A., Condon, R. H., Lucas, C. H., Novaes de Santana, C., Duarte, C. M. 2016. Flawed citation practices facilitate the unsubstantiated perception of a global trend toward increased jellyfish blooms. *Global Ecology and Biogeography* 25(9), 1039-1049.
- Seipel, K., Schmid, V. 2006. Mesodermal anatomies in cnidarian polyps and medusae. *International Journal of Developmental Biology* 50(7), 589.
- Sommer, F. A. 1992. Husbandry Aspects of a Jellyfish Exhibit at the Monterey Bay Aquarium. En *American Association of Zoological Parks and Aquariums 1992 Annual Conference Proceedings* (pp. 362-369).
- Strychalski, W., Bryant, S., Jadamba, B., Kilikian, E., Lai, X., Shahriyari, L., Segal, R., Wei, N., Miller, L.A. 2018. Fluid Dynamics of Nematocyst Prey Capture. En A. Radunskaya, R. Segal, B. Shtylla (Eds.), *Understanding Complex Biological Systems with Mathematics (Association for Women in Mathematics Series 14)*. Springer.
- Tardent, P. 1978. Coelenterata, Cnidaria. En F. Seidel (Ed.), *Morphogenese der Tiere*. Gustav Fischer.
- Technau, U., Genikhovich, G., Kraus, J. E. M. 2015. Cnidaria. En A. Wanninger (Ed.) *Evolutionary developmental biology of invertebrates 1* (pp. 115-163). Springer.
- Tilves, U., Fuentes, V. L., Milisenda, G., Parrish, C. C., Vizzini, S., Sabatés, A. 2018a. Trophic interactions of the jellyfish *Pelagia noctiluca* in the NW Mediterranean: evidence from stable isotope signatures and fatty acid composition. *Marine Ecology Progress Series* 591, 101-116.

- Tilves, U., Sabatés, A., Blázquez, M., Raya, V., Fuentes, V. L. 2018b. Associations between fish and jellyfish in the NW Mediterranean. *Marine biology* 165, 1-14.
- Torri, L., Tuccillo, F., Bonelli, S., Piraino, S., Leone, A. 2020. The attitudes of Italian consumers towards jellyfish as novel food. *Food Quality and Preference* 79, 103782.
- Touzri, C., Hamdi, H., Goy, J., Daly-Yahia, M. N. 2012. Diversity and distribution of gelatinous zooplankton in the Southwestern Mediterranean Sea. *Marine Ecology* 33(4), 393-406.
- Tugcu, C. T. 2014. Tourism and economic growth nexus revisited: A panel causality analysis for the case of the Mediterranean Region. *Tourism Management* 42, 207-212.
- UNEP. 1984. United Nations Environmental Programme: Report on the workshop on jellyfish blooms in the Mediterranean. 31 de octubre - 4 de noviembre de 1983. Atenas, Grecia.
- UNEP. 1991. Jellyfish blooms in the Mediterranean. En *Proceedings of the II workshop on jellyfish in the Mediterranean Sea*. Mediterranean Action Plan (MAP) Technical Reports Series 47. 2-5 de septiembre de 1987. Atenas, Grecia.
- UNESCO. 1968. *Zooplankton sampling*. United Nations Educational, Scientific and Cultural Organization.
- Uye, S.-I. 2008. Blooms of the giant jellyfish *Nemopilema nomurai*: a threat to the fisheries sustainability of the East Asian Marginal Seas. *Plankton and Benthos Research* 3, 125-131.
- van Walraven, L., van Bleijswijk, J., van der Veer, H. W. 2020. Here are the polyps: in situ observations of jellyfish polyps and podocysts on bivalve shells. *PeerJ* 8, e9260.
- Vučetić, T. 1984. Some causes of the blooms and unusual distribution of the jellyfish *Pelagia noctiluca* in the Mediterranean (Adriatic). *United Nations Environmental Programme: Report on the workshop on jellyfish blooms in the Mediterranean* (pp. 167-176). 31 de octubre - 4 de noviembre de 1983. Atenas, Grecia.

- White, V., McCrum, G., Blackstock, K. L., Scott, A. 2006. Indicators and Sustainable Tourism: Literature Review. *The Macaulay Institute*.
- Wong, W. W., Chung, S. W., Kwong, K. P., Yin Ho, Y., Xiao, Y. 2010. Dietary exposure to aluminium of the Hong Kong population. *Food Additives and Contaminants* 27(4), 457-463.
- WoRMS. 2023. Cnidaria. *World Register of Marine Species*. Disponible en: <https://www.marinespecies.org/aphia.php?p=taxdetails&id=1267>. Accedido el 16-04-2025.
- Wright, D. A., Purcell, J. E. 1997. Effect of salinity on ionic shifts in mesohaline scyphomedusae, *Chrysaora quinquecirrha*. *The Biological Bulletin* 192(2), 332-339.
- Zavodnik, D. J. M. B. 1987. Spatial aggregations of the swarming jellyfish *Pelagia noctiluca* (Scyphozoa). *Marine Biology* 94(2), 265-269.



CAPÍTULO II

APLICACIÓN DE REDES NEURONALES
ARTIFICIALES A COMENTARIOS DE
CIENCIA CIUDADANA PARA LA
EVALUACIÓN DE LA PRESENCIA DE
MEDUSAS EN EL LITORAL ANDALUZ

Resumen

La proliferación de medusas en las zonas costeras puede plantear importantes problemas a los usuarios de las playas y a las autoridades locales. Entender los factores que influyen en la presencia de medusas es crucial para una gestión eficaz y estrategias de mitigación.

En este estudio, se utilizan datos de ciencia ciudadana de la costa andaluza (232 playas, de 40 localidades diferentes) y técnicas de aprendizaje automático para investigar si se puede predecir la presencia y ausencia de medusas a lo largo de las zonas costeras. Se empleó una red neuronal Perceptrón Multicapa (MLP, *Multi-Layer Perceptron*) para clasificar los comentarios de los usuarios sobre la presencia o ausencia de medusas, alcanzando una precisión aproximada del 96%.

El modelo MLP demostró solidez en el manejo de problemas de clasificación no lineal y ruido, aunque mostró menor precisión para predecir la presencia de medusas, probablemente debido a un desequilibrio en el conjunto de datos. También se incorporaron datos ambientales para caracterizar la influencia de la temperatura superficial del mar (SST, *Sea Surface Temperature*), la dirección y la velocidad del viento en la distribución de las medusas. Los resultados coinciden con estudios anteriores que sugieren que estos factores ambientales influyen significativamente en la presencia de medusas.

Esta investigación ofrece recomendaciones prácticas para la gestión de las playas. La realización de un seguimiento continuo de la SST y las condiciones del viento permitirá predecir con mayor exactitud la distribución de las medusas. Las estrategias de gestión adaptativa que responden dinámicamente a los datos ambientales ayudarán a mitigar el impacto de las floraciones de medusas sobre el turismo costero y la salud pública.

Palabras clave: Medusas; Perceptrón multicapa; Aplicación Infomedusa; Temperatura superficial del mar; Condiciones del viento; Aprendizaje automático; Gestión de playas; Ciencia ciudadana.

Abstract

Jellyfish blooms along coastal areas can pose significant challenges for beach users and local authorities. Understanding the factors influencing jellyfish presence is crucial for effective management and mitigation strategies.

In this study, citizen science data from the Andalusian coast (232 beaches, in 40 different localities) and machine learning techniques are used to investigate if the presence and absence of jellyfish along coastal areas can be predicted. A Multi-Layer Perceptron (MLP) neural network was employed to classify user comments regarding jellyfish presence or absence, achieving an accuracy of approximately 96%.

The MLP model demonstrated robustness in handling non-linear classification problems and noise, although it showed lower precision for predicting jellyfish presence, likely due to an imbalance in the dataset. Environmental data were also incorporated to characterise the influence of Sea Surface Temperature (SST), wind direction, and wind speed on jellyfish distribution. The results align with previous studies, suggesting these environmental factors significantly impact jellyfish presence.

This research provides actionable recommendations for beach management. The implementation of continuous monitoring of SST and wind conditions will enable more accurate predictions of jellyfish distribution. Adaptive management strategies that respond dynamically to environmental data will help mitigate the impact of jellyfish blooms on coastal tourism and public health.

Keywords: *Jellyfish; Multi-Layer Perceptron; Infomedusa APP; Sea Surface Temperature; Wind conditions; Machine learning; Beach management; Citizen science.*

2.1. Introducción

Las poblaciones de medusas han recibido recientemente una atención significativa debido al impacto que tiene la proliferación de estos organismos urticantes en el turismo regional, los bañistas y los ecosistemas locales (Pauly *et al.*, 2009; Richardson *et al.*, 2009; Purcell, 2012; Canepa *et al.*, 2014). Sus picaduras pueden constituir un riesgo para la salud humana (Mariottini *et al.*, 2008; Mariottini and Pane, 2010; Brotz *et al.*, 2012), y su presencia en la costa puede disuadir a los turistas de acudir a los destinos costeros, afectando negativamente a las economías locales (Galil, 2008; Brotz *et al.*, 2012; De Donno *et al.*, 2014; Ruiz-Frau, 2022). Dada la importancia de estos impactos, resulta fundamental llevar a cabo programas de monitoreo de la presencia de medusas con el objetivo de proteger la seguridad pública y mejorar la gestión de estos eventos (Ghermandi *et al.*, 2015; Bellido *et al.*, 2020). Sin embargo, los programas de seguimiento que abarcan grandes extensiones durante períodos relativamente largos requieren una inversión financiera y de personal que es inasumible para la administración o los programas de investigación. En este sentido, la recopilación de datos a través de la participación ciudadana ofrece una solución alternativa para monitorear fenómenos ambientales, aprovechando la información generada por los usuarios (Goodchild, 2007).

2.1.1. Ciencia ciudadana

La ciencia ciudadana, definida como la participación activa de personas no expertas en la realización de tareas de investigación científica, proporciona una solución eficaz para la vigilancia de fenómenos ambientales gracias al uso de la información generada por los propios usuarios (Bonney *et al.*, 2009; Silvertown, 2009). Esta es una práctica en expansión que fomenta la colaboración entre profesionales de la ciencia y la ciudadanía, con el fin de generar nuevo conocimiento que beneficie tanto a la comunidad científica como a la sociedad en general (Bonney *et al.*, 2016; Haklay *et al.*, 2021). Este enfoque invita a la población general a contribuir en la recolección, análisis y difusión de información, ampliando de forma espacial y temporal tanto la cantidad como la diversidad de los datos que se obtienen en distintos campos del conocimiento, lo que resulta especialmente valioso para el monitoreo de gran escala (Bonney *et al.*, 2009; Dickinson *et al.*, 2010). Las iniciativas de ciencia ciudadana suelen apoyarse en herramientas digitales (como aplicaciones móviles o plataformas web) que permiten una comunicación

eficaz entre investigadores y colaboradores. De este modo, es posible un seguimiento continuo y una retroalimentación casi inmediata sobre la calidad de los datos ingresados, ofreciendo una sólida base para el desarrollo de estudios a gran escala (Vohland *et al.*, 2021).

La relevancia de la ciencia ciudadana en el ámbito marino radica en la naturaleza extensa y a menudo inaccesible de los océanos, así como en la heterogeneidad de sus ecosistemas (Kelly *et al.*, 2020). La integración de voluntarios como buceadores recreativos, pescadores o navegantes permite abarcar zonas que serían imposibles de cubrir íntegramente por equipos científicos (Hermoso *et al.*, 2021). Mediante la recogida de observaciones directas, fotografías y mediciones ambientales, se genera un volumen considerable de información (McClure *et al.*, 2020). Esta metodología, ampliamente adoptada en disciplinas como la oceanografía, la ecología marina y la biología de la conservación, ha demostrado ser eficaz para detectar problemas emergentes, como la acidificación del agua, la proliferación de especies invasoras y los cambios en la distribución de poblaciones animales (Silvertown, 2009).

En particular, las iniciativas relacionadas con el estudio de las medusas han cobrado un interés creciente en los últimos años debido a los efectos negativos que pueden ocasionar en la pesca, el turismo y la salud humana, así como en otros sectores económicos (Lucas *et al.*, 2014). Muchas de estas especies tienen ciclos de vida complejos y presentan dinámicas poblacionales fuertemente influenciadas por las condiciones ambientales, lo cual dificulta su predicción y control. Para investigar sus hábitos y patrones de distribución, en el Mediterráneo se han promovido proyectos de ciencia ciudadana en los que bañistas, navegantes, socorristas y otros usuarios del medio marino registran avistamientos de los enjambres (Tabla II-1). Muchas de estas iniciativas de ciencia ciudadanas han sido revisadas en profundidad por Edelist *et al.* (2025). Por ejemplo, el proyecto MED-JELLYRISK se centró en la creación de una plataforma de previsión de afloramientos de medusas en la cuenca occidental y central del Mediterráneo (Canepa *et al.*, 2016; Marambio *et al.*, 2021). Este proyecto utilizó un enfoque integrado de ciencia ciudadana y modelos de distribución de especies para predecir la aparición de medusas, al mismo tiempo que ofrecía información actualizada al público a través de la aplicación iMedJelly (<https://apps.apple.com/es/app/imedjelly/id544677070>). Además, la iniciativa mundial de ciencia ciudadana Jellywatch (<https://www.jellywatch.org/>) se basa en los avistamientos de medusas notificados por los usuarios para rastrear y mejorar la

comprensión de las poblaciones de medusas y sus patrones de distribución (Boero *et al.*, 2009; Purcell *et al.*, 2015). Por otro lado, Jelly Monitor (<https://www.uea.ac.uk/groups-and-centres/colour-and-imaging/projects/environmental-monitoring/jelly-monitor>) tiene como objetivo establecer una plataforma de imágenes portátil capaz de detectar medusas cerca de tomas de agua, proporcionando un sistema de alerta temprana para el ingreso de medusas (French *et al.*, 2018). Marambio *et al.* (2021) utilizaron la ciencia ciudadana para investigar la dinámica de las floraciones de medusas en el mar Mediterráneo basándose en observadores voluntarios para informar de avistamientos de cuatro países diferentes. Este enfoque basado en los datos procedentes de la ciudadanía tiene el potencial de ser rentable y preciso, puesto que se basa en observaciones directas realizadas por numerosos usuarios que experimentan directamente el entorno costero. La utilidad de algunas de estas iniciativas puede extenderse a la emisión de alertas y la prevención de picaduras (Richardson *et al.*, 2009).

Tabla II-1. Resumen de iniciativas de ciencia ciudadana relacionadas con la monitorización de medusas llevadas a cabo en el Mar Mediterráneo. Nota: El asterisco (*) significa que el proyecto se llevó a cabo en el marco más amplio del Programa JellyWatch del CIESM.

Iniciativa	Institución	Cobertura geográfica	Duración	Referencia
Projecte Medusa	Institut de Ciències del Mar (CSIC)	Cataluña	2007 – Act.	Canepa <i>et al.</i> (2014) Ballesteros <i>et al.</i> (2020)
Spot the Jellyfish	Universidad de Malta	Mar Mediterráneo	2010 – Act.	Deidun <i>et al.</i> (2014)
JellyWatch Programme	CIESM	Global	2009 – Act.	https://www.jellywatch.org/
SWYMM	Universidad de Patras	Grecia	2017 – NA	Komninos (2019)
Infomedusa	Fundación Aula del Mar Mediterráneo	España	2013 – Act.	https://auladelmarmed.org/infomedusa/
MED-JELLYRISK*	Consorzio Nazionale Interuniversitario per le Scienze del Mare	España, Italia, Túnez y Malta	2012 – 2015	Canepa <i>et al.</i> (2016)
Meduzot Ba'am	Universidad de Haifa	Israel	2011 – Act.	https://www.meduzot.co.il/
Costasoleando	Universidad de Málaga	Málaga	2020 – Act.	https://www.costasoleando.es/home
Cubomed	UA-ICM/CSIC	Mediterráneo español	2010 – Act.	www.cubomed.eu
PERSEUS Jellyfish Spotting Campaign*	Hellenic Centre for Marine Research	Mediterráneo y Mar Negro	2012 – 2015	Kideys (2015)

Las ventajas de la ciencia ciudadana se hacen evidentes en muchos aspectos (Fritz *et al.*, 2019). En primer lugar, puede reducir los costes operativos de la investigación, ya que involucra a voluntarios que realizan la mayor parte de la labor de campo (Danielsen *et al.*, 2005). En segundo lugar, la cobertura geográfica y temporal que se logra es mucho mayor que la alcanzable por un grupo científico reducido, lo que favorece la detección de variaciones ambientales puntuales y la elaboración de modelos predictivos más sólidos (Earp y Liconti, 2020; McClure *et al.*, 2020). Además, el hecho de que la ciudadanía participe directamente en la generación de conocimiento promueve una conciencia ecológica y social más profunda, fomentando actitudes responsables frente a la conservación de los entornos marinos (Irwin, 2002). Por último, la integración de datos procedentes de diversas localizaciones y periodos temporales facilita estudios de carácter

longitudinal que permitan identificar tendencias a lo largo de décadas (Conrad y Hilchey, 2011).

No obstante, la ciencia ciudadana también enfrenta algunas limitaciones importantes. La fiabilidad de la información depende, en gran medida, del nivel de capacitación de los voluntarios y de la constancia con que se implementan los protocolos de registro (Dickinson *et al.*, 2010). Ante estas dificultades, varios autores recomiendan que las actividades estén dirigidas de tal forma que el científico no sea un simple recolector de datos e información. Así, diversos estudios controlan la calidad de la información incorporando exámenes de conocimientos a los voluntarios (por ejemplo, mediante cuestionarios en línea) y proporcionando retroalimentación personalizada para incrementar la precisión en la identificación (Dickinson *et al.*, 2010; Crall *et al.*, 2011). Asimismo, se ha observado que las personas con más años de formación o con experiencia reiterada en la misma tarea, en general, son capaces de recopilar datos comparables a los de un profesional (Delaney *et al.*, 2008).

La fiabilidad de los datos recabados a través de iniciativas de ciencia ciudadana puede verse afectada por diversos factores, como la mencionada habilidad y experiencia de los voluntarios, la frecuencia con que se repasan los procedimientos de muestreo o el nivel de complejidad en la identificación de las especies estudiadas (Danielsen *et al.*, 2005). Tal y como sucede en algunos programas de seguimiento de aves, anfibios o especies invasoras, los participantes muestran habilidades muy variables que tienden a mejorar con la práctica, el tiempo de servicio acumulado y el acompañamiento experto (Dickinson *et al.*, 2010). A pesar de estos desafíos, la ciencia ciudadana continúa consolidándose como una herramienta valiosa para la investigación y la conservación marina, evidenciando su capacidad de complementar y potenciar el trabajo de los científicos profesionales, especialmente cuando se trata de monitorear especies tan impredecibles como las medusas (Castro-Gutiérrez *et al.*, 2024).

Bajo este contexto, la Diputación Provincial de Málaga en colaboración con el Aula del Mar de Málaga (ahora Fundación Aula del Mar Mediterráneo) desarrolló en 2013 la aplicación móvil Infomedusa (<https://auladelmarmed.org/infomedusa/>). Esta aplicación permite a los ciudadanos monitorizar la presencia de enjambres de medusas a lo largo de la costa de Andalucía (sur de España). Sin embargo, Infomedusa funciona como un foro en el que los usuarios pueden participar en debates más allá del tema de las medusas, por lo que de forma estricta no se puede considerar una aplicación de ciencia

ciudadana. La naturaleza de foro abierto conlleva un elevado volumen de comentarios de temática muy variada, por lo que antes de abordar análisis estadísticos resulta necesario llevar a cabo un cuidadoso filtrado y una clasificación de la información. En este sentido, técnicas como las incluidas en el campo del aprendizaje automático podrían ayudar a automatizar la extracción de datos relacionados con medusas a partir de los comentarios de los usuarios, haciendo que el proceso de análisis de datos sea más eficiente y preciso (Tang *et al.*, 2015; Young *et al.*, 2018).

En los últimos años, ha aumentado el interés en la clasificación de textos mediante redes neuronales artificiales (RNAs) para la extracción de información (Zhang, 2000; Hovy, 2022; Mukhamediev *et al.*, 2022). Esto se debe al creciente volumen de datos generados en plataformas en línea y a la necesidad de gestionar eficazmente dicha información. Las RNAs pueden ofrecer ventajas significativas en este ámbito, como la identificación y clasificación de especies de medusas a partir de imágenes, además de la capacidad de detectar patrones complejos y manejar conjuntos de datos de gran escala (Kim *et al.*, 2016; Minaee *et al.*, 2021; Do y Tran, 2022). De esta forma, las RNAs constituyen uno de los pilares fundamentales de la inteligencia artificial y han experimentado un crecimiento exponencial en las últimas décadas, sentando las bases de numerosos avances tecnológicos y científicos (Martín del Brío y Sanz-Molina, 2006).

Asimismo, comprender la compleja relación entre las medusas y el entorno es esencial para predecir y gestionar posibles proliferaciones de medusas en las áreas costeras. Se ha demostrado que diversos factores ambientales, como la temperatura superficial del mar (SST), la dirección y la velocidad del viento, influyen en la presencia de medusas en las costas. Así, el aumento de la SST se ha asociado con una mayor abundancia de medusas, puesto que las temperaturas más elevadas pueden acelerar sus tasas de crecimiento y reproducción, favoreciendo la expansión de sus poblaciones (Purcell, 2005). Por ejemplo, Avian *et al.* (1991) determinaron que un incremento en la SST influye en la dinámica poblacional de *Pelagia noctiluca* al promover el desarrollo de óvulos y, por consiguiente, su proliferación. Además, se ha demostrado que la SST es uno de los principales impulsores de la composición de comunidades de cnidarios en el mar Mediterráneo (Guerrero *et al.*, 2018). La dirección y la velocidad del viento también desempeñan un papel relevante en la distribución y acumulación de medusas a lo largo de las costas. El viento puede transportar medusas hacia la orilla mediante corrientes superficiales impulsadas por el viento, tal como señalan estudios previos (Graham *et al.*,

2014; Gutiérrez-Estrada *et al.*, 2021). Por lo tanto, comprender mejor los efectos combinados de la SST, la dirección y la velocidad del viento en las poblaciones de medusas puede contribuir a la implementación de estrategias más eficaces de gestión y mitigación para abordar su impacto en ecosistemas costeros y las actividades humanas.

El objetivo de este capítulo fue investigar el potencial de los datos de ciencia ciudadana y de las técnicas de aprendizaje automático para rastrear la presencia de medusas. Para lograrlo, utilizamos un modelo clasificador perceptrón multicapa (MLP, *Multi-Layer Perceptron*) para procesar y clasificar los comentarios de la aplicación Infomedusa (versión 6.7). Adicionalmente, se analizaron los conjuntos de datos ambientales sobre la presencia de medusas, con el fin de incrementar el conocimiento acerca de la aparición de estos organismos en las playas. Esta investigación pretende proporcionar información valiosa para la investigación y entendimiento de la dinámica de poblaciones de medusas y para la gestión en las playas, contribuyendo así a la seguridad pública.

2.2. Material y métodos

2.2.1. Área de estudio

El área de estudio del presente capítulo se ubica a lo largo de la costa de Andalucía, la región más meridional de España (aproximadamente entre las latitudes 36.0°N y 37.4°N, y las longitudes 1.5°O y 7.5°O; Figura II-1). El contexto hidrográfico de Andalucía abarca tanto la costa atlántica como la costa mediterránea. Esta situación geográfica única expone a la región a diversos fenómenos oceanográficos, como la entrada de aguas atlánticas al Mediterráneo a través del Estrecho de Gibraltar, sistemas de afloramiento a lo largo de la costa atlántica y el carácter oligotrófico del mar Mediterráneo (Peliz *et al.*, 2002; García-Lafuente *et al.*, 2021). En conjunto, estos factores dan lugar a la gran biodiversidad y productividad de los ecosistemas marinos andaluces (Bianchi y Morri, 2000; Rueda *et al.*, 2021; Perret *et al.*, 2023).




Figura II-1. Área de estudio abarcada en este estudio. Los distintos conjuntos de playas se indican con recuadros rojos. Las localidades cubiertas por cada conjunto de playas se muestran en la Tabla II-2.

En este estudio se analizaron un total de 232 playas pertenecientes a 40 localidades diferentes (Figura II-1 y Tabla II-2). Siguiendo la metodología de Gutiérrez-Estrada *et al.* (2021) y Castro-Gutiérrez *et al.* (2022), las playas se agruparon en 11 conjuntos distintos para facilitar el análisis de la presencia de medusas de acuerdo con su posición geográfica. Concretamente, esta agrupación se basó en la proximidad entre playas y la estación meteorológica más cercana, lo que permite un análisis más preciso con datos meteorológicos locales para comprender la distribución geográfica de las medusas.

Tabla II-2. Resumen de las localidades y número de playas abarcadas por cada conjunto de playas.

Conjunto de playa	Localidades	Nº de playas
Set 1	Málaga	18
Set 2	Algarrobo, Nerja, Rincón de la Victoria, Torrox, Vélez-Málaga.	34
Set 3	Benalmádena, Fuengirola, Mijas, Torremolinos	38
Set 4	Marbella	25
Set 5	Casares, Estepona, Manilva, San Roque	22
Set 6	Tarifa	3
Set 7	Chiclana de la Frontera, San Fernando, El Puerto de Santa María	5
Set 8	Almonte, Palos de la Frontera, Punta Umbría, Lepe, Isla Cristina, Ayamonte	19
Set 9	Almuñécar, Salobreña, Motril, Gualchos, Lújar, Rubite, Polopos, Adra	26
Set 10	Roquetas de Mar, Almería	13
Set 11	Níjar, Carboneras, Mojácar, Garrucha, Vera	29

2.2.2. Recopilación de datos: Aplicación Infomedusa

La información sobre la presencia o ausencia de medusas utilizada en el presente estudio se obtuvo de la aplicación Infomedusa (disponible para iOS y Android, <https://auladelmarmed.org/infomedusa/>), desarrollada en 2013 por la Diputación Provincial de Málaga en colaboración con el Aula del Mar de Málaga (ahora Fundación Aula del Mar Mediterráneo, <https://auladelmarmed.org/>). Esta se trata de una aplicación para teléfonos móviles inteligentes que permite a la ciudadanía monitorear la presencia y

la abundancia de enjambres de medusas a lo largo de la costa de Andalucía (sur de España). La interfaz de Infomedusa (Figura II-2) se inicia permitiendo al usuario comprobar el estado de las playas más cercanas a él según su ubicación, o comprobar el estado de otra playa utilizando un buscador. Al acceder a la playa deseada, el usuario puede comprobar diferentes condiciones ambientales como la velocidad del viento o el estado del oleaje. Cada playa contiene una sección de “Mensajes”, donde el usuario puede participar en un foro abierto sobre temas que van más allá de las medusas como las condiciones del mar y la playa, así como cuestiones relacionadas con sus experiencias en la costa. Los participantes también pueden incluir imágenes o fotografías que hayan tomado durante su experiencia en la playa.




Figura II-2. Interfaz de la aplicación Infomedusa. A la izquierda, se muestra la información de la playa Burriana, en Nerja (Málaga). A la derecha, se muestra la sección de “Mensajes”, donde los usuarios Jenifer y Xexu han comentado sobre la ausencia de medusas y su experiencia durante su visita a esta playa.

Este enfoque de foro abierto fomenta un sentido de comunidad y alienta la participación más amplia de los usuarios de la aplicación, a la vez que proporciona datos valiosos sobre la presencia de medusas. Sin embargo, esta aplicación no fue inicialmente desarrollada para obtener datos utilizables para realizar análisis y estudios científicos, por lo que los estudios derivados de la información procedente de esta aplicación en su

versión inicial pueden ser agrupados dentro del campo de la “ciencia ciudadana no dirigida²”.

Para los análisis llevados a cabo en este capítulo se recopilaron un total 9.433 comentarios en 2019 (comprendidos desde el 5 de enero hasta el 8 de diciembre). Cabe destacar que la mayoría de estos comentarios corresponden a los meses de verano, coincidiendo con la época de mayor afluencia de personas a las playas. Esta estacionalidad en la disponibilidad de los datos refleja tanto la capacidad operativa de Infomedusa como el incremento natural de usuarios en temporada alta, lo que influye en el volumen y frecuencia de los avistamientos de medusas notificados.

Además, se obtuvieron tres variables ambientales para caracterizar los principales factores que podrían contribuir a la llegada de medusas a la costa andaluza: (i) Temperatura superficial del mar (SST, *Sea Surface Temperature*), (ii) dirección del viento, y (iii) velocidad del viento.

La SST se obtuvo a partir del servicio *Copernicus Marine Environment Monitoring Service* (CMEMS, <https://marine.copernicus.eu/>) con observaciones satelitales de resolución temporal horaria y una resolución espacial de 0,0625° x 0,0625°. El Programa Copernicus es la iniciativa de la Unión Europea para la observación de la Tierra, orientada a recopilar, analizar y difundir información sobre el planeta y su entorno en beneficio de la ciudadanía. En este contexto, el CMEMS se establece como un servicio integral que ofrece datos y productos marinos gratuitos y de libre acceso con el propósito de facilitar la ejecución de políticas relacionadas con el medio marino, impulsar el crecimiento azul y promover la innovación científica en este ámbito. Dicha iniciativa cubre un amplio espectro de políticas y compromisos legales, y pone a disposición del público informes periódicos y sistemáticos sobre el estado físico, biogeoquímico y dinámico de los océanos, tanto a escala regional como global.

² A partir de junio de 2024, la aplicación Infomedusa recibió una actualización de gran alcance que modificó sustancialmente su funcionamiento en el foro. Con esta nueva versión, cada usuario que desea compartir un comentario en la sección de “Mensajes” está obligado a especificar de forma explícita si ha observado medusas o no, aportando así datos más estructurados para su posible utilización en análisis. Este cambio tuvo como propósito principal reducir la proporción de comentarios irrelevantes, facilitándose de esta forma que la información registrada resultara más uniforme y tratable con fines científicos. No obstante, en el momento de la realización del presente estudio, la aplicación operaba aún en su versión inicial, es decir, aquella en la que los usuarios no estaban obligados a indicar la presencia o ausencia de medusas en cada intervención. Por este motivo, la base de datos utilizada procede de un sistema denominado “ciencia ciudadana no dirigida”, lo que a su vez exigió un esfuerzo considerable de preprocesamiento y filtrado antes de poder extraer conclusiones fiables sobre la ocurrencia de medusas en el área de estudio.

Por su parte, los datos diarios de dirección y velocidad del viento se obtuvieron de las estaciones meteorológicas más cercanas a la ubicación de cada uno de los conjuntos de playas. Las estaciones meteorológicas utilizadas forman parte de la Agencia Estatal de Meteorología (AEMET, <http://www.aemet.es>). La AEMET ejerce como organismo oficial responsable de los servicios meteorológicos y climatológicos en España. Entre sus principales cometidos se encuentra la elaboración y difusión de predicciones que advierten sobre fenómenos meteorológicos adversos, así como el suministro de información de interés general a escala nacional.

2.2.3. *Preprocesamiento de datos y codificación one-hot*

La base de datos se filtró para incluir únicamente comentarios escritos en español que indicaran la presencia de medusas como “Presencia” (1) o “Ausencia” (0), excluyendo los datos ausentes (NA, *Not Available*). Para ello, y de forma manual, se analizaron todos los comentarios disponibles en la base de datos generada por la aplicación Infomedusa.

A modo de ejemplo, a continuación se muestran algunos comentarios utilizados y cómo fueron interpretados:

- “*Están sacando medusas de tamaño considerable toda la mañana. No hay muchas, pero son muy grandes*” se clasificó como Presencia (1), reflejando explícitamente la presencia de medusas.
- “*Ahora mismo el agua está a muy buena temperatura, sin medusas*” se clasificó como Ausencia (0), indicando la ausencia de medusas.
- “*¿Cómo está la playa hoy?*” se clasificó como NA debido a la falta de información sobre la presencia o ausencia de medusas.
- “*Día estupendo. Agua limpia, clara y temperatura del agua buena, nada fría*” se clasificó como NA debido a que, aunque el usuario menciona que las condiciones de baño son buenas y se podría entender que no está avistando ninguna medusa, no existe información explícita sobre la presencia o ausencia de estos organismos.

Cualquier comentario con información sobre medusas en pasado se trató como NA, debido a que no está informando sobre la presencia o ausencia de medusas en el momento de escritura del comentario. Por ejemplo, el comentario “*Ayer por la tarde no hubo medusas, aunque sí algunas algas*” fue tratado como NA.

Adicionalmente, se llevó a cabo un preprocesamiento léxico simple en cada comentario para eliminar caracteres especiales (por ejemplo, @, \$, &, ñ, entre otros), emoticonos, palabras con errores ortográficos y también preposiciones, dado que estos elementos no aportaban información relevante para el análisis.

A partir del conjunto depurado de comentarios, se generó un diccionario de palabras únicas en orden alfabético. Este diccionario se filtró para incluir únicamente palabras con una frecuencia de aparición igual o superior a 10 veces en el conjunto principal de datos, ya que las palabras de baja frecuencia suelen ser de poca utilidad en el proceso de aprendizaje (Cunha *et al.*, 2019). Este umbral se seleccionó con el fin de focalizar el análisis en los términos más relevantes y utilizados con mayor frecuencia en los comentarios.

Mediante el método de codificación *one-hot* (Hancock y Khoshgoftaar, 2020; Samuels, 2024), cada comentario se transformó en un sistema de código binario utilizando el diccionario generado (Figura II-3). El tamaño del código binario es igual al número de palabras en el diccionario. El código asignado a cada comentario es una secuencia de ceros (0) y unos (1), donde cada posición en la secuencia corresponde a una palabra del diccionario. Un valor de 1 indica que la palabra está presente en el comentario, mientras que un valor de 0 indica que no lo está.




Figura II-3. Resumen gráfico del proceso de tratamiento de cada comentario j para la obtención del vector de entrada tras la codificación one-hot.

Finalmente, cada dígito del código se dividió en columnas individuales. De este modo, mediante el proceso de codificación *one-hot*, la información de cada palabra en

cada comentario se representa binarizada de manera compacta y eficiente. Este código servirá como vector de entrada para su modelización en la red neuronal artificial. Todo este procedimiento se programó utilizando el software estadístico R versión 4.1.2 (R Core Team, 2021) y es descrito en detalle en el Anexo 1.

2.2.4. *Redes neuronales artificiales*

Las Redes Neuronales Artificiales (RNAs) son modelos computacionales inspirados en la estructura y el funcionamiento de los sistemas nerviosos biológicos que están diseñados para reconocer patrones y resolver problemas complejos (McCulloch y Pitts, 1943; Rumelhart *et al.*, 1986a). De esta forma, estos modelos emulan el *hardware* del cerebro y su objetivo principal es “aprender” a partir de ejemplos, adaptando gradualmente sus parámetros internos (o pesos) para mejorar su rendimiento en una tarea específica.

Para entender mejor el concepto de qué es una neuronal artificial, se puede hacer una analogía con la neurona biológica. La neurona biológica es la unidad funcional de procesamiento básica del sistema nervioso biológico y se caracteriza por poseer tres partes principales: las dendritas, el soma y el axón. Las dendritas cumplen la función de antenas receptoras, recibiendo impulsos (ya sean químicos o eléctricos) procedentes de otras neuronas. El soma ejerce como centro regulador de la neurona, donde se procesan las señales entrantes para decidir si se alcanza el umbral necesario para generar un potencial de acción. Este potencial de acción es un impulso eléctrico que se origina en la zona de conexión entre el soma y el axón.

El axón, generalmente más largo que las dendritas, se encarga de conducir el potencial de acción a lo largo de la neurona hasta llegar a los terminales axónicos, donde se producen las sinapsis con otras neuronas o con células efectoras (por ejemplo, células musculares). En los terminales axónicos, el impulso eléctrico se convierte de nuevo en una señal química, liberando neurotransmisores en la hendidura sináptica. Así, cada neurona puede comunicarse con múltiples células adyacentes. Este funcionamiento coordinado de millones de neuronas forma el fundamento de los sistemas nerviosos de los animales (Silverthorn, 2015).

El estudio de la neurona biológica ofrece una base conceptual para entender la neurona artificial (Basheer y Hajmeer, 2000). Mientras que la primera integra señales

químicas y eléctricas a través de dendritas y somas, la segunda emula este proceso combinando entradas con pesos para generar una respuesta. Así, la emulación de la neurona biológica no se limita a su estructura, sino también al principio de “aprendizaje” y adaptación, ya que tanto la neurona biológica como la artificial ajustan su forma de procesar información según reciben estímulos o ejemplos. De este modo, la analogía entre ambas también justifica la capacidad de las neuronas artificiales para captar y modelar relaciones complejas en los datos.

2.2.4.1. *Elementos básicos de una RNA*

La neurona artificial (Figura II-4) constituye la unidad básica en los modelos de red neuronal. Su estructura principal se compone de entradas, pesos, un sesgo (*bias*, θ), una función de activación y una salida. Las entradas representan la información que recibe la neurona artificial, mientras que cada entrada posee un peso que indica la intensidad de dicha señal. Adicionalmente, suele incluirse un valor de sesgo, un valor constante que se suma a la combinación lineal de las entradas y que aporta un grado de libertad adicional a la neurona.




Figura II-4. Diagrama del modelo básico de una neurona artificial, la unidad fundamental en redes neuronales artificiales. Las entradas ($x_1, x_2, \dots, x_n$) corresponden a las señales de entrada, que pueden provenir de datos externos o de otras neuronas. Los pesos asociados ($w_1, w_2, \dots, w_n$) se multiplican por su entrada correspondiente (x_i) y ajustan su contribución al resultado final. La suma ponderada se calcula multiplicando cada entrada (x_i) por su peso asociado (w_i) más el sesgo (θ), que es un término constante que permite desplazar la función de activación para mejorar la flexibilidad del modelo. La función de activación transforma la suma ponderada en una salida que puede ser lineal o no lineal (ver Figura II-5). Por último, la salida (y) es el resultado final de la neurona, que puede transmitirse a otras neuronas o capas en una red.

En el proceso de cálculo se obtiene la regla de propagación (z_i , Ecuación II-1) de la neurona artificial, que es la suma ponderada de las entradas multiplicadas por sus respectivos pesos (más el sesgo, θ) y, sobre ese valor resultante, aplica la función de activación.

$$z_i(t) = \theta + \sum_{i=1}^n x_i w_i \quad (\text{Ec. II-1})$$

Existen diferentes funciones de activación, que puede ser lineal o no lineal, permitiendo que la neurona modele relaciones complejas en los datos. Entre las funciones de activación más comunes se pueden encontrar las representadas en la Figura II-5.




Figura II-5. Ecuación y gráficos de cuatro funciones de activación diferentes.

El valor que finalmente se produce tras la función de activación es la salida de la neurona, la cual puede servir de entrada a otra neurona en capas posteriores o constituir un resultado final en la capa de salida.

Las neuronas artificiales se conectan entre sí de modo que la salida de cada neurona de una capa se convierte en la entrada de las neuronas de la siguiente. Las conexiones entre estas pueden ser tanto excitatorias como inhibitorias, dependiendo de si el peso sináptico es positivo o negativo, respectivamente. Asimismo, el flujo de datos en una red neuronal puede ser unidireccional (*feedforward*), en el que la información circula en un solo sentido, o recurrente (*feedback*), en el que la circulación puede darse en cualquier sentido.

Al igual que en el sistema nervioso biológico, las neuronas artificiales se combinan para formar una estructura de un nivel superior denominado Red Neuronal Artificial (RNA). Una RNA puede tener diferentes arquitecturas según su estructura o patrón de conexiones. Las neuronas artificiales se agrupan en unidades estructurales llamadas “capas” y pueden ser (Figura II-6): (i) Capa de entrada; (ii) capa de salida y; (iii) capas ocultas. La capa de entrada recibe la información del entorno, mientras que la de salida contiene las neuronas que proporcionan la respuesta de la red neuronal. Por su

parte, las capas ocultas no tienen conexión directa con el entorno, por lo que únicamente proporcionan un mayor grado de libertad y una mayor capacidad computacional a la red.




Figura II-6. Arquitectura de una Red Neuronal Artificial con una capa de entrada compuesta de tres neuronas, dos capas ocultas compuestas de cuatro neuronas cada una, y una capa de salida con dos neuronas.

Del mismo modo que las capas, los tipos de neuronas también son agrupados bajo la misma nomenclatura según la presencia de sinapsis de entrada o de salida, existiendo neuronas de entrada (sin sinapsis entrantes), neuronas de salida (sin sinapsis salientes), y neuronas ocultas (neuronas que no son ni de entrada ni de salida).

El aprendizaje de la neurona artificial se fundamenta en el ajuste de los pesos y del sesgo para minimizar un error o función de coste. A lo largo de sucesivas iteraciones (o también llamadas “épocas de aprendizaje”), se compara la salida de la red con el valor esperado y se corrigen los pesos mediante diferentes procedimientos iterativos como por ejemplo el algoritmo de retropropagación estándar (*back-propagation*) (Rumelhart *et al.*, 1986b). Gracias a estos algoritmos iterativos, la neurona artificial es calibrada o “aprende” los patrones subyacentes en los datos, de forma análoga, aunque de modo simplificado, a la forma en que la neurona biológica se adapta y modifica sus conexiones sinápticas.

Existen dos tipos de aprendizaje en las RNAs: (i) el aprendizaje supervisado, y (ii) el aprendizaje no supervisado. La diferencia entre estos dos radica en la presencia o

ausencia de información sobre la salida esperada. En el aprendizaje no supervisado no hay salidas conocidas y el modelo debe encontrar por sí mismo cómo organizar o representar la información que se está modelando. Por otro lado, en una red de aprendizaje supervisado se introduce un conjunto de datos junto a la salida esperada, de modo que la red es capaz de ajustar iterativamente los pesos para estimar relaciones entrada-salida.

2.2.4.2. *El Perceptrón Multicapa (MLP)*

A finales de los años 50, Frank Rosenblatt desarrolló el perceptrón, el cual consiste en una sola neurona artificial (o una única capa de neuronas) que recibe un conjunto de entradas ponderadas y produce una salida binaria (generalmente 0 o 1) según un umbral de activación (Rosenblatt, 1958). Sin embargo, las limitaciones matemáticas expuestas por Minsky y Papert (1969) en su libro *Perceptrons* generaron el conocido “invierno” en la investigación de las redes neuronales, en el cual disminuyó el interés en este campo durante varios años. El renacimiento de las redes neuronales se dio en la década de los 80, cuando se popularizó el algoritmo de retropropagación del error, propuesto entre otros por Rumelhart *et al.* (1986b). A partir de este momento, el campo volvió a adquirir relevancia y, con el aumento de la capacidad computacional y la disponibilidad de grandes volúmenes de datos, las RNAs han logrado impactar de forma notable en numerosos ámbitos. Precisamente, las limitaciones del perceptrón fueron las impulsoras de la investigación hacia arquitecturas de mayor capacidad: los Perceptrones Multicapa (MLP, *Multi-Layer Perceptron*), que añaden capas ocultas y utilizan algoritmos de retropropagación para ajustar los pesos. Estas capas intermedias permiten la representación de relaciones no lineales y la resolución de problemas mucho más elaborados (Rumelhart *et al.*, 1986b).

En este estudio, se emplearon clasificadores MLP programados en Python (versión 3.9.16) mediante la biblioteca *scikit-learn* (Pedregosa *et al.*, 2011) para analizar los comentarios de los ciudadanos recopilados en la aplicación Infomedusa (Anexo 2). El objetivo principal de emplear el perceptrón multicapa fue aprovechar las capacidades analíticas avanzadas de las redes neuronales para clasificar de manera efectiva los comentarios de usuarios en la aplicación Infomedusa, diferenciando entre aquellos que informaban sobre la presencia y ausencia de medusas. La elección de utilizar MLPs en este estudio se basó en su robustez y eficacia reconocidas en clasificación de textos

(Goldberg, 2022), en especial para tareas de clasificación binaria (Shridhar *et al.*, 2020). Los clasificadores MLP son capaces de capturar y modelar la complejidad en grandes conjuntos de datos textuales, haciéndolos idóneos para analizar y clasificar comentarios de usuarios.

El conjunto de datos se dividió en entrenamiento y prueba con una proporción de 70/30, destinando el 70% de los datos a la calibración o entrenamiento y el 30% a la prueba o test. El primer conjunto de datos es utilizado para entrenar el modelo de RNA, mientras que el segundo conjunto se utiliza para evaluar el funcionamiento del modelo entrenado, reservando un conjunto reducido de datos para comprobar cómo funciona el modelo con datos que no ha visto previamente.

En las MLP, el proceso de cálculo comienza con la fase de propagación directa (*feed-forward*). En esta etapa, cada capa de la red toma las salidas de la capa anterior como entradas, las multiplica por sus respectivos pesos y las combina con el sesgo. Se debe tener en cuenta que en la primera etapa (o época), los pesos iniciales son establecidos de forma aleatoria (generalmente números pequeños, tanto positivos como negativos). En esta fase, cada capa oculta calcula la salida de sus neuronas aplicando la siguiente ecuación (Ecuación II-2):

$$z_j^l = \sum_{i=1}^{n_{l-1}} w_{ij}^l a_i^{(l-1)} + \theta_j^l, \quad (\text{Ec. II-2})$$

donde l es el índice de la capa actual, j refiere a la neurona en dicha capa, n_{l-1} es el número de neuronas de la capa anterior, w_{ij}^l son los pesos entre la neurona i de la capa anterior ($l-1$) y la neurona j de la capa l , $a_i^{(l-1)}$ es la salida de la neurona i en la capa previa, y θ_j^l es el sesgo de la neurona j .

Seguidamente, se aplica una función de activación a cada neurona para introducir la no linealidad necesaria (Ecuación II-3).

$$a_i^j = \phi(z_i^j), \quad (\text{Ec. II-3})$$

Siendo ϕ una función lineal o no lineal como cualquiera de las presentadas en la Figura II-5.

El resultado de esta operación avanza capa por capa hasta llegar a la salida final del modelo, que genera un vector de salida para las clases 0 y 1 en el caso de este estudio.

Una vez comparada esa salida con la respuesta real, se mide el error mediante una función de pérdida. Para tareas de clasificación, como es el caso del objetivo de nuestra red, se utiliza la entropía cruzada (también llamada función *log-loss*) (Ecuación II-4):

$$\text{Log-loss} = -\frac{1}{N} \sum_{p=1}^N \sum_{k=1}^K y_{p,k} \log(\hat{p}_{p,k}), \quad (\text{Ec. II-4})$$

Donde N es el número de muestras, $y_{p,k}$ vale 1 si la muestra p pertenece a la clase k (y 0 en caso contrario), $\hat{p}_{p,k}$ es la probabilidad de salida de la red para la clase k . Esta función se ajusta especialmente bien a problemas de clasificación, ya que mide la discrepancia entre las probabilidades estimadas y las salidas reales, penalizando con mayor intensidad los errores en la clase prevista.

Para reducir esa diferencia entre la salida del MLP y la etiqueta verdadera, se emplea el algoritmo de retropropagación de errores (*back-propagation*) (Werbos, 1974; Rumelhart *et al.*, 1986b). A partir de la función de pérdida, se calcula la derivada de los pesos y sesgos, y se ajustan iterativamente para minimizar dicho error de la siguiente manera (Ecuación II-5):

$$\frac{\partial E}{\partial w_{ij}^l} = \delta_j^l a_i^{(l-1)}, \quad (\text{Ec. II-5})$$

Donde $\frac{\partial E}{\partial w_{ij}^l}$ representa la derivada del error E con respecto al peso w_{ij}^l , y δ_j^l es el término de error de la neurona j en la capa l . Con estos gradientes, se actualizan los pesos siguiendo la Ecuación II-6:

$$w_{ij}^l \leftarrow w_{ij}^l - \eta \frac{\partial E}{\partial w_{ij}^l}, \quad (\text{Ec. II-6})$$

Donde η es la tasa de aprendizaje. En el caso de este estudio, *scikit-learn* utiliza por defecto el optimizador Adam (Kingma y Ba, 2014), que ajusta dinámicamente η y acumula información sobre la media y varianza de los gradientes, lo que suele agilizar la convergencia sin necesidad de afinar manualmente la tasa de aprendizaje. La tasa de aprendizaje inicial (α) utilizada fue 0,001 y la penalización L2 fue 0,0001. Ambas tasas se encuentran definidas por defecto en *scikit-learn*. El término L2 realiza una penalización de los pesos para atenuar el sobreajuste. Por tanto, la red primero ajusta sus pesos con un descenso del gradiente adaptativo (por defecto, *scikit-learn* utiliza el Optimizador Adam;

Kingma y Ba, 2014) y después aplica una ligera regularización L2. Este ajuste se organiza en épocas. Cada época consiste en presentar el conjunto de entrenamiento completo, aplicando en cada iteración el método de aprendizaje y optimización descrito. De este modo, la red ajusta sus parámetros mediante un descenso del gradiente adaptativo y una ligera penalización de los pesos para limitar el sobreajuste, sin configurar manualmente métodos de regularización adicionales. A partir de estas medidas, la red encuentra un equilibrio entre aproximar fielmente las muestras de entrenamiento y conservar la capacidad de generalización hacia datos nuevos.

2.2.4.3. Selección de hiperparámetros

Las entradas del modelo clasificador MLP fueron los comentarios de los usuarios previamente transformados en representaciones binarias mediante la codificación *one-hot* (como fue descrito en la sección 2.2.3).

Los hiperparámetros (arquitectura de la red) se ajustaron utilizando “GridSearchCV”, un método de búsqueda exhaustiva incluido en *scikit-learn* que evalúa todas las combinaciones posibles de hiperparámetros en una cuadrícula definida. Para cada combinación, se realiza una validación cruzada con el fin de estimar el rendimiento del modelo y seleccionar los valores óptimos de hiperparámetros según la métrica de evaluación especificada (Pedregosa *et al.*, 2011). La cuadrícula de parámetros incluyó diferentes combinaciones de una y dos capas ocultas, abarcando todas las posibles combinaciones de 5, 10, 15, 20, 25 y 30 neuronas para cada una de estas capas. Se consideraron tres funciones de activación (Sigmoide –Sig–, Tangente hiperbólica –TanH– y ReLU), y el valor máximo de iteraciones o épocas de calibración se fijó en 500 (Figura II-7).




Figura II-7. Diagrama de flujo de la información de entrada a la red, desde la codificación one-hot hasta el proceso de configuración de los diferentes hiperparámetros establecidos en el Perceptrón Multicapa.

Se empleó una estrategia de validación cruzada estratificada *k-fold* repetida (*repeated stratified k-fold cross validation*), con 5 particiones (*folds*) y 30 repeticiones, para evaluar el rendimiento de las diversas combinaciones de hiperparámetros. La validación estratificada garantiza que la proporción de cada clase en el conjunto de datos se mantenga en cada partición, ofreciendo así una evaluación más representativa del rendimiento del modelo (Kohavi, 1995; Kelleher *et al.*, 2015). La naturaleza repetida de este método permite múltiples iteraciones de la estratificación, lo cual aumenta la fiabilidad de las estimaciones del rendimiento. Este número de repeticiones permite que el modelo seleccionado se ubique entre el 14% superior de la distribución de todos los modelos posibles con un nivel de confianza del 99% (Iyer y Rhinehart, 1999).

Los modelos se evaluaron y clasificaron según su rendimiento en la métrica de sensibilidad, que cuantifica la proporción de verdaderos positivos (VP) entre todas las instancias que son realmente positivas (VP y Falsos Negativos, FN). Esta métrica resulta particularmente útil para conjuntos de datos desbalanceados, donde es crucial identificar correctamente la clase minoritaria (Branco *et al.*, 2016). La Sensibilidad (S) se define como (Ecuación II-7):

$$S = \frac{VP}{VP + FN} \quad (\text{Ec. II-7})$$

Otras métricas se utilizan con frecuencia para una evaluación más exhaustiva: (i) Precisión (P), y (ii) la *F1-score* (Sokolova y Lapalme, 2009).

La Precisión (P) se define como la proporción de verdaderos positivos (VP) entre la suma de verdaderos positivos y falsos positivos (FP) (Ecuación II-8):

$$P = \frac{VP}{VP + FP} \quad (\text{Ec. II-8})$$

La *F1-score* (F1) es la media armónica de la precisión y la sensibilidad, lo que proporciona una medida equilibrada del rendimiento de un modelo (Ecuación II-9):

$$F1 = \frac{2 * (P * R)}{P + S} \quad (\text{Ec. II-9})$$

La búsqueda en cuadrícula se ejecutó con los datos de entrenamiento, y se identificó el mejor modelo junto con sus hiperparámetros. El rendimiento de los 10 mejores modelos según su clasificación se evaluó empleando los datos de prueba. Así, los modelos se ajustaron con los datos de entrenamiento y sus predicciones se compararon y evaluaron con los valores reales de los datos de prueba. Adicionalmente, se generó un informe de clasificación para cada uno de los 10 mejores modelos, proporcionando información más detallada sobre su rendimiento. Finalmente, se evaluó el mejor modelo en la cuadrícula y, si fue necesario, se repitió el proceso hasta hallar la arquitectura de MLP más adecuada.

2.2.5. *Análisis de factores ambientales*

Para caracterizar las variables ambientales en la presencia de medusas en cada conjunto de playas fue necesario evaluar la representación de las observaciones de medusas en los comentarios de cada conjunto de playas. Ello implicó eliminar los conjuntos con escasa representación de datos para asegurar la fiabilidad del análisis. Se procedió a la visualización y comparación de la distribución de la presencia (1) y ausencia (0) de medusas en función de las tres variables ambientales (SST, dirección y velocidad del viento). Cada variable se examinó en cada conjunto de datos, agrupada de acuerdo con los distintos conjuntos de playas. Con el fin de visualizar la distribución de los datos y explorar la relación entre la presencia/ausencia de medusas y otros factores ambientales, se generaron gráficas de Estimación de Núcleos de Densidad (KDE, *Kernel Density Estimation*) utilizando la biblioteca *seaborn* en Python (Waskom, 2021). El enfoque KDE es un método no paramétrico que estima la función de densidad de probabilidad de una variable aleatoria. Este método funciona colocando un núcleo, el cual es una función

suave y simétrica, alrededor de cada punto de datos, para posteriormente sumar estos núcleos y generar una curva de densidad suave que represente la distribución de los datos. En este estudio, se empleó un núcleo de tipo gaussiano, que por defecto produce curvas con forma de campana alrededor de cada punto. Las gráficas KDE se generaron por separado para cada conjunto de playas y para cada variable ambiental evaluada. Se comparó la distribución de estas variables entre los comentarios que indicaron presencia (Clase 1) y ausencia (Clase 0) de medusas.

Adicionalmente, se llevó a cabo un análisis estadístico de las variables ambientales para determinar la magnitud de su variación en función de su efecto en los distintos conjuntos de playas. Se aplicó la prueba no paramétrica de Kruskal-Wallis para comprobar la existencia de diferencias estadísticamente significativas en la distribución de las tres variables ambientales (SST, dirección y velocidad del viento) entre los diferentes conjuntos de playas. Para cada variable, se realizó un test de Kruskal-Wallis y los p -valores resultantes se corrigieron para comparaciones múltiples mediante el procedimiento de Benjamini-Hochberg con el fin de controlar la tasa de descubrimientos falsos y aumentar la fiabilidad de los resultados (García, 2003). Cuando el valor de p corregido resultó menor que 0,05, se llevó a cabo la prueba *post-hoc* de Dunn para comparaciones pareadas entre los grupos. En estas comparaciones pareadas, se ajustaron los p -valores utilizando el método de Holm para contemplar múltiples comparaciones.

2.2.5.1. Modelos GAMM

Los Modelos Aditivos Generalizados Mixtos (GAMM, *Generalized Additive Mixed Models*) constituyen una extensión de los Modelos Aditivos Generalizados (GAM, *Generalized Additive Model*) que permiten la inclusión de relaciones no lineales entre variables explicativas y la variable respuesta, además de incorporar efectos aleatorios para capturar variaciones que no pueden describirse únicamente mediante efectos fijos (Wood, 2017). En el caso de la presencia o ausencia de medusas, la naturaleza potencialmente compleja de los factores implicados (como las condiciones ambientales o las características de las localizaciones geográficas de la procedencia de los datos) hace que los GAMM resulten especialmente útiles, pues proporcionan la flexibilidad de estimar curvas de suavizado adaptadas a la forma real de los datos.

Al igual que un GAM, un GAMM expresa la variable respuesta Y (en este caso, la presencia o ausencia de medusas) mediante la suma de funciones suavizadas de las covariables, sustituyendo las relaciones lineales habituales por funciones no paramétricas que se ajustan a la forma de los datos siguiendo la Ecuación II-10:

$$g(\mu_i) = \beta_0 + f_1(X_i) + f_2(X_i) + \dots + u_{grupo(i)} \quad (\text{Ec. II-10})$$

Donde $g(\cdot)$ representa la función de enlace, β_0 es la ordenada en el origen (o intercepto), f_1 y f_2 son funciones suavizadas que describen cómo cambia μ_i (la media o probabilidad estimada) en respuesta a cada covariable, y u_{grupo} simboliza un efecto aleatorio asociado a un grupo de muestreo correspondiente, controlando variaciones específicas no capturadas por las covariables fijas.

La parte “mixta” del modelo se activa cuando cada unidad (por ejemplo, diferentes lugares de muestreo) aporta un componente de variabilidad aleatorio. Este efecto aleatorio es esencial para no atribuir a las variables ambientales cualquier fluctuación particular de un grupo o lugar de muestreo, lo que mejora la robustez del modelo y ayuda a evitar falsos positivos.

En la práctica, los GAMM pueden ajustarse mediante metodologías como la máxima verosimilitud restringida (REML, *REstricted Maximum Likelihood*), que equilibra la complejidad de las funciones suavizadas y la estructura de varianzas-covarianzas de los efectos aleatorios. La interpretación de un GAMM se centra tanto en la forma de las funciones suavizadas como en la magnitud y relevancia de los efectos aleatorios. Estas funciones suavizadas se suelen representar gráficamente para evidenciar tendencias no lineales que no se capturarían bien con un modelo lineal clásico. Además, si el efecto aleatorio relacionado con cada localización es significativo, puede interpretarse que existen variaciones intrínsecas entre localizaciones que no se explican exclusivamente por las covariables ambientales.

El GAMM se configuró para incluir términos de suavizado para la SST, dirección, y velocidad del viento, así como un efecto aleatorio para los conjuntos de playas. La implementación se llevó a cabo usando la biblioteca *mgcv* en R (Wood, 2021) (Anexo 3). Los parámetros se seleccionaron mediante REML, optimizando así el ajuste del modelo sin incurrir en sobreajuste. La evaluación del modelo ajustado se realizó mediante la inspección visual de los efectos suavizados y resúmenes estadísticos. Este enfoque

permitió un análisis detallado y sistemático del impacto de cada variable explicativa en la presencia de medusas.

2.3. Resultados

Se analizaron un total de 9.433 comentarios de usuarios del foro de la aplicación Infomedusa. Únicamente 1.234 comentarios (13,08%) contenían información explícita acerca de la presencia o ausencia de medusas. Entre estos, 148 observaciones informaron la presencia de medusas y 1.086 indicaron su ausencia. Los registros restantes no incluían información sobre medusas y se clasificaron como No Aplicable (NA). La frecuencia de comentarios en cada conjunto de playas se muestra en la Figura II-8.




Figura II-8. Frecuencia de comentarios de usuarios de la aplicación Infomedusa que mencionan explícitamente la presencia de medusas (barra naranja, etiquetada como 1) o su ausencia (barra azul, etiquetada como 0) para cada conjunto de playas.

El diccionario de palabras únicas constó de 340 términos. Tras el proceso de codificación *one-hot*, cada comentario se representó como un punto de datos en un espacio de características de 340 dimensiones. Adicionalmente, se incluyó una dimensión más para la variable de respuesta, resultando en una matriz de datos final de $n \times 341$, donde n es el número total de comentarios con información sobre medusas.

2.3.1. Perceptrón Multicapa (MLP)

Se implementó un algoritmo de red neuronal artificial Perceptrón Multicapa (MLP) para la clasificación de los comentarios preprocesados de los usuarios de Infomedusa, basándose en si mencionaban la presencia (1) o ausencia (0) de medusas.

En el proceso de optimización de hiperparámetros, se llevó a cabo una búsqueda exhaustiva sobre la cuadrícula de parámetros especificada. Dicha cuadrícula incluyó 21 configuraciones diferentes de neuronas y capas ocultas, así como 3 funciones de activación diferentes para dichas capas, dando lugar a un total de 63 combinaciones únicas. Combinadas con la estrategia de validación cruzada estratificada repetida, que involucra 5 particiones repetidas 30 veces, la metodología completa supuso el ajuste y evaluación de 9.450 modelos distintos entrenados y evaluados. Los 10 mejores modelos en cuanto al rendimiento de sensibilidad para la clase minoritaria (Clase 1) se presentan en la Tabla II-3.

Tabla II-3. Resumen de resultados de los 10 mejores modelos generados por el algoritmo de optimización de ajuste de hiperparámetros mediante GridSearchCV con las 63 combinaciones únicas. La clasificación de modelos se ordena a partir del mejor modelo (#1) en términos de sensibilidad de la clase minoritaria (Clase 1). Ausencia de medusas (Clase 0); Presencia de medusas (Clase 1). Clave: Unidad lineal rectificada (ReLU, Rectified Linear Unit); Sigmoide (Sig); Precisión (P); Sensibilidad (S); F1-score (F1).

Ranking	Capas ocultas	Neuronas	Función de activación	Exactitud (%)	Clase 0			Clase 1		
					P	S	F1	P	S	F1
#1	1	15	ReLU	96,0	0,98	0,98	0,98	0,82	0,79	0,81
#2	1	30	ReLU	96,2	0,98	0,98	0,98	0,82	0,82	0,82
#3	1	20	ReLU	95,7	0,98	0,98	0,98	0,79	0,79	0,79
#4	1	10	ReLU	96,2	0,98	0,98	0,98	0,80	0,85	0,83
#5	2	20, 15	Sig	94,9	0,98	0,96	0,97	0,73	0,82	0,77
#6	2	15, 10	Sig	94,6	0,98	0,96	0,97	0,71	0,82	0,76
#7	2	10, 10	Sig	94,6	0,98	0,96	0,97	0,71	0,82	0,76
#8	2	10, 5	ReLU	95,7	0,98	0,97	0,98	0,78	0,82	0,80
#9	2	25, 25	ReLU	95,4	0,97	0,97	0,97	0,79	0,77	0,78
#10	1	5	ReLU	94,9	0,98	0,97	0,97	0,74	0,79	0,77

Los modelos generados incluyeron diversas configuraciones de capas ocultas y neuronas, utilizando las funciones de activación ReLU y Sigmoide. En general, todos los modelos mostraron un comportamiento similar en los datos de prueba, con altos valores de exactitud entre 94,9% y 96,2%. Para la clase 0 (ausencia de medusas), tanto la

precisión como la sensibilidad se mantuvieron consistentemente elevadas, lo que indica un comportamiento fiable. Sin embargo, hubo variabilidad en la sensibilidad de la clase 1 (presencia de medusas). El cuarto modelo en el ranking alcanzó la sensibilidad más alta (0,85), siendo el mejor al clasificar ambas clases. Este modelo, con una capa oculta de 10 neuronas y activación ReLU, alcanzó además una exactitud de 96,2%.

La matriz de confusión de este modelo reflejó que el modelo predijo correctamente la ausencia de medusas (clase 0) en 324 ocasiones, mientras que en 8 ocasiones no detectó medusas cuando realmente estaban presentes (falsos negativos). Inversamente, predijo correctamente la presencia de medusas (clase 1) en 33 ocasiones, y en 6 ocasiones anunció erróneamente presencia de medusas cuando en realidad no las había (falsos positivos).

2.3.2. Efecto de los factores ambientales en la presencia de medusas

En la recolección de datos de este estudio, se observó una concentración significativa de observaciones en los meses de verano (junio a septiembre), con un total de 77, 524, 502 y 104 observaciones en junio, julio, agosto y septiembre, respectivamente. En contraste, los meses de marzo, abril y mayo presentaron un número muy limitado de datos (1, 9 y 17 observaciones, respectivamente). Debido a esta distribución desigual, se decidió excluir estos meses menos representados de los análisis ambientales. Asimismo, se excluyeron los conjuntos de playas 6 y 7 de las siguientes fases de la investigación debido a su escaso número de comentarios de usuarios en dichas ubicaciones. La Figura II-9 muestra la distribución de la presencia (1) y ausencia (0) de medusas para cada variable mediante gráficas de KDE.




Figura II-9. Gráficos de densidad del núcleo para las variables de temperatura superficial del mar (SST), dirección del viento y velocidad del viento en cada conjunto de playas. Cada fila de gráficos corresponde a un conjunto de playas, mientras que cada columna representa una de las variables ambientales. Para cada gráfico se representan dos distribuciones: una para la presencia de medusas (en naranja, indicada como 1) y otra para la ausencia de medusas (en azul, indicada como 0).

En este estudio, se evaluó la influencia de diversas variables ambientales sobre la presencia de medusas en diferentes conjuntos de playas. Se aplicó la prueba de Kruskal-Wallis a cada una de estas variables, seguida de un ajuste de los p -valores mediante el procedimiento de Benjamini-Hochberg para controlar la tasa de falsos descubrimientos en las comparaciones múltiples (García, 2003). La aplicación de la prueba de Kruskal-Wallis a cada variable ambiental mostró diferencias estadísticamente significativas entre los diferentes conjuntos de playas, lo cual indica variaciones en las condiciones ambientales que podrían influir en la presencia de medusas. Tras el ajuste de Benjamini-Hochberg, los resultados siguieron siendo significativos, reforzando el impacto de estas variables ambientales en la presencia de medusas en los distintos conjuntos de playas.

Tal como se muestra en la Tabla II-4, se compararon los valores medios de la temperatura superficial del mar (SST), la dirección del viento y la velocidad del viento en los distintos conjuntos de playas utilizando la prueba *post-hoc* de Dunn.

Tabla II-4. Valores medios de las variables ambientales temperatura de la superficie del mar (SST, °C), dirección del viento (°x10) y velocidad del viento (km/h) en los diferentes grupos de playas. Para cada variable ambiental, las medias con diferentes letras minúsculas en superíndice (a, b, c, d, e, f) indican diferencias estadísticamente significativas entre los grupos ($p < 0,05$). Por ejemplo, una letra diferente junto al valor de la SST para cada conjunto de playas indica que estos valores son estadísticamente diferentes entre sí. Los conjuntos de playas 6 y 7 se excluyeron del análisis ambiental dado el escaso volumen de datos generados por los usuarios sobre avistamiento de medusas.

Conjunto de playa	SST (°C)	Dirección del viento (° x10)	Velocidad del viento (km/h)
Set 1	23,59 ^a	17,73 ^a	7,69 ^a
Set 2	24,28 ^a	15,26 ^b	6,45 ^c
Set 3	22,94 ^a	16,96 ^a	5,72 ^d
Set 4	21,37 ^b	17,51 ^a	11,26 ^e
Set 5	20,95 ^c	14,02 ^c	8,46 ^a
Set 8	21,47 ^d	37,72 ^d	11,51 ^f
Set 9	23,78 ^a	17,98 ^a	6,29 ^b
Set 10	23,67 ^a	17,39 ^a	13,50 ^e
Set 11	24,41 ^a	16,35 ^a	11,87 ^e

En cuanto a la SST, los conjuntos 1, 2, 3, 9, 10 y 11 presentaron medias similares ($p > 0,05$), con valores que iban de 23,59 °C a 24,41 °C. No obstante, los conjuntos 4, 5 y 8 registraron valores de SST significativamente más bajos, con promedios de 21,37 °C, 20,95 °C y 21,47 °C, respectivamente.

Respecto a la dirección del viento, los conjuntos 1, 3, 4, 9, 10 y 11 mostraron valores similares ($p>0,05$), con medias entre 16,35 y 17,98 ($^{\circ} \times 10$). En cambio, los conjuntos 2 y 5 presentaron valores significativamente inferiores, con 15,26 y 14,02 ($^{\circ} \times 10$), respectivamente. Cabe destacar que el conjunto 8 exhibió una dirección del viento significativamente mayor de 37,72 ($^{\circ} \times 10$).

En relación con la velocidad del viento, los conjuntos 1, 5, 10 y 11 mostraron valores promedio similares ($p>0,05$), que fueron desde 7,69 a 13,50 km/h. Los conjuntos 2 y 9 registraron velocidades del viento significativamente inferiores, con 6,45 y 6,29 km/h, respectivamente. El conjunto 3 presentó la velocidad promedio más baja, 5,72 km/h. Por su parte, el conjunto 8 mostró una velocidad del viento media de 11,51 km/h.

El Modelo Aditivo Generalizado Mixto (GAMM) reveló una influencia significativa de las variables ambientales en la presencia de medusas. El modelo ajustado explicó el 40,3% de la desviación explicada y mostró un R^2 ajustado de 0,34, indicando un ajuste moderado a los datos. Entre los términos suavizados, la velocidad del viento ($df=1,000$; $p=0,003$) y los conjuntos de playas ($df=7,570$; $p<0,001$) resultaron ser predictores altamente significativos, y la dirección del viento mostró significancia marginal ($df=4,130$, $p=0,070$). La SST ($df=2,011$, $p=0,130$) no fue estadísticamente significativa al nivel 0,05, aunque mostró una tendencia hacia la significancia.

Las gráficas de efectos suavizados (Figura II-10) muestran las relaciones no lineales entre las variables ambientales y la presencia de medusas. La velocidad del viento tuvo un efecto notablemente fuerte, asociándose mayores velocidades con una menor probabilidad de presencia de medusas. La SST mostró una ligera tendencia ascendente en la presencia de medusas a temperaturas más altas, aunque sin alcanzar significancia estadística. En cuanto a la dirección del viento, se observó una relación más compleja, con ciertas direcciones que presentaban mayor probabilidad de presencia de medusas, sugiriendo la posible influencia de vientos que empujan a las medusas hacia la orilla. El efecto aleatorio asociado a los conjuntos de playas capturó una variabilidad sustancial entre las distintas ubicaciones costeras.




Figura II-10. Efectos suavizados de las variables ambientales sobre la presencia de medusas. Las zonas sombreadas azules representan el intervalo de confianza del 95%.

2.4. Discusión

Los resultados indican que se emplearon con éxito métodos de aprendizaje automático para examinar la presencia de medusas en la costa andaluza utilizando datos de ciencia ciudadana procedentes de la aplicación Infomedusa. Se utilizó eficazmente un clasificador Perceptrón Multicapa (MLP, *Multi Layer Perceptron*) para clasificar los comentarios de la ciudadanía, y se combinaron datos ambientales con dichos comentarios para caracterizar la presencia de medusas en la costa del sur de España, proporcionando información valiosa tanto para los usuarios de las playas como para las autoridades.

El modelo MLP maneja de manera eficiente problemas de clasificación no lineal y muestra robustez frente al ruido y valores atípicos (Haykin, 2009). Estas redes neuronales artificiales mostraron un buen rendimiento, sobre todo a la hora de informar acerca de la ausencia de medusas. No obstante, su precisión resultó menor al informar sobre la presencia de medusas, posiblemente debido al desequilibrio en la base de datos, que contenía un menor número de comentarios que mencionan la presencia de estos organismos. Este tipo de desbalanceo es un reto común en las tareas de clasificación binaria cuando se utilizan datos del mundo real (He y Garcia, 2009; Szeghalmy y Fazekas, 2023). A pesar de aplicar estrategias como el uso de la métrica de sensibilidad para evaluar los modelos MLP y combatir este problema, es probable que se mantenga cierto grado de sesgo en nuestras predicciones. Para solucionar este escenario, sería beneficioso fomentar un uso más generalizado de la aplicación Infomedusa, no sólo durante la temporada alta de visitas a las playas, sino durante todo el año. Además, podría implementarse el uso de técnicas de sobremuestreo para crear un conjunto de datos equilibrado entre temporadas de afluencia de usuarios altas y bajas en las playas, compensando la escasez de datos de la clase minoritaria y mejorando aún más la solidez y fiabilidad de los modelos (Branco *et al.*, 2016). Estas dos aproximaciones permitirían obtener una imagen más completa y equilibrada de la presencia de medusas, y así mejorar la precisión y la capacidad de generalización de futuros modelos predictivos.

De forma análoga a nuestro estudio, Gutiérrez-Estrada *et al.* (2021) implementaron una Red de Transición Aumentada (ATN, *Augmented Transition Network*) para procesar automáticamente los comentarios de Infomedusa del año 2018. A través de un procedimiento de análisis sintáctico, este algoritmo alcanzó una exactitud de 89,2% (aproximadamente un 7% menos preciso que el modelo MLP más preciso obtenido en

este estudio). En este sentido, los resultados del presente estudio implican una mejora significativa respecto a usos previos de esta fuente de información, lo que se traduce en un aumento en la precisión de futuros trabajos basados en ciencia ciudadana con datos procedentes de Infomedusa. La misma metodología fue aplicada por Gutiérrez-Estrada *et al.* (2005), quienes desarrollaron y evaluaron un sistema experto para diagnosticar patologías en anguilas. La ATN obtuvo una tasa de éxito del 69,9% en las respuestas estrictamente correctas, que aumentó a 96,6% cuando se consideraron correctas las respuestas aproximadas. En comparación con esta tasa de éxito de la ATN (tomando solo las respuestas estrictamente correctas), nuestro mejor clasificador de red neuronal artificial alcanzó una precisión del 96,2%, lo que sugiere un nivel de exactitud y fiabilidad más elevado.

Las técnicas de aprendizaje profundo (*deep learning*) como las redes neuronales convolucionales (CNN, *Convolutional Neural Networks*) también se han utilizado en la gestión de poblaciones de medusas aplicadas al reconocimiento de imágenes y el desarrollo de herramientas de monitoreo (Gauci *et al.*, 2020; Martin-Abadal *et al.*, 2020; Han *et al.*, 2021; Ruiz-Frau *et al.*, 2022). Estas técnicas han demostrado ser eficientes al identificar y clasificar especies de medusas en imágenes, permitiendo análisis más rápidos y precisos, mejorando así la calidad y la cantidad de datos recopilados, y contribuyendo a un mejor conocimiento de las poblaciones de medusas y sus patrones de distribución.

2.4.1. La ciencia ciudadana para monitorear medusas

El auge de la ciencia ciudadana ha transformado la forma en que se recopilan datos ambientales, proporcionando volúmenes masivos de información que antes eran inalcanzables mediante métodos tradicionales (Cappa *et al.*, 2022). La participación de voluntarios en la recolección de datos no solo amplía la escala y resolución espacial de los estudios científicos, sino que también fomenta el compromiso público con la conservación y la gestión sostenible de los ecosistemas, convirtiendo a la sociedad en una aliada activa de la investigación. Esta colaboración facilita la identificación de incidencias en zonas de difícil acceso o en horarios en los que no se dispone de personal investigador (Silvertown, 2009; Johnston *et al.*, 2023). Sin embargo, la utilidad de estos datos depende de su validación y de la implementación de estrategias que mitiguen los sesgos introducidos por la variabilidad en la participación y el esfuerzo de muestreo (Johnston

et al., 2023). En este contexto, el monitoreo de medusas a través de iniciativas de ciencia ciudadana representa una oportunidad para mejorar la comprensión de los patrones de distribución y proliferación de estas especies, al tiempo que plantea desafíos metodológicos que deben abordarse para garantizar la fiabilidad de los datos.

La importancia de continuar con el monitoreo local de medusas no debe subestimarse. Para ampliar nuestro conocimiento sobre los patrones de distribución de poblaciones de estos organismos, es esencial llevar a cabo un seguimiento continuo a escala local (Danielsen *et al.*, 2005). Este monitoreo permite registrar las múltiples fluctuaciones y refinar la comprensión de dichos patrones.

Según Danielsen *et al.* (2005), el monitoreo local no solo resulta rentable, sino que también produce resultados relevantes a nivel regional y, en determinados contextos, puede ser tan confiable como el monitoreo profesional. Esto cobra especial importancia dado el carácter localizado de las condiciones ambientales que afectan a las poblaciones de medusas. Cuando se diseña e implementa adecuadamente un programa de monitoreo local puede proporcionar datos de gran valor para la toma de decisiones y la adopción de medidas de gestión oportunas (Fraisl *et al.*, 2022). Además, el monitoreo local puede reforzar los sistemas de gestión de recursos basados en la comunidad y propiciar un cambio en las actitudes de los ciudadanos hacia una gestión más sostenible de los recursos. Estas iniciativas promueven de forma considerable la concienciación y el compromiso público con la biodiversidad, formando una comunidad informada y dispuesta a contribuir positivamente a los esfuerzos de conservación. Esto coincide con los hallazgos de otros estudios que destacan el potencial de la participación de la comunidad en la conservación de la biodiversidad (Irwin, 2002; Berkes *et al.*, 2007; Conrad y Hilchey, 2011).

No obstante, la participación ciudadana presenta importantes desafíos. Uno de los más comunes radica en los sesgos de muestreo (Revisado en Dickinson *et al.*, 2010). La recolección de datos a partir de ciencia ciudadana depende en gran medida de la distribución espacial y temporal de los voluntarios, lo que tiende a sobrerrepresentar áreas de fácil acceso y a dejar de lado regiones remotas. Además, la heterogeneidad en el esfuerzo de muestreo y la falta de protocolos uniformes en algunos casos añade una capa adicional de incertidumbre que requiere el empleo de métodos estadísticos avanzados para corregir posibles distorsiones (Johnston *et al.*, 2023). En el caso de los datos procedentes de Infomedusa, las playas más concurridas reciben mayor número de

reportes, y las observaciones se concentran con frecuencia en periodos vacacionales o momentos de día con mayor afluencia. Por lo tanto, este enfoque basado en las observaciones de usuarios que viven la experiencia del entorno costero, aunque puede resultar rentable y fiable, requiere tener en cuenta los posibles sesgos y errores introducidos por los observadores, pues las decisiones de los usuarios acerca de qué y cuándo informar pueden afectar los patrones de datos observados (Arazy y Malkinson, 2021). Según Silvertown (2009), para superar los obstáculos que presenta el uso de la ciencia ciudadana es esencial establecer protocolos estandarizados que permitan validar los datos recogidos por voluntarios. Esto implica diseñar métodos de recolección bien definidos, hacer explícitas las suposiciones implícitas y formular hipótesis claras. Además, es crucial aprovechar las nuevas tecnologías para facilitar la formación, el seguimiento y la retroalimentación a los participantes, lo que a su vez incentiva una mejora continua en la calidad de los datos y promueve una colaboración efectiva entre profesionales y ciudadanos.

En el caso de la aplicación Infomedusa, a pesar de no estar diseñada explícitamente con fines científicos, los datos que recopila pueden resultar valiosos para el análisis científico, siempre y cuando se validen y procesen adecuadamente. Este enfoque aprovecha las observaciones diarias de la ciudadanía para mejorar el monitoreo y la gestión ambiental. La aplicación Infomedusa recoge comentarios de los usuarios sobre las condiciones de la playa y la presencia de medusas. Si bien cuenta con administradores que gestionan el uso inapropiado e informan de las novedades, quienes contribuyen con datos no saben que sus aportaciones se usan con fines de investigación. Durante todo el estudio, se mantuvo la confidencialidad de los datos de los usuarios, salvaguardando su identidad e información personal. Esto presenta desafíos y oportunidades para incrementar la precisión y la utilidad de los datos recopilados.

Los resultados tienen un potencial impacto real, sobre todo en el ámbito turístico, un sector fundamental de la economía española (Moreno-Luna *et al.*, 2021). De acuerdo con el Instituto Nacional de Estadística (INE), Andalucía recibió 10 millones de turistas internacionales en 2022, con un gasto diario promedio de 133,33 euros. El turismo de sol y playa en Andalucía, así como en otras regiones costeras de España, puede verse seriamente afectado por la presencia de medusas, ya que sus picaduras pueden provocar desde molestias leves hasta problemas de salud de mayor gravedad, disuadiendo a los visitantes (Bordehore *et al.*, 2016; Rubio-Gómez y Gutiérrez-Hernández, 2020; Cantarero

Prados y Moreno Portillo, 2021; Crowley-Cyr *et al.*, 2022; Ruiz-Frau, 2022). Por consiguiente, la predicción de proliferaciones de medusas y la emisión de avisos tempranos basados en nuestros resultados podrían mejorar sustancialmente la seguridad y la satisfacción de los bañistas, fomentando experiencias más positivas en las playas (De Donno *et al.*, 2014). Con un flujo continuo de información veraz y de calidad, las autoridades y gestores costeros pueden reaccionar con mayor antelación, mejorando la prevención y mitigación de posibles efectos adversos para el turismo y la biodiversidad. En este sentido, la ciencia ciudadana puede ser una herramienta fundamental para los desafíos futuros en la conservación y uso sostenible de los recursos marinos (Earp y Liconti, 2020).

2.4.2. *Impacto de los factores ambientales estudiados*

En relación con el posible impacto de los factores ambientales en la presencia de medusas, los resultados concuerdan con estudios previos que sugieren que la temperatura superficial del mar (SST, *Sea Surface Temperature*), así como la dirección y la velocidad del viento, influyen de manera significativa en la distribución de medusas (Zavodnik, 1987; Graham *et al.*, 2001; Purcell, 2005; Canepa *et al.*, 2014; Messié y Chavez, 2017). Se observaron variaciones significativas de la SST en ciertas zonas de la costa andaluza, que podrían estar determinadas por características geográficas o ambientales específicas, como la orientación de la línea de costa, las corrientes marinas o los patrones meteorológicos locales (Canepa *et al.*, 2014). De acuerdo con otros autores (Purcell, 2005; Brotz *et al.*, 2012; Heim-Ballew y Olsen, 2019), los resultados de este estudio corroboran que la presencia de medusas tiende a ser más frecuente en condiciones de temperatura elevada. Esto coincide con estudios que han demostrado un efecto directo de la SST en la reproducción de medusas, al favorecer el desarrollo de huevos y, así, su éxito reproductivo (Avian *et al.*, 1991). En particular, en la región mediterránea, el aumento de la temperatura se ha relacionado de manera notable con la proliferación de la medusa *Pelagia noctiluca*, conocida por su abundancia, frecuencia de brotes (Brotz y Pauly, 2012), y la más reportada fotográficamente a través de Infomedusa. Además, la bibliografía indica que el pico de desove de esta especie ocurre en primavera, alcanzando su máximo cuando la temperatura ronda los 17°C (Augustine *et al.*, 2014), lo que sugiere una variación estacional en las poblaciones de medusas. Esto recalca la importancia de considerar las especies de medusas y sus ciclos reproductivos específicos al examinar el

efecto de la SST sobre la presencia de estos organismos. Se debe aclarar que, debido a la disponibilidad de datos concentrados en los meses estivales, es posible que estos hallazgos no reflejen por completo los patrones de presencia de medusas en otras estaciones, ni que se apliquen a especies de medusas diferentes a *P. noctiluca*.

Aun así, la formación de enjambres de medusas de alta densidad no solo es consecuencia de elevadas tasas de proliferación, potencialmente dependientes de la SST, sino también de los cambios en los patrones de agregación y distribución de las especies, inducidos por variaciones en la dirección del viento (Bellido *et al.*, 2020). De acuerdo con los resultados, las condiciones de viento parecen favorecer la presencia de medusas en la costa cuando sopla viento en dirección hacia la orilla, como se observa en la frecuencia de medusas observada en los conjuntos de playas 1, 2, 9 y 11. Este patrón es coherente con la naturaleza planctónica de estos organismos, los cuales pueden ser transportados pasivamente y concentrarse cerca de la costa por efecto de corrientes, mareas y vientos (Zavodnik, 1987; Graham *et al.*, 2001; Mills, 2001; MacAli *et al.*, 2018). Cabe destacar que en algunos conjuntos de playas (como los conjuntos 3, 4, 8 y 10) la influencia de la dirección y la velocidad del viento en la presencia de medusas no es tan clara, ya sea por la poca frecuencia de medusas registrada o por la superposición de condiciones ambientales que a veces se asocian a la presencia de medusas y otras veces no. Estos hallazgos ofrecen información valiosa para futuros estudios que busquen predecir la aparición de medusas según condiciones ambientales específicas.

Asimismo, los resultados muestran que la velocidad del viento, aunque quizá no tenga un efecto tan evidente como la dirección, podría influir en la distribución de medusas. El efecto de la velocidad del viento varía con cada conjunto de playas, en consonancia con lo reportado por Gutiérrez-Estrada *et al.* (2021), quienes identificaron que la distribución regional de medusas se veía afectada de forma significativa por factores locales. Esto puede relacionarse con la interacción del viento con los giros oceánicos a lo largo de la costa sur de España, donde las medusas pueden concentrarse en el interior de dichos giros o bien dispersarse hacia la orilla (Franks, 1992; Bellido *et al.*, 2020; Castro-Gutiérrez *et al.*, 2022). En el área de estudio, la velocidad del viento tiende a disminuir durante el verano (Vargas-Yáñez *et al.*, 2021), periodo en el que se recopiló la mayoría de los datos. Debido a que la velocidad del viento disminuye de forma estacional en esta época, la capacidad para observar y comprender plenamente su influencia en la distribución de medusas puede verse limitada en algunas ubicaciones.

Ello se debe a que, si las velocidades del viento son generalmente bajas, no se dispone de un rango completo de condiciones de viento que permita capturar la magnitud total de los impactos de la variación de la velocidad en la distribución de medusas.

La complejidad de los patrones de temperatura y viento, junto con la variabilidad en la presencia de medusas, dificulta establecer con exactitud la relación entre estos factores. Además, la superposición en la distribución de datos sugiere que, si bien ciertas condiciones pueden propiciar la aparición de medusas, su presencia no está siempre garantizada. Esto indica que su aparición no depende únicamente de factores concretos como la temperatura del mar o el viento, sino que existen otros factores y combinaciones de procesos ambientales y biológicos mucho más complejos (Canepa *et al.*, 2014).

En este capítulo, se han utilizado variables ambientales fáciles de medir y obtener a través de estaciones meteorológicas, satélites o boyas oceanográficas. Estos factores permiten identificar patrones generales de transporte pasivo, ya que las medusas, al carecer de una gran capacidad de movimiento propio, dependen en gran medida de las corrientes y los vientos para desplazarse una vez se han aproximado a la costa (Canepa *et al.*, 2014). Sin embargo, hay otros factores que también influyen en su presencia o en la formación de enjambres y que resultan más difíciles de medir con precisión, lo que complica su inclusión en modelos predictivos (Revisado en el Capítulo I). Además, el efecto de estas variables sobre las medusas puede diferir entre especies (Purcell, 2005).

La modelización de la dinámica poblacional de medusas a partir de variables ambientales puede resultar muy útil para predecir su aparición, que en ocasiones puede ocasionar riesgos para la salud humana a causa de sus picaduras (Gershwin *et al.*, 2014). Los modelos desarrollados podrían utilizarse potencialmente para prever la presencia de medusas en las playas andaluzas, alertando así a los bañistas y contribuyendo a prevenir picaduras, con el consiguiente aumento de la seguridad y disfrute en las playas (CIESM, 2001; Lucas *et al.*, 2014; Martín-Abadal *et al.*, 2020). No obstante, para mejorar la capacidad de previsión, es fundamental seguir avanzando en la parametrización de los factores biológicos y ambientales que regulan la dinámica de estos organismos. Determinar los límites de tolerancia ambiental de cada estadio del ciclo de vida, cuantificar cómo varían las tasas de crecimiento, reproducción asexual y mortalidad en condiciones cambiantes, y profundizar en las interacciones interespecíficas y tróficas permitirá desarrollar modelos más robustos y realistas. Solo con un enfoque ecosistémico

y una mejora progresiva en la complejidad de los experimentos es posible conseguir a una predicción más precisa y útil para la gestión costera (Fernández-Alías *et al.*, 2024).

2.4.3. Limitaciones de este estudio

Pese a la relevancia de los resultados obtenidos, este capítulo presenta varias limitaciones que deben ser reconocidas y abordadas en futuras investigaciones. En primer lugar, los datos de la aplicación han sido recopilados predominantemente en los meses de verano, lo que impide generalizar estos hallazgos de forma fiable a otras estaciones del año. La variabilidad estacional puede influir significativamente en la presencia y abundancia de medusas, y la ausencia de datos durante el invierno u otras épocas limita la capacidad de generalización de nuestros resultados (Silvertown, 2009).

En segundo lugar, el carácter desequilibrado de los datos (menos observaciones de presencia de medusas que de ausencia) pudo haber afectado la exactitud de nuestros resultados, en especial en la clasificación de la presencia de medusas. Dado el contexto de nuestro estudio, en el que la presencia de medusas supone un riesgo para los bañistas, maximizar la sensibilidad del modelo es especialmente valioso. Este enfoque da prioridad a minimizar los errores por omisión (falsos negativos), que en nuestro caso significaría no predecir la presencia de medusas que podrían tener implicaciones potenciales para la seguridad, aunque esta elección podría derivar en una reducción de la precisión y, consecuentemente, en un incremento de falsos positivos (Fawcett, 2006; Hanson, 2011). Por lo tanto, aunque los modelos generados pretenden alcanzar una alta sensibilidad, la métrica F -beta, que equilibra la sensibilidad y la precisión, podría considerarse una alternativa útil más equilibrada una vez se logre abordar el desbalanceo de las clases. La métrica F -beta permite ajustar de forma flexible la importancia relativa de la sensibilidad frente a la precisión. Por ejemplo, asignar un valor de β mayor que 1 daría mayor peso a la sensibilidad, lo que resulta ventajoso en escenarios en los que se pretende minimizar la cantidad de falsos negativos. Este enfoque podría conducir a modelos que equilibren de manera más adecuada ambos tipos de error, mejorando así la capacidad predictiva en contextos con datos desbalanceados (He y García, 2009).

Otra vía de mejora sería emplear técnicas de sobremuestreo o submuestreo para crear conjuntos de datos artificialmente balanceados. Para este estudio, solo se consideraron los comentarios que contenían información explícita de la presencia o

ausencia de medusas, lo que derivó en el uso de menos del 20% de los comentarios totales. Herramientas como la librería *imbalanced-learn* de Python ofrecen métodos eficientes para reequilibrar las clases, permitiendo al modelo aprender patrones representativos tanto de la presencia como de la ausencia de medusas. Esta estrategia podría reducir el sesgo inherente al desbalanceo y mejorar la generalización del modelo a diferentes contextos y condiciones (Branco *et al.*, 2016).

Asimismo, la actualización implementada en junio de 2024 en la aplicación Infomedusa ofrece una oportunidad prometedora para mejorar el equilibrio en el conjunto de datos, reduciendo la necesidad de recurrir a técnicas de balanceo artificial. Al requerir que los usuarios indiquen explícitamente si han observado medusas en sus comentarios, se facilita la generación de registros más estructurados y uniformes, lo que podría reducir el problema inherente a la recopilación de datos mediante un sistema de "ciencia ciudadana no dirigida" como es el de la primera versión de la aplicación Infomedusa. Como consecuencia, futuros estudios podrán desarrollar modelos predictivos sin necesidad de aplicar técnicas de balanceo artificial de datos, optimizando el proceso de ajuste de hiperparámetros y, en última instancia, la capacidad del modelo para detectar situaciones de riesgo de presencia de medusas. Siguiendo a Edelist *et al.* (2025), otras de las mejoras que podrían implementarse incluyen la adopción de un esquema de estandarización de datos para favorecer la interoperabilidad con otras bases de datos; la introducción de "usuarios expertos" que verifiquen avistamientos dudosos o identifiquen errores taxonómicos y de conteo; así como la incorporación de sistemas de clasificación por intervalos de abundancia, lo que facilitaría comparar la información de Infomedusa con la de otras iniciativas de ciencia ciudadana en el Mediterráneo. Este enfoque ampliado contribuiría a afinar la capacidad de los modelos predictivos de medusas y a reforzar la utilidad de los datos para la gestión costera y la emisión de alertas tempranas.

2.5. Conclusiones

Los resultados de este estudio ponen de manifiesto la eficacia de combinar datos de ciencia ciudadana con técnicas de aprendizaje automático para monitorear la presencia de medusas en zonas costeras. La red neuronal Perceptrón Multicapa (MLP) mostró una alta exactitud en la clasificación de la presencia y ausencia de medusas, pese a las dificultades derivadas del desequilibrio de los datos. Asimismo, se resalta el impacto significativo de las variables ambientales, en particular la temperatura superficial del mar y las condiciones de viento, sobre la distribución de medusas.

Con objeto de mejorar la gestión costera a partir de estos hallazgos, resulta esencial llevar a cabo un monitoreo continuo de estas variables ambientales. La integración en tiempo real de datos de SST y viento en la aplicación Infomedusa y en otras herramientas de monitoreo ofrecería información actualizada, posibilitando predicciones más precisas y oportunas de la presencia de medusas. Dicha integración favorece una gestión más proactiva de las playas. A su vez, el desarrollo de sistemas de información pública que notifiquen a los bañistas sobre las condiciones ambientales actuales y la probabilidad de aparición de medusas es fundamental.

Además, se recomienda destinar más esfuerzos de investigación para analizar la influencia de otros posibles factores ambientales. Conocer la relación de estos factores y sus efectos combinados ayudaría a perfeccionar aún más los modelos predictivos y las estrategias de gestión. La adopción de estrategias de gestión adaptativa, en respuesta a datos ambientales en tiempo real y a los resultados de modelos predictivos, posibilitaría ajustes dinámicos de las prácticas de gestión de playas, reduciendo el impacto de las proliferaciones de medusas en los bañistas.

Gracias a la aplicación de estas recomendaciones, las autoridades encargadas de la gestión costera podrán mejorar la seguridad y el disfrute de los usuarios de las playas, optimizar la precisión del monitoreo de medusas y contribuir a la comprensión global de los ecosistemas marinos. Este enfoque específico, basado en el análisis de factores ambientales, puede derivar en una gestión más eficaz y eficiente de las zonas costeras afectadas por proliferaciones de medusas mediante sistemas de alerta temprana.

2.6. Referencias

- Arazy, O., Malkinson, D. 2021. A framework of observer-based biases in citizen science biodiversity monitoring: semi-structuring unstructured biodiversity monitoring protocols. *Frontiers in Ecology and Evolution* 9, 1-13.
- Augustine, S., Rosa, S., Kooijman, S. A., Carlotti, F., Poggiale, J. C. 2014. Modeling the eco-physiology of the purple mauve stinger, *Pelagia noctiluca* using Dynamic Energy Budget theory. *Journal of sea research* 94, 52-64.
- Avian, M., Rottini-Sandrini, L., Stravisi, F. 1991. The effect of seawater temperature on the swimming activity of *Pelagia noctiluca* (Forsskal). *Italian Journal of Zoology* 58(2), 135-143.
- Ballesteros, A., Marambio, M., Fuentes, V., Gili, J. M. 2020. The use of a citizen science tool (IMEDJELLY App) to deliver First Aid Protocols for Mediterranean jellyfish stings. En *VII International Symposium on Marine Sciences (ISMS 2020)*, 1-3 de julio de 2020. Barcelona, España.
- Basheer, I. A., Hajmeer, M. 2000. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods* 43(1), 3-31.
- Bellido, J. J., Baez, J. C., Souviron-Priego, L., Ferri-Yáñez, F., Salas, C., López, J. A., Real, R. 2020. Atmospheric indices allow anticipating the incidence of jellyfish coastal swarms. *Mediterranean Marine Science* 21(2), 289-297.
- Berkes, F., Berkes, M. K., Fast, H. 2007. Collaborative integrated management in Canada's north: The role of local and traditional knowledge and community-based monitoring. *Coastal Management* 35(1), 143-162.
- Bianchi, C. N., Morri, C. 2000. Marine biodiversity of the Mediterranean Sea: situation, problems and prospects for future research. *Marine Pollution Bulletin* 40(5), 367-376.
- Boero, F., Putti, M., Trainito, E., Prontera, E., Piraino, S., Shiganova, T. A. 2009. First records of *Mnemiopsis leidyi* (Ctenophora) from the Ligurian, Thyrrenian and Ionian Seas (Western Mediterranean) and first record of *Phyllorhiza punctata* (Cnidaria) from the Western Mediterranean. *Aquatic Invasions* 4(4), 675-680.

- Bonney, R., Cooper, C. B., Dickinson, J., Kelling, S., Phillips, T., Rosenberg, K. V., Shirk, J. 2009. Citizen science: a developing tool for expanding science knowledge and scientific literacy. *BioScience* 59(11), 977-984.
- Bonney, R., Phillips, T. B., Ballard, H. L., Enck, J. W. 2016. Can citizen science enhance public understanding of science? *Public understanding of science* 25(1), 2-16.
- Bordehore, C., Alonso, C., Sánchez-Fernández, L., Canepa, A., Acevedo, M., Nogué, S., Fuentes, V. L. 2016. Lifeguard assistance at Spanish Mediterranean beaches: jellyfish prevail and proposals for improving risk management. *Ocean & Coastal Management* 131, 45-52.
- Branco, P., Torgo, L., Ribeiro, R. P. 2016. A Survey of Predictive Modeling on Imbalanced Domains. *ACM Computing Surveys* 49(2), 1-50.
- Brotz, L., Cheung, W. W. L., Kleisner, K., Pakhomov, E., Pauly, D. 2012. Increasing jellyfish populations: trends in large marine ecosystems. *Hydrobiologia* 690(1), 3-20.
- Brotz, L., Pauly, D. 2012. Jellyfish populations in the Mediterranean Sea. *Acta Adriatica* 53(2), 213-231.
- Canepa A., Fuentes M., Marambio M., Lopez L., Deidun A., Yahia K. D. O., Yahia, M. N. D., Piraino, S., Fuentes, V. 2016. Forecasting jellyfish blooms in the Mediterranean Sea: The med-JellyRisk project. En *5th International Jellyfish Bloom Symposium*. 30 de mayo – 3 de junio 2016. Barcelona, España.
- Canepa, A., Fuentes, V., Sabatés, A., Piraino, S., Boero, F., Gili, J. M. 2014. *Pelagia noctiluca* in the Mediterranean Sea. En K. Pitt, C. Lucas (Eds.), *Jellyfish blooms* (pp. 237-266). Springer.
- Cantarero-Prados, F. J., Moreno Portillo, A. M. 2021. Jellyfish Swarms and Degree of Exposure and Vulnerability of Recreational and Tourist Activities on Beaches. Methodological Approach to Their Assessment in the Lagos-Ferrara Sector (Málaga, Spain). En J. V. de Carvalho, Á. Rocha, P. Liberato, A. Peña (Eds.), *Advances in Tourism, Technology and Systems. ICOTTS 2020. Smart Innovation, Systems and Technologies* (Vol. 208, pp. 331-340). Springer.

- Cappa, F., Franco, S., Rosso, F. 2022. Citizens and cities: Leveraging citizen science and big data for sustainable urban development. *Business Strategy and the Environment* 31(2), 648-667.
- Castro-Gutiérrez, J., Gutiérrez-Estrada, J. C., Aroba, J., Pulido-Calvo, I., Peregrín, A., Báez, J. C., Bellido, J. J., Souviron-Priego, L. 2022. Estimation of jellyfish abundance in the south-eastern Spanish coastline by using an explainable artificial intelligence model based on fuzzy logic. *Estuarine, Coastal and Shelf Science* 277, 108062.
- Castro-Gutiérrez, J., Gutiérrez-Estrada, J. C., Báez, J. C. 2024. Using artificial neural networks and citizen science data to assess jellyfish presence along coastal areas. *Journal of Applied Ecology* 61(9), 2244-2257.
- CIESM. 2001. Gelatinous zooplankton outbreaks: theory and practice. *CIESM Workshop Series* 14, 112.
- Conrad, C. C., Hilchey, K. G. 2011. A review of citizen science and community-based environmental monitoring: issues and opportunities. *Environmental monitoring and assessment* 176, 273-291.
- Crall, A. W., Newman, G. J., Stohlgren, T. J., Holfelder, K. A., Graham, J., Waller, D. M. 2011. Assessing citizen science data quality: an invasive species case study. *Conservation Letters* 4(6), 433-442.
- Crowley-Cyr, L., Gershwin, L., Bremser, K., Abraham, V., Moreno Martin, M. J., Carreño, M., Wüst, K. 2022. Jellyfish risk communications: the effect on risk perception, travel intentions and behaviour, and beach tourism destinations. *Journal of Hospitality and Tourism Management* 51, 196-206.
- Cunha, A. A. L., Costa, M. C., Pacheco, M. A. C. 2019. Sentiment analysis of youtube video comments using deep neural networks. En L. Rutkowski, R. Scherer, M. Korytkowski, W. Pedrycz, R. Tadeusiewicz, J. Zurada (Eds.), *Artificial Intelligence and Soft Computing. ICAISC 2019. Lecture Notes in Computer Science* (Vol. 11508). Springer.
- Danielsen, F., Burgess, N. D., Balmford, A. 2005. Monitoring matters: examining the potential of locally-based approaches. *Biodiversity & Conservation* 14, 2507-2542.

- De Donno, A., Idolo, A., Bagordo, F., Grassi, T., Leomanni, A., Serio, F., Guido, M., Canitano, M., Zampardi, S., Boero, F., Piraino, S. 2014. Impact of stinging jellyfish proliferations along south Italian coasts: Human health hazards, treatment and social costs. *International journal of environmental research and public health* 11(3), 2488-2503.
- Deidun, A., Drago, A., Cutajar, D., Gauci, A., Galea Degiovanni, M. 2014. Jellyfish spotting citizen science campaign in Malta: Spot the jellyfish. En *MED-JELLYRISK Conference and Training Seminar. Addressing Jellyfish Blooms to Safeguard Coastal Economic Activities. Research, Innovation, Management and Education* (p. 18). San Julián, Malta.
- Delaney, D. G., Sperling, C. D., Adams, C. S., Leung, B. 2008. Marine invasive species: validation of citizen science and implications for national monitoring networks. *Biological Invasions* 10, 117-128.
- Dickinson, J. L., Zuckerberg, B., Bonter, D. N. 2010. Citizen science as an ecological research tool: challenges and benefits. *Annual Review of Ecology, Evolution, and Systematics* 41, 149-172.
- Do, A. N. T., Tran, H. D. 2022. Potential application of artificial neural networks for analyzing the occurrences of fish larvae and juveniles in an estuary in northern Vietnam. *Aquatic Ecology* 57, 1-19.
- Earp, H. S., Liconti, A. 2020. Science for the future: the use of citizen science in marine research and conservation. En Jungblut, S., Liebich, V., Bode-Dalby, M. (Eds.), *YOUMARES 9-The Oceans: Our Research, Our Future*. Springer.
- Earp, H. S., Liconti, A. 2020. Science for the future: the use of citizen science in marine research and conservation. En S. Jungblut, V. Liebich, M. Bode-Dalby (Eds.), *YOUMARES 9 - The Oceans: Our Research, Our Future* (pp. 1-19). Springer.
- Edelist, D., Canepa-Oneto, A., Azzopardi, J., Ballesteros, A., Bellido, J., Boero, F., Bordehore, C., Deidun, A., Fonfría, E. S., Gauci, A., Gili, J. M., Gueroun, S. K. M., Guy-Haim, T., Kuplik, Z., Leoni, V., Kogovsek, T., Marambio, M., Mangin, A., Moranduzzo, T., Öztürk, I. D., Öztürk, B., Palma, R., Piraino, S., Robertson, E., Savva, I., Tankovic, M. S., Souviron-Priego, L., Tirelli, V., Troullier, A., Venus,

- V., Zampardi, S., Angel, D. L. 2025. Citizen science-based jellyfish observation initiatives in the Mediterranean Sea. *Hydrobiologia*, 1-20.
- Fawcett, T. 2006. An introduction to ROC analysis. *Pattern recognition letters* 27(8), 861-874.
- Fernández-Álías, A., Marcos, C., Pérez-Ruzafa, A. 2024. The unpredictability of scyphozoan jellyfish blooms. *Frontiers in Marine Science* 11, 1349956.
- Fraisl, D., Hager, G., Bedessem, B., Gold, M., Hsing, P. Y., Danielsen, F., Hitchcock, C. B., Hulbert, J. M., Piera, J., Spiers, H., Thiel, M., Haklay, M. 2022. Citizen science in environmental and ecological sciences. *Nature Reviews Methods Primers* 2(1), 64.
- Franks, P. J. 1992. Sink or swim: Accumulation of biomass at fronts. *Marine Ecology Progress Series* 82(1), 1-12.
- French, G., Mackiewicz, M., Fisher, M., Challiss, M., Knight, P., Robinson, B., Bloomfield, A. 2018. JellyMonitor: Automated detection of jellyfish in sonar images using neural networks. En *14th IEEE International Conference on Signal Processing (ICSP)* (pp.406-412). 12-16 de agosto de 2018. Pekín, China.
- Fritz, S., See, L., Carlson, T., Haklay, M., Oliver, J., Fraisl, D., Mondardini, R., Brocklehurst, M., Shanley, L., Schade, S., Wehn, U., Abrate, T., Anstee, J., Arnold, S., Billot, M., Campbell, J., Parker, A., Gold, M., Hager, G., He, S., Hepburn, L., Hsu, A., Long, D., Masó, J., McCallum, I., Muniafu, M., Moorthy, I., Obersteiner, M., Weissplug, M., West, S. 2019. Citizen science and the United Nations sustainable development goals. *Nature Sustainability* 2(10), 922-930.
- Galil, B. S. 2008. The price of change: The economic impacts of alien species and jellyfish outbreaks in the Mediterranean Sea. En *Economic valuation of natural coastal and marine ecosystems. CIESM Workshop Monographs* 37 (pp. 41-45).
- García, L. V. 2003. Controlling the false discovery rate in ecological research. *Trends in Ecology and Evolution* 18(11), 553-554.
- García-Lafuente, J., Sánchez-Garrido, J.C., Garcia, A., Hidalgo, M., Sammartino, S., Laíz, R. 2021. Biophysical processes determining the connectivity of the Alboran Sea fish populations. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli

- Idrissi (Eds.), *Alboran Sea-Ecosystems and Marine Resources* (pp. 459-487). Springer International Publishing.
- Gauci, A., Deidun, A., Abela, J. 2020. Automating jellyfish species recognition through faster region- based convolution neural networks. *Applied Sciences* 10, 8257.
- Gershwin, L., Condie, S. A., Mansbridge J. V., Richardson A. J. 2014. Dangerous jellyfish blooms are predictable. *Journal of the Royal Society Interface* 11(96), 20131168.
- Ghermandi, A., Galil, B., Gowdy, J., Nunes, P. A. 2015. Jellyfish outbreak impacts on recreation in the Mediterranean Sea: welfare estimates from a socioeconomic pilot survey in Israel. *Ecosystem services* 11, 140-147.
- Goldberg, Y. 2022. *Neural network methods for natural language processing*. Springer Nature.
- Goodchild, M. F. 2007. Citizens as sensors: the world of volunteered geography. *GeoJournal* 69(4), 211-221
- Graham, W. M., Gelcich, S., Robinson, K. L., Duarte, C. M., Brotz, L., Purcell, J. E., Madin, L. P., Mianzan, H., Sutherland, K. R., Uye, S, Pitt, K. A., Lucas, C. H., Bøgeberg, M., Brodeur, R. D., Condon, R. H. 2014. Linking human well-being and jellyfish: ecosystem services, impacts, and societal responses. *Frontiers in Ecology and the Environment* 12(9), 515-523.
- Graham, W. M., Pagès, F., Hamner, W. M. 2001. A physical context for gelatinous zooplankton aggregations: a review. *Hydrobiologia* 451(1-3), 199-212.
- Guerrero, E., Gili, J.M., Grinyó, J., Raya, V., Sabatés, A. 2018. Long-term changes in the planktonic cnidarian community in a mesoscale area of the NW Mediterranean. *PLoS ONE* 13(5), e0196431.
- Gutiérrez-Estrada, J. C., Pulido-Calvo, I., Peregrín, A., García-Gálvez, A., Báez, J. C., Bellido, J. J., Souviron-Priego, L., Sánchez-Laulhé, J. M., López, J. A. 2021. Integrating local environmental data and information from non-driven citizen science to estimate jellyfish abundance in Costa del Sol (southern Spain). *Estuarine, Coastal and Shelf Science* 249, 107112.

- Gutiérrez-Estrada, J. C., Sanz, E. D. P., López-Luque, R., Pulido-Calvo, I. 2005. SEDPA, an expert system for disease diagnosis in eel rearing systems. *Aquacultural engineering* 33(2), 110-125.
- Haklay, M., Dörler, D., Heigl, F., Manzoni, M., Hecker, S., Vohland, K. 2021. What is citizen science? The challenges of definition. En K. Vohland, A. Land-Zandstra, L. Ceccaroni, R. Lemmens, J. Perelló, M. Ponti, R. Samson, K. Wagenknecht (Eds.), *The science of citizen science* (pp. 13-33). Springer.
- Han, Y., Chang, Q., Ding, S., Gao, M., Zhang, B., Li, S. 2021. Research on multiple jellyfish classification and detection based on deep learning. *Multimedia Tools and Applications* 81, 19429-19444.
- Hancock, J. T., Khoshgoftaar, T. M. 2020. Survey on categorical data for neural networks. *Journal of big data* 7(1), 28.
- Hanson, N. 2011. Using biological data from field studies with multiple reference sites as a basis for environmental management: The risks for false positives and false negatives. *Journal of Environmental Management* 92(3), 610-619.
- Haykin, S. S. 2009. *Neural Networks and Learning Machines* (Vol. 3). Pearson Education.
- He, H., Garcia, E. A. 2009. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering* 21(9), 1263-1284.
- Heim-Ballew, H., Olsen, Z. 2019. Salinity and temperature influence on Scyphozoan jellyfish abundance in the Western Gulf of Mexico. *Hydrobiologia* 827, 247-262.
- Hermoso, M. I., Martin, V. Y., Gelcich, S., Stotz, W., Thiel, M. 2021. Exploring diversity and engagement of divers in citizen science: Insights for marine management and conservation. *Marine Policy* 124, 104316
- Hovy, D. 2022. *Text analysis in Python for social scientists: prediction and classification*. Cambridge University Press.
- Irwin, A. 2002. *Citizen science: A study of people, expertise and sustainable development*. Routledge.
- Iyer, M. S., Rhinehart, R. R. 1999. A method to determine the required number of neural-network training repetitions. *IEEE Transactions on Neural Networks* 10(2), 427-432.

- Johnston, A., Matechou, E., Dennis, E. B. 2023. Outstanding challenges and future directions for biodiversity monitoring using citizen science data. *Methods in Ecology and Evolution* 14(1), 103-116.
- Kelleher, J. D., Mac Namee, B., D'Arcy, A. 2015. *Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies*. The MIT Press.
- Kelly, R., Fleming, A., Pecl, G. T., von Gönner, J., Bonn, A. 2020. Citizen science and marine conservation: a global review. *Philosophical Transactions of the Royal Society B* 375(1814), 20190461.
- Kideys, A. E. 2015. Policy-oriented marine Environmental Research in the Southern European Seas (PERSEUS). Extraído de: <https://hdl.handle.net/11511/58248>.
- Kim, H., Koo, J., Kim, D., Jung, S., Shin, J. U., Lee, S., Myung, H. 2016. Image-based monitoring of jellyfish using deep learning architecture. *IEEE Sensors Journal* 16(8), 2215-2216.
- Kingma, D. P., Ba, J. 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv: 1412.6980*.
- Kohavi, R. 1995. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. En *Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI 95)* (pp. 1137-1143). Montréal, Canada.
- Komninos, A. 2019. Pro-social behaviour in crowdsourcing systems: Experiences from a field deployment for beach monitoring. *International Journal of Human-Computer Studies* 124, 93-115.
- Lucas, C. H., Gelcich, S., Uye, S.-I. 2014. Living with jellyfish: management and adaptation strategies. En K. Pitt, C. Lucas (Eds.), *Jellyfish blooms* (pp. 129-150). Springer.
- MacAli, A., Semenov, A., Venuti, V., Crupi, V., D'Amico, F., Rossi, B., Corsi, I., Bergami, E. 2018. Episodic records of jellyfish ingestion of plastic items reveal a novel pathway for trophic transference of marine litter. *Scientific Reports* 8(1), 6105.
- Marambio, M., Canepa, A., Lòpez, L., Gauci, A. A., Gueroun, S. K., Zampardi, S., Boero, F., Yahia, O. K. D., Yahia, M. N. D., Fuentes, V., Piraino, S., Deidun, A. 2021.


- Unfolding jellyfish bloom dynamics along the Mediterranean basin by transnational citizen science initiatives. *Diversity* 13(6), 274.
- Mariottini, G. L., Giacco, E., Pane, L. 2008. The Mauve Stinger *Pelagia noctiluca* (Forsskal, 1775). Distribution, ecology, toxicity and epidemiology of stings. A review. *Marine Drugs* 6, 496-513
- Mariottini, G. L., Pane, L. 2010. Mediterranean Jellyfish Venoms: A Review on Scyphomedusae. *Marine Drugs* 8(4), 1122–1152.
- Martin-Abadal, M., Ruiz-Frau, A., Hinz, H., Gonzalez-Cid, Y. 2020. Jellytoring: Real-time jellyfish monitoring based on deep learning object detection. *Sensors* 20, 1708.
- Martín del Brío, B., Sanz-Molina, A. 2006. *Redes neuronales y sistemas borrosos*. Rama.
- McClure, E. C., Sievers, M., Brown, C. J., Buelow, C. A., Ditria, E. M., Hayes, M. A., Pearson, R. M., Tulloch, V. J. D., Unsworth, R. K. F., Connolly, R. M. 2020. Artificial intelligence meets citizen science to supercharge ecological monitoring. *Patterns* 1(7).
- McCulloch, W. S., Pitts, W. 1943. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics* 5, 115-133.
- Messié, M., Chavez, F. P. 2017. Nutrient supply, surface currents, and plankton dynamics predict zooplankton hotspots in coastal upwelling systems. *Geophysical Research Letters* 44(17), 8979-8986.
- Mills, C. E. 2001. Jellyfish blooms: are populations increasing globally in response to changing ocean conditions? *Hydrobiologia* 451(1-3), 55-68.
- Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., Gao, J. 2021. Deep learning-based text classification: a comprehensive review. *ACM Computing Surveys (CSUR)* 54(3), 1-40.
- Minsky, M., Papert, S. 1969. *Perceptrons: An introduction to computational geometry*. MIT Press.
- Moreno-Luna, L., Robina-Ramírez, R., Sánchez, M. S. O., Castro-Serrano, J. 2021. Tourism and sustainability in times of COVID-19: The case of

- Spain. *International Journal of Environmental Research and Public Health* 18(4), 1859.
- Mukhamediev, R. I., Popova, Y., Kuchin, Y., Zaitseva, E., Kalimoldayev, A., Symagulov, A., Levashenko, V., Abdoldina, F., Gopejenko, V., Yakunin, K., Muhamedijeva, E., Yelis, M. 2022. Review of Artificial Intelligence and Machine Learning Technologies: Classification, Restrictions, Opportunities and Challenges. *Mathematics* 10(15), 2552.
- Pauly, D., Graham, W. M., Libralato, S., Morissette, L., Palomares, M. L. D. 2009. Jellyfish in ecosystems, online databases, and ecosystem models. *Hydrobiologia* 616, 67-85.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Duborg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E. 2011. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research* 12, 2825-2830.
- Peliz, Á., Rosa, T. L., Santos, A. M. P., Pissarra, J. L. 2002. Fronts, jets, and counter-flows in the Western Iberian upwelling system. *Journal of Marine Systems* 35(1-2), 61-77.
- Perret, J., Cobelli, O., Taudière, A., Andrieu, J., Aumeeruddy-Thomas, Y., Souissi, J. B., Bernard, G., Casazza, G., Crochet, P.-A., Decaëns, T., Denis, F., Geniez, P., Loizides, M., Médail, F., Pasqualini, V., Speciale, C., Battesti, V., Chevaldonné, P., Lejeusne, C., Richard, F. 2023. Time to refine the geography of biodiversity hotspots by integrating molecular data: The Mediterranean Basin as a case study. *Biological Conservation* 284, 110162.
- Purcell, J. E. 2005. Climate effects on formation of jellyfish and ctenophore blooms: a review. *Journal of the Marine Biological Association of the United Kingdom* 85(3), 461-476.
- Purcell, J. E. 2012. Jellyfish and ctenophore blooms coincide with human proliferations and environmental perturbations. *Annual review of marine science* 4(1), 209-235.
- Purcell, J. E., Milisenda, G., Rizzo, A., Carrion, S. A., Zampardi, S., Airolidi, S., Zagami, G., Guglielmo, L., Boero, F., Doyle, T. K., Piraino, S. 2015. Digestion and predation rates of zooplankton by the pleustonic hydrozoan *Velella velella* and

- widespread blooms in 2013 and 2014. *Journal of Plankton Research* 37(5), 1056-1067.
- R Core Team. 2021. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing. <https://www.R-project.org>.
- Richardson, A. J., Bakun, A., Hays, G. C., Gibbons, M. J. 2009. The jellyfish joyride: causes, consequences and management responses to a more gelatinous future. *Trends in Ecology and Evolution* 24(6), 312-322.
- Rosenblatt, F. 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review* 65(6), 386.
- Rubio Gómez, A., Gutiérrez-Hernández, O. 2020. Impact of jellyfish and other gelatinous organisms on the Andalusian coast. Implications for sun and beach tourism. *Estudios Geográficos* 81(288), e038.
- Rueda, J. L., Gofas, S., Aguilar, R., de la Torriente, A., García Raso, J. E., Lo Iacono, C., Luque, A. A., Marina, P., Mateo-Ramírez, A., Moya-Urbano, E., Moreno, D., Navarro-Barranco, C., Salas, C., Sánchez-Tocino, L., Templado, J., Urra, J. (2021). Benthic fauna of littoral and deep-sea habitats of the Alboran Sea: a hotspot of biodiversity. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli Idrissi (Eds.), *Alboran Sea-Ecosystems and Marine Resources* (pp. 285-358). Springer International Publishing.
- Ruiz-Frau, A. 2022. Impacts of jellyfish presence on tourists' holiday destination choices and their willingness to pay for mitigation measures. *Journal of Environmental Planning and Management* 66(10), 2107-2125.
- Ruiz-Frau, A., Martin-Abadal, M., Jennings, C. L., Gonzalez- Cid, Y., Hinz, H. 2022. The potential of Jellytoring 2.0 smart tool as a global jellyfish monitoring platform. *Ecology and Evolution* 12, e9472.
- Rumelhart, D. E., Hinton, G. E., Williams, R. J. 1986b. Learning representations by back-propagating errors. *Nature* 323(6088), 533-536.
- Rumelhart, D. E., McClelland, J. L., PDP Research Group. 1986a. *Parallel distributed processing, volume 1: Explorations in the microstructure of cognition: Foundations*. The MIT press.

- Samuels, J. I. 2024. One-hot encoding and two-hot encoding: an introduction. *Preprint*.
- Shridhar, K., Jain, H., Agarwal, A., Kleyko, D. 2020. End to end binarized neural networks for text classification. En *Proceedings of SustaiNLP: Workshop on Simple and Efficient Natural Language Processing* (pp. 29-34). Association of Computational Linguistics.
- Silverthorn, D. U. 2015. *Human physiology*. Jones & Bartlett Publishers.
- Silvertown, J. 2009. A new dawn for citizen science. *Trends in Ecology & Evolution* 24(9), 467-471.
- Sokolova, M., Lapalme, G. 2009. A systematic analysis of performance measures for classification tasks. *Information Processing and Management* 45(4), 427-437.
- Szeghalmy, S., Fazekas, A. 2023. A Comparative Study of the Use of Stratified Cross-Validation and Distribution-Balanced Stratified Cross-Validation in Imbalanced Learning. *Sensors* 23(4), 2333.
- Tang, D., Qin, B., Liu, T. 2015. Document modeling with gated recurrent neural network for sentiment classification. En *Proceedings of the 2015 conference on empirical methods in natural language processing* (pp. 1422-1432). 17-21 septiembre 2015. Lisboa, Portugal.
- Vargas-Yáñez, M., García-Martínez, M. C., Moya, F., Balbín, R., López-Jurado, J. L. 2021. The oceanographic and climatic context. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli Idrissi (Eds.), *Alboran Sea-Ecosystems and Marine Resources* (pp. 85-109). Springer International Publishing.
- Vohland, K., Land-Zandstra, A., Ceccaroni, L., Lemmens, R., Perelló, J., Ponti, M., Samson, R., Wagenknecht, K. 2021. The Science of Citizen Science Evolves. En K. Vohland, A. Land-Zandstra, L. Ceccaroni, R. Lemmens, J. Perelló, M. Ponti, R. Samson, K. Wagenknecht (Eds.), *The Science of Citizen Science* (pp. 1-12). Springer.
- Waskom, M. L. 2021. Seaborn: statistical data visualization. *Journal of Open Source Software* 6(60), 3021.
- Werbos, P. 1974. *Beyond regression: New tools for prediction and analysis in the behavioral sciences* [Tesis de doctorado, Universidad de Harvard].

- Wood, S. N. 2017. *Generalized Additive Models: An Introduction with R* (2^a ed.). CRC Press.
- Wood, S. N. 2021. *mgcv: Mixed GAM Computation Vehicle with Automatic Smoothness Estimation*. R package version 1.8-36.
- Young, T., Hazarika, D., Poria, S., Cambria, E. 2018. Recent trends in deep learning based natural language processing. *IEEE Computational Intelligence Magazine* 13(3), 55-75.
- Zavodnik, D. 1987. Spatial aggregations of the swarming jellyfish *Pelagia noctiluca* (Scyphozoa). *Marine Biology* 94, 265-269.
- Zhang, G. P. 2000. Neural networks for classification: a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 30(4), 451-462.



CAPÍTULO III

MODELIZACIÓN DE LA DISTRIBUCIÓN DE MEDUSAS EN LA COSTA ANDALUZA: UN ENFOQUE BASADO EN EL PRINCIPIO DE MÁXIMA ENTROPÍA

Resumen

Las proliferaciones de medusas son fenómenos naturales con importantes impactos ecológicos y socioeconómicos, especialmente en regiones como la costa mediterránea andaluza, donde el turismo constituye una industria relevante. Este estudio emplea un modelo de distribución de especies de Máxima Entropía (MaxEnt) para predecir la presencia de medusas utilizando datos de ciencia ciudadana procedentes de la aplicación Infomedusa y variables ambientales derivadas de la plataforma Copernicus. En particular, aunque los informes de los usuarios no permiten identificar la especie con certeza, *Pelagia noctiluca* probablemente dominó los avistamientos en nuestra región de estudio. Se analizaron datos de presencia exclusivos del verano de 2019 junto con factores ambientales clave comprendidos entre marzo y septiembre.

Los modelos identificaron de manera consistente la profundidad de la capa de mezcla en abril como la variable más influyente, contribuyendo entre el 72,7% y el 93,9% a la distribución de probabilidad, lo que resalta el papel de las condiciones de inicios de primavera en la dinámica estival de las medusas. Los resultados revelaron patrones espaciales y temporales en la presencia de medusas, proporcionando información valiosa para la gestión costera y los sistemas de alerta temprana. Para validar las predicciones de MaxEnt, se utilizaron datos observados de ausencia con el fin de comparar las áreas con baja probabilidad predicha de presencia de medusas con aquellas de alta densidad de ausencias observadas, revelando un nivel de coincidencia moderado, con entre un 22,58% y un 37,13% de concordancia entre ambas.

Aunque el estudio se limita a una única temporada estival debido a la disponibilidad de datos, pone de manifiesto el potencial de integrar técnicas de modelización avanzadas con datos generados por la ciudadanía. Este estudio subraya el valor de la ciencia ciudadana para la ecología marina y destaca la importancia de estrategias proactivas para mitigar los impactos socioeconómicos de las proliferaciones de medusas sobre las comunidades locales y los ecosistemas. Estos hallazgos pueden contribuir a la planificación regional y a los esfuerzos globales para abordar la proliferación de zooplancton gelatinoso.

Palabras clave: *Pelagia noctiluca*; Modelo de Máxima Entropía; Gestión de playas; Ciencia ciudadana; Costa occidental del Mediterráneo.

Abstract

*Jellyfish blooms are natural events with significant ecological and socio-economic impacts, particularly in regions like the Andalusian Mediterranean coast, where tourism is an important industry. This study employs Maximum Entropy (MaxEnt) species distribution model to predict jellyfish presence using citizen science data from the Infomedusa app and environmental variables derived from the Copernicus platform. In particular, while users' reports do not enforce species-level identification, *Pelagia noctiluca* likely dominated the sightings in our study region. Presence-only data from summer 2019 were analysed alongside key environmental factors from March to September.*

The models consistently identified the mixed layer depth in April as the most influential variable, contributing between 72.7% and 93.9% to the probability distribution, highlighting the role of early spring conditions in shaping summer jellyfish dynamics. The results revealed spatial and temporal patterns in jellyfish presence, providing valuable insights for coastal management and early-warning systems. To validate the MaxEnt predictions, observed absence data were used to compare areas of low predicted probability of jellyfish presence with high densities of observed absences, revealing a moderate level of agreement, with 22.58% to 37.13% coincidence between low-probability MaxEnt predictions and areas of high absence density.

While the study is limited to a single summer season due to data availability, it highlights the potential of integrating advanced modelling techniques with crowd-sourced data, this study underscores the value of citizen science for marine ecology and highlights the importance of proactive strategies to mitigate the socio-economic impacts of jellyfish blooms on local communities and ecosystems. These findings can inform regional planning and contribute to global efforts to address gelatinous zooplankton proliferation.

Key words: *Pelagia noctiluca; Maximum Entropy model; Beach management; Citizen science; West Mediterranean coast.*

3.1. Introducción

Las proliferaciones de medusas son un evento natural que ha ocurrido de manera recurrente en los ecosistemas marinos a lo largo de la historia (Condon *et al.*, 2012; Marambio *et al.*, 2021). En particular, el mar Mediterráneo se ha visto afectado de forma constante por densas proliferaciones de diversas especies de medusas (Canepa *et al.*, 2014). El aumento en la frecuencia e intensidad de estas proliferaciones ha sido objeto de intenso debate y estudio científico en las últimas décadas (Sanz-Martín *et al.*, 2016; Pitt *et al.*, 2018). A pesar de la ambigüedad en las tendencias a largo plazo, es evidente que las proliferaciones de medusas son una parte natural de los ecosistemas marinos, con una presencia notable en el Mediterráneo y diversos efectos tanto en actividades humanas como en los servicios ecosistémicos (Bergamasco *et al.*, 2022). No solo constituyen eventos de importancia ecológica, sino que también pueden considerarse fenómenos socioeconómicos con potencial para impactar en distintos sectores. Si bien las medusas desempeñan funciones esenciales en los servicios de regulación, soporte, provisión y culturales (Doyle *et al.*, 2014; Graham *et al.*, 2014), sus efectos negativos sobre las actividades humanas han aumentado con el tiempo (Purcell *et al.*, 2007). Así, a medida que crecen las interacciones humanas con los ecosistemas costeros, también aumentan los encuentros con estos organismos gelatinosos.

La región de Andalucía (sur de España) depende en gran medida del turismo, sector directamente vinculado al crecimiento económico de la zona (Tugcu, 2014; Bernier *et al.*, 2014). Las proliferaciones de medusas han tenido un impacto económico significativo en esta región costera, reduciendo notablemente las visitas turísticas y causando pérdidas económicas en el sector recreativo (Ghermandi *et al.*, 2015; Cantarero-Prados *et al.*, 2023). A pesar de los esfuerzos por mitigar el problema, los afloramientos de *Pelagia noctiluca* (Forsskål, 1775), la medusa más conspicua del Mediterráneo (Brotz y Pauly, 2012), pueden provocar cierres de playas a lo largo de la costa para proteger la salud pública, lo que afecta gravemente la temporada turística de verano (Ghermandi *et al.*, 2015). Asimismo, la presencia de medusas no solo plantea riesgos para la salud pública debido a sus picaduras, sino que también afecta negativamente a la imagen turística de la región, generando pérdidas económicas significativas. Ante esta situación, resulta fundamental comprender la dinámica ecológica que impulsa estas proliferaciones y desarrollar estrategias efectivas para su gestión y mitigación.

Varios estudios han empleado diversas técnicas de modelización de recursos y del entorno para comprender la distribución y proliferación de las medusas. Por ejemplo, Canepa *et al.* (2014) y Gutiérrez-Estrada *et al.* (2021) utilizaron Modelos Aditivos Generalizados (GAMs, *Generalized Additive Models*) para analizar factores ambientales, como la dirección y velocidad del viento, demostrando su influencia en la ocurrencia de medusas en playas del Mediterráneo occidental. La misma técnica de modelización fue empleada por Siapatis *et al.* (2008) para predecir el hábitat potencial del ctenóforo invasivo *Mnemiopsis leidyi* en el mar Egeo. Benedetti-Cecchi *et al.* (2015) emplearon un análisis bayesiano jerárquico para modelar las proliferaciones de *P. noctiluca* a lo largo de la costa catalana, incorporando variables ambientales como la temperatura superficial del mar (SST, *Sea Surface Temperature*), la producción primaria, la concentración de clorofila y las corrientes geostroficas para predecir la proliferación de medusas. Edelist *et al.* (2022) emplearon un modelo de seguimiento de partículas de tipo lagrangiano combinado con datos de medusas obtenidos mediante ciencia ciudadana y análisis genético para estudiar los patrones de dispersión de *Rhopilema nomadica* en el Mediterráneo oriental. Por su parte, Castro-Gutiérrez *et al.* (2022) aplicaron un modelo de inteligencia artificial explicable basado en lógica difusa para predecir afloramientos de medusas en el sur de España, identificando la dirección y la velocidad del viento como factores clave en la aparición de enjambres de medusas en la zona estudiada.

La mayoría de estos enfoques tradicionales dependen de la disponibilidad de datos tanto de presencia como de ausencia, y aunque estos modelos resultan útiles, requieren datos de alta calidad y amplia cobertura, algo no siempre factible en los estudios de medusas. Según Brotz *et al.* (2012), hace una década las medusas solían estar subrepresentadas en la investigación marina histórica debido a limitaciones metodológicas y a la falta general de atención en los estudios científicos. En la actualidad, a pesar del creciente interés, la investigación específica sobre medusas resulta costosa y requiere tecnologías innovadoras (Hamel *et al.*, 2021).

Sin embargo, a pesar de este creciente interés por los afloramientos de medusas en zonas costeras, existen escasas investigaciones que integren en su análisis de forma simultánea componentes espacio-temporales y la variabilidad intrínsecamente alta de las poblaciones (Marambio *et al.*, 2021). Este tipo de modelos, englobados en el campo de la geoestadística, pueden ser herramientas valiosas para anticipar y manejar la aparición de medusas u organismos similares en zonas costeras, permitiendo establecer sistemas de

alerta temprana, planificar cierres preventivos de playas y gestionar riesgos para el turismo costero de manera más proactiva (Gershwin *et al.*, 2014). Por ejemplo, Cimino *et al.* (2018) utilizaron técnicas como el *kriging* ordinario, para mapear con precisión la distribución espacial y temporal de medusas en un lago marino de Palau, revelando patrones agregados relacionados con variables ambientales. Por otro lado, Benedetti-Cecchi *et al.* (2015), aplicaron un modelo jerárquico bayesiano espacio-temporal para investigar los factores detrás de los afloramientos de *P. noctiluca* en la costa catalana, incorporando en el modelo variables oceanográficas y geomorfológicas para explicar la probabilidad de estos brotes según la zona de estudio.

En este estudio, se emplearon modelos de máxima entropía (MaxEnt), una herramienta ampliamente utilizada para predecir la distribución potencial de especies basándose en datos de presencia. Estos modelos se basan en el principio que establece que, en ausencia de información adicional, la mejor predicción sobre la distribución de una especie es aquella más uniforme o que maximiza la entropía (Phillips *et al.*, 2006). Este modelo funciona seleccionando los puntos donde se ha observado la especie y utilizando un conjunto de variables ambientales para caracterizar las condiciones bajo las cuales la especie está presente. A partir de ahí, MaxEnt estima una función de probabilidad para predecir la distribución geográfica de la especie, identificando áreas donde las condiciones ambientales son similares a las de los puntos de presencia conocidos. Esto se realiza sin necesidad de datos de ausencia, lo que lo hace especialmente útil en situaciones donde la obtención de datos de ausencia es limitada o inexistente.

La sencillez del modelo y su capacidad para generar predicciones precisas han convertido a MaxEnt en una herramienta habitual en biogeografía, ecología de la conservación y en la gestión de recursos naturales (Wang *et al.*, 2018; Melo-Merino *et al.*, 2020; Smith *et al.*, 2021). Así, MaxEnt ha demostrado ser una herramienta efectiva para modelizar la distribución de medusas en diversos estudios de ecología marina. Por ejemplo, Benthage *et al.* (2009) aplicaron este modelo para inferir la distribución de medusas cubozoos del género *Chirops*, revelando patrones de hábitat basados en variables ambientales específicas. Guo *et al.* (2023) utilizaron MaxEnt para evaluar los factores ambientales que determinan la distribución de grandes medusas a lo largo de la costa norte de China, identificando la temperatura y la concentración de clorofila como variables clave para su proliferación. Otro estudio, realizado por Pantiukhin *et al.* (2024),

empleó una versión adaptada en tres dimensiones de MaxEnt para modelizar el desplazamiento de zooplankton gelatinoso hacia el Ártico impulsado por el clima, destacando la utilidad de MaxEnt para predecir cambios en la distribución de especies en escenarios ambientales futuros. Además, los datos de ciencia ciudadana también han sido incorporados a modelos MaxEnt. Por ejemplo, Record *et al.* (2018) desarrollaron un sistema de pronóstico de avistamientos de medusas basado en MaxEnt, integrando datos recopilados a través de redes sociales para generar mapas en tiempo real de áreas con alta probabilidad de presencia de medusas.

Sobre esta base, el presente estudio tiene como objetivo modelar la distribución de avistamientos de medusas durante el verano de 2019 a lo largo de la costa andaluza empleando la técnica de modelización MaxEnt y utilizando datos de la aplicación móvil Infomedusa. Mediante la integración de variables ambientales proporcionadas por la plataforma Copernicus, esta investigación busca identificar los factores clave que determinan la distribución de medusas y predecir las zonas de mayor y menor ocurrencia. El estudio pretende así ofrecer predicciones sólidas y espacialmente explícitas que contribuyan a orientar futuras estrategias de gestión, reforzar las medidas de seguridad en las playas y mitigar los impactos socioeconómicos de las proliferaciones de medusas en la región andaluza del mar de Alborán.

3.2. Material y métodos

3.2.1. Área de estudio

Este estudio se llevó a cabo a lo largo de la costa mediterránea de Andalucía, situada en el sur de España (Figura III-1). Esta región abarca las provincias de Málaga, Granada y Almería, desde el Estrecho de Gibraltar en el oeste hasta Pulpí, el municipio más al este de Almería que limita con la Región de Murcia. La costa andaluza, de aproximadamente 500 kilómetros de longitud, limita con el mar de Alborán, cuya circulación superficial es altamente dinámica, caracterizada por fuertes corrientes, zonas frontales y estructuras a mesoescala (Vargas-Yáñez *et al.*, 2021). Esta circulación en la capa superficial está dominada por el Chorro Atlántico (AJ, *Atlantic Jet*), que ingresa al mar de Alborán en dirección noreste y, alrededor de los 3-4°O, gira hacia el sur, rodeando dos grandes giros anticiclónicos: el Giro Occidental del mar de Alborán (WAG, *Western Alboran Gyre*) y el Giro Oriental del mar de Alborán (EAG, *Eastern Alboran Gyre*). Entre estos dos giros anticiclónicos se localiza un giro ciclónico de menor tamaño. Las características fisicoquímicas de estas estructuras han sido descritas en detalle por Sánchez-Garrido y Nadal (2022).

Además del flujo de aguas atlánticas, diferentes masas de agua mediterránea también circulan desde los 200 m de profundidad hasta el fondo marino hacia el Atlántico a través del estrecho de Gibraltar, principalmente la Masa de Agua Intermedia Levantina (LIW, *Levantine Intermediate Water*), caracterizada por su alta salinidad, la Masa de Agua Profunda del Mediterráneo Occidental (WMDW, *Western Mediterranean Depth Water*), más densa y fría, y la Masa de Agua Densa Tirrénica (TDW, *Tyrrhenian Dense Water*) (García-Lafuente *et al.*, 2017; Vargas-Yáñez *et al.*, 2021). Estas dinámicas contribuyen a las características únicas de este mar, incluyendo sus patrones de circulación, su biodiversidad marina y sus ecosistemas (García-Lafuente *et al.*, 2021).




Figura III-1. Mapa de la costa mediterránea andaluza, destacando el área de estudio con una línea discontinua roja que se extiende desde el estrecho de Gibraltar en el oeste hasta Pulpí en el este en la frontera con la Región de Murcia. El mapa muestra los patrones generales de circulación superficial en los 200 m superiores del mar de Alborán, dominados por el Chorro del Atlántico (AJ, Atlantic Jet), que forma dos importantes giros anticiclónicos: el Giro Occidental del mar de Alborán (WAG, Western Alboran Gyre) y el Giro Oriental del mar de Alborán (EAG, Eastern Alboran Gyre). Entre estos dos sistemas se encuentra el Giro Ciclónico Central (CCG, Central Cyclonic Gyre), de menor tamaño.

3.2.2. Datos de avistamientos de medusas

Los datos de presencia y ausencia de medusas se obtuvieron a través de la aplicación móvil Infomedusa, desarrollada por el Aula del Mar de Málaga (ahora Fundación Aula del Mar Mediterráneo) en colaboración con la Diputación Provincial de Málaga. Infomedusa es una herramienta de ciencia ciudadana no dirigida que permite a los usuarios informar en tiempo real sobre las condiciones de las playas andaluzas, incluyendo observaciones de presencia o ausencia de medusas. En total, se recopilieron 9.433 comentarios durante 2019 procedentes de la costa sur de España, correspondientes a toda la región andaluza, abarcando desde el 5 de enero hasta el 8 de diciembre.

Cada comentario se analizó para determinar su relevancia en cuanto a la información de medusas. Se asignó un valor de 1 (presencia) o 0 (ausencia) a cada observación, dependiendo de si el usuario mencionaba explícitamente la presencia o ausencia de medusas. Aquellos comentarios que no aportaban información específica al respecto se clasificaron como NA (*Not Available*) y se excluyeron de análisis posteriores. Esta metodología está descrita en detalle en estudios previos sobre el procesamiento de datos de la app Infomedusa (Castro-Gutiérrez *et al.*, 2024) y en el Capítulo II de la

presente Tesis Doctoral. La aplicación Infomedusa permite a los usuarios reportar la presencia de medusas sin especificar la especie observada, por lo que se consideraron todos los avistamientos de medusas de forma conjunta, sin distinción taxonómica.

La distribución temporal de los comentarios mostró una mayor concentración durante los meses de verano. Debido a la escasez de datos de medusas en otros meses del año, el análisis de avistamientos se centró en el periodo de verano, de junio a septiembre de 2019. Además, como este estudio se enfoca en la región del mar de Alborán, solo se tuvieron en cuenta las observaciones de los municipios dentro de esta zona. Se excluyeron los registros de municipios de la costa atlántica andaluza debido a la menor disponibilidad de avistamientos de medusas y a la dificultad de obtener una malla regular espacio-temporal de datos ambientales de la plataforma Copernicus para esas áreas.

Los datos de presencia y ausencia se organizaron en dos bases de datos separadas. Las observaciones de presencia se agruparon por mes y se exportaron como archivos “.csv” individuales, cumpliendo con los requisitos del software MaxEnt para la modelización de la distribución de especies. Las observaciones de ausencia, si bien no se utilizaron directamente en el modelo MaxEnt, se conservaron para el análisis de validación posterior.

3.2.3. *Datos ambientales*

Para comprender los factores ambientales que influyen en la distribución de las medusas, se obtuvieron variables oceanográficas y biogeoquímicas de dos productos del Servicio de Monitoreo del Medio Marino de Copernicus (CMEMS, *Copernicus Marine Environmental Monitoring Service*): el *Mediterranean Sea Physical Reanalysis Product* (Escudier *et al.*, 2020; Escudier *et al.*, 2021; Nigam *et al.*, 2021) y el *Mediterranean Sea Biogeochemistry Reanalysis* (Teruzzi *et al.*, 2021a; Teruzzi *et al.*, 2021b).

Del producto de reanálisis físico, se obtuvieron las variables de temperatura superficial del mar (°C) y la temperatura potencial en el fondo marino (°C). La temperatura potencial representa la temperatura que tendría una masa de agua si se trasladara de manera adiabática a la presión de la superficie del mar, teniendo en cuenta los efectos de la presión sobre la temperatura. Además, se obtuvo la variable correspondiente a la altura de la superficie del mar con respecto al geoide (m), que

representa la diferencia entre la altura real de la superficie oceánica, medida en un lugar y momento determinados, y la altura del geoide, que actúa como superficie de referencia equipotencial del campo gravitatorio terrestre. También se consideró el espesor de la capa de mezcla oceánica definido por sigma theta (σ_θ ; m) (en adelante “Profundidad de la capa de mezcla”). Esta variable representa la profundidad a la que la densidad potencial aumenta en $0,01 \text{ kg} \cdot \text{m}^{-3}$ con respecto a la densidad a 10 m de profundidad, lo cual indica una estratificación sutil en la parte superior de la columna de agua. Asimismo, se incluyeron la salinidad superficial del mar medida en Unidades Prácticas de Salinidad (PSU, *Practical Salinity Unit*) y las velocidades de la corriente marina en dirección este y norte ($\text{m} \cdot \text{s}^{-1}$). A partir de los componentes de corriente este y norte, se calculó la dirección de las corrientes en grados, combinándolos para representar el flujo de agua en general.

Por otro lado, del producto de reanálisis biogeoquímico se incorporaron la concentración de clorofila-a en el agua de mar ($\text{mg} \cdot \text{m}^{-3}$), indicador comúnmente utilizado para estimar la biomasa de fitoplancton presente y la actividad fotosintética, y la producción primaria neta de biomasa ($\text{mg C} \cdot \text{m}^{-3} \cdot \text{día}^{-1}$), la cual representa la tasa diaria de carbono orgánico producido por el fitoplancton y disponible como recurso alimentario para niveles tróficos superiores.

Los datos ambientales se obtuvieron en archivos NetCDF con una resolución de malla horizontal de $1/24^\circ$ (aproximadamente 4-5 km) en ambos productos. La selección de variables se basó en estudios previos que señalan su relevancia en la dinámica de las medusas (por ejemplo, Richardson *et al.*, 2009; Canepa *et al.*, 2014). Todas las variables se promediaron mensualmente. Los datos ambientales abarcaron el periodo de marzo a septiembre de 2019, comenzando antes del pico de observaciones de medusas para permitir el análisis de posibles desfases temporales entre las condiciones ambientales y la aparición de medusas. Cada variable ambiental se convirtió y separó en archivos ASCII mensuales, siguiendo los requisitos del software MaxEnt.

3.2.4. Preprocesamiento de datos y análisis exploratorio

Para asignar una localización geográfica precisa a cada comentario, se empleó una base de datos externa que permitió geolocalizar las observaciones en función del municipio costero correspondiente. Si bien un mismo municipio puede contar con varias playas, los

comentarios se agruparon a nivel municipal para homogeneizar la información y facilitar el análisis espacial. La geolocalización se realizó asignando las coordenadas del núcleo urbano del municipio a cada observación. Posteriormente, las ubicaciones municipales se ajustaron al punto más cercano con datos ambientales disponibles en las rejillas obtenidas de Copernicus, lo que permitió relacionar de forma efectiva los datos de presencia y ausencia de medusas con las condiciones ambientales correspondientes.

3.2.4.1. *Análisis exploratorio de datos ambientales*

Para abordar la posible multicolinealidad entre las variables ambientales y reducir la dimensionalidad del conjunto de datos, se realizó un Análisis de Componentes Principales (PCA, *Principal Component Analysis*) (Abdi y Williams, 2010; Forkman *et al.*, 2019). El PCA se empleó para identificar el número óptimo de componentes principales necesario para representar adecuadamente la variabilidad de los datos sin perder información esencial (Jolliffe, 2002).

Una vez identificados los componentes principales relevantes, se seleccionaron las variables ambientales con una contribución significativa a dichos componentes. Esta selección se basó en los valores de las cargas (*loadings*) asociadas a cada variable, considerando significativas aquellas con valores absolutos superiores a 0,2 en al menos uno de los componentes principales seleccionados. Dichas variables se identificaron como las más influyentes en la estructura de los datos y se conservaron para análisis posteriores.

Para visualizar las relaciones entre las variables seleccionadas y entender mejor su influencia en los componentes principales, se generó un gráfico tridimensional que representa las cargas de las variables en el espacio definido por los componentes principales elegidos. Esta representación gráfica facilitó la identificación de posibles agrupaciones entre las variables ambientales. Con el fin de agrupar estadísticamente las variables altamente correlacionadas y abordar la multicolinealidad, se aplicó el algoritmo de agrupamiento *k-means* al conjunto de variables seleccionadas para clasificarlas en grupos según su proximidad en el espacio de componentes principales, identificando así clústeres de variables con comportamientos similares. Dentro de cada grupo, la multicolinealidad se evaluó calculando el Factor de Inflación de la Varianza (VIF, *Variance Inflation Factor*) para cada variable.

El VIF cuantifica cuánto aumenta la varianza del coeficiente estimado de una variable explicativa debido a su colinealidad con otras variables del modelo. Se calcula para cada variable según se muestra en la Ecuación III-1:

$$VIF_i = \frac{1}{1 - R_i^2}, \quad (\text{Ec. III-1})$$

donde R_i^2 es el coeficiente de determinación obtenido al realizar la regresión de la variable X_i frente al resto de variables explicativas. Valores de VIF superiores a 10 indican una colinealidad elevada y sugieren que la variable podría ser redundante (O'Brien, 2007). Entre las variables de cada clúster identificado se siguió el siguiente procedimiento: (1) se calcularon los VIF de las variables dentro de cada clúster, (2) se eliminaron aquellas que superaban el umbral de 10 para reducir la multicolinealidad, y (3) se repitió este proceso hasta que todas las variables tuvieran valores de VIF por debajo de dicho umbral. En situaciones donde, tras todas las iteraciones posibles de cálculo de VIF persistían dos variables con varianza explicada mutua superior a 10 pero correspondientes a meses distintos, ambas se conservaron en el análisis debido a su relevancia temporal. Este enfoque sigue la recomendación de O'Brien (2007) de considerar la pertinencia contextual junto con la reducción de la multicolinealidad, permitiendo así la selección de un conjunto final de variables ambientales representativas y no colineales para el modelo MaxEnt.

La Figura III-2 muestra un diagrama de flujo que resume el preprocesamiento de datos y sus diferentes etapas realizado en Python (versión 3.9.18) (Anexo 4).




Figura III-2. Diagrama de flujo que ilustra el proceso de obtención, procesado y preparación tanto de los datos de ocurrencia de medusas como de los datos ambientales para su integración en el modelo MaxEnt.

3.2.5. Modelos MaxEnt

Los modelos de Máxima Entropía (MaxEnt) son una herramienta ampliamente utilizada para modelar distribuciones geográficas de especies, especialmente cuando la disponibilidad de datos de ausencia es limitada o inexistente (Phillips *et al.*, 2006; Elith *et al.*, 2011). La popularidad de MaxEnt radica principalmente en su alta precisión predictiva en comparación con otros métodos de modelado, así como en la simplicidad y accesibilidad del software (Phillips y Dudík, 2008; Merow *et al.*, 2013).

En este estudio, la distribución potencial de medusas fue modelada utilizando el software MaxEnt (versión 3.4.4) (Phillips *et al.*, 2006). Los modelos MaxEnt resultan particularmente adecuados para tratar datos de presencia al incorporar de forma interna la generación de puntos de fondo que representan el espectro de condiciones ambientales accesibles en el área de estudio.

3.2.5.1. Fundamentos teóricos y matemáticos de MaxEnt

El modelo MaxEnt se fundamenta en el principio de máxima entropía, el cual establece que, en ausencia de información completa sobre la distribución de una especie, la mejor aproximación es aquella que maximiza la entropía (Jaynes, 1957). Así, MaxEnt permite

estimar la distribución de probabilidad más uniforme posible, condicionada a las restricciones impuestas por los registros de presencia y las variables ambientales disponibles. Esto significa que, de entre todas las distribuciones posibles que cumplen con las restricciones impuestas por los datos observados, se selecciona aquella que es la menos sesgada o, dicho de otro modo, la que introduce el mínimo de información adicional. En el contexto de distribución de especies, MaxEnt busca la distribución geográfica que “*está de acuerdo con todo lo que se conoce, pero evita cuidadosamente asumir todo lo que no se conoce*” (Jaynes, 1957). Este enfoque permite modelar el nicho ecológico de una especie utilizando únicamente datos de presencia, los cuales suelen estar sesgados hacia áreas de fácil acceso o más estudiadas, presentando así desafíos particulares que deben abordarse durante el modelado (Phillips y Dudík, 2008).

MaxEnt asume que los registros de presencia disponibles son muestras de la verdadera distribución de la especie en el espacio ambiental. En este contexto, la entropía de Shannon (H) de una distribución de probabilidad discreta $q(x)$ se define como (Ecuación III-2):

$$H(q) = - \sum_{x \in X} q(x) \ln q(x) \quad (\text{Ec. III-2})$$

Esta función de entropía mide la incertidumbre o "uniformidad" de la distribución $q(x)$, en el que valores altos de entropía corresponden a distribuciones más uniformes, mientras que valores bajos reflejan distribuciones más concretas (Phillips *et al.*, 2006).

Así, el método MaxEnt busca la distribución que maximiza esta entropía, pero condicionada a que se cumplan restricciones derivadas de los datos de presencia observados. Matemáticamente, estas restricciones implican que los valores esperados de ciertas funciones ambientales $f_j(x)$, calculadas sobre toda el área de estudio, coincidan con los valores medios observados en los sitios de presencia observada. Formalmente, estas restricciones se expresan como (Ecuación III-3):

$$\sum_{x \in X} q(x) f_j(x) = \mu_j, \quad (\text{Ec. III-3})$$

donde μ_j representa el valor medio empírico de la variable ambiental f_j en los sitios de presencia conocidos (Elith *et al.*, 2011).

Para resolver este problema de optimización restringida, MaxEnt utiliza el método de multiplicadores de Lagrange, lo que lleva a la distribución de probabilidad conocida como distribución de Gibbs (Phillips *et al.*, 2006) (Ecuación III-4):

$$q_{\lambda}(x) = \frac{e^{\sum_{j=1}^n \lambda_j f_j(x)}}{Z_{\lambda}}, \quad (\text{Ec. III-4})$$

donde $q_{\lambda}(x)$ es la probabilidad estimada en cada ubicación x , $f_j(x)$ representa las funciones ambientales utilizadas como predictores, λ_j son los parámetros o pesos ajustados para cumplir las restricciones, y Z_{λ} es una constante de normalización que asegura que todas las probabilidades suman exactamente 1 (Phillips *et al.*, 2006).

Además de satisfacer las restricciones impuestas por los datos de presencia, es fundamental regular el ajuste del modelo a los datos. La regularización es un componente clave en la formulación matemática de los modelos, diseñada específicamente para controlar la complejidad del modelo y evitar el sobreajuste (*overfitting*) a los datos utilizados para entrenarlo (Phillips *et al.*, 2006). Este mecanismo limita la magnitud de los coeficientes (λ_j), evitando que el modelo reproduzca patrones específicos de los datos de entrenamiento que no sean generalizables, lo que podría perjudicar su capacidad predictiva con datos nuevos (Phillips y Dudík, 2008). Matemáticamente, la regularización en los modelos MaxEnt se implementa mediante una penalización que se incorpora a la función objetivo del modelo, la cual combina el ajuste a los datos observados con un término adicional que limita la complejidad del modelo (Ecuación III-5):

$$\frac{1}{m} \sum_{i=1}^m \ln(q_{\lambda}(x_i)) - \sum_{j=1}^n \beta |\lambda_j|, \quad (\text{Ec. III-5})$$

donde m es el número total de sitios con registros de presencia utilizados para entrenar el modelo, x_i representa cada uno de los sitios específicos en los que se registró la presencia de medusas, $q_{\lambda}(x_i)$ es la probabilidad estimada por el modelo para cada sitio con presencia registrada, n corresponde al número total de las variables ambientales incluidas en el modelo, λ_j son los coeficientes ajustados por el modelo para cada variable ambiental, y β es un parámetro de regularización que determina la penalización aplicada a cada λ_j . Así, el primer término corresponde a la verosimilitud (*log likelihood*), que será mayor cuando el modelo asigne probabilidades altas a los sitios donde la especie está presente y bajas probabilidades a los datos de fondo, y el segundo término corresponde a

la regularización, que penaliza la complejidad del modelo incrementando su valor conforme aumentan los valores absolutos de los parámetros (λ_j) para evitar sobreajustes excesivos y favoreciendo soluciones predictivas más generalizables (Phillips y Dudík, 2008; Elith *et al.*, 2011).

Esta estrategia es comparable a las técnicas utilizadas en modelos estadísticos tradicionales como los Modelos Lineales Generalizados (GLMs, *Generalized Linear Models*) y Modelos Aditivos Generalizados (GAMs, *Generalized Additive Models*). Al igual que en los GLMs y en los GAMs, donde métodos como la penalización mediante criterios de información como el Criterio de Información de Akaike (AIC, *Akaike Information Criterion*) o la regularización tipo LASSO son comunes para controlar la complejidad del modelo, MaxEnt regula explícitamente la complejidad de las relaciones ambientales ajustadas mediante este mecanismo (Elith *et al.*, 2011; Merow *et al.*, 2013).

3.2.5.2. *Proceso de modelización*

El proceso de generación de los modelos partió del uso de las bases de datos de presencia de medusas generados y almacenados de forma mensual previamente (sección 3.2.2). Se generó un modelo MaxEnt independiente para cada mes con observaciones de medusas, ajustando las variables ambientales según el mes específico. Por ejemplo, para el modelo del mes de junio solo se incluyeron las variables disponibles hasta ese mes, sin considerar datos ambientales de meses posteriores. Se seleccionaron 10.000 puntos de fondo de forma aleatoria en todo el área de estudio definida. La elección de un número elevado de puntos de fondo permite una representación más exhaustiva de la variabilidad ambiental, lo que permite contrastar las condiciones observadas en las localizaciones de presencia (Merow *et al.*, 2013). A su vez, los registros de presencia duplicados dentro de la misma celda de la malla se eliminaron para evitar sesgos de muestreo espacial.

En la configuración del modelo, se seleccionó la opción “*autofeature*”, que permite al software MaxEnt determinar automáticamente las funciones de características más adecuadas para describir la respuesta del modelo a las condiciones ambientales (Phillips *et al.*, 2017). Estas funciones pueden ser lineales, cuadráticas, bisagra, o producto, y su selección automática facilita la modelización en ausencia de un conocimiento previo detallado de la relación entre variables (Phillips *et al.*, 2006). El número máximo de iteraciones se fijó en 500 y se estableció un umbral de convergencia

de 0,00001. Para evitar sobreajuste, se aplicó un factor de regularización con valor 1 (Phillips *et al.*, 2006). Este parámetro penaliza los ajustes excesivamente complejos y promueve soluciones más generalizables, algo especialmente importante cuando se trabaja con conjuntos de datos de presencia limitados (Phillips y Dudík, 2008).

El formato de salida del modelo seleccionado fue “cloglog” (*complementary log-log*), el cual ofrece una interpretación directa de la probabilidad de presencia en una escala continua entre 0 y 1. Este formato se basa en el modelo de Proceso Puntual de Poisson Inhomogéneo (IPP, *Inhomogeneous Poisson Point Process*), donde los registros de presencia se modelan como puntos en el espacio con una intensidad λ que varía según las condiciones ambientales (Phillips *et al.*, 2017).

Bajo este modelo, el número de individuos en una celda sigue una distribución de Poisson con media λ . Por tanto, la probabilidad de que al menos un individuo esté presente en una celda se calcula mediante la siguiente fórmula (Ecuación III-6):

$$\text{Probabilidad de presencia} = 1 - e^{-\lambda}, \quad (\text{Ec. III-6})$$

donde $e^{-\lambda}$ es la probabilidad de no observar individuos en una celda. Al aplicar la transformación “cloglog”, MaxEnt ofrece la probabilidad estimada de presencia en cada celda, lo cual resulta adecuado para datos de presencia únicamente. Este resultado proporciona una medida intuitiva de la probabilidad de encontrar medusas en distintas zonas a partir de las variables ambientales incluidas en el modelo.

3.2.5.3. Evaluación de los modelos MaxEnt

El rendimiento de cada modelo de MaxEnt se evaluó empleando el Área Bajo la Curva (AUC, *Area Under the Curve*) de la curva ROC (*Receiver Operating Characteristic*), calculada sobre los datos de entrenamiento. La curva ROC se construye representando la tasa de verdaderos positivos (sensibilidad) frente a la tasa de falsos positivos (1 - especificidad) para diferentes valores de umbral. Un AUC de 1 indica un modelo perfecto, mientras que un valor de 0,5 sugiere un funcionamiento equivalente a la selección aleatoria (Bradley, 1997). Sin embargo, cuando se trabaja con datos exclusivamente de presencia como en MaxEnt, el valor máximo de AUC alcanzable es inferior a 1 y depende de la fracción (a) del área ocupada por la especie (Wiley *et al.*,

2003). En concreto, el AUC máximo es igual a $1 - (a/2)$, aunque normalmente este valor de a no es conocido con exactitud (Phillips *et al.*, 2006).

Para estimar la influencia de cada variable en el funcionamiento del modelo, se usaron tanto el análisis de contribución de variables como la importancia por permutación. La contribución de una variable estima en qué proporción esta explica la variación en los datos de presencia, basada en el incremento de la “ganancia regularizada” durante el proceso de entrenamiento. La importancia por permutación evalúa cuánto disminuye el rendimiento del modelo al permutar aleatoriamente los valores de una variable, y de esta forma se determina la dependencia del modelo respecto a dicha variable (Phillips *et al.*, 2006).

Para identificar la relevancia individual de cada predictor, se realizó un análisis *Jackknife*, que consiste en entrenar el modelo utilizando cada variable por separado y también excluyéndola del modelo completo. La comparación de la ganancia del modelo en estas condiciones permite determinar si una variable aporta información única o si su efecto está compensado por otras variables. Además, se generaron curvas de respuesta que ilustran cómo varía la probabilidad de presencia en función de cada predictor, manteniendo constantes las demás variables (Elith *et al.*, 2011).

3.2.5.4. Validación de los modelos MaxEnt utilizando datos de ausencia

Aunque el método MaxEnt se fundamenta en datos de presencia y puntos de fondo, se utilizó un conjunto independiente de registros de ausencia (filtrados en el apartado 3.2.2) para validar las predicciones del modelo MaxEnt y evaluar su capacidad de identificar zonas con baja probabilidad de presencia de medusas (Anexo 5).

En primer lugar, se elaboró un mapa de calor que representa la distribución espacial de las ausencias de medusas usando las observaciones de ausencia de cada mes correspondiente. Se construyó una malla regular con la misma resolución que la salida de MaxEnt para el área de estudio y se realizó un recuento del número de registros de ausencia en cada celda para obtener la densidad de ausencias. Para suavizar variaciones locales y reducir el ruido, se aplicó un filtro gaussiano con un valor de sigma igual a 1 a dicho mapa de densidad de ausencia, lo que permitió generalizar los patrones de ausencia y resaltar las zonas con densidades consistentemente altas.

Con el fin de comparar de forma coherente las predicciones del modelo MaxEnt con las densidades de ausencia observadas, ambos conjuntos de datos se alinearon asegurando que tuvieran las mismas dimensiones espaciales y puntos de datos válidos. Para ello se emplearon máscaras que excluyeron las celdas que contenían valores ausentes (NaNs) en cualquiera de los dos conjuntos de datos. Al hacer coincidir directamente las mallas de las probabilidades de MaxEnt y la malla de densidad de ausencias, se estableció una base uniforme para la comparación sin necesidad de remuestreo o interpolación. Se aplicaron máscaras espaciales para limitar el análisis a zonas costeras, excluyendo áreas alejadas de la costa donde no se disponía de datos de ausencia de medusas que reducirían el total de coincidencias posibles. Se establecieron umbrales para identificar zonas de baja probabilidad en las predicciones de MaxEnt y zonas de alta densidad de ausencia en los datos observados. Para las predicciones de MaxEnt, se clasificaron como áreas de baja probabilidad aquellas celdas con valores de probabilidad por debajo de 0,50. Para las ausencias observadas, se consideraron áreas de alta densidad de ausencia las celdas con densidades de ausencia superiores a 0,10. De esta forma, se generaron máscaras binarias para ambos conjuntos de datos en función de estos umbrales, asignando el valor 1 a las celdas que cumplían los criterios y 0 al resto.

Finalmente, se superpusieron las máscaras binarias de áreas de baja probabilidad y de alta densidad de ausencia para identificar las celdas en las que coincidían las predicciones y observaciones. El grado de superposición se cuantificó calculando el número total de celdas coincidentes y el porcentaje de coincidencia con respecto al total de celdas clasificadas como de alta densidad de ausencia.

3.3. Resultados

Los 9.433 comentarios recopilados a través de la aplicación Infomedusa en 2019 se distribuyeron de forma desigual a lo largo del año, concentrándose notablemente durante los meses de verano, coincidiendo con el periodo de máxima afluencia turística en las playas (Tabla III-1). El número de comentarios que mencionaban información sobre la presencia o ausencia de medusas fue sustancialmente mayor entre junio y septiembre, lo cual coincide con el periodo de mayor participación ciudadana en la aplicación.

Tabla III-1. Resumen mensual de los comentarios enviados a través de la aplicación Infomedusa a lo largo de 2019, informando de la presencia o ausencia de medusas en el litoral andaluz, así como los registros específicos del litoral andaluz del mar de Alborán durante los meses de verano (junio-septiembre). Se desglosan los valores por meses, incluyendo el número total de comentarios publicados, los que informan de la presencia de medusas y los que informan de su ausencia. Clave: AND, datos obtenidos en toda la costa de Andalucía; ALB, datos obtenidos en el litoral andaluz del mar de Alborán en el verano de 2019.

Mes	Total de comentarios	Presencia (AND)	Ausencia (AND)	Presencia (ALB)	Ausencia (ALB)
Enero	6	0	0	-	-
Febrero	0	0	0	-	-
Marzo	12	1	0	-	-
Abril	39	0	9	-	-
Mayo	181	3	14	-	-
Junio	779	19	58	18	58
Julio	3675	53	471	40	468
Agosto	3765	60	442	47	432
Septiembre	879	12	92	12	91
Octubre	93	0	0	-	-
Noviembre	0	0	0	-	-
Diciembre	4	0	0	-	-
Total	9433	148	1086	117	1049

El conjunto de datos se filtró para incluir únicamente los registros de municipios ubicados dentro de la región del mar de Alborán. Tras este proceso, la base de datos final correspondiente al periodo estival (junio-septiembre) quedó conformada por 1.166 comentarios (12,4% del total de 9.433 comentarios totales), de los cuales 117 indicaban presencia de medusas y 1.049 señalaban ausencia. En junio se registraron 76 observaciones (18 presencias y 58 ausencias), en julio 508 observaciones (40 presencias y 468 ausencias), en agosto 479 observaciones (47 presencias y 432 ausencias) y en septiembre 103 observaciones (12 presencias y 91 ausencias).

3.3.1. Análisis exploratorio de variables ambientales

El Análisis de Componentes Principales (PCA, *Principal Component Analysis*) inicial incluyó 56 variables ambientales, considerando mediciones mensuales de cada variable desde marzo hasta septiembre. Se identificaron los tres primeros Componentes Principales (CP) como los más representativos, ya que en conjunto explican el 66 % de la varianza total de los datos. Las cargas de los componentes principales fueron analizadas tras aplicar un filtro de umbral de 0,2. En la Tabla III-2 se muestran las variables ambientales que contribuyeron de manera significativa (valor absoluto de carga > 0,2) a al menos uno de los tres primeros componentes principales, junto con sus valores de

carga. Estas variables se seleccionaron para análisis posteriores debido a su relevancia en la explicación de la variabilidad observada.

Tabla III-2. Variables ambientales que contribuyeron de forma significativa (valor absoluto de la carga > 0,2) en al menos uno de los tres primeros Componentes Principales (CP). En negrita se destacan los valores de carga absolutos superiores a 0,2.

Variable	Mes	Carga		
		CP1	CP2	CP3
Temperatura potencial del fondo marino	Marzo	0,007	0,240	0,085
	Abril	0,008	0,238	0,089
	Mayo	0,008	0,234	0,095
	Junio	0,012	0,226	0,095
	Julio	0,017	0,213	0,086
	Agosto	0,016	0,208	0,091
	Septiembre	0,020	0,211	0,091
Dirección de la corriente marina	Abril	0,040	0,043	-0,250
Profundidad de la capa de mezcla	Abril	-0,010	-0,215	0,078
Concentración de Clorofila-a	Marzo	-0,144	0,089	0,200
	Abril	-0,066	0,159	0,231
	Julio	-0,210	0,065	-0,087
Productividad primaria neta	Marzo	-0,052	0,126	0,251
	Abril	0,007	0,174	0,226
Salinidad superficial	Marzo	0,204	-0,006	0,088
	Abril	0,207	0,089	0,063
	Junio	0,202	0,040	-0,060
Altura de la superficie del mar	Junio	-0,083	-0,121	0,211
	Julio	-0,030	-0,198	0,230
	Agosto	0,002	-0,137	0,281
	Septiembre	0,008	-0,119	0,214
Temperatura superficial del mar	Marzo	-0,136	-0,110	-0,237
	Abril	-0,064	-0,212	-0,110
	Mayo	0,209	-0,008	0,057
	Junio	0,208	-0,059	0,096
	Julio	0,218	-0,019	0,072
	Agosto	0,204	-0,035	0,095
	Septiembre	0,210	-0,043	0,104

El gráfico tridimensional de las cargas del PCA reveló agrupaciones de variables ambientales en función de su contribución a los tres primeros componentes principales. Para identificar estadísticamente grupos de variables altamente correlacionadas, se aplicó el algoritmo de agrupamiento *k-means*, identificándose cuatro clústeres independientes. El primer clúster agrupó las variables relacionadas con la temperatura potencial en el fondo marino entre marzo y septiembre, junto con la concentración de clorofila-a en marzo y abril, así como la producción primaria neta en los mismos meses. El segundo clúster incluyó la dirección de las corrientes marinas en abril, la concentración clorofila-a en julio y la temperatura superficial del mar en marzo y abril. El tercer clúster estuvo conformado por la salinidad superficial del mar en marzo, abril y junio, además de la temperatura superficial del mar entre mayo y septiembre. El cuarto clúster agrupó el espesor de la capa de mezcla (MLD, *Mixed Layer Depth*) en abril y la altura de la superficie del mar con respecto al geoide desde junio hasta septiembre.

Tras calcular el Factor de Inflación de la Varianza (VIF, *Variance Inflation Factor*) para las variables de cada clúster, se identificó y redujo la multicolinealidad mediante un procedimiento iterativo. Los resultados posteriores a estas iteraciones mostraron que algunas variables presentaban valores de VIF por encima del umbral de 10.

En el primer clúster, la temperatura potencial en el fondo en septiembre y la producción primaria superficial en abril mostraron valores de VIF de 23,65. A pesar de superar el umbral, ambas se conservaron al corresponder a meses diferentes y por aportar información temporal de relevancia ecológica.

En el segundo clúster, la dirección de la corriente superficial en abril y la concentración superficial de clorofila-a en julio presentaron valores de VIF de aproximadamente 1,01, lo que indica ausencia de colinealidad, por lo que se mantuvieron ambas variables.

El tercer clúster incluyó la salinidad superficial del mar en junio y la temperatura superficial en julio, ambas con valores de VIF elevados (391,28). Aunque dichos valores indican una colinealidad alta, las variables pertenecen a meses consecutivos y podrían capturar dinámicas ambientales relevantes para el periodo estival, por lo que se decidió conservar ambas en análisis posteriores.

Por último, en el cuarto clúster, el espesor de la capa de mezcla en abril y la altura de la superficie del mar con respecto al geoide en agosto arrojaron valores de VIF de 9,74, por debajo del umbral crítico.

3.3.2. Modelos MaxEnt

Para comprender mejor la distribución espacial de los registros de medusas antes de modelizar su hábitat potencial, se analizó la densidad de observaciones de presencia obtenidas mediante la aplicación Infomedusa a lo largo de la costa mediterránea andaluza. La Figura III-3 muestra la distribución espacial de la densidad de presencia de medusas en cada mes desde junio hasta septiembre de 2019. Los valores de densidad representan el número de reportes de presencia por celda de la malla, ilustrando las zonas con mayor y menor número de avistamientos.

Estos mapas evidencian una heterogeneidad espacial en la aparición de medusas, con ciertas áreas costeras que presentan una mayor concentración de registros de presencia. Las densidades más altas se observaron en puntos concretos, especialmente en la ciudad de Málaga, coincidiendo con la temporada turística de mayor intensidad, cuando la participación ciudadana en la ciencia ciudadana fue más frecuente.




Figura III-3. Distribución espacial de la densidad de presencia de medusas a lo largo de la costa mediterránea andaluza de junio a septiembre de 2019, basada en los informes de usuarios de Infomedusa. Los valores de densidad representan el número de informes de presencia de avistamientos por cuadrícula.

El rendimiento de los modelos de MaxEnt generados para cada mes se presenta en la Figura III-4. Las curvas ROC muestran una elevada capacidad de los modelos para discriminar entre zonas de presencia y ausencia de medusas. El modelo de junio fue el que ofreció mejor desempeño, mientras que el de agosto presentó un ligero descenso en la precisión.




Figura III-4. Curvas ROC de los modelos MaxEnt de junio a septiembre de 2019.

3.3.3. Análisis de importancia de las variables ambientales

El análisis de la contribución de variables y de la importancia por permutación en los modelos MaxEnt de junio a septiembre mostró que la profundidad de la capa de mezcla (MLD, *Mixed Layer Depth*) en abril fue de manera consistente la variable más influyente para predecir la presencia potencial de medusas en todos los meses estudiados (Tabla III-

3). Esta variable obtuvo los valores más altos tanto en porcentaje de contribución como en importancia por permutación en cada modelo. Las demás variables ambientales presentaron contribuciones menores y variaron en su influencia según el mes. Por ejemplo, la producción primaria neta en abril y la salinidad superficial del mar en junio destacaron de manera más notable en los modelos MaxEnt de julio y agosto. La dirección de la corriente marina en abril también mostró cierta relevancia, especialmente en agosto, aunque su contribución fue menor que la de la profundidad de la capa de mezcla en abril.

Tabla III-3. Porcentaje de contribución (%C) e importancia por permutación (%P) de las variables ambientales en los modelos MaxEnt de cada uno de los meses analizados.

Variable ambiental	Modelo MaxEnt							
	Junio		Julio		Agosto		Septiembre	
	%C	%P	%C	%P	%C	%P	%C	%P
Profundidad de la capa de mezcla (Abril)	90,0	90,4	77,1	62,7	72,7	65,5	93,9	98,3
Productividad primaria neta (Abril)	7,3	4,6	0,1	8,8	12,9	6,4	6,1	1,7
Salinidad superficial (Junio)	1,5	3,2	12	11,1	2,8	4,9	0	0
Dirección de las corrientes marinas (Abril)	1,3	1,8	9,9	14,2	7,7	20,2	0	0
Temperatura superficial del mar (Julio)	-	-	1,0	3,2	0	0	0	0
Concentración de clorofila-a (Julio)	-	-	0	0	1,7	3,0	0	0
Altura de la superficie del mar (Agosto)	-	-	-	-	2,1	0	0	0
Temperatura potencial del fondo marino (Septiembre)	-	-	-	-	-	-	0	0

La prueba *jackknife* corroboró la importancia de la profundidad de la capa de mezcla en abril, ya que su uso individual originó la mayor ganancia de entrenamiento, mientras que su omisión provocó la mayor disminución en la ganancia en todos los modelos. Esto indica que la profundidad de la capa de mezcla en abril contiene información esencial no presente en las demás variables y resulta determinante para el rendimiento predictivo del modelo. Las curvas de respuesta de las variables ambientales más influyentes se presentan en la Figura III-5. Cada gráfico muestra cómo varía la

probabilidad de presencia de medusas en respuesta a cambios en estas variables durante los distintos meses analizados:

En primer lugar, la Figura III-5A destaca la influencia de la profundidad de la capa de mezcla en abril, que resultó ser la variable más determinante en todos los modelos. De manera consistente, se observa una mayor probabilidad de presencia de medusas asociada a capas de mezcla más superficiales, lo que sugiere que una columna de agua más estable en primavera favorece la presencia de medusas durante los meses estivales. La Figura III-5B muestra la relación con la producción primaria neta registrada en abril. La probabilidad de presencia aumenta claramente conforme se incrementan los niveles de producción primaria, lo que indica que un aumento temprano en la productividad marina puede facilitar la proliferación de medusas durante el verano. En la Figura III-5C, se aprecia que la influencia de la salinidad superficial del mar registrada en junio varía en función del mes considerado. Destaca especialmente en julio, mientras que en otros meses su efecto es menos evidente. Cabe señalar que esta variable no mostró ningún impacto en la predicción realizada para el mes de septiembre. Finalmente, la Figura III-5D representa la respuesta a la dirección de las corrientes marinas medidas en abril. El patrón es bastante estable a lo largo de los meses estudiados, observándose probabilidades más altas cuando la dirección de la corriente se aproxima a los 0 grados, lo que corresponde a corrientes orientadas hacia el norte.




Figura III-5. Curvas de respuesta de las principales variables ambientales que influyen en la probabilidad prevista de presencia de medusas de junio a septiembre de 2019. Cada panel muestra la respuesta de una variable específica a lo largo de los cuatro meses estudiados. Las líneas rojas representan junio, las azules julio, las verdes agosto y las negras septiembre.

3.3.4. Mapas de distribución de probabilidad de ocurrencia de medusas

Los mapas generados por MaxEnt (Figura III-6) mostraron variaciones espaciales y temporales en la probabilidad de presencia de medusas a lo largo de la costa. Los mapas muestran un gradiente costero, en el que las zonas con mayor probabilidad de presencia de medusas (colores rojo y amarillo) se concentran predominantemente cerca de la línea de costa. Las zonas con tonos azules representan áreas con una probabilidad relativamente baja, lo que indica una menor predisposición a la presencia de medusas en estos lugares.




Figura III-6. Mapas de probabilidad de aparición de medusas predichos por MaxEnt de junio a septiembre de 2019 para la costa mediterránea andaluza.

3.3.5. Validación de los modelos MaxEnt utilizando datos de ausencia

El conjunto de datos de observaciones de ausencia de medusas, recopiladas entre junio y septiembre de 2019, se empleó para generar mapas de densidad de ausencias. Se construyó una malla regular con celdas de 0,05 grados de resolución sobre el área de estudio y se contabilizaron los registros de ausencia en cada celda de dicha malla. Para suavizar las variaciones locales y resaltar tendencias espaciales, se aplicó un filtro gaussiano con un valor de sigma de 1 a la matriz de densidad, obteniendo así mapas de calor suavizados para cada mes.

Con el fin de evaluar la concordancia entre las predicciones del modelo MaxEnt y las observaciones de ausencia, se superpusieron los mapas de probabilidad de presencia de medusas con los mapas de densidad de ausencia. Se establecieron umbrales para identificar zonas de baja probabilidad de presencia en las predicciones de MaxEnt (valores de probabilidad de presencia de medusas inferiores a 0,50) y áreas de alta densidad de ausencia en los mapas de calor (valores de densidad de ausencia normalizada superiores a 0,1). En la Figura III-7 se muestran los resultados de las áreas identificadas según estos umbrales, así como las zonas de solapamiento obtenidas para los cuatro meses analizados.




Figura III-7. Superposición de áreas de baja probabilidad predichas por MaxEnt y áreas de alta densidad de ausencia observadas para cada mes. La columna de la izquierda representa las zonas en las que el modelo MaxEnt predijo una baja probabilidad de presencia de medusas (rojo). La columna central muestra las zonas con alta densidad de ausencia observada según los informes de los usuarios de Infomedusa (azul). La columna de la derecha destaca el solapamiento espacial entre ambos conjuntos de datos, donde las predicciones de baja probabilidad de MaxEnt coinciden con altas densidades de ausencia observadas (verde). La zona costera del área de estudio se muestra en blanco, mientras que las aguas mar adentro se representan en azul claro.

Se cuantificó el grado de coincidencia entre las predicciones MaxEnt y las observaciones de ausencia de cada mes. Se calculó el número total de celdas en las que coincidían las zonas de baja probabilidad y alta densidad de ausencias, así como el porcentaje de coincidencia con respecto al total de zonas de alta densidad de ausencias. Los resultados son mostrados en la Tabla III-4.

Tabla III-4. Resultados de la coincidencia entre las predicciones MaxEnt y las observaciones de ausencia por mes.

Mes	Áreas de baja probabilidad	Áreas de alta ausencia	Número de coincidencias	Porcentaje de coincidencias (%)
Junio	301	96	33	34,38
Julio	301	167	62	37,13
Agosto	249	155	35	22,58
Septiembre	329	39	12	30,77

Los resultados indican que el modelo MaxEnt fue capaz de identificar una proporción moderada de las zonas de alta ausencia de medusas en los meses de junio, julio y septiembre, con porcentajes de coincidencia que oscilaron entre el 30,77% y el 37,13%. En agosto, el porcentaje de coincidencia fue inferior (22,58%), lo que sugiere una disminución de la capacidad del modelo para predecir correctamente las zonas libres de medusas durante este mes.

3.4. Discusión

Este estudio empleó MaxEnt para modelizar la distribución de medusas a lo largo de la costa andaluza durante el verano de 2019, utilizando datos de presencia obtenidos a partir de los reportes de usuarios de la app Infomedusa y variables ambientales proporcionadas por la plataforma Copernicus. Los modelos señalaron de forma consistente que la profundidad de la capa de mezcla en abril fue el predictor más influyente de la presencia de medusas en todos los meses estudiados. Otras variables ambientales, como la producción primaria neta, la dirección de la corriente marina en abril, así como la salinidad superficial del mar en junio, también contribuyeron a los modelos, aunque en menor medida.

MaxEnt es una herramienta especialmente adecuada para modelizar distribuciones de medusas debido a su capacidad para manejar relaciones complejas entre variables ambientales y ocurrencias de especies (Bentlage *et al.*, 2009; Record *et al.*, 2018; Guo *et al.*, 2023; Pantiukhin *et al.*, 2024). Según Olivero *et al.* (2016), estos modelos tienden a sobreajustarse cuando se emplean resoluciones espaciales gruesas, siendo más recomendables resoluciones más finas. En nuestro caso, el uso de MaxEnt permitió aprovechar de manera efectiva los datos de presencia procedentes de la aplicación Infomedusa combinados con datos ambientales de Copernicus obtenidos a la resolución espacial más fina disponible, evitando así las limitaciones derivadas de este tipo de modelos.

Aunque las series temporales a largo plazo pueden mejorar la robustez de los modelos de distribución de medusas al capturar la variabilidad interanual (Condon *et al.*, 2012; Rosa *et al.*, 2013; Sanz-Martín *et al.*, 2016; Fernández-Alías *et al.*, 2024), la aplicación Infomedusa se utiliza predominantemente en los meses de verano. Por tanto, en este estudio carecemos de datos suficientes fuera de ese periodo para realizar un

análisis multi-anual robusto. La base de datos actual permite únicamente una evaluación estacional (junio-septiembre de 2019), limitando nuestra capacidad para analizar potenciales cambios interanuales en la distribución de medusas. Sin embargo, diversos estudios han demostrado que la escala mensual es ampliamente aceptada para modelizar la distribución de medusas a partir de modelos MaxEnt (por ejemplo, Record *et al.*, 2018; Guo *et al.*, 2023).

3.4.1. Principales variables ambientales y su efecto en *Pelagia noctiluca*

La interpretación de nuestros resultados se fundamenta en el hecho de que *Pelagia noctiluca* es la especie de medusa más abundante y conspicua del Mediterráneo (Brotz y Pauly, 2012) y la más comúnmente reportada en nuestra zona de estudio, la costa mediterránea andaluza (Gutiérrez-Hernández y Rubio-Gómez, 2023). Aunque los escifozoos son el grupo predominante en la región, es posible que algunos reportes incluyeran otros tipos de zooplancton gelatinoso, tales como *Cotylorhiza tuberculata* y *Rhizostoma pulmo* (Rubio-Gómez y Gutiérrez-Hernández, 2020). Sin embargo, debido a que la aplicación Infomedusa no requiere identificación obligatoria de especies, no fue posible verificar la exactitud taxonómica de todas las observaciones. Estudios previos y comunicaciones con el equipo de Infomedusa indican que la gran mayoría de los reportes de usuarios corresponden a *P. noctiluca*, la cual aparece con mayor frecuencia en las fotografías enviadas a la aplicación. Su predominio en el conjunto de datos sugiere que las variables ambientales que influyen en la distribución de medusas afectan principalmente a esta especie. Dado que *P. noctiluca* es una medusa holoplanctónica (Lucas *et al.*, 2012), su presencia depende estrechamente de las condiciones de las aguas superficiales, lo que probablemente explique la fuerte correlación entre su presencia y las variables oceanográficas clave identificadas en nuestros modelos.

La importancia constante de la profundidad de la capa de mezcla (MLD, *Mixed Layer Depth*) en abril sugiere que las condiciones oceanográficas de principios de primavera desempeñan un papel clave en la distribución de medusas durante los meses de verano. En este estudio, se utilizó la variable espesor de la capa de mezcla definida por sigma theta (σ_θ) como medida de la MLD. Una capa de mezcla más somera en primavera se traduce como una columna de agua más estable. Esta situación puede conducir a una estratificación temprana, incrementando la temperatura superficial y favoreciendo las

floraciones de fitoplancton (Wihsgott *et al.*, 2019). El aumento en la productividad primaria proporciona mayor disponibilidad de alimento para las fases tempranas de *P. noctiluca* (Ottmann *et al.*, 2021), además de generar mayor estabilidad en la columna de agua, favoreciendo la supervivencia y reproducción (Molinero *et al.*, 2005).

Esto coincide con los resultados obtenidos para la producción primaria neta en el mismo mes, que señala una mayor biomasa de fitoplancton. Como es evidente, cualquier organismo gelatinoso puede beneficiarse de mayor disponibilidad de alimento (Purcell *et al.*, 2007), ya que un aumento en los recursos tróficos puede favorecer el crecimiento exponencial de sus poblaciones (Milisenda *et al.*, 2018; Goldstein y Steiner, 2020). Un incremento en la abundancia de fitoplancton favorece poblaciones más grandes de zooplancton, principal fuente de alimento para los estadios tempranos de *P. noctiluca* (Ottmann *et al.*, 2021). Como indican Boero *et al.* (2008), los picos de abundancia de medusas se sostienen energéticamente tanto por el fitoplancton como por el zooplancton herbívoro. Por lo tanto, unas condiciones de primavera temprana con alta productividad primaria pueden fomentar el crecimiento y las tasas de supervivencia de las medusas juveniles al proveerles recursos alimenticios, facilitando la aparición de enjambres de medusas (Kogovšek *et al.*, 2010; Boero, 2013; Milisenda *et al.*, 2018). Además, la disponibilidad de presas influye en la supervivencia de las larvas y, por ende, en el éxito de las proliferaciones de medusas (Hecq, 2009). No obstante, la cantidad de éfiras presentes en una población no siempre se traduce en una mayor abundancia de medusas adultas, como señalaron Bernard *et al.* (2011), lo que sugiere que otros factores también intervienen en la regulación de sus dinámicas poblacionales. Además, dado que las medusas se alimentan principalmente de organismos planctónicos, en zonas donde el agua está enriquecida con nutrientes debido a la actividad humana o a procesos naturales, se ha observado un aumento en la biomasa del plancton, lo que puede favorecer la proliferación de medusas (Purcell, 2012). Sin embargo, medir la cantidad de plancton en una zona determinada no es tan sencillo como medir la temperatura del agua, ya que requiere muestreos específicos y análisis en laboratorio, lo que encarece y complica su inclusión en modelos de predicción.

Cabe destacar que se ha observado que *P. noctiluca* se reproduce durante todo el año, con un pico de actividad reproductiva en primavera (Mghili *et al.*, 2020a), lo que subraya la relevancia ecológica de esta estación en la dinámica poblacional. Asimismo, una capa de mezcla más somera puede incidir en la distribución de peces pelágicos

pequeños, como anchoas y sardinas, concentrándolos cerca de la superficie. Esta agregación incrementada puede aumentar su capturabilidad y, por ende, la presión pesquera (Báez *et al.*, 2022). Dado que estos peces se alimentan de las fases tempranas de *P. noctiluca* (Ottmann *et al.*, 2021), una actividad pesquera más intensa podría reducir sus poblaciones, disminuyendo la depredación sobre éfiras y otros estadios juveniles. Esta reducción en la presión depredadora podría, a su vez, favorecer la supervivencia y proliferación de medusas adultas, subrayando un posible vínculo entre las condiciones oceanográficas de principios de primavera, la pesca y la dinámica de los enjambres de medusas.

La salinidad superficial del mar en junio también resultó ser una variable influyente, aunque con menor importancia en comparación con la MLD y la productividad primaria. La correlación positiva observada entre la salinidad superficial en junio y la probabilidad de presencia de medusas en nuestros modelos coincide con estudios previos (Tegaccia, 1983; Aouititen *et al.*, 2021). Canepa *et al.* (2014) demostraron que la salinidad se relaciona de manera positiva con la presencia de *P. noctiluca*. Salinidades comprendidas entre 35 y 38 son consecuencia de bajas precipitaciones, lo que se traduce en una menor influencia de aportes de agua dulce y, por ende, mayor estabilidad de la columna de agua. Dado que Ottmann *et al.* (2021) mostraron que la salinidad no afectaba significativamente a los estadios más tempranos de *P. noctiluca*, es probable que el efecto de esta variable se explique por la estabilidad que confiere a la columna de agua.

La salinidad del agua puede tener un efecto en la distribución de diferentes especies de medusas. Por ejemplo, en el caso de *Carybdea marsupialis* en la costa de Denia (Alicante), Canepa *et al.* (2017) corroboraron que la salinidad, junto con la temperatura superficial del mar y nutrientes como nitratos y fosfatos al comienzo de la primavera, influyen en su distribución espaciotemporal de *C. marsupialis* en el verano siguiente, asociándose mayores abundancias con zonas de mezcla de aguas dulces y marinas, ricas en producción primaria. Estos autores destacaron que estos mecanismos explican los brotes de la especie en áreas impactadas por actividades humanas, como la agricultura intensiva o vertidos urbanos, que alteran la salinidad y la carga de nutrientes costeros (Sebastiá *et al.*, 2012). En el mar Mediterráneo, varias especies de medusas holoplanctónicas también han sido más abundantes en condiciones cálidas y de alta salinidad (Purcell, 2012). Del mismo modo, en especies de medusa con fase pólipo ha

sido demostrado que la salinidad tiene un efecto positivo en la producción de medusas (Purcell, 2012). La salinidad es un parámetro que varía según múltiples factores, como las lluvias, la evaporación o el aporte de los ríos, por lo que medir esta variable con precisión en cada punto de la costa requiere un monitoreo constante, algo que no siempre es viable (Gu *et al.*, 2022).

La dirección de la corriente marina en abril fue otra variable que contribuyó a los modelos, lo que sugiere que los patrones de circulación oceánica durante la primavera temprana desempeñan una función en la distribución de medusas en verano. Las corrientes con dirección norte podrían facilitar el transporte de individuos de *P. noctiluca* desde zonas de desove hasta la costa andaluza (Gutiérrez-Estrada *et al.*, 2021; Castro-Gutiérrez *et al.*, 2022, 2024). En el mar de Alborán, la entrada de agua atlántica a través del Estrecho de Gibraltar (conocida como Chorro del Atlántico o “*Atlantic Jet*”) interactúa con el Giro Occidental del mar de Alborán (WAG) para conformar la circulación oceánica y, en consecuencia, la distribución del plancton gelatinoso (Bellido *et al.*, 2020). El WAG suele funcionar como zona de retención que concentra grandes cantidades de medusas, especialmente en su periferia, donde tienden a acumularse recursos alimenticios (Bellido *et al.*, 2020). Sin embargo, alteraciones en este giro, a menudo ocasionadas por frentes atlánticos entrantes o cambios en la intensidad y trayectoria del Chorro del Atlántico, pueden generar remolinos ciclónicos que arrastran grandes agregaciones de medusas hacia la plataforma continental (Sánchez-Garrido *et al.*, 2013). Una vez cerca de la costa, la interacción entre factores locales como los vientos y la topografía costera pueden ayudar a retener y desviar estas agregaciones a zonas como la bahía de Málaga o el golfo de Almería (Graham *et al.*, 2001; Sánchez-Garrido *et al.*, 2013). De la Fuente Roselló *et al.* (2024) destacaron la relevancia de la orientación costera en la llegada de medusas a las playas de la Costa del Sol, señalando que tramos orientados hacia el este o el sur pueden verse más afectados por corrientes litorales y vientos dominantes, lo que incrementa su susceptibilidad a la retención de enjambres cerca de la orilla.

Por su parte, el Frente Almería-Orán actúa a modo de barrera ecológica que, por lo general, mantiene los enjambres dentro del mar de Alborán, impidiendo su dispersión hacia otros sectores del Mediterráneo Occidental (Pérez-Portela *et al.*, 2019). En años con un WAG robusto y estable, las medusas pueden permanecer en alta mar, resultando en menos varamientos costeros; mientras que, cuando el WAG se debilita o desorganiza, aumentan las probabilidades de encallamientos costeros y enjambres de alta densidad.

Esto subraya el papel determinante de los procesos oceanográficos de mesoescala en la distribución de las especies gelatinosas (Bellido *et al.*, 2020). Aunque la variable de corriente marina en este estudio representa condiciones de abril, su efecto puede manifestarse más adelante, conforme los individuos transportados crecen y se desarrollan, lo que se traduce en mayores densidades de medusas durante el verano. El modelo MaxEnt identifica correlaciones entre variables ambientales y presencia de la especie sin considerar retrasos temporales, por lo que puede detectar relaciones en las que condiciones oceanográficas tempranas influyen en patrones biológicos posteriores (Wang *et al.*, 2018). Por tanto, las corrientes marinas de abril pueden determinar la distribución inicial de las poblaciones de medusas que se mantienen hasta el verano, destacando la importancia de incorporar la dinámica temporal en los modelos ecológicos de medusas.

La predicción de eventos de enjambres resulta compleja debido a que las medusas pueden favorecer u obstaculizar la formación de enjambres mediante nado activo o modificando su flotabilidad (Zavodnik, 1987; Malej, 1989; Fossette *et al.*, 2015; Bellido *et al.*, 2020). Sin embargo, una vez cerca de la costa, la capacidad natatoria de las medusas es superada por las corrientes someras dominadas por el viento, quedando su dinámica fundamentalmente determinada por la advección (Graham *et al.*, 2001; Berline *et al.*, 2013). Así, el forzamiento del viento, aunque no se incluyó en nuestros modelos, es reconocido como un factor ambiental clave en el transporte y los varamientos costeros de medusas (Long *et al.*, 2024), especialmente en el área de la Costa del Sol (Gutiérrez-Estrada *et al.*, 2021; Castro-Gutiérrez *et al.*, 2022). Diversos estudios han demostrado que los patrones de viento también desempeñan un papel crucial en los eventos de varamientos de medusas en la costa sur del mar de Alborán (Mghili *et al.*, 2020a, b). Aunque en este capítulo nos hemos centrado en los factores ambientales a gran escala más que en los mecanismos de transporte a corto plazo, la incorporación de variables asociadas al viento podría mejorar la precisión predictiva de los modelos de ocurrencia de medusas, especialmente para la predicción a corto plazo de eventos de aparición de enjambres de medusas en las costas, por lo que el efecto de estas variables se analizará en detalle en el Capítulo IV.

3.4.2. Efecto de otras variables ambientales

Además de las variables ambientales incluidas en este estudio, existen otros factores relevantes que no se han incluido explícitamente en estos modelos o que se analizan de modo secundario y que pueden modular la abundancia de medusas en distintas fases del ciclo de vida. La interacción de estos factores y su variabilidad interanual explican por qué, a pesar de más de tres décadas de investigación, sigue siendo extremadamente difícil predecir con precisión la aparición de enjambres de medusas en los ecosistemas marinos (Fernández-Alías *et al.*, 2024).

La aparición de enjambres de medusas también puede aumentar o disminuir por factores climatológicos de gran escala. Por ejemplo, Bellido *et al.* (2020) detectaron que los índices climáticos de la Oscilación del Atlántico Norte (NAO) y la Oscilación del Ártico (AO) influyen en los enjambres de medusas al afectar tanto la reproducción como la producción primaria de la zona. Además, la respuesta de los enjambres a los cambios de temperatura difiere según el área geográfica: en regiones más frías, son los eventos de enfriamiento extremo los que estimulan la formación de enjambres mientras que, en zonas más cálidas, como la de este estudio, lo hacen los episodios de temperaturas elevadas (Purcell, 2005; Bellido *et al.*, 2020). También se ha demostrado que los eventos de altas temperaturas favorecen la presencia de distintas especies de medusas en el margen atlántico de la península ibérica (Rodríguez-García *et al.*, 2021), por lo que esta variable debería contemplarse en trabajos futuros.

Aunque la temperatura superficial del mar (SST) no se incluyó como predictor principal en nuestros modelos de MaxEnt debido a problemas de colinealidad, la literatura respalda ampliamente su papel en la dinámica de poblaciones de medusas (Aouititen *et al.*, 2024) y su efecto sobre la presencia de medusas ya fue discutido en el Capítulo II. A menudo, la SST se correlaciona con otros parámetros ambientales clave, como la concentración de clorofila-a y la productividad primaria, que influyen en la dinámica de las poblaciones de medusas al afectar la disponibilidad de alimento para sus fases tempranas (Zavodnik, 1987; Canepa *et al.*, 2014). Numerosos estudios han mostrado que la SST puede influir significativamente en la aparición de medusas, ya que condiciones más cálidas suelen fomentar densidades mayores de estos organismos (Purcell, 2005; Brotz y Pauly, 2012; Canepa *et al.*, 2014). Este efecto puede vincularse a un incremento en el éxito reproductivo, puesto que temperaturas más altas aceleran el desarrollo de huevos y éfiras (Avian *et al.*, 1991), aumentando el potencial de proliferación. Además,

la bibliografía señala que el desove de *P. noctiluca* alcanza su máximo en primavera, cuando la temperatura se sitúa en torno a 17 °C (Augustine *et al.*, 2014), lo que indica una variación estacional en sus poblaciones. Esto pone de relieve la importancia de considerar especies de medusas específicas y sus ciclos reproductivos al estudiar el efecto de la SST en su presencia. Asimismo, las variaciones en la SST pueden influir en los patrones de transporte y agregación de las medusas al modificar la estabilidad y la estratificación de la columna de agua (Graham *et al.*, 2001; Messié y Chavez, 2017). Las zonas con mayor SST pueden facilitar la retención de medusas cerca de la costa al reducir la mezcla vertical y aumentar la disponibilidad de presas. Cabe subrayar que, debido a la disponibilidad de datos fundamentalmente en los meses de verano, estos hallazgos podrían no reflejar por completo los patrones de presencia de medusas en otras estaciones ni la dinámica de otras especies distintas de *P. noctiluca*.

Por su parte, el cambio climático, entendido como el aumento progresivo de la temperatura superficial de los océanos y la acidificación oceánica por reducción del pH marino, puede considerarse uno de los factores ambientales más influyentes en la distribución y proliferación de las medusas (Kroeker *et al.*, 2010; Gissi *et al.*, 2021). En los últimos dos siglos, las emisiones antropogénicas de CO₂ han incrementado sustancialmente, generando no solo una acumulación de este gas en la atmósfera, sino también una absorción masiva por parte de los océanos (Thor y Dupont, 2018). Este proceso, si bien contribuye a mitigar parte del efecto invernadero, desencadena una serie de cambios químicos conocidos de forma global como acidificación oceánica (Thor y Dupont, 2018), que incluyen la disminución paulatina del pH y la transformación de iones carbonato (CO₃²⁻) en bicarbonato (HCO₃⁻), con la consiguiente disminución de la disponibilidad de carbonato para diversos organismos marinos calcificadores (Billé *et al.*, 2013). A este fenómeno de acidificación se une, además, el rápido aumento de la temperatura superficial del océano, documentado de forma intensa en las últimas décadas (Cheng *et al.*, 2021; IPCC *et al.*, 2022).

Aunque históricamente las investigaciones sobre la acidificación se han centrado en especies calcificadoras debido al efecto directo que la reducción de CO₃²⁻ ejerce sobre la formación de conchas y esqueletos de carbonato de calcio (Fabry *et al.*, 2008), organismos no calcificadores como las medusas han permanecido relativamente menos estudiados (Pitt *et al.*, 2018). Las medusas scyphozoas contienen unas estructuras sólidas denominadas estatolitos, compuestos de sulfato cálcico hemihidratado, una forma mineral

distinta del carbonato que permite a las medusas orientarse en la columna de agua (León-Cobo *et al.*, 2024). Debido a que estas estructuras no dependen directamente de la concentración de iones carbonato, podrían mostrar una tolerancia mayor a la acidificación que otros invertebrados (León-Cobo *et al.*, 2024). Sin embargo, los estudios al respecto han arrojado resultados dispares. Mientras que algunas investigaciones señalan alteraciones en el tamaño o número de estatolitos bajo condiciones de pH reducido y alta temperatura (Winans y Purcell, 2010; Klein *et al.*, 2014), otras no detectan cambios significativos (Enrique-Navarro *et al.*, 2021; León-Cobo *et al.*, 2024).

A pesar de esta incertidumbre, el consenso general apunta a que los efectos conjuntos de la acidificación y el calentamiento oceánicos podría favorecer a largo plazo la proliferación de poblaciones de medusas (Purcell *et al.*, 2007; Boero *et al.*, 2016). El calentamiento oceánico puede influir en la dinámica de poblaciones de medusas de diversas maneras (Boero *et al.*, 2016). A escala latitudinal, el incremento de la temperatura marina favorece la expansión de especies tropicales hacia zonas templadas, ya que amplía o adelanta sus periodos de reproducción y potencia su supervivencia invernal. Al mismo tiempo, algunas especies de aguas frías reducen sus ventanas de reproducción y se ven desplazadas a latitudes mayores o zonas más profundas donde la temperatura se ajusta mejor a sus límites térmicos. El resultado es un escenario en el que, en áreas costeras de latitudes medias, las floraciones de medusas tienden a ser más frecuentes e intensas, con mayores riesgos para actividades humanas. Sin embargo, en regiones tropicales, el calentamiento adicional puede ejercer un efecto perjudicial sobre ciertas medusas al situarlas cerca o por encima de su tolerancia térmica. Estas dinámicas subrayan la complejidad de los efectos del calentamiento global sobre las medusas, ya que los cambios de temperatura pueden simultáneamente favorecer la proliferación de unas especies e impactar negativamente en otras, modificando así la estructura de las redes tróficas marinas y la interacción de las medusas con las actividades humanas.

La mencionada resiliencia fisiológica ante la acidificación, unida a la sensibilidad de las medusas al incremento de la temperatura, encaja con la hipótesis de que estos organismos funcionen como “bioindicadores” de los cambios regionales en el mar Mediterráneo (Rossi *et al.*, 2019). Tal y como señalan Lacoue-Labarthe *et al.* (2016), la región mediterránea está viviendo un ascenso térmico más rápido que la media global, lo cual podría adelantar o intensificar las floraciones de medusas, afectando directamente al turismo, la pesca y la salud pública (Richardson *et al.*, 2009).

3.5. Conclusiones

Este estudio demuestra que las condiciones ambientales del mar de Alborán a principios de primavera, en particular la profundidad de la capa de mezcla en abril, son factores clave para predecir la presencia de medusas a lo largo de la costa andaluza durante los meses de verano, lo que sugiere que los procesos tempranos de estratificación desempeñan un papel fundamental en la aparición de medusas durante este periodo.

Otras variables relevantes incluyen la producción primaria neta en abril, que probablemente refleje la disponibilidad de alimento para las fases tempranas de desarrollo, así como la dirección de la corriente marina en abril, la cual puede influir en el transporte de las poblaciones de medusas hasta el área de estudio. Asimismo, la salinidad superficial del mar en junio mostró una relación positiva con la presencia de medusas, posiblemente asociada a la estabilidad de la columna de agua. La temperatura superficial del mar y la altura de la superficie marina respecto al geoide también fueron incluidas en los modelos, pero presentaron contribuciones menores, probablemente debido a su colinealidad con otras variables. El uso de modelos MaxEnt con datos de ciencia ciudadana demostró ser eficaz para predecir la distribución de medusas sin necesidad de datos de ausencia, aportando una mejor comprensión de los factores que impulsan las proliferaciones de medusas y ofreciendo implicaciones prácticas para la gestión de sus impactos socioeconómicos.

Al reconocer los predictores ambientales críticos y aprovechar fuentes de datos innovadoras, esta investigación aporta información valiosa para la gestión costera y destaca el potencial de combinar técnicas avanzadas de modelización con la ciencia ciudadana en la ecología marina. El esfuerzo continuo en la recopilación de datos, el desarrollo de modelos y los enfoques colaborativos potenciará nuestra capacidad para predecir y mitigar los efectos de las proliferaciones de medusas en el futuro. El establecimiento de programas de monitoreo a largo plazo permitiría evaluar la variabilidad interanual y las tendencias en las poblaciones de medusas. Por otro lado, ampliar el alcance geográfico para incluir otras regiones del Mediterráneo podría facilitar estudios comparativos y fortalecer las estrategias de gestión a nivel regional.

3.6. Referencias

- Abdi, H., Williams, L. J. 2010. Principal component analysis. *Wiley interdisciplinary reviews: computational statistics* 2(4), 433-459.
- Aouititen, M., Mrhraoui, A. R. M., Luan, X. 2021. Causes of Outbreak in M'Diq Beach, *Pelagia noctiluca* Northwest Moroccan Mediterranean Coastline. *Indian Journal of Ecology* 48(2), 519-523.
- Aouititen, M., Ravibhanu, A., Ang, S. C., Magabandi Mouanda, D. C., Luan, X. 2024. New records of two jellyfish species *Rhizostoma luteum* (Quoy and Gaimard 1827) and *Cotylorhiza tuberculata* (Macri 1778) in the Moroccan northwest Mediterranean coast. *Discover Life* 54, 5.
- Augustine, S., Rosa, S., Kooijman, S. A., Carlotti, F., Poggiale, J. C. 2014. Modeling the eco-physiology of the purple mauve stinger, *Pelagia noctiluca* using Dynamic Energy Budget theory. *Journal of sea research* 94, 52-64
- Avian, M., Rottini Sandrini, L., Stravisi, F. 1991. The effect of seawater temperature on the swimming activity of *Pelagia noctiluca* (Forsskål). *Italian Journal of Zoology* 58(2), 135-143.
- Báez, J. C., Pennino, M. G., Albo-Puigserver, M., Coll, M., Giraldez, A., Bellido, J. M. 2022. Effects of environmental conditions and jellyfish blooms on small pelagic fish and fisheries from the Western Mediterranean Sea. *Estuarine, Coastal and Shelf Science* 264, 107699.
- Bellido, J. J., Baez, J. C., Souviron-Priego, L., Ferri-Yanez, F., Salas, C., López, J. A., Real, R. 2020. Atmospheric indices allow anticipating the incidence of jellyfish coastal swarms. *Mediterranean Marine Science* 21(2), 289-297.
- Benedetti-Cecchi, L., Canepa, A., Fuentes, V., Tamburello, L., Purcell, J. E., Piraino, S., Roberts, J., Boero, F., Halpin, P. 2015. Deterministic factors overwhelm stochastic environmental fluctuations as drivers of jellyfish outbreaks. *PLoS ONE* 10(10), e0141060.
- Bentlage, B., Peterson, A. T., Cartwright, P. 2009. Inferring distributions of chirodropid box-jellyfishes (Cnidaria: Cubozoa) in geographic and ecological space using ecological niche modeling. *Marine Ecology Progress Series* 384, 121-133.

- Bergamasco, A., Cucco, A., Guglielmo, L., Minutoli, R., Quattrocchi, G., Guglielmo, R., Palumbo, F., Pansera, M., Zagami, G., Vodopivec, M., Malej, A., Granata, A. 2022. Observing and modeling long-term persistence of *P. noctiluca* in coupled complementary marine systems (Southern Tyrrhenian Sea and Messina Strait). *Scientific Reports* 12(1), 14905.
- Berline, L., Zakardjian, B., Molcard, A., Ourmieres, Y., Guihou, K. 2013. Modeling jellyfish *Pelagia noctiluca* transport and stranding in the Ligurian Sea. *Marine Pollution Bulletin* 70(1-2), 90-99.
- Bernard, P., Berlin, L., Gorsky, G. 2011. Long term (1981–2008) monitoring of the jellyfish *Pelagia noctiluca* (Cnidaria, Scyphozoa) on the French Mediterranean Coasts. *Journal of Oceanography, Research and Data* 4, 1-10.
- Bernier, E. T., Sánchez, R. R., Díaz, B. R. 2014. La crisis económica en el sector turístico. Un análisis de sus efectos en la Costa del Sol. *Revista de análisis turístico* 18, 11-18.
- Billé, R., Kelly, R., Biastoch, A., Harrould-Kolieb, E., Herr, D., Joos, F., Kroeker, K., Laffoley, D., Oschlies, A., Gattuso, J. P. 2013. Taking action against ocean acidification: a review of management and policy options. *Environmental Management* 52, 761-779.
- Boero, F. 2013. Review of jellyfish blooms in the Mediterranean and Black Sea. *General Fisheries Commission for the Mediterranean. Studies and Reviews* 92.
- Boero, F., Bouillon, J., Gravili, C., Miglietta, M. P., Parsons, T., Piraino, S. 2008. Gelatinous plankton: irregularities rule the world (sometimes). *Marine Ecology Progress Series* 356, 299-310.
- Boero, F., Brotz, L., Gibbons, M. J., Piraino, S., Zampardi, S. 2016. Impacts and effects of ocean warming on jellyfish. En D. Laffoley, Baxter, J. M. (Eds.) *Explaining ocean warming: Causes, scale, effects and consequences* (pp. 213-237). IUCN.
- Bradley, A. P. 1997. The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern recognition* 30(7), 1145-1159.
- Brotz, L., Pauly, D. 2012. Jellyfish populations in the Mediterranean Sea. *Acta Adriatica* 53(2), 213-232.

- Brotz, L., Cheung, W. W., Kleisner, K., Pakhomov, E., Pauly, D. 2012. Increasing jellyfish populations: trends in large marine ecosystems. En J. E. Purcell, H. Mianzan, J. R., Frost (Eds.), *Jellyfish Blooms IV: Interactions with humans and fisheries* (pp. 3-20). Springer.
- Canepa, A., Fuentes, V., Sabatés, A., Piraino, S., Boero, F., Gili, J. M. 2014. *Pelagia noctiluca* in the Mediterranean Sea. En K. A. Pitt, C. H. Lucas (Eds.), *Jellyfish Blooms* (pp. 237-266). Springer.
- Canepa, A., Fuentes, V., Bosch-Belmar, M., Acevedo, M., Toledo-Guedes, K., Ortiz, A., Durá, E., Bordehore, C., Gili, J. M. 2017. Environmental factors influencing the spatio-temporal distribution of *Carybdea marsupialis* (Lineo, 1978, Cubozoa) in South-Western Mediterranean coasts. *PLoS ONE* 12(7), e0181611.
- Cantarero-Prados, F. J., de la Fuente Roselló, A., López, J. J. B. 2023. El impacto de las medusas en el uso recreativo de las playas. Un enfoque desde la perspectiva del riesgo. *Cuadernos Geográficos* 62(1), 300-318.
- Castro-Gutiérrez, J., Gutiérrez-Estrada, J. C., Báez, J. C. 2024. Using artificial neural networks and citizen science data to assess jellyfish presence along coastal areas. *Journal of Applied Ecology* 61(9), 2244-2257.
- Castro-Gutierrez, J., Gutiérrez-Estrada, J. C., Aroba, J., Pulido-Calvo, I., Peregrín, A., Báez, J. C., Bellido, J. C., Souviron-Priego, L. 2022. Estimation of jellyfish abundance in the south-eastern Spanish coastline by using an explainable artificial intelligence model based on fuzzy logic. *Estuarine, Coastal and Shelf Science* 277, 108062.
- Cheng, L., Abraham, J., Trenberth, K. E., Fasullo, J., Boyer, T., Locarnini, R., Zhang, B., Yu, F., Wan, L., Chen, X., Song, X., Liu, Y., Mann, M. E., Reseghetti, F., Simoncelli, S., Gouretski, V., Chen, G., Mishonov, A., Reagan, J., Zhu, J. 2021. Upper ocean temperatures hit record high in 2020. *Advances in Atmospheric Sciences* 38, 523-530.
- Cimino, M. A., Patris, S., Ucham, G., Bell, L. J., Terrill, E. 2018. Jellyfish distribution and abundance in relation to the physical habitat of Jellyfish Lake, Palau. *Journal of Tropical Ecology* 34(1), 17-31.

- Condon, R. H., Graham, W. M., Duarte, C. M., Pitt, K. A., Lucas, C. H., Haddock, S. H., Sutherland K. R., Robinson, K. L., Dawson, M. N., Decker, M. B., Mills, C. E., Purcell, J. E., Malej, A., Mianzan, H., Uye, S.-I., Gelcich, S., Madin, L. P. 2012. Questioning the rise of gelatinous zooplankton in the world's oceans. *Bioscience* 62(2), 160-169.
- de la Fuente Roselló, A., Perles Roselló, M. J., Cantarero Prados, F. J. 2024. A Predictive Analysis of Beach Susceptibility to Jellyfish Arrivals in Costa del Sol. *Journal of Marine Science and Engineering* 12(12), 2316.
- Doyle, T. K., Hays, G. C., Harrod, C., Houghton, J. D. 2014. Ecological and societal benefits of jellyfish. En K. Pitt, C. Lucas (Eds.), *Jellyfish blooms* (pp. 105-127). Springer.
- Edelist, D., Knutsen, Ø., Ellingsen, I., Majaneva, S., Aberle, N., Dror, H., Angel, D. L. 2022. Tracking jellyfish swarm origins using a combined oceanographic-genetic-citizen science approach. *Frontiers in Marine Science* 9, 869619.
- Elith, J., Phillips, S. J., Hastie, T., Dudík, M., Chee, Y. E., Yates, C. J. 2011. A statistical explanation of MaxEnt for ecologists. *Diversity and distributions* 17(1), 43-57.
- Enrique-Navarro, A., Huertas, I. E., León Cobo, M. J., Prieto, L. 2021. Impact of ocean warming and ocean acidification on asexual reproduction and statolith formation of the symbiotic jellyfish *Cotylorhiza tuberculata*. *PLoS ONE* 16(8), e0254983.
- Escudier, R., Clementi, E., Cipollone, A., Pistoia, J., Drudi, M., Grandi, A., Lyubartsev, V., Lecci, R., Aydogdu, A., Delrosso, D., Omar, M., Masina, S., Coppini G., Pinardi, N. 2021. A high resolution reanalysis for the Mediterranean Sea. *Frontiers in Earth Science* 9, 702285.
- Escudier, R., Clementi, E., Omar, M., Cipollone, A., Pistoia, J., Aydogdu, A., Drudi, M., Grandi, A., Lyubartsev, V., Lecci, R., Cretí, S., Masina, S., Coppini, G., Pinardi, N. 2020. *Mediterranean Sea Physical Reanalysis (CMEMS MED-Currents)* (Version 1) [Data set]. Copernicus Monitoring Environment Marine Service (CMEMS). https://doi.org/10.25423/CMCC/MEDSEA_MULTIYEAR_PHY_006_004_E3R1.

- Fabry, V. J., Seibel, B. A., Feely, R. A., Orr, J. C. 2008. Impacts of ocean acidification on marine fauna and ecosystem processes. *ICES Journal of Marine Science* 65(3), 414-432.
- Fernández-Álías, A., Marcos, C., Pérez-Ruzafa, A. 2024. The unpredictability of scyphozoan jellyfish blooms. *Frontiers in Marine Science* 11, 1349956.
- Forkman, J., Josse, J., Piepho, H. P. 2019. Hypothesis tests for principal component analysis when variables are standardized. *Journal of Agricultural, Biological and Environmental Statistics* 24, 289-308.
- Fossette, S., Gleiss, A. C., Chalumeau, J., Bastian, T., Armstrong, C. D., Vandenabeele, S., Karpytchev, M., Hays, G. C. 2015. Current-oriented swimming by jellyfish and its role in bloom maintenance. *Current Biology* 25(3), 342-347.
- García-Lafuente, J., Naranjo, C., Sammartino, S., Sánchez-Garrido, J. C., Delgado, J. 2017. The Mediterranean outflow in the Strait of Gibraltar and its connection with upstream conditions in the Alborán Sea. *Ocean Science* 13(2), 195-207.
- García-Lafuente, J., Sánchez-Garrido, J.C., Garcia, A., Hidalgo, M., Sammartino, S., Laíz, R. 2021. Biophysical processes determining the connectivity of the Alboran Sea fish populations. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli Idrissi (Eds.), *Alboran Sea-Ecosystems and Marine Resources* (pp. 459-487). Springer International Publishing.
- Gershwin, L. A., Condie, S. A., Mansbridge, J. V., Richardson, A. J. 2014. Dangerous jellyfish blooms are predictable. *Journal of the Royal Society Interface* 11(96), 20131168.
- Ghermandi, A., Galil, B., Gowdy, J., Nunes, P. A. 2015. Jellyfish outbreak impacts on recreation in the Mediterranean Sea: welfare estimates from a socioeconomic pilot survey in Israel. *Ecosystem services* 11, 140-147.
- Gissi, E., Manea, E., Mazaris, A. D., Fraschetti, S., Almpanidou, V., Bevilacqua, S., Coll, M., Guarnieri, G., Lloret-Lloret, E., Pascual, M., Petza, D., Rilov, G., Schonwald, M., Stelzenmüller, V., Katsanevakis, S. 2021. A review of the combined effects of climate change and other local human stressors on the marine environment. *Science of the Total Environment* 755(1), 142564.

- Goldstein, J., Steiner, U. K. 2020. Ecological drivers of jellyfish blooms – The complex life history of a ‘well-known’ medusa (*Aurelia aurita*). *Journal of Animal Ecology* 89(3), 910-920.
- Graham, W. M., Gelcich, S., Robinson, K. L., Duarte, C. M., Brotz, L., Purcell, J. E., Madin, L. P., Mianzan, H., Sutherland, K. R., Uye, S.-I., Pitt, K. A., Lucas, C. H., Bøgeberg, M., Brodeur, R. D., Condon, R. H. 2014. Linking human well-being and jellyfish: ecosystem services, impacts, and societal responses. *Frontiers in Ecology and the Environment* 12(9), 515-523.
- Graham, W. M., Pagès, F., Hamner, W. M. 2001. A physical context for gelatinous zooplankton aggregations: a review. *Hydrobiologia* 451(1-3), 199-212.
- Gu, L., He, X., Zhang, M., Lu, H. 2022. Advances in the technologies for marine salinity measurement. *Journal of Marine Science and Engineering* 10(12).
- Guo, D., Zhang, F., Wang, P., Sun, S. 2023. Distribution patterns of large jellyfish and their effects on the Zooplankton Community in the Northern Chinese Coastal seas during the summer of 2021. *Diversity* 15(6), 729.
- Gutiérrez-Estrada, J. C., Pulido-Calvo, I., Peregrín, A., García-Gálvez, A., Báez, J. C., Bellido, J. J., Souviron-Priego, L., Sánchez-Laulhé, J. M., López, J. A. 2021. Integrating local environmental data and information from non-driven citizen science to estimate jellyfish abundance in Costa del Sol (southern Spain). *Estuarine, Coastal and Shelf Science* 249, 107112.
- Gutiérrez-Hernández, O., Rubio Gómez, A. 2023. Jellyfish Distribution and Abundance on the Southern Coast of the Iberian Peninsula. En M. L. De Lázaro Torres, R. De Miguel González (Eds.), *Sustainable Development Goals in Europe. Key Challenges in Geography*. Springer.
- Hamel, H., Lhoumeau, S., Wahlberg, M., Javidpour, J. 2021. Using Drones to Measure Jellyfish Density in Shallow Estuaries. *Journal of Marine Science and Engineering* 9(6), 659.
- Hecq, J. H., Goffart, A., Collignon, A., Piazza, S., Defreygne, P. S., Lejeune, P. 2009. La variabilité de la méduse *Pelagia noctiluca* (Forsskål, 1775) en Baie de Calvi (Corse) en relation avec l’environnement.

- IPCC (Intergovernmental Panel on Climate Change). 2022. Summary for Policymakers. En P. R. Shukla, J. Skea, R. Slade, A. Al Khourdajie, R. van Diemen, D. McCollum, M. Pathak, S. Some, P. Vyas, R. Fradera, M. Belkacemi, A. Hasija, G. Lisboa, S. Luz, J. Malley (Eds.), *Climate Change 2022: Mitigation of Climate Change: Working Group III Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* (pp. 3-48). Cambridge University Press.
- Jaynes, E.T., 1957. Information theory and statistical mechanics. *Physical Review* 106(4), 620–630.
- Jolliffe, I. T. 2002. Choosing a subset of principal components or variables. En I. T. Jolliffe (Ed.), *Principal component analysis* (pp. 111-149). Springer.
- Klein, S. G., Pitt, K. A., Rathjen, K. A., Seymour, J. E. 2014. Irukandji jellyfish polyps exhibit tolerance to interacting climate change stressors. *Global Change Biology* 20(1), 28-37.
- Kogovšek, T., Bogunović, B., Malej, A. 2010. Recurrence of bloom-forming scyphomedusae: wavelet analysis of a 200-year time series. *Hydrobiology* 212, 81-96.
- Kroecker, K. J., Kordas, R. L., Crim, R. N., Singh, G. G. 2010. Meta-analysis reveals negative yet variable effects of ocean acidification on marine organisms. *Ecology Letters* 13(11), 1419-1434.
- Lacoue-Labarthe, T., Nunes, P. A., Ziveri, P., Cinar, M., Gazeau, F., Hall-Spencer, J. M., Hilmi, N., Moschella, P., Safa, A., Sauzade, D., Turley, C. 2016. Impacts of ocean acidification in a warming Mediterranean Sea: An overview. *Regional Studies in Marine Science* 5, 1-11.
- León-Cobo, M. J., Enrique-Navarro, A., Bartual, A., Prieto, L. 2024. Impact of warming and acidification of the Mediterranean Sea on statolith formation of the scyphozoan jellyfish *Rhizostoma pulmo* Macri (1778). *Marine Environmental Research* 202, 106788.
- Long, A. P., Bastian, T., Haberlin, D., Stokes, D., Lyashevskaya, O., Brophy, D., Lawton, C., Doyle, T. K. 2024. Regular widespread aggregations of the oceanic jellyfish


- Pelagia noctiluca* in the northeast Atlantic over 11 years. *Estuarine, Coastal and Shelf Science* 303, 108805.
- Lucas, C. H., Graham, W. M., Widmer, C. 2012. Jellyfish life histories: role of polyps in forming and maintaining scyphomedusa populations. *Advances in Marine Biology* 63, 133-196.
- Malej, A., 1989. Behaviour and trophic ecology of the jellyfish *Pelagia noctiluca* (Forsskal, 1775). *Journal of Experimental Marine Biology and Ecology* 126, 259-270.
- Marambio, M., Canepa, A., Lòpez, L., Gauci, A. A., Gueroun, S. K., Zampardi, S., Boero, S., Yahia, O. K. D., Yahia, M. N. D., Fuentes, V., Piraino, S., Deidun, A. 2021. Unfolding jellyfish bloom dynamics along the Mediterranean basin by transnational citizen science initiatives. *Diversity* 13(6), 274.
- Melo-Merino, S. M., Reyes-Bonilla, H., Lira-Noriega, A. 2020. Ecological niche models and species distribution models in marine environments: A literature review and spatial analysis of evidence. *Ecological Modelling* 415, 108837.
- Merow, C., Smith, M. J., Silander Jr, J. A. 2013. A practical guide to MaxEnt for modeling species' distributions: what it does, and why inputs and settings matter. *Ecography* 36(10), 1058-1069.
- Messié, M., Chavez, F. P. 2017. Nutrient supply, surface currents, and plankton dynamics predict zooplankton hotspots in coastal upwelling systems. *Geophysical Research Letters* 44(17), 8979-8986.
- Mghili B., A., Analla, M., Aksissou, M. 2020a. Temporal Dynamics of Jellyfish *Pelagia noctiluca* Stranded on the Mediterranean Coast of Morocco. *Turkish Journal Fisheries and Aquatic Sciences* 21(2), 87-94.
- Mghili B., A., Analla, M., Aksissou, M. 2020b. First records of the jellyfish *Physalia physalis* (Linnaeus, 1758) on the Mediterranean coast of Morocco. *Cahiers de Biologie Marine* 61, 263-269.
- Milisenda, G., Martinez-Quintana, A., Fuentes, V. L., Bosch-Belmar, M., Aglieri, G., Boero, F., Piraino, S. 2018. Reproductive and bloom patterns of *Pelagia noctiluca* in the Strait of Messina, Italy. *Estuarine, Coastal and Shelf Science* 201, 29-39.

- Molinero, J. C., Ibanez, F., Nival, P., Buecher, E., Souissi, S. 2005. North Atlantic climate and northwestern Mediterranean plankton variability. *Limnology and Oceanography* 50(4), 1213-1220.
- Nigam, T., Escudier, R., Pistoia, J., Aydogdu, A., Omar, M., Clementi, E., Cipollone, A., Drudi, M., Grandi, A., Mariani, A., Lyubartsev, V., Lecci, R., Cretí, S., Masina, S., Coppini, G., Pinardi, N. 2021. *Mediterranean Sea Physical Reanalysis INTERIM (CMEMS MED-Currents, E3R1i system)* (Versión 1) [Dataset]. Copernicus Monitoring Environment Marine Service (CMEMS). https://doi.org/10.25423/CMCC/MEDSEA_MULTIYEAR_PHY_006_004_E3R1I.
- O'Brien, R. M. 2007. A caution regarding rules of thumb for variance inflation factors. *Quality & quantity* 41, 673-690.
- Olivero, J., Toxopeus, A. G., Skidmore, A. K., Real, R. 2016. Testing the efficacy of downscaling in species distribution modelling: a comparison between MaxEnt and favourability function models. *Animal Biodiversity and Conservation* 39.1, 99-114.
- Ottmann, D., Álvarez-Berastegui, D., Prieto, L., Balbín, R., Alemany, F., Fiksen, Ø., Gordo, A., Reglero, P. 2021. Abundance of *Pelagia noctiluca* early life stages in the western Mediterranean Sea scales with surface chlorophyll. *Marine Ecology Progress Series* 658, 75-88.
- Pantiukhin, D., Verhaegen, G., Havermans, C. 2024. Pan-Arctic distribution modeling reveals climate-change-driven poleward shifts of major gelatinous zooplankton species. *Limnology and Oceanography* 69(6), 1316-1334.
- Pérez-Portela, R., Wangensteen, O. S., Garcia-Cisneros, A., Valero-Jiménez, C., Palacín, C., Turon, X. 2019. Spatio-temporal patterns of genetic variation in *Arbacia lixula*, a thermophilous sea urchin in expansion in the Mediterranean. *Heredity* 122(2), 244-259.
- Phillips, S. J., Dudík, M. 2008. Modeling of species distributions with Maxent: new extensions and a comprehensive evaluation. *Ecography* 31(2), 161-175.
- Phillips, S. J., Anderson, R. P., Schapire, R. E. 2006. Maximum entropy modeling of species geographic distributions. *Ecological modelling* 190(3-4), 231-259.

- Phillips, S. J., Anderson, R. P., Dudík, M., Schapire, R. E., Blair, M. E. 2017. Opening the black box: An open-source release of Maxent. *Ecography* 40(7), 887-893.
- Pitt, K. A., Lucas, C. H., Condon, R. H., Duarte, C. M., Stewart-Koster, B. 2018. Claims that anthropogenic stressors facilitate jellyfish blooms have been amplified beyond the available evidence: a systematic review. *Frontiers in Marine Science* 5, 451.
- Purcell, J. E. 2005. Climate effects on formation of jellyfish and ctenophore blooms: a review. *Journal of the Marine Biological Association of the United Kingdom* 85(3), 461-476
- Purcell, J. E. 2012. Jellyfish and ctenophore blooms coincide with human proliferations and environmental perturbations. *Annual review of marine science* 4(1), 209-235.
- Purcell, J. E., Uye, S-I., Lo, W. T. 2007. Anthropogenic causes of jellyfish blooms and their direct consequences for humans: a review. *Marine Ecology Progress Series* 350, 153-174.
- Record, N. R., Tupper, B., Pershing, A. J. 2018. The jelly report: Forecasting jellyfish using email and social media. *Anthropocene Coasts* 1(1), 34-43.
- Richardson, A. J., Bakun, A., Hays, G. C., Gibbons, M. J. 2009. The jellyfish joyride: Causes, consequences and management responses to a more gelatinous future. *Trends in Ecology & Evolution* 24(6), 312-322.
- Rodríguez-García, C., Sanz-Fernández, V., Muñoz-Lechuga, R., Gutiérrez-Martínez, M., Cabrera-Castro, R. 2021. First records and presence over time of the cubozoan *Carybdea marsupialis* (Linnaeus, 1758) on the southwestern Spanish coast (Northeast Atlantic). *Regional Studies in Marine Science* 44, 101712.
- Rosa, S., Pansera, M., Granata, A., Guglielmo, L. 2013. Interannual variability, growth, reproduction and feeding of *Pelagia noctiluca* (Cnidaria: Scyphozoa) in the Straits of Messina (Central Mediterranean Sea): Linkages with temperature and diet. *Journal of Marine Systems* 111, 97-107.
- Rossi, S., Gravili, C., Milisenda, G., Bosch-Belmar, M., De Vito, D., Piraino, S. 2019. Effects of global warming on reproduction and potential dispersal of Mediterranean Cnidarians. *The European Zoological Journal* 86(1), 255-271.

- Rubio-Gómez, A., Gutiérrez-Hernández, O. 2020. Impacto de las medusas en el litoral andaluz. Implicaciones para el turismo de Sol y Playa. *Estudios Geográficos* 81(288), e038-e038.
- Sanchez-Garrido, J. C., Nadal, I. 2022. The Alboran Sea circulation and its biological response: A review. *Frontiers in Marine Science* 9, 933390.
- Sánchez-Garrido, J. C., Lafuente, J. G., Fanjul, E. Á., Sotillo, M. G., de los Santos, F. J. 2013. What does cause the collapse of the Western Alboran Gyre? Results of an operational ocean model. *Progress in Oceanography* 116, 142-153.
- Sanz-Martín, M., Pitt, K. A., Condon, R. H., Lucas, C. H., Novaes de Santana, C., Duarte, C. M. 2016. Flawed citation practices facilitate the unsubstantiated perception of a global trend toward increased jellyfish blooms. *Global Ecology and Biogeography* 25(9), 1039-1049.
- Sebastiá, M. T., Estornell, J., Rodilla, M., Marti, J., Falco, S. L. 2012. Estimation of chlorophyll «A» on the Mediterranean coast using a QuickBird image. *Revista de Teledetección* 37, 23-33.
- Siapatis, A., Giannoulaki, M., Valavanis, V. D., Palialexis, A., Schismenou, E., Machias, A., Somarakis, S. 2008. Modelling potential habitat of the invasive ctenophore *Mnemiopsis leidyi* in Aegean Sea. *Essential Fish Habitat Mapping in the Mediterranean* 281-295.
- Smith, J. N., Kelly, N., Renner, I. W. 2021. Validation of presence-only models for conservation planning and the application to whales in a multiple-use marine park. *Ecological Applications* 31(1), e02214.
- Tegaccia, N. 1983. Condizioni idrologiche collegate alla presenza di *Pelagia noctiluca* in Adriatico. *Nova Thalassia* 84(6), 59-64.
- Teruzzi, A., Di Biagio, V., Feudale, L., Bolzon, G., Lazzari, P., Salon, S., Coidessa, G., Cossarini, G. 2021a. *Mediterranean Sea Biogeochemical Reanalysis (CMEMS MED-Biogeochemistry, MedBFM3 system)* (Versión 1) [Dataset]. Copernicus Monitoring Environment Marine Service (CMEMS).
- Teruzzi, A., Feudale, L., Bolzon, G., Lazzari, P., Salon, S., Di Biagio, V., Coidessa, G., Cossarini, G. 2021b. *Mediterranean Sea Biogeochemical Reanalysis INTERIM*

- (CMEMS MED-Biogeochemistry, MedBFM3i system) (Versión 1) [Dataset]. Copernicus Monitoring Environment Marine Service (CMEMS).
- Thor, P., Dupont, S. 2018. Ocean acidification. En M. Salomon, T. Markus (Eds.), *Handbook on marine environment protection: science, impacts and sustainable management* (Vol. 1 y 2, pp. 375-394). Springer.
- Tugcu, C. T. 2014. Tourism and economic growth nexus revisited: A panel causality analysis for the case of the Mediterranean Region. *Tourism Management* 42, 207-212.
- Vargas-Yáñez, M., García-Martínez, M. C., Moya, F., Balbín, R., López-Jurado, J. L. 2021. The oceanographic and climatic context. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli Idrissi (Eds.), *Alboran Sea-Ecosystems and Marine Resources* (pp. 85-109). Springer International Publishing.
- Wang, L., Kerr, L. A., Record, N. R., Bridger, E., Tupper, B., Mills, K. E., Armstrong, E. M., Pershing, A. J. 2018. Modeling marine pelagic fish species spatiotemporal distributions utilizing a maximum entropy approach. *Fisheries Oceanography* 27(6), 571-586.
- Wihsgott, J. U., Sharples, J., Hopkins, J. E., Woodward, E. M. S., Hull, T., Greenwood, N., Sivyver, D. B. 2019. Observations of vertical mixing in autumn and its effect on the autumn phytoplankton bloom. *Progress in Oceanography* 177, 102059.
- Wiley, E. O., McNyset, K. M., Peterson, A. T., Robins, C. R., Stewart, A. M. 2003. Niche modeling perspective on geographic range predictions in the marine environment using a machine-learning algorithm. *Oceanography* 16(3), 120-127.
- Winans, A. K., Purcell, J. E. 2010. Effects of pH on asexual reproduction and statolith formation of the scyphozoan, *Aurelia labiata*. *Hydrobiologia* 645, 39-52.
- Zavodnik, D. 1987. Spatial aggregations of the swarming jellyfish *Pelagia noctiluca* (Scyphozoa). *Marine Biology* 94(2), 265-269.



CAPÍTULO IV

MODELIZACIÓN DE LA ABUNDANCIA DE
MEDUSAS A CORTO PLAZO UTILIZANDO
INTELIGENCIA ARTIFICIAL EXPLICABLE
BASADA EN LÓGICA DIFUSA

Resumen

El presente capítulo explora la utilidad de la lógica difusa (FL, *Fuzzy Logic*) como herramienta de inteligencia artificial explicable para modelar la aparición de enjambres de medusas en playas de la Costa del Sol, una zona altamente turística en el sur de España. Dado el creciente impacto de estos organismos en la salud pública y la economía costera, se propone un enfoque novedoso para aprovechar datos de ciencia ciudadana recopilados por la aplicación Infomedusa, en combinación con variables meteorológicas locales, como la dirección y velocidad del viento.

Los datos sobre abundancia relativa de medusas se integraron en un sistema basado en reglas difusas (FRBS, *Fuzzy Rule-Based System*) calibrado para cinco conjuntos de playas agrupadas geográficamente. La metodología permitió generar modelos interpretable mediante reglas tipo “SI... ENTONCES...”.

Los resultados indican que los vientos perpendiculares favorecen la llegada de medusas en la zona centro-oriental, mientras que los vientos paralelos a la costa lo hacen en la zona occidental. En conjunto, los FRBS explicaron entre un 12% y un 53% de la varianza observada, destacando especialmente en el Conjunto 4 (Marbella). Esta variabilidad entre zonas subraya la influencia de la orografía costera y la dinámica oceanográfica local, vinculada a la circulación superficial del mar de Alborán.

Los resultados demuestran el potencial de los modelos FRBS como sistema de alerta temprana ante enjambres de medusas, capaz de integrar datos meteorológicos y ciudadanos en tiempo real. Si bien su capacidad predictiva aún es limitada en ciertas zonas, su valor reside en la interpretabilidad de las reglas y su aplicabilidad práctica para la gestión costera. Finalmente, se plantea que estos sistemas podrían constituir una base sólida para futuras investigaciones que incluyan nuevas variables y amplíen el análisis hacia la dimensión socioeconómica del problema.

Palabras clave: Modelo-ecosistema; Aguas costeras; Inteligencia Artificial Explicable; Sistema basado en reglas difusas; Clustering difuso; Ciencia ciudadana ambiental.

Abstract

The present chapter explores the usefulness of fuzzy logic (FL) as an explainable artificial-intelligence tool for modelling jellyfish swarms on beaches along the Costa del Sol, a highly touristic area in southern Spain. Given the growing impact of these organisms on public health and the coastal economy, a novel approach is proposed that harnesses citizen-science data collected via the Infomedusa application, in combination with local meteorological variables such as wind direction and speed.

Data on the relative abundance of jellyfish were integrated into a fuzzy rule-based system (FRBS) calibrated for five geographically grouped beach clusters. The methodology enabled the generation of interpretable models expressed through ‘IF... THEN...’ rules.

The results indicate that winds blowing perpendicularly to the shoreline favour the arrival of jellyfish in the central-eastern sector; whereas winds parallel to the coast do so in the western sector. Overall, the FRBS explained between 12 % and 53 % of the observed variance, performing particularly well in Cluster 4 (Marbella). This spatial variability underscores the influence of coastal orography and local oceanographic dynamics associated with the surface circulation of the Alboran Sea.

The findings demonstrate the potential of FRBS models as an early-warning system for jellyfish swarms, capable of integrating meteorological and citizen data in real time. Although their predictive capacity remains limited in certain areas, their value lies in the interpretability of the rules and their practical applicability for coastal management. Finally, it is suggested that these systems could provide a solid foundation for future research incorporating new variables and extending the analysis to the socio-economic dimension of the problem.

Keywords: *Model-ecosystem, Coastal Waters, Explainable Artificial Intelligence, Fuzzy Rules-Based System, Fuzzy Clustering, Environmental Citizen Science.*

4.1. Introducción

Desde mediados del siglo XX, el incremento en las poblaciones de medusas ha generado preocupación debido a los impactos negativos sobre diversas actividades humanas como la pesca (Graham *et al.*, 2003; Nagata *et al.*, 2009; Boero, 2013), la acuicultura (Delannoy *et al.*, 2011; Halsband *et al.*, 2018) y los procesos industriales costeros (Daryanabard y Dawson, 2008). Uno de los sectores más afectados en España es el turismo de sol y playa (Bernier *et al.*, 2014), especialmente en regiones como la Costa del Sol (al sur de España), donde la llegada masiva de medusas puede dañar la imagen turística y generar pérdidas económicas significativas debido tanto al rechazo visual como a las molestias por picaduras (De Donno *et al.*, 2014; Romero-Padilla *et al.*, 2020). Ante esta problemática, desarrollar estrategias basadas en el monitoreo poblacional, el análisis histórico de avistamientos (Ghermandi *et al.*, 2015), y modelos predictivos, pueden permitir acciones preventivas y mitigadoras en playas (Bellido *et al.*, 2020).

Sin embargo, las medusas han sido tradicionalmente infravaloradas en los estudios ecológicos marinos y excluidas sistemáticamente de las metodologías convencionales para el muestreo rutinario de zooplancton y prospecciones pesqueras (Pugh, 1989; Hay, 2006), lo que ha derivado en una marcada escasez de datos históricos (Brotz *et al.*, 2012). Como solución ante estas limitaciones, recientemente se ha extendido el uso de métodos participativos fundamentados en la ciencia ciudadana ambiental. Estas iniciativas aprovechan las ventajas tecnológicas de los dispositivos móviles, permitiendo a ciudadanos contribuir mediante aplicaciones y sensores integrados en sus teléfonos (Boero, 2013; García-Soto *et al.*, 2021). Gracias a esta participación ciudadana, es posible generar grandes cantidades de datos útiles para el análisis científico, reduciendo las barreras económicas, tecnológicas y espaciales características de muchos estudios tradicionales (Zamora *et al.*, 2016; Komninos, 2018).

Un ejemplo destacado de colaboración abierta no dirigida es la aplicación móvil Infomedusa, desarrollada en 2013 por la Diputación Provincial de Málaga y el Aula del Mar (ahora Fundación Aula del Mar Mediterráneo), que ha permitido evaluar la eficacia de la ciencia ciudadana ambiental aplicada al estudio de medusas (Bellido *et al.*, 2020; Gutiérrez-Estrada *et al.*, 2021). En este tipo de aplicaciones la información generada no está controlada por un programa científico estructurado enfocado en obtener conclusiones concretas. Por ello, la recopilación de datos útiles y la formulación de conclusiones requieren un preprocesamiento intensivo de la información aportada por los usuarios,

seguido de un metaanálisis caracterizado por el manejo de datos correlacionados de manera no lineal y con un alto grado de incertidumbre. Bajo estas circunstancias, las técnicas de inteligencia artificial explicable, como la lógica difusa (FL, *Fuzzy Logic*), presentan un mejor rendimiento en comparación con los resultados obtenidos mediante otros procedimientos estadísticos (Tang y Chi, 2005; Yi *et al.*, 2016; Arrieta *et al.*, 2020).

La FL formaliza matemáticamente la forma en que los seres humanos interactúan con el entorno y toman decisiones. Así, los modelos basados en FL permiten gestionar información imprecisa en términos de conjuntos difusos, lo que hace posible modelar procesos no lineales de cualquier naturaleza y aprender de los datos mediante diferentes algoritmos de aprendizaje (Martín del Brío y Sanz-Molina, 2006). Por tanto, los modelos FL resultan muy adecuados para procesar datos en un contexto de ciencia ciudadana.

En los últimos años, la aplicación de la FL en diferentes estudios del ámbito marino ha aumentado su frecuencia, abordando de manera eficaz la complejidad e incertidumbre inherentes a diversos contextos recurso-ambiente. Por ejemplo, Do *et al.* (2024) implementaron técnicas de modelado basado en reglas difusas para predecir y mapear la salinidad en un estuario vietnamita, evidenciando la mejora en la precisión cuando combinaban teledetección y algoritmos de *machine learning*. Gutiérrez-Estrada *et al.* (2012) evaluaron diversos enfoques lineales y no lineales como regresiones múltiples, modelos aditivos generalizados, redes neuronales y controladores basados en FL para la gestión de caudales de agua en un cultivo semi-intensivo de dorada (*Sparus aurata*) en un estuario, encontrando que tanto los modelos basados en FL como las redes neuronales artificiales alcanzaban los mejores niveles de correlación al simular el intercambio hídrico.

En el ámbito acuícola, Nagothu *et al.* (2025) presentaron un novedoso sistema de monitoreo de calidad del agua, respaldado por FL, que ajustaba de forma autónoma aeradores y bombas al detectar variaciones dinámicas de temperatura, pH y oxígeno disuelto, logrando así un mantenimiento más estable de las condiciones óptimas, con una exactitud del modelo difuso superior al 95%. Asimismo, Gutiérrez-Estrada *et al.* (2005) desarrollaron el sistema experto SEDPA, que integra un controlador difuso y la teoría Dempster-Shafer para diagnosticar enfermedades en la cría de anguilas. En pruebas comparativas, el rendimiento diagnóstico del sistema resultó estadísticamente similar al de patólogos humanos, demostrando su potencial para automatizar procesos críticos de toma de decisiones. Por su parte, Xiong *et al.* (2024) desarrollaron un marco integrado de aprendizaje automático y FL para evaluar riesgos químicos en peces. Su modelo estimó

concentraciones de contaminantes orgánicos y, posteriormente, aplicó inferencias difusas para determinar la exposición humana bajo distintos escenarios de cocinado.

Desde la perspectiva de la conservación y cambio climático, Jones y Cheung (2018) aplicaron un enfoque de FL para sintetizar datos de sensibilidad, capacidad adaptativa y exposición a peligros climáticos en más de un millar de especies marinas explotadas, ofreciendo un índice de vulnerabilidad y riesgo de impacto. En un enfoque orientado a la planificación y gestión costera, Hattab *et al.* (2013) demostraron la pertinencia de integrar presencia o ausencia de especies comerciales modeladas con pseudo-ausencias y *kriging* de regresión, empleando luego FL para identificar zonas prioritarias de conservación y detectar la incertidumbre inherente a distintos modelos predictivos. Finalmente, relacionado con estudios que involucran a las medusas, Brotz *et al.* (2012) emplearon la FL para analizar tendencias en las poblaciones de medusas a nivel global combinando información de múltiples fuentes mediante esta aproximación para evaluar tendencias temporales a escala de grandes ecosistemas marinos. Estos autores detectaron incrementos en la abundancia de medusas en la mayoría de las regiones analizadas (28 de 45, equivalentes al 62%). Todos estos ejemplos evidencian la versatilidad de la FL al incorporar de forma explícita la incertidumbre medioambiental, proporcionando a la vez un formato interpretativo (basado en reglas lingüísticas) valioso para la toma de decisiones en un amplio espectro de aplicaciones, desde la gestión de pesquerías hasta la protección de la biodiversidad.

Los fundamentos de la metodología propuesta utilizada en este capítulo (Aroba, 2003) han demostrado su eficacia a la hora de modelar el comportamiento cualitativo de sistemas complejos en diversos ámbitos, como el medioambiental (Fernández-Camacho *et al.*, 2015), el bioquímico (Luis *et al.*, 2018) o el médico (Enríquez *et al.*, 2018), donde los resultados obtenidos fueron validados por expertos de cada disciplina, confirmando la veracidad y el valor de la información cualitativa generada.

En este sentido, el presente capítulo propone una metodología basada en un enfoque de lógica difusa para caracterizar el efecto de las condiciones ambientales locales en la incidencia de medusas en las playas de la Costa del Sol, situado en la región costera andaluza (sur de España). Así, el principal objetivo de este capítulo consiste en evaluar el rendimiento de un modelo de lógica difusa para estimar la incidencia de medusas en función de la velocidad y dirección del viento, comparándolo con Modelos Aditivos Generalizados y valorando su interpretabilidad en contextos de ciencia ciudadana.

4.2. Material y métodos

4.2.1. Área de estudio

La zona de abarcada por este estudio es la Costa del Sol, que se localiza en la provincia de Málaga (región de Andalucía, en el sureste de España). La Costa del Sol se extiende desde La Línea de la Concepción, en el límite con la provincia de Cádiz al oeste, hasta los acantilados de Maro-Cerro Gordo, en el límite con la provincia de Granada al este, a lo largo de aproximadamente 185 km (Figura IV-1). La Costa del Sol se compone de tres áreas diferenciadas: (1) la Costa del Sol Occidental, especializada en turismo internacional; (2) la Costa del Sol Oriental, orientada hacia el turismo residencial y de interior; y (3) la zona de Málaga capital, con funciones administrativas y comerciales (García y Ocaña, 1982).

Las aguas del mar de Alborán bañan la línea costera del área de estudio, donde la circulación superficial se caracteriza por la presencia de dos giros anticiclónicos de tamaño medio (el Giro Anticiclónico Occidental y el Giro Anticiclónico Oriental), que rodean el flujo meandriforme de agua superficial atlántica, también llamado “*Atlantic Jet*”. Ambos giros anticiclónicos están separados por una estructura ciclónica de existencia más elusiva, conocida como Giro Ciclónico Central (Peliz *et al.*, 2013; Macías *et al.*, 2016; García-Lafuente *et al.*, 2021).

En este trabajo se analizaron un total de 149 playas pertenecientes a 14 localidades diferentes, desde la playa Ancha de Casares en el oeste hasta la playa de Las Alberquillas en el este (Figura IV-1). La agrupación de las playas se basó en la proximidad de cada una a la estación meteorológica más cercana. Esto facilitó el análisis de las playas de acuerdo con su ubicación geográfica, empleando así datos meteorológicos locales lo más representativos posibles.




Figura IV-1. Ubicación de las principales ciudades que agrupan los conjuntos de playas. Los colores de los marcadores reflejan la pertenencia a cada conjunto de playas: Conjunto 1 (azul), playas de la ciudad de Málaga; Conjunto 2 (gris), playas de Nerja a Rincón de la Victoria; Conjunto 3 (verde), playas de Torremolinos a Fuengirola; Conjunto 4 (rojo), playas de Marbella; Conjunto 5 (amarillo), playas de Manilva a Estepona. Asimismo, se muestran los límites de la Costa del Sol al oeste (La Línea de la Concepción) y al este (Maro-Cerro Gordo). Las líneas punteadas en azul, rojo y verde representan respectivamente la Costa del Sol Occidental, la Costa del Sol Oriental y la zona de la capital.

4.2.2. Datos de abundancia relativa de medusas

La abundancia relativa de medusas se obtuvo de la aplicación Infomedusa. Infomedusa es una app de ciencia ciudadana, disponible para teléfonos móviles inteligentes con sistema operativo iOS o Android, y desarrollada por la institución Aula del Mar de Málaga (ahora Fundación Aula del Mar Mediterráneo). Mediante dicha aplicación, los usuarios pueden consultar en tiempo real variables climáticas y oceanográficas de las playas que visitan. La aplicación ofrece una funcionalidad que permite a los ciudadanos interactuar en un foro específico para cada playa, donde discuten acerca de las condiciones climáticas y la presencia o ausencia de medusas. De esta forma,

se genera una base de datos a partir de los comentarios de los usuarios. Durante 2018 (desde el 25 de enero hasta el 3 de octubre), se registraron 40.276 comentarios, de los cuales 9.963 fueron validados y seleccionados para la presente investigación.

Puesto que los comentarios de los usuarios se expresan en lenguaje natural, se diseñó una red de transición aumentada (ATN, *Augmented Transition Network*) para su procesamiento. Este tipo de redes se ha utilizado ampliamente en diversos campos de conocimiento (Woods, 1973; De Carolis *et al.*, 1996; Gangopadhyay, 2001; Gutiérrez-Estrada *et al.*, 2005). Las ATN se basan en una estructura de datos compuesta por un conjunto de nodos (estados finitos) conectados entre sí mediante arcos. El modelo consiste en una transición de estados regida por la categoría gramatical de cada palabra leída (Woods, 1973). En el caso de este estudio la red consta de ocho nodos que consisten en las siguiente categorías gramaticales: (1) Nombre, (2) Adverbio de cantidad, (3) Adverbio de locución, (4) Adverbio de negación, (5) Verbo principal, (6) Verbo “haber”, (7) Verbo auxiliar y (8) Reflexivo, relacionados a través de veinte subredes. Cada uno de estos nodos se asocia con un conjunto de términos que forman un diccionario vinculado a la detección de medusas. En total, se incluyeron 557 conjuntos, de los cuales 322 se engloban en la etiqueta “Adverbio de cantidad”, la cual se dividió a su vez en cinco categorías: “Ninguna”, “Pocas”, “Algunas”, “Muchas” y “Muchísimas”. Gracias a esta clasificación, la red puede discriminar de manera automática qué cantidad de medusas se describe en cada comentario.

Para establecer una escala de abundancia relativa, se asignaron valores discretos a las categorías: “Ninguna” = 0, “Pocas” = 1, “Algunas” = 2, “Muchas” = 3 y “Muchísimas” = 4. Antes de procesar la información con la ATN, dos investigadores revisaron cada mensaje de manera independiente y clasificaron la presencia o ausencia de medusas (0 para “sin información de medusas” y 1 para “con información de medusas”), así como el correspondiente adverbio de cantidad. Una vez validados, los mensajes fueron analizados de forma automatizada mediante la ATN, extrayendo de cada texto la información sobre abundancia relativa de medusas (Gutiérrez-Estrada *et al.*, 2021). Este procedimiento facilita una lectura estructurada de la información en lenguaje natural, maximizando la homogeneidad y confiabilidad de los datos para su posterior uso en los modelos de predicción.

4.2.3. Datos ambientales

Dado el carácter planctónico de las medusas, las condiciones climáticas pueden propiciar grandes acumulaciones de estos organismos a lo largo del litoral. Dos de los factores principales que influyen en la llegada de medusas a la costa son la dirección y la velocidad de los vientos locales predominantes, que generan la migración de las masas de agua superficial hacia la orilla (Graham *et al.*, 2001; Bellido *et al.*, 2020; García-Lafuente *et al.*, 2021; Gutiérrez-Estrada *et al.*, 2021). En el área de estudio, los vientos muestran un comportamiento estacional: durante invierno-primavera suelen presentar componente noroeste, mientras que en verano predomina la componente sureste (Mercado *et al.*, 2012).

Los datos de velocidad y dirección del viento se obtuvieron de la Agencia Estatal de Meteorología (AEMET, <http://www.aemet.es/en/portada>). Para hacer frente a las diferencias en la morfología y orientación de la costa, se emplearon cinco grupos de playas y cuatro estaciones meteorológicas (Tabla IV-1).

Tabla IV-1. Descripción de las estaciones meteorológicas de las que se obtuvieron los datos ambientales utilizados en este capítulo y los conjuntos de playas y municipios cubiertos por cada estación.

Estación meteorológica	Localización	Altitud (m)	Conjunto de playas	Municipios asociados
Málaga	36° 39' N, 4° 28' O	5	1, 2	Nerja, Torrox, Algarrobo, Vélez-Málaga, Rincón de la Victoria, Málaga
Fuengirola	36° 32' N, 4° 37' O	8	3	Torremolinos, Benalmádena, Mijas, Fuengirola
Marbella	36° 29' N, 4° 44' O	2	4	Marbella
Manilva	36° 22' N, 5° 15' O	140	5	Estepona, Casares, Manilva

Estas estaciones registran cada hora los datos de temperatura (promedio, máxima y mínima, en °C), viento (racha, velocidad media y máxima, y dirección, en km/h), presión atmosférica (hPa), precipitaciones (mm) y humedad (%). Para el presente estudio, únicamente se utilizaron la velocidad y dirección medias del viento. Cada variable se promedió de manera diaria.

4.2.4. Análisis estadísticos

4.2.4.1. Inteligencia Artificial Explicable

La denominada Inteligencia Artificial Explicable (XAI, *eXplanaible Artificial Intelligence*) surge como respuesta a la necesidad de dotar de transparencia y comprensibilidad a modelos predictivos y de toma de decisión que, en muchos casos, se comportan como cajas negras (Gunning *et al.*, 2019; Barredo Arrieta *et al.*, 2020). El auge de algoritmos cada vez más complejos (como las redes neuronales artificiales, vistas en el Capítulo II) ha impulsado la obtención de resultados muy eficientes en tareas de clasificación, regresión o reconocimiento de patrones, pero a costa de sacrificar la claridad sobre cómo estos modelos llegan a sus conclusiones. En entornos donde el factor humano resulta esencial (por ejemplo, para la toma de decisiones en gestión costera), la obtención de altas tasas de acierto puede ser insuficiente si no se comprende el proceso de razonamiento interno del modelo.

Frente a esta problemática, la XAI propone metodologías, técnicas y herramientas que hacen posible interpretar, explicar y, en última instancia, confiar en los resultados de la Inteligencia Artificial. Así, el objetivo principal de la XAI radica en obtener, o en reconstruir a partir de un modelo complejo, una explicación transparente y cercana al lenguaje humano. A efectos prácticos, la XAI permite la generación de modelos intrínsecamente explicables que consisten en enfoques que parten de algoritmos cuyo funcionamiento resulta interpretable. Determinadas técnicas de XAI buscan extraer o sintetizar el conocimiento contenido en los pesos y parámetros de un modelo difícil de explicar, traducéndolo a un conjunto de prototipos, reglas lógicas o representaciones gráficas que resulten más familiares para el ser humano (Adadi y Berrada, 2018).

La interpretabilidad del modelo no sólo atiende a la necesidad de comprender los resultados ante usuarios finales (como personal sanitario o responsables de la gestión costera), sino que también es relevante para otros actores, como la administración pública, que deben cerciorarse de que ciertos patrones decisorios no incurran en sesgos o vulneren normativas éticas y legales (Doshi-Velez y Kim, 2017). Asimismo, la XAI contribuye a la robustez de los sistemas, ya que la posibilidad de auditar y verificar el razonamiento del modelo brinda mayor confianza al detectar inconsistencias y puntos débiles.

En este contexto, la lógica difusa ocupa un lugar destacado como técnica de XAI, dado que sus fundamentos están anclados en la representación lingüística de conceptos y en la gradación de la pertenencia. Esto facilita la generación de reglas difusas (del tipo “SI... ENTONCES...”) capaces de describir fenómenos continuos y ambiguos de una forma muy próxima a la forma humana de razonar (Takagi y Sugeno, 1985; Bouchon-Meunier *et al.*, 2022). El grado de pertenencia, comprendido entre 0 y 1, permite hablar de “ligeramente elevado” o “muy bajo” sin necesidad de imponer fronteras discretas, lo que se traduce en un discurso más natural y gradual. Todo ello redundando en una interpretación más intuitiva para especialistas de distintas áreas, incluso sin formación matemática o computacional avanzada. De esta manera, incorporar la lógica difusa dentro de un marco de XAI significa unir la expresividad y la flexibilidad propias de los conjuntos difusos con la necesidad de transparencia en la toma de decisiones (Alonso Moral *et al.*, 2021).

4.2.4.2. *Lógica difusa (Fuzzy logic)*

La lógica difusa (FL, *Fuzzy Logic*) surgió a mediados de la década de 1960 cuando Lotfi A. Zadeh propuso la teoría de los conjuntos difusos (Zadeh, 1965). En aquel momento, se planteó una alternativa a la lógica clásica (o booleana), en la que la pertenencia a un conjunto se consideraba de forma binaria (0 o 1). Zadeh argumentó que muchos conceptos del mundo real no pueden describirse con exactitud en términos de verdadero o falso, sino que presentan zonas grises en las que un elemento puede pertenecer a un conjunto con un grado intermedio. Este reconocimiento de la gradación en la pertenencia permitió definir una nueva forma de representar la información, introduciendo funciones de pertenencia que asignan a cada elemento un valor entre 0 y 1 (Klir y Yuan, 1995).

El concepto de “difuso” alude a la imposibilidad de establecer límites nítidos entre las categorías que describen la realidad. De esta manera, la lógica difusa aporta un valor práctico al capturar la ambigüedad y la subjetividad inherentes a muchos fenómenos, permitiendo elaborar modelos de razonamiento más cercanos al modo en que las personas interpretan el entorno. En el Capítulo II se compararon las redes neuronales con el “*hardware*” biológico del cerebro, enfatizando cómo aprenden a partir de ejemplos y ajustan sus parámetros para reconocer patrones complejos. En este caso, los sistemas basados en lógica difusa se inspiran más directamente en la forma en que el cerebro razona ante información ambigua (Martín del Brío y Sanz-Molina, 2006).

Imaginemos que medimos la cantidad de medusas avistadas diariamente en la zona costera de un municipio turístico durante la temporada estival. El rango de la variable “abundancia de medusas” podría oscilar entre 0 (ninguna medusa en el día) hasta 500 (en casos de floraciones masivas). En un enfoque clásico, definiríamos umbrales fijos para categorizar el número de medusas, por ejemplo: Escaso (0-50 medusas), Moderado (51-200 medusas), y Abundante (más de 200 medusas). Si se utiliza la lógica clásica, la transición entre conjuntos debe establecerse en un punto determinado. Sin embargo, la realidad puede ser menos nítida, de manera que 50 o 60 medusas en un día no se perciban de manera totalmente distinta, o 170 y 210 individuos pueden suponer un impacto semejante. Por ello, con la lógica difusa se admite que, alrededor de ciertos rangos, exista un grado de pertenencia paulatino a uno u otro conjunto (Martín del Brío y Sanz-Molina, 2006), definiendo funciones de pertenencia graduales para cada categoría.

En la teoría de conjuntos difusos, cada elemento x de un dominio X posee un grado de pertenencia $\mu_A(x)$ asociado a un conjunto difuso $A \in X$ (Figura IV-2). Dicho grado $\mu_A(x)$ varía en el intervalo $[0, 1]$. Cuanto más próximo a 1, mayor es la “afinidad” o “adecuación” de ese elemento a las características representadas por el conjunto A (Ross, 2005). Siguiendo el ejemplo anterior, supongamos que hemos definido tres conjuntos difusos (Escaso, Moderado y Abundante) para la variable “Abundancia de medusas” mediante las funciones trapezoidales de la Figura IV-2 siguiendo el siguiente esquema:

- Escaso se mantiene con pertenencia 1 hasta alrededor de 30 medusas y luego desciende linealmente a 0 hasta las 50.
- Moderado se activa gradualmente a partir de unas 30 medusas, permanece en 1 entre 50 y 150, y luego vuelve a bajar hasta 0 hacia las 180.
- Abundante comienza a ascender de 0 a 1 en torno a 150 medusas, alcanzando 1 a partir de 200 en adelante.




Figura IV-2. Funciones de pertenencia para los conjuntos difusos “Escaso” (línea verde), “Moderado” (línea azul) y “Abundante” (línea roja) en función del número diario de medusas (eje X). El eje Y representa el grado de pertenencia.

De esta forma, en un día en el que se avistan 40 medusas, la pertenencia tanto a “Escaso” como a “Moderado” resulta aproximadamente de 0,5, y la de “Abundante” permanece en 0, reflejando la transición entre considerar una abundancia de avistamientos entre escasa y moderada. Si en otro día se registran 80 medusas, la pertenencia a

“Moderado” pasa a ser 1, mientras que para “Escaso” y “Abundante” se sitúa en 0, lo que indica un dominio de la categoría “Moderado”. Por último, ante 200 medusas avistadas, “Abundante” adopta el valor 1, mientras que “Escaso” y “Moderado” dejan de tener relevancia (pertenencia 0), evidenciando un escenario en el que las medusas son claramente abundantes.

En un planteamiento clásico, el sistema asignaría a cada día una etiqueta de forma rígida, por ejemplo “Abundante” (pertenencia = 1) o “No abundante” (pertenencia = 0), sin dejar margen para valores intermedios. De esta manera, un día con 79 medusas podría clasificarse estrictamente como “Moderado”, mientras que con 81 medusas pasaría a “Abundante”. La lógica difusa reconoce grados de pertenencia, reflejando de manera más fiel la continuidad de los fenómenos biológicos. De este modo, pasar de 79 a 81 medusas avistadas no implica un salto brusco de una categoría a otra, sino un leve cambio en la intensidad con la que se considera “Abundante”.

Para especificar estas funciones de pertenencia, se emplean expresiones matemáticas tales como modelos triangulares, trapezoidales, o sigmoides, entre otros (Martín del Brío y Sanz-Molina, 2006). La elección del tipo de función depende del problema a modelar, del conocimiento experto disponible y de las características de la base de datos.

Una de las ventajas más significativas de la lógica difusa reside en el uso de variables lingüísticas. En lugar de asignar un valor numérico exacto, dichas variables se describen mediante términos lingüísticos, acompañados de sus correspondientes funciones de pertenencia difusa (Zadeh, 1975). Esta representatividad lingüística favorece la interpretabilidad del sistema, que puede expresar el comportamiento de un fenómeno con oraciones cercanas al lenguaje natural.

La estructura típica de un sistema basado en reglas difusas (FRBS, *Fuzzy Rule-Based System*) consta de diferentes elementos. En primer lugar, el borrosificador realiza una conversión de los valores de entrada (datos numéricos) a términos borrosos. El término de borrosificación más utilizado es el de tipo singleton, que utiliza los propios valores discretos como conjuntos borrosos. Así, para cada valor de entrada x se define un conjunto A' que lo soporta, con función de pertenencia $\mu_A(x')$. La salida de este borrosificador es utilizada por el dispositivo de inferencia borrosa para aplicarla a cada una de las reglas de la base de reglas difusas. Las reglas borrosas combinan uno o más

conjuntos de entrada, denominados antecedentes, y lo asocian a un conjunto borroso de salida, llamado consecuente. Estas reglas contienen enunciados del tipo SI-ENTONCES (Figura IV-3). Así, la regla difusa mostrada en la Figura IV-3 podría interpretarse en lenguaje natural como:

SI A es “pequeño” o “grande” **Y** B es “medio”, **ENTONCES** C es “muy pequeño”.




Figura IV-3. Ejemplo de regla difusa gráfica IF-THEN (SI-Entonces).

La salida del borrosificador es utilizada por el dispositivo de inferencia borrosa para aplicarla a cada una de las reglas del FRBS según el método de inferencia establecido, que aplica estas reglas a los valores difusos de entrada, combinándolos según operadores lógicos difusos para generar una salida difusa (Martín del Brío y Sanz-Molina, 2006). Finalmente, la salida difusa se convierte en un valor numérico concreto desborrosificado.

4.2.4.3. Metodología propuesta de un sistema basado en reglas difusas

En el presente capítulo se pretende construir un sistema basado en reglas difusas capaz de representar de forma interpretable el comportamiento de un conjunto de datos de avistamientos de medusas.

Para la creación de este sistema, en primer lugar se seleccionan las variables de estudio, determinando aquellas variables del conjunto de datos cuyo comportamiento se considera relevante. Dichas variables pueden actuar como consecuentes en las reglas difusas (salidas del sistema), mientras que el resto se emplea como antecedentes

(entradas). En nuestro caso, se tomaron las variables de dirección y velocidad del viento como antecedentes, y la cantidad relativa de medusas avistadas como consecuente.

El enfoque basado en lógica difusa propuesto en este capítulo sigue la metodología descrita por Aroba (2003) basado en Sugeno y Yasukawa (1993) para construir modelos difusos basados en el algoritmo *fuzzy C-Means* (Bezdek, 1981; Höppner y Klawonn, 2003) con el fin de generar reglas difusas del tipo: SI $x \in A$ ENTONCES $y \in B$, donde $x = (x_1, x_2, \dots, x_n) \in \mathfrak{R}^n$ son variables de entrada (antecedentes), A representa n conjuntos difusos, $y \in \mathfrak{R}$ es la variable de salida (consecuente), y B el conjunto difuso asociado a esta variable.

Posteriormente, la metodología propuesta analiza automáticamente el conjunto, de modo que las variables consecuentes se *clusterizan* de forma difusa en un número óptimo de conjuntos o “*clusters*” (Fukuyama y Sugeno, 1989). Una vez identificados los *clusters* en las variables consecuentes, cada uno de ellos se proyecta sobre el espacio de los antecedentes (Sugeno y Yasukawa, 1993), obteniendo el grado de pertenencia de los antecedentes a cada conjunto difuso. Dicho análisis posibilita la construcción de reglas de la forma que se representó en la Figura IV-3.

4.2.4.4. Validación del FRBS mediante comparación con modelos GAM

Para validar los resultados obtenidos con los sistemas basados en lógica difusa (FRBS, *Fuzzy Rule-Based System*), se utilizaron los resultados obtenidos por Gutiérrez-Estrada *et al.* (2021), quien utilizó Modelos Aditivos Generalizados (GAMs, *Generalized Additive Models*) para modelar los mismos datos analizados en este capítulo.

Los GAM permiten modelar la relación entre una variable de respuesta y diversas covariables a través de funciones de suavizado. Cada covariable está asociada a una función $f_j(\cdot)$ que no se restringe a ser lineal, sino que puede adoptar la forma que mejor se ajuste a los datos. Así, un GAM suele expresarse según la Ecuación IV-1:

$$g(\mu_i) = \beta_0 + f_1(x_{i1}) + f_2(x_{i2}) + \dots + f_p(x_{ip}), \quad (\text{Ec. IV-1})$$

donde μ_i es la media (o el valor esperado) de la respuesta para la observación i , $g(\cdot)$ es la denominada función de enlace, β_0 es un intercepto global y $f_j(\cdot)$ representan funciones que se construyen, en la mayoría de los casos, a partir de técnicas de suavizado similares

(Wood, 2017). Este carácter “aditivo” le confiere gran flexibilidad al modelo, ya que cada covariable puede presentar patrones no lineales, puntos de quiebre o cambios de tendencia sin que se penalice la interpretabilidad global.

La elección de la distribución (o familia) y la función enlace de un GAM depende del tipo de variable que se desea modelar:

- Distribución Normal (o Gaussiana), con enlace identidad, si la respuesta se comporta de manera aproximadamente continua y simétrica.
- Distribuciones de conteo (Poisson o binomial negativa) con enlace *log*, cuando la variable consiste en números enteros de individuos.
- Distribución Gamma con enlace *log*, en situaciones donde la respuesta es positiva y su variabilidad crece con la media.

El proceso de ajuste de un GAM consiste primero en seleccionar la familia de la distribución y la función enlace que mejor describan la naturaleza de la respuesta. Posteriormente, se aproxima cada $f_j(\cdot)$ mediante *splines* que capturan cambios de forma local en la curva. Por último, se toman medidas para evitar sobreajuste regulando la flexibilidad del *spline* o usando criterios de penalización que buscan un equilibrio entre la fidelidad a los datos y la suavidad de la curva (Wood, 2017).

Uno de los atributos más importantes de los GAMs es la visualización de los efectos parciales de cada variable. Esto se lleva a cabo a través de gráficos que muestran cómo evoluciona la respuesta media μ_i ante distintos valores de un factor explicativo, manteniendo las demás variables en su promedio (Zuur *et al.*, 2009).

Para la validación de los FRBS generados, se compararon los resultados obtenidos con los GAM generados por Gutiérrez-Estrada *et al.* (2021). Concretamente, se determinaron “puntos calientes” extraídos de los propios GAMs, es decir, valores críticos en las variables de entrada identificados a partir de los efectos parciales de estos modelos aditivos (Gutiérrez-Estrada *et al.*, 2021). A continuación se presentan los pasos seguidos para la realización de la comparativa:

1. Se fijaron dichos valores de entrada (puntos calientes) y se introdujeron en el FRBS, que ofrece una predicción difusa de la abundancia de medusas.

2. Se comparó la salida numérica del FRBS con la estimación de la curva suavizada en el GAM para esos mismos escenarios.
3. Se analizaron coincidencias y discrepancias, valorando en qué punto el método difuso coincide con el GAM, así como la existencia de zonas donde uno de los modelos capture algún comportamiento que el otro no reflejó con claridad.

Esta aproximación contribuye a reforzar la confianza en los resultados. Si ambos modelos coinciden en los valores clave, se añade certeza de que el fenómeno se está capturando de manera consistente. En caso de discrepancias, dichas divergencias pueden revelar aspectos que estén siendo capturados por un modelo y omitidos por el otro, motivando nuevas reflexiones o estudios adicionales.

Para contrastar la fiabilidad del FRBS frente a las observaciones empíricas de medusas, se tomaron los valores diarios de velocidad y dirección del viento procedentes de la misma base de datos y se introdujeron en el FRBS para obtener una “cantidad esperada” de medusas en cada día. De este modo, se comparó la salida del modelo con la cantidad real de medusas registrada, realizando para cada zona costera una regresión lineal entre la cantidad predicha por los FRBS y la observada en la matriz de datos original. El coeficiente de determinación (R^2) resultante permitió cuantificar qué proporción de la variabilidad observada se explicaba por el modelo difuso. Estos coeficientes de determinación fueron comparados con la devianza explicada obtenida por los modelos GAM de Gutiérrez-Estrada *et al.* (2021).

4.3. Resultados

Con objeto de comprender mejor las reglas difusas obtenidas en cada zona analizada del sistema basado en reglas difusas (FRBS, *Fuzzy Rule-Based System*), se exportaron los resultados al formato de la *Fuzzy Logic Toolbox* de Matlab (MathWorks®), lo que permitió representar las reglas en formato de superficies 3D y favorecer su lectura e interpretación en lenguaje natural.

4.3.1. Conjunto 1 de playas

Para el Conjunto 1 (playas de la ciudad de Málaga), se generó un FRBS de 7 reglas difusas. La Figura IV-4 muestra la representación en 3D de dichas reglas, donde la abundancia relativa de medusas actúa como consecuente. El modelo señala la mayor incidencia de medusas cuando la dirección del viento se sitúa en torno a 225° y la velocidad es de 10,5 km/h. Se observa una incidencia nula de medusas con direcciones de viento en 135° y el intervalo 230°-250°.




Figura IV-4. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 1 de playas, correspondiente a las playas de la ciudad de Málaga.

Para evaluar el ajuste entre los valores de abundancia de medusas estimados por el FRBS y las abundancias observadas contenidas en la base de datos original, se realizó una regresión lineal entre ambas (Figura IV-5). Los resultados indicaron una varianza explicada por el FRBS relativamente baja con un $R^2=0,20$ ($p<0,05$).




Figura IV-5. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 1 de playas.

Adicionalmente, los efectos suavizados de los GAM de Gutiérrez-Estrada *et al.* (2021) (Figura IV-6) mostraron que la dirección y la velocidad del viento presentaban cambios significativos en sus residuos parciales, permitiendo ubicar puntos calientes que describen incrementos o descensos marcados de abundancia relativa de medusas. Así, a partir de la inspección de dichas curvas, se establecieron valores críticos en las direcciones del viento a 180, 210 y 250°, y a velocidades del viento de 10,5, 14, y 19 km/h.






Figura IV-6. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada et al. (2021) correspondientes al Conjunto 1 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la presencia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h). Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).

En la Tabla IV-2 se muestran los resultados del FRBS al fijar las variables de entrada en los puntos calientes establecidos. De acuerdo con el FRBS, la disminución en la incidencia de medusas está asociada a valores de dirección y velocidad del viento cercanos a 250° o 10 km/h, respectivamente. Sin embargo, el nivel de varianza explicada por el enfoque difuso es menor que el alcanzado por los GAM calibrados por Gutiérrez-Estrada et al. (2021) (GAM $R^2=0,77$; FRBS_{presencia} $R^2=0,20$; $p<0,05$).

Tabla IV-2. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 1 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada et al. (2021) como valores de entrada para las variables de dirección y velocidad del viento.

Puntos calientes de dirección del viento (°)			
Puntos calientes de velocidad del viento (km/h)	180	210	250
10,5			
14,0			
19,0			

4.3.2. Conjunto 2 de playas

En el Conjunto 2 (playas comprendidas entre Nerja y Rincón de la Victoria), la metodología basada en lógica difusa generó un total de 6 reglas. La Figura IV-7 muestra los resultados en 3D, que evidencian una presencia relativamente baja de medusas durante todo el período de estudio, aunque el mayor número se concentra en vientos procedentes del sur (180° - 200°). Las medusas solo aparecen con velocidades de viento entre 9 y 21 km/h.




Figura IV-7. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 2 de playas, correspondiente a las playas comprendidas entre Nerja y Rincón de la Victoria.

Para evaluar el ajuste de estas predicciones, se realizó una regresión lineal entre la abundancia estimada por el modelo difuso y la observada en la base de datos (Figura IV-8). La regresión lineal obtuvo un $R^2=0,24$ ($p<0,05$).




Figura IV-8. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 2 de playas.

Mediante la observación de los efectos suavizados de los GAM generados por Gutiérrez-Estrada *et al.* (2021) (Figura IV-9) se establecieron puntos calientes en las direcciones del viento a 175, 215 y 260°, y a velocidades del viento de 10, 13, y 18 km/h.




Figura IV-9. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada *et al.* (2021) correspondientes al Conjunto 2 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la abundancia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h). Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).

Estos valores fueron fijados en los modelos difusos y se observó la respuesta del sistema. Coincidiendo con Gutiérrez-Estrada *et al.* (2021), la dirección de viento por encima de aproximadamente 230° conduce a una reducción en la abundancia de medusas (Tabla IV-3). De nuevo, los GAM para este Conjunto 2 ofrecen mejores ajustes que los FRBS (GAM $R^2=0,75$; FRBS_{presencia} $R^2=0,24$, $p<0,05$).

Tabla IV-3. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 2 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada *et al.* (2021) como valores de entrada para las variables de dirección y velocidad del viento.

Puntos calientes de dirección del viento (°)			
Puntos calientes de velocidad del viento (km/h)	175	215	260
10,0			
13,0			
18,0			

4.3.3. Conjunto 3 de playas

Para el Conjunto 3 (playas de Torremolinos-Fuengirola), se generó un sistema de 4 reglas difusas. La Figura IV-10 ilustra la superficie 3D de las reglas encontradas. Las variables ambientales se mantuvieron relativamente constantes durante todo el período analizado, dificultando la evaluación de su efecto en la abundancia de medusas. Además, la velocidad del viento no superó los 10 km/h, a diferencia de las zonas anteriores, lo que impide interpretar con precisión el papel de esta variable.




Figura IV-10. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 3 de playas, correspondiente a las playas comprendidas entre Torremolinos y Fuengirola.

La regresión lineal simple entre la abundancia estimada por el modelo difuso y la observada en la base de datos (Figura IV-11) mostró un ajuste relativamente bajo con un $R^2=0,12$ ($p<0,05$).




Figura IV-11. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 3 de playas.

Los efectos parciales de los GAM generados por Gutiérrez-Estrada *et al.* (2021) (Figura IV-12) permitieron establecer puntos calientes en los que la abundancia relativa de medusas variaba en las direcciones del viento de 170, 210 y 225°, y a velocidades del viento de 5; 5,5; 6; 6,5; 7 y 7,5 km/h.




Figura IV-12. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada *et al.* (2021) correspondientes al Conjunto 3 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la abundancia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h). Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).

La respuesta del FRBS al fijar estos valores en el sistema son mostrados en la Tabla IV-4. Al igual que en los GAM generados por Gutiérrez-Estrada *et al.* (2021), el modelo difuso sugiere que la incidencia de medusas empieza a decrecer cuando la dirección del viento supera los 225°. En este caso, tanto los GAM como los FRBS presentaron la menor capacidad de ajuste, reflejada en un bajo nivel de varianza explicada (GAM $R^2=0,37$; FRBS_{presencia} $R^2=0,12$, $p<0,05$).

Tabla IV-4. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 3 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada *et al.* (2021) como valores de entrada para las variables de dirección y velocidad del viento.

Puntos calientes de velocidad del viento (km/h)	Puntos calientes de dirección del viento (°)		
	170	210	225
5,0			
5,5			
6,0			
6,5			
7,0			

4.3.4. Conjunto 4 de playas

En el Conjunto 4 (playas de Marbella), se generaron 12 reglas difusas. La Figura IV-13 muestra la representación 3D del FRBS. Los resultados revelan que la incidencia de medusas es menor cuando la velocidad del viento ronda los 15 km/h (valor medio-alto en la serie temporal analizada) y con dirección de 180°. Por el contrario, el mayor número de avistamientos se asocia a vientos de 90° con velocidad de 10,4 km/h. En general, la incidencia de medusas se mantuvo en un nivel intermedio (alrededor de 2, en una escala de 0 a 5) para todas las combinaciones de velocidad y dirección del viento.




Figura IV-13. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 4 de playas, correspondiente a las playas de Marbella.

La regresión lineal entre la abundancia relativa de medusas obtenida por el modelo difuso frente a la abundancia relativa observada evidenció una mejora significativa frente a los Conjuntos 1, 2 y 3 ($R^2=0,53$, $p<0,05$) (Figura IV-14).




Figura IV-14. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 4 de playas.

Los efectos suavizados de los GAM generados por Gutiérrez-Estrada *et al.* (2021) (Figura IV-15) permitieron establecer puntos de interés en las direcciones del viento de 80, 200 y 240°, y a velocidades del viento de 7,5; 10,5; 12,5; 14,5 y 16 km/h.




Figura IV-15. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada *et al.* (2021) correspondientes al Conjunto 4 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la abundancia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h). Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).

La Tabla IV-5 presenta los resultados del FRBS al fijar los valores establecidos como puntos calientes. Siguiendo a Gutiérrez-Estrada *et al.* (2021), direcciones de viento por encima de 200° suelen disminuir la incidencia de medusas a ciertas velocidades. En concreto, para una velocidad de 16 km/h, el modelo difuso genera un caso particular de incidencia nula de medusas en el intervalo 14-16 km/h al combinarse con direcciones inferiores a 80° y en el rango de 180°-250°. Este modelo obtuvo resultados de ajuste superiores a los GAM (GAM $R^2=0,41$; FRBS_{presencia} $R^2=0,53$, $p<0,05$).

Tabla IV-5. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 4 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada *et al.* (2021) como valores de entrada para las variables de dirección y velocidad del viento.

Puntos calientes de dirección del viento (°)			
Puntos calientes de velocidad del viento (km/h)	80	200	240
7,5			
10,5			
12,5			
14,5			
16,0			

4.3.5. Conjunto 5 de playas

Por último, el modelo basado en lógica difusa para el Conjunto 5 (playas de Manilva-Estepona) generó 6 reglas difusas. La Figura IV-16 ilustra la superficie 3D de este FRBS. Se observa que la incidencia de medusas disminuye con vientos de alta velocidad y aumenta con direcciones comprendidas entre 70° y 140° . Sin embargo, existe un caso específico en el que la incidencia se ve favorecida en este mismo rango de direcciones si la velocidad del viento es lo bastante alta.




Figura IV-16. Representación gráfica 3D de los resultados del sistema basado en lógica difusa generado para el Conjunto 5 de playas, correspondiente a las playas comprendidas entre Manilva y Estepona.

La regresión lineal simple entre la abundancia relativa de medusas estimada por el FRBS y la observada arrojó un ajuste con un R^2 de 0,31 ($p < 0,05$) (Figura IV-17).




Figura IV-17. Regresión lineal entre las medusas observadas y las medusas estimadas por el sistema basado en lógica difusa del Conjunto 5 de playas.

Las gráficas de efectos parciales de los GAM generados por Gutiérrez-Estrada *et al.* (2021) (Figura IV-18) permitieron establecer puntos calientes en las direcciones del viento de 60, 95, 115, 135 y 170°, y velocidades del viento de 4,5; 5,5 y 7,5 km/h.




Figura IV-18. Análisis de residuos parciales del modelo GAM generado por Gutiérrez-Estrada *et al.* (2021) correspondientes al Conjunto 5 de playas, considerando la dirección y velocidad del viento como variables explicativas. El panel izquierdo muestra la relación entre la dirección del viento (°) y la abundancia de medusas, y el panel derecho representa el efecto de la velocidad del viento (km/h). Valores superiores a 0 están asociados con una mayor abundancia de medusas (flechas rojas) y los valores inferiores con una menor abundancia (flechas azules).

Al establecer estos puntos calientes en los modelos difusos, los resultados coinciden con los de Gutiérrez-Estrada *et al.* (2021), que muestran la misma franja direccional donde aumenta el número de medusas, así como la disminución de su incidencia con alta intensidad de viento (Tabla IV-6). Los modelos difusos no lograron explicar más del 31% de la varianza, mientras que los GAM obtuvieron un R^2 de 0,70 (GAM $R^2=0,70$; FRBS_{presencia} $R^2=0,31$, $p<0,05$).

Tabla IV-6. Representación gráfica de la cantidad relativa de medusas estimada por el sistema basado en reglas difusas generado para el Conjunto 5 de playas al establecer los puntos calientes identificados en Gutiérrez-Estrada *et al.* (2021) como valores de entrada para las variables de dirección y velocidad del viento.

Puntos calientes de velocidad del viento (km/h)	Puntos calientes de dirección del viento (°)				
	60	95	115	135	170
4,5					
5,5					
7,5					

4.4. Discusión

En este capítulo se han calibrado una serie de modelos basados en lógica difusa (FL, *Fuzzy Logic*) como alternativa a los enfoques estadísticos tradicionales para analizar e interpretar la información proveniente de ciencia ciudadana sobre los varamientos de medusas en las playas de la Costa del Sol. El enfoque heurístico propuesto se ha elegido porque la FL permite asignar valores de pertenencia intermedios a partir de la información extraída de comentarios en lenguaje natural (Martín del Brío y Sanz-Molina, 2006), brindando así un soporte formal para manejar información imprecisa. Esta capacidad de la FL resulta muy interesante desde el punto de vista ecológico, ya que facilita la detección de relaciones no lineales en sistemas multidimensionales de un modo relativamente sencillo. Ello explica el crecimiento, en la última década, del uso de técnicas heurísticas aplicadas a problemas ecológicos mediante sistemas de reglas difusas (Albajes-Eizagirre *et al.*, 2011; Brotz *et al.*, 2012; Gutiérrez-Estrada *et al.*, 2013; Colbach *et al.*, 2020; Balbuena *et al.*, 2021).

Por otra parte, el desarrollo de este estudio se enmarca en uno de los lugares con mayor afluencia turística en España, lo cual convierte al área de estudio en un entorno de especial interés para la evaluación de fuentes de información no dirigidas como la ciencia ciudadana. Una parte de la serie temporal de comentarios de la ciudadanía que se analizó se concentró en la época estival, coincidiendo con el pico de visitantes y el periodo de mayor incidencia de enjambres de medusas (Hamner y Dawson, 2009), lo que supone una oportunidad para afrontar la escasez de datos temporales sobre estos organismos gelatinosos, como ya se discutió en el Capítulo II.

Dada la naturaleza planctónica de las medusas, la aparición de estos organismos puede estar influenciada por factores climatológicos de gran escala (Bellido *et al.*, 2020), pero su varamiento en las costas puede estar influenciada sobre todo por condiciones locales, especialmente la interacción entre los vientos y las corrientes marinas (Zavodnik, 1987; Canepa *et al.*, 2014). En el norte del mar de Alborán, la entrada de aguas atlánticas a través del estrecho de Gibraltar da lugar a dos giros anticiclónicos cuya circulación superficial, de marcada estacionalidad, se ve modulada por vientos predominantes del oeste en primavera y más débiles del este en verano (Vargas-Yáñez *et al.*, 2021). Esta dinámica, combinada con la orientación de la costa, condiciona el patrón de varamientos que han hallado los resultados de este estudio: en la zona oriental (Conjuntos 1-3), los

vientos perpendiculares a la línea de costa aumentan la probabilidad de llegada de medusas, mientras que en el sector occidental (Conjuntos 4 y 5), son los vientos paralelos los que favorecen su acumulación. Esta interpretación coincide con lo señalado por Bellido *et al.* (2020), quienes destacan el papel del Giro Anticiclónico Occidental en la acumulación de medusas en la Costa del Sol, desde donde son desplazadas hacia el este por acción de vientos laterales. La dispersión y posterior llegada a la costa, por tanto, responde a una compleja interacción entre la dinámica poblacional y los procesos físicos locales (Hamner y Dawson, 2009; Berline *et al.*, 2013; de la Fuente Roselló *et al.*, 2024).

4.4.1. Comparativa entre los resultados de lógica difusa y GAM

Los sistemas basados en reglas difusas (FRBS) que se obtuvieron muestran, en términos cualitativos, ciertas coincidencias con los modelos calibrados por Gutiérrez-Estrada *et al.* (2021), aunque en cuatro de los cinco grupos de playas los valores de varianza explicada son inferiores a los alcanzados por los GAM. Para los Conjuntos 1 y 2, donde la lógica difusa solo explica un 20% y un 24% de la variabilidad, respectivamente, resulta plausible que la menor amplitud de combinaciones en los rangos de velocidad y dirección del viento limite la capacidad del FRBS para generar reglas que distingan eficazmente los días con mayor y menor abundancia de medusas. En dichos conjuntos, es habitual observar registros relativamente similares en la componente de viento, con valores de abundancia relativa de medusas observados muy similares e inferiores a uno. De este modo, la curva aditiva de los GAM se ajusta mejor a los cambios graduales sin requerir esos umbrales nítidos que la FL aprovecha para establecer reglas claras. En el Conjunto 3, esta situación se hace aún más evidente, ya que tanto los GAM ($R^2=0,37$) como los FRBS ($R^2=0,12$) muestran la menor capacidad de ajuste. En este conjunto, a pesar de ser una zona con vientos de escasa intensidad (con valores registrados entre 3 y 10 km/h) en los que se podría interpretar con mayor facilidad el efecto de la dirección del viento, existe un solapamiento de valores bajos de abundancia relativa de medusas que dificulta que el FRBS extraiga reglas contundentes. En el Conjunto 5 (FRBS $R^2=0,31$), la FL tampoco logra establecer reglas sólidas ante valores de viento que, si bien varían moderadamente, no presentan saltos tan marcados para asociarse a las situaciones con mayor abundancia relativa de medusas, mientras que, en este caso, los GAM aprovechan mejor su suavización aditiva para llegar al 70% de varianza explicada.

Sin embargo, para el Conjunto 4, el FRBS ($R^2=0,53$) supera la capacidad predictiva de los GAM ($R^2=0,41$). Este rendimiento diferencial no solo está relacionado con la amplitud en dirección y velocidad del viento, sino también con el número de reglas creadas: el modelo de FL en esta zona definió doce reglas (un número sensiblemente superior al resto de conjuntos), lo cual le otorga mayor flexibilidad para identificar intervalos de viento con distintas probabilidades de aparición de medusas. Al existir diferencias más evidentes entre situaciones de dirección y velocidad del viento, el FRBS puede ajustar dichos umbrales de pertenencia y asignar distintos grados de probabilidad de abundancia relativa de medusas. Así, la FL se beneficia de esa estructura segmentada para formular reglas más específicas.

Estos hallazgos concuerdan con otros trabajos en los que se han comparado ambos enfoques. Por ejemplo, Gutiérrez-Estrada *et al.* (2012), al modelizar tasas de entrada de agua para la gestión del recambio en estanques de acuicultura semi-intensiva en el sur de España, observaron que los GAM y los modelos basados en lógica difusa ofrecían funciones de respuesta similares, pero con distintos niveles de varianza explicada. Asimismo, Gutiérrez-Estrada *et al.* (2013) mostraron, al analizar la consistencia de reglas difusas para predecir la diversidad de coleópteros acuáticos en aguas temporales y fluctuantes, que los GAM y los FRBS arrojaban comportamientos parecidos. Sin embargo, estos autores subrayaron una ventaja importante de los métodos basados en lógica difusa frente a los GAM en la interpretación de los resultados: mientras que en los GAM el análisis de la relación entre predictores y la variable dependiente se fundamenta en el cálculo de residuos parciales, lo cual requiere valorar la naturaleza de la relación entre cada predictor y el valor ajustado de la variable dependiente, en los FRBS los resultados se interpretan como reglas vinculadas a categorías lingüísticas, muy cercanas al modo en que los seres humanos resolvemos problemas cotidianos.

4.4.2. Implicaciones para una gestión adaptativa de medusas

La evidencia sugiere que ciertas proliferaciones de medusas, particularmente de *Pelagia noctiluca*, están aumentando en el mar Mediterráneo (Brotz y Pauly, 2012). Dado que las picaduras de *P. noctiluca* son responsables de la mayoría de las lesiones por picadura de medusa registradas en la costa de Málaga (Canepa *et al.*, 2014; Templado *et al.*, 2021), se subraya la necesidad de estrategias de gestión proactivas que aborden las

proliferaciones de medusas a partir de una comprensión integral de sus causas (Boero, 2013). Así, la aplicación de sistemas basados en reglas difusas resulta una herramienta de gran utilidad para mejorar la gestión de los eventos de aparición masiva de enjambres, tanto desde la perspectiva de la salud de los bañistas como de la economía de los destinos turísticos (Lucas *et al.*, 2014; Gutiérrez-Estrada *et al.*, 2021). La utilización de sistemas basados en lógica difusa para la detección temprana de eventos adversos ha demostrado ser una estrategia eficaz en diversos campos, y podría trasladarse con éxito a la gestión de estos eventos. Por ejemplo, Nagothu *et al.* (2025) desarrollaron un sistema de alerta para el control de la calidad del agua en tanques de acuicultura, en el que la lógica difusa ajustaba de forma automática aireadores y bombas de recirculación al detectar fluctuaciones peligrosas de pH, temperatura y oxígeno disuelto. Esta capacidad de disparar alertas inmediatas ante condiciones que superan ciertos umbrales garantiza una respuesta eficaz y minimiza la mortalidad de los peces cultivados. Del forma similar, Gutiérrez-Estrada *et al.* (2005) implementaron un sistema basado en lógica difusa para el diagnóstico temprano de enfermedades en la acuicultura de anguilas. El sistema fue capaz de identificar signos de infección con una precisión equiparable a la de expertos humanos, emitiendo recomendaciones de tratamiento de forma temprana.

Dado que las poblaciones de medusas responden dinámicamente a cambios ambientales y antrópicos, los modelos de gestión deben incorporar información local precisa y detallada (Gibbons *et al.*, 2016). Así, un FRBS orientado a la detección temprana de enjambres de medusas podría recibir varias veces al día datos meteorológicos, oceanográficos y de ciencia ciudadana, integrarlos en un motor de inferencia difusa y generar alertas tempranas cuando la probabilidad de llegada de enjambres sobrepase un umbral crítico. Del mismo modo que en los casos previos, la interpretabilidad de las reglas difusas permitiría a las autoridades costeras, servicios de emergencia y gestores turísticos reaccionar con suficiente antelación, permitiendo implementar planes de actuación y respuesta en aquellos días con mayor probabilidad de picaduras. Las medidas locales inmediatas en respuesta a las indicaciones de los FRBS, como la retirada de medusas en zonas de baño, la instalación de redes anti-medusas, el uso de banderas de aviso ante la presencia de medusas, o incluso el cierre de playas, podrían contribuir a reducir los riesgos para la salud pública y minimizar los impactos económicos sobre el turismo (Gershwin *et al.*, 2014; Bordehore *et al.*, 2016; Piraino *et al.*, 2016; Macías *et al.*, 2021).

Según Ruiz-Frau (2022), este tipo de iniciativas de respuesta en el Mediterráneo occidental pueden disminuir hasta un 83 % el porcentaje de turistas disuadidos por la presencia de medusas, mitigando así los impactos económicos sobre las comunidades costeras. Cantarero-Prados *et al.* (2023) señalan que las playas de Málaga, Marbella y Torrox figuran entre las más afectadas por las proliferaciones de medusas, dando lugar a un descenso de la actividad turística y pérdidas económicas notables. Eventos similares han ocurrido en otras zonas, como el Mar Menor, donde brotes masivos de *Cotylorhiza tuberculata* requirieron la retirada de miles de toneladas de medusas para proteger el turismo. La Costa del Sol ha experimentado episodios graves de medusas, como los afloramientos de *P. noctiluca* en 2012, que obligaron al cierre de playas y afectaron la temporada estival (Ghermandi *et al.*, 2015). En las costas marroquíes también se han documentado numerosos casos de picaduras de *P. noctiluca* que han afectado tanto a turistas como a residentes, requiriendo un porcentaje considerable de las personas afectadas asistencia médica (Mghili *et al.*, 2020). Además, las proliferaciones de medusas han causado pérdidas económicas significativas para la pesca local, no solo por la disminución de capturas al interactuar con las redes, sino también por el tiempo y coste adicionales asociados a la reparación de los aparejos de pesca dañados (Mghili *et al.*, 2022a, b). Estos efectos refuerzan la urgencia de implementar estrategias de seguimiento y mitigación que integren la colaboración entre los sectores turístico, pesquero y la administración pública para minimizar el impacto de estos eventos en el mar de Alborán. En este sentido, la ciencia ciudadana desempeña un papel esencial para complementar y potenciar los estudios científicos y las acciones de gobierno en aquellos ámbitos donde los recursos disponibles sean insuficientes (Lee *et al.*, 2006; Marambio *et al.*, 2021).

No obstante, estas intervenciones no abordan los factores subyacentes que impulsan las proliferaciones de medusas. Una gestión a largo plazo requiere un enfoque ecosistémico que integre la monitorización continua y la investigación para entender la dinámica ecológica (Richardson *et al.*, 2009). Es importante mencionar que las medusas desempeñan funciones vitales en los ecosistemas marinos (Hamner y Dawson, 2009; Lucas *et al.*, 2014), cumpliendo funciones decisivas en el flujo de energía del ecosistema marino en múltiples niveles de la cadena trófica, lo que exige considerarlas como organismos que también aportan ventajas a la sociedad (Doyle *et al.*, 2014; Aubert *et al.*, 2018; Hays *et al.*, 2018). La cooperación entre organismos gubernamentales, el sector turístico, el sector pesquero y la sociedad en su conjunto resulta esencial para adoptar

medidas efectivas ajustadas a las condiciones regionales (Macías *et al.*, 2021) y combinar estrategias inmediatas con otras de largo plazo. En este sentido, el enfoque preventivo basado en la detección temprana, la respuesta coordinada y la monitorización continua puede atenuar notablemente los impactos de las proliferaciones de medusas y mejorar la gestión de los recursos marinos (Richardson *et al.*, 2009).

4.5. Conclusiones

Los resultados de la presente investigación ponen de manifiesto que el uso de técnicas de inteligencia artificial como la lógica difusa (FL) puede paliar la escasez de datos acerca de la incidencia de medusas en la costa. Los sistemas basados en reglas difusas (FRBS) obtenidos han permitido modelizar el conocimiento derivado de los comentarios en lenguaje natural de los usuarios de la aplicación Infomedusa. Asimismo, ha quedado confirmado que variables ambientales locales, como la dirección y la velocidad del viento, desempeñan un papel clave en la aparición de enjambres de medusas en la provincia de Málaga. Para las zonas central y oriental de la provincia, los vientos perpendiculares a la costa propician una mayor afluencia de enjambres, mientras que en la parte más occidental la mayor incidencia se observa con vientos paralelos a la costa. Dependiendo de la localización y la orientación del viento, una alta velocidad de este puede favorecer o disminuir la presencia de medusas.

Partiendo de estos hallazgos, la aplicación de FRBS y su uso con los datos obtenidos de Infomedusa facilita la colaboración ciudadana para profundizar en los factores climáticos que determinan la llegada de estos organismos gelatinosos a la costa. La función de estos modelos radica en proveer una base inicial para comprender en qué condiciones surgen los enjambres de medusas en la Costa del Sol.

Una alarma temprana de enjambres de medusas puede convertirse en una herramienta de gestión en los protocolos de prevención de riesgos para los usuarios de las playas. Estos protocolos servirían para reforzar la protección de los bañistas al mismo tiempo que mitigaría pérdidas económicas producidas por la aparición de estos eventos.

En última instancia, estos modelos constituyen un primer paso hacia una comprensión global de la presencia de medusas en cada conjunto de playas. Tal y como se ha demostrado, el efecto del viento varía según la ubicación, por lo que estudios futuros analizarán el impacto de otras variables en cada una de estas áreas concretas. Asimismo, dichas investigaciones podrían abordar en mayor profundidad la vertiente socioeconómica que suponen las medusas en las regiones altamente dependientes del turismo de sol y playa.

4.6. Referencias

- Adadi, A., Berrada, M. 2018. Peeking inside the black-box: a survey on Explainable Artificial Intelligence (XAI). *IEEE Access* 6, 52138–52160.
- Albajes-Eizaguirre, A., Romero, L., Soria-Frisch, A., Vanhellemont, Q. 2011. Jellyfish prediction of occurrence from remote sensing data and a non-linear pattern recognition approach. En *SPIE Remote Sensing* (Vol. 8174, pp. 382-391). 7 de octubre de 2011. Praga, República Checa.
- Alonso Moral, J. M., Castiello, C., Magdalena, L., Mencar, C. 2021. Toward Explainable Artificial Intelligence Through Fuzzy Systems. En J. M. Alonso Moral, C. Castiello, L. Magdalena, C. Mencar (Eds.), *Explainable Fuzzy Systems. Paving the Way from Interpretable Fuzzy Systems to Explainable AI Systems. Studies in Computer Intelligence* (Vol. 970, pp. 1-23). Springer.
- Aroba, J. 2003. *Advances in the decision making in software development projects* [Tesis de doctorado, Universidad de Sevilla].
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., Chatila, R., Herrera, F. 2020. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information fusion* 58, 82-115.
- Aubert, A., Antajan, E., Lynam, C., Pitois, S., Pliru, A., Vaz, S., Thibault, D. 2018. No more reason for ignoring gelatinous zooplankton in ecosystem assessment and marine management: concrete cost-effective methodology during routine fishery trawl surveys. *Marine Policy* 89, 100-108.
- Balbuena, J. A., Monlleó-Borrull, C., Llopis-Belenguer, C., Blasco-Costa, I., Sarabeev, V. L., Morand, S. 2021. Fuzzy quantification of common and rare species in ecological communities (FuzzyQ). *Methods in ecology and evolution* 12(6), 1070-1079.
- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., Garcia, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., Herrera, F. 2020. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information fusion* 58, 82-115.

- Bellido, J. J., Baez, J. C., Souviron-Priego, L., Ferri-Yáñez, F., Salas, C., López, J. A., Real, R. 2020. Atmospheric indices allow anticipating the incidence of jellyfish coastal swarms. *Mediterranean Marine Science* 21(2), 289-297.
- Berline, L., Zakardjian, B., Molcard, A., Ourmieres, Y., Guihou, K. 2013. Modeling jellyfish *Pelagia noctiluca* transport and stranding in the Ligurian Sea. *Marine Pollution Bulletin* 70(1-2), 90-99.
- Bernier, E. T., Sánchez, R. R., Díaz, B. R. 2014. La crisis económica en el sector turístico. Un análisis de sus efectos en la Costa del Sol. *Revista de análisis turístico* 18, 11-18.
- Bezdek, J. C. 1981. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Plenum Press.
- Boero, F. 2013. Review of jellyfish blooms in the Mediterranean and Black Sea. *Studies and Reviews. General Fisheries Commission for the Mediterranean* 92.
- Bordehore, C., Alonso, C., Sánchez-Fernández, L., Canepa, A., Acevedo, M., Nogué, S., Fuentes, V. L. 2016. Lifeguard assistance at Spanish Mediterranean beaches: jellyfish prevail and proposals for improving risk management. *Ocean & Coastal Management* 131, 45-52.
- Bouchon-Meunier, B., Laurent, A., & Lesot, M. J. 2022. XAI: a natural application domain for fuzzy set theory. En A. E. Smith (Ed.) *Women in Computational Intelligence: Key Advances and Perspectives on Emerging Topics* (pp. 23-49). Springer International Publishing.
- Brotz, L., Cheung, W. W. L., Kleisner, K., Pakhomov, E., Pauly, D. 2012. Increasing jellyfish populations: trends in Large Marine Ecosystems. *Hydrobiologia* 690(1), 3-20.
- Brotz, L., Pauly, D. 2012. Jellyfish populations in the Mediterranean Sea. *Acta Adriatica* 53(2), 213-231.
- Canepa, A., Fuentes, V., Sabatés, A., Piraino, S., Boero, F., Gili, J. M. 2014. *Pelagia noctiluca* in the Mediterranean Sea. En K. A. Pitt, C. H. Lucas (Eds.), *Jellyfish Blooms* (pp. 237-266). Springer.

- Cantarero-Prados, F. J., de la Fuente Roselló, A., López, J. J. B. 2023. El impacto de las medusas en el uso recreativo de las playas. Un enfoque desde la perspectiva del riesgo. *Cuadernos Geográficos* 62(1), 300-318.
- Colbach, N., Chauvel, B., Messean, A., Villerd, J., Bockstaller, C. 2020. Feeding pollinators from weeds could promote pollen allergy. A simulation study. *Ecological Indicators* 117, 106635.
- Daryanabard, R., Dawson, M. N. 2008. Jellyfish blooms: *Crambionella orsini* (Scyphozoa: Rhizostomeae) in the Gulf of Oman, Iran, 2002–2003. *Journal of the Marine Biological Association of the United Kingdom* 88(3), 477-483.
- De Carolis, B., de Rosis, F., Grasso, F., Rossiello, A., Berry, D. C., Gillie, T. 1996. Generating recipient-centered explanations about drug prescription. *Artificial Intelligence in Medicine* 8(2), 123-145.
- De Donno, A., Idolo, A., Bagordo, F., Grassi, T., Leomanni, A., Serio, F., Guido, M., Canitano, M., Zampardi, S., Boero, F., Piraino, S. 2014. Impact of stinging jellyfish proliferations along south Italian coasts: human health hazards, treatment and social costs. *International Journal of Environmental Research and Public Health* 11(3), 2488-2503.
- de la Fuente Roselló, A., Perles Roselló, M. J., Cantarero Prados, F. J. 2024. A Predictive Analysis of Beach Susceptibility to Jellyfish Arrivals in Costa del Sol. *Journal of Marine Science and Engineering* 12(12), 2316.
- Delannoy, C. M. J., Houghton, J. D. R., Fleming, N. E. C., Ferguson, H. W. 2011. Mauve Stingers (*Pelagia noctiluca*) as carriers of the bacterial fish pathogen *Tenacibaculum maritimum*. *Aquaculture* 311(1-4), 255-257.
- Do, A. N. T., Do, T. A. T., Tran, H. D. 2024. Distribution of fish larvae and juveniles on salinity in an estuary predicted from remote sensing and fuzzy logic approach. *Aquatic Ecology* 58, 983–998.
- Doshi-Velez, F., Kim, B. 2017. Towards a rigorous science of interpretable machine learning. *arXiv preprint*, 1702.08608.

- Doyle, T. K., Hays, G. C., Harrod, C., Houghton, J. D. 2014. Ecological and societal benefits of jellyfish. En K. A. Pitt, C. H. Lucas (Eds.), *Jellyish Blooms* (pp. 105-127). Springer.
- Enríquez, J. G, Cid, V., Muntaner, N., Aroba, J., Navarro, J., Domínguez, F. J., Escalona, M. J., Ramos, I. 2018. Behavior patterns in hormonal treatments using fuzzy logic-based models. *Soft Computing* 22, 79-90.
- Fernández-Camacho, R., Brito Cabeza, I., Aroba, J., Gómez-Bravo, F., Rodríguez, S., de la Rosa, J. 2015. Assessment of ultrafine particles and noise measurements using fuzzy logic and data mining techniques. *Journal of Science of the Total Environment* 512-513, 103-113.
- Fukuyama, Y., Sugeno, M. 1989. A new method of choosing the number of clusters for fuzzy means method. *Proceedings of the 5th Fuzzy Systems Symposium* (pp. 247-250).
- Gangopadhyay, A. 2001. Conceptual modeling from natural language functional specifications. *Artificial Intelligence in Engineering* 15(2), 207-218.
- García, E., Ocaña, C. 1982. La organización espacial de la Costa Mediterránea Andaluza. *Baetica* 5, 15-57.
- García-Lafuente, J., Sánchez-Garrido, J. C., Garcia, A., Hidalgo, M., Sammartino, S., Laíz, R. 2021. Biophysical Processes Determining the Connectivity of the Alboran Sea Fish Populations. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli Idrissi (Eds.), *Alboran Sea-Ecosystems and Marine Resources* (pp. 459-487). Springer International Publishing.
- García-Soto, C., Seys, J. J. C., Zielinski, O., Busch, J. A., Luna, S. I., Baez, J. C., Domegan, C., Dubsky, K., Kotynska-Zielinska, I., Loubat, P., Malfatti, F., Mannaerts, G., McHugh, P., Monestiez, P., van der Meeren, G.I., Gorsky, G. 2021. Marine Citizen Science: Current State in Europe and New Technological Developments. *Frontiers in Marine Science* 8, 621472.
- Gershwin, L. A., Condie, S. A., Mansbridge, J. V., Richardson, A. J. 2014. Dangerous jellyfish blooms are predictable. *Journal of the Royal Society Interface* 11(96), 20131168.

- Ghermandi, A., Galil, B., Gowdy, J., Nunes, P. A. L. D. 2015. Jellyfish outbreak impacts on recreation in the Mediterranean Sea: welfare estimates from a socioeconomic pilot survey in Israel. *Ecosystem Services* 11, 140–147.
- Gibbons, M. J., Boero, F., Brotz, L. 2016. We should not assume that fishing jellyfish will solve our jellyfish problem. *ICES Journal of Marine Science* 73(4), 1012-1018.
- Graham, W. M., Martin, D. L., Felder, D. L., Asper, V. L., Perry, H. M. 2003. Ecological and economic implications of a tropical jellyfish invader in the Gulf of Mexico. *Biological Invasions* 5, 53-69.
- Graham, W. M., Pagès, F., Hamner, W. M. 2001. A physical context for gelatinous zooplankton aggregations: a review. *Hydrobiologia* 451, 199-212.
- Gunning, D., Stefik, M., Choi, J., Miller, T., Stumpf, S., Yang, G. Z. 2019. XAI—Explainable artificial intelligence. *Science robotics* 4(37), eaay7120.
- Gutiérrez-Estrada, J. C., Pulido-Calvo, I., Bilton, D. T. 2013. Consistency of fuzzy rules in an ecological context. *Ecological modelling* 251, 187-198.
- Gutiérrez-Estrada, J. C., Pulido-Calvo, I., de la Rosa, I., Marchini, B. 2012. Modeling inflow rates for the water exchange management in semi-intensive aquaculture ponds. *Aquacultural Engineering* 48, 19-30.
- Gutiérrez-Estrada, J. C., Pulido-Calvo, I., Peregrín, A., García-Gálvez, A., Báez, J. C., Bellido, J. J., Souviron-Priego, L., Sánchez-Laulhé, J. M., López, J. A. 2021. Integrating local environmental data and information from non-driven citizen science to estimate jellyfish abundance in Costa del Sol (southern Spain). *Estuarine, Coastal and Shelf Science* 249, 107112.
- Gutierrez-Estrada, J. C., Sanz, E. D. P., López-Luque, R., Pulido-Calvo, I. 2005. SEDPA, an expert system for disease diagnosis in eel rearing systems. *Aquacultural engineering* 33(2), 110-125.
- Halsband, C., Majaneva, S., Hosia, A., Emaus, P. A., Gaardsted, F., Zhou, Q., Nøst, O. A., Renaud, P. E. 2018. Jellyfish summer distribution, diversity and impact on fish farms in a Nordic fjord. *Marine Ecology Progress Series* 591, 267-279.

- Hamner, W. M., Dawson, M. N. 2009. A review and synthesis on the systematics and evolution of jellyfish blooms: advantageous aggregations and adaptive assemblages. *Hydrobiologia* 616, 161-191.
- Hattab, T., Ben Rais Lasram, F., Albouy, C., Sammari, C., Romdhane, M. S., Cury, P., Leprieur, F., Le Loc'h, F. 2013. The use of a predictive habitat model and a fuzzy logic approach for marine management and planning. *PLoS ONE* 8(10), e76430.
- Hay, S. 2006. Marine ecology: gelatinous bells may ring change in marine ecosystems. *Current Biology* 16, R679–R682.
- Hays, G. C., Doyle, T. K., Houghton, J. D. 2018. A paradigm shift in the trophic importance of jellyfish?. *Trends in Ecology & Evolution* 33(11), 874-884.
- Höppner, F., Klawonn, F. 2003. A contribution to convergence theory of fuzzy c-means and derivatives. *IEEE Transactions on Fuzzy Systems* 11(5), 682-694.
- Jones, M. C., Cheung, W. W. 2018. Using fuzzy logic to determine the vulnerability of marine species to climate change. *Global change biology* 24(2), e719-e731.
- Klir, G. J., Yuan, B. 1995. *Fuzzy Sets and Fuzzy Logic: Theory and Applications*. Prentice Hall.
- Komninos, A. 2018. Pro-social Behaviour in Crowdsourcing Systems: Experiences from a field deployment for beach monitoring. *International Journal of Human-Computer Studies* 124, 93-115.
- Lee, T., Quinn, M. S., Duke, D. 2006. Citizen, science, highways, and wildlife: using a web-based GIS to engage citizens in collecting wildlife information. *Ecology and Society* 11(1).
- Lucas, C. H., Gelcich, S., Uye, S.-I. 2014. Living with jellyfish: management and adaptation strategies. En K. Pitt, C. Lucas (Eds.), *Jellyfish blooms* (pp. 129-150). Springer.
- Luis, A. T., Grande, J. A., Dávila, J. M., Aroba, J., Duraes, N., Almeida, S. F., de la Torre, M. L., Sarmiento, A. M., Fortes, J. C., Ferreira da Silva, E., Santisteban, M. 2018. Application of fuzzy logic tools for the biogeochemical characterisation of (un)contaminated waters from Aljustrel mining area (South Portugal). *Chemosphere* 211, 736-744.

- Macías, D., García-Gorriz, E., Stips, A. 2016. The seasonal cycle of the Atlantic Jet dynamics in the Alboran Sea: direct atmospheric forcing versus Mediterranean thermohaline circulation. *Ocean Dynamics* 66(2): 137-151.
- Macías, D., Prieto, L., García-Gorriz, E. 2021. A model-based management tool to predict the spread of *Physalia physalis* in the Mediterranean Sea. Minimizing risks for coastal activities. *Ocean & Coastal Management* 212, 105810.
- Marambio, M., Canepa, A., Lòpez, L., Gauci, A. A., Gueroun, S. K., Zampardi, S., Boero, F., Kéfi-Daly Yahia, O., Daly Yahia, M. N., Fuentes, V., Deidun, A. 2021. Unfolding jellyfish bloom dynamics along the Mediterranean basin by transnational citizen science initiatives. *Diversity* 13(6), 274.
- Martín del Brío, B., Sanz-Molina, A. 2006. *Redes neuronales y sistemas borrosos*. Rama.
- Mercado, J. M., Cortés, D., Ramírez, T., Gómez, F. 2012. Decadal weakening of the wind-induced upwelling reduces the impact of nutrient pollution in the Bay of Málaga (western Mediterranean Sea). *Hydrobiologia* 680, 91-107.
- Mghili B., A., Analla, M., Aksissou, M. 2020. Epidemiology of the cnidarian *Pelagia noctiluca* stings on Moroccan Mediterranean beaches. *Tropical Doctor* 50(4), 1-4.
- Mghili, B., Analla, M., Aksissou, M. 2022a. Medusae (Scyphozoa and hydrozoa) from the Moroccan Mediterranean coast: abundance and spatiotemporal dynamics and their economic impact. *Aquatic Ecology* 56(1), 213-226.
- Mghili, B., Analla, M., Aksissou, M. 2022b. Estimating the economic damage caused by jellyfish to fisheries in Morocco. *African Journal of Marine Science* 44(3), 271-277.
- Nagata, R. M., Haddad, M. A., Nogueira, M. 2009. The nuisance of medusae to shrimp trawls in central part of southern Brazilian Bight, from the perspective of artisanal fishermen. *Pan-American Journal of Aquatic Sciences* 4, 312-325.
- Nagothu, S. K., Bindu Sri, P., Anitha, G., Vincent, S., Kumar, O. P. 2025. Advancing aquaculture: Fuzzy logic-based water quality monitoring and maintenance system for precision aquaculture. *Aquaculture International* 33, 32.

- Peliz, A., Boutov, D., Teles-Machado, A. 2013. The Alboran Sea mesoscale in a long term high resolution simulation: Statistical analysis. *Ocean Modelling* 72, 32-52.
- Piraino, S., Deidun, A., Fuentes, V., Daly-Yahia, M. N., Daly-Yahia, O., Marambio, M., Canepa, A., Olariaga, A., Gueroun, S. K. M., Aissi, M., Aglieri, G., Milisenda, G., Purcell, J. 2016. Are anti-jellyfish nets a useful mitigation tool for coastal tourism? Hindsight from the MED-JELLYRISK experience. En *5th International Jellyfish Bloom Symposium*, 30 de mayo - 3 de junio, Barcelona, España.
- Pugh, P. R. 1989. Gelatinous zooplankton – the forgotten fauna. *Progress in Underwater Science* 14, 67-78
- Richardson, A. J., Bakun, A., Hays, G. C., Gibbons, M. J. 2009. The jellyfish joyride: causes, consequences and management responses to a more gelatinous future. *Trends in Ecology & Evolution* 24(6), 312-322.
- Romero-Padilla, Y., Navarro-Jurado, E., Romero-Martínez, J.-M. 2020. Tourist destinations and creative capital: The case of costa del sol in southern Spain. *Revista de geografía Norte Grande* 77, 339-365.
- Ross, T. J. 2005. *Fuzzy logic with engineering applications*. John Wiley & Sons.
- Ruiz-Frau, A. 2022. Impacts of jellyfish presence on tourists' holiday destination choices and their willingness to pay for mitigation measures. *Journal of Environmental Planning and Management* 66(10), 2107-2125.
- Sugeno, M., Yasukawa, A. 1993. A fuzzy-logic based approach to qualitative modeling. *IEEE Transactions on Fuzzy Systems* 1(1), 7-31.
- Takagi, T., Sugeno, M. 1985. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics* 15(1), 116-132.
- Tang, T.-C., Chi, L.-C. 2005. Predicting multilateral trade credit risks: comparisons of Logit and Fuzzy logic-based models using ROC curve analysis. *Expert Systems with Applications* 28(3), 547-556.
- Templado, J., Luque, Á. A., Moreno, D., Tierno de Figueroa, J. M., Sánchez Tocino, L., Aguilar, R., de la Torriente, A. 2021. Invertebrates: The realm of diversity. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli Idrissi (Eds.), *Alboran Sea-*

- Ecosystems and Marine Resources* (pp. 359-430). Springer International Publishing.
- Vargas-Yáñez, M., García-Martínez, M. C., Moya, F., Balbín, R., López-Jurado, J. L. 2021. The oceanographic and climatic context. En J. C. Báez, J. A. Camiñas, J. T. Vázquez, M. Malouli Idrissi (Eds.), *Alboran Sea-Ecosystems and Marine Resources* (pp. 85-109). Springer International Publishing.
- Wood, S. N. 2017. *Generalized additive models: an introduction with R* (2ª Ed.). Chapman and hall/CRC.
- Woods, W. A. 1973. Progress in natural language understanding: an application to lunar geology. En *Proceedings of the national computer conference and exposition* (pp. 441-450). 4-8 de junio de 1973. Nueva York, Estados Unidos.
- Xiong, J., Zhang, Y., Li, Z. 2024. Assessing human exposure to organic contaminants in fish: A modeling approach integrating chemical bioconcentration and food thermal processing. *Toxicology Reports* 13, 101805.
- Yi, Y., Sun, J., Zhang, S., Yang, Z. 2016. Assessment of Chinese sturgeon habitat suitability in the Yangtze River (China): Comparison of generalized additive model, data-driven fuzzy logic-based model, and preference curve model. *Journal of Hydrology* 536, 447-456.
- Zadeh, L. A. 1965. Fuzzy sets. *Information and Control* 8(3), 338-353.
- Zadeh, L. A. 1975. The concept of a linguistic variable and its application to approximate reasoning-I. *Information sciences* 8(3), 199-249.
- Zamora, W., Calafate, C. T., Cano, J. -C., Manzoni, P. 2016. A survey on smartphone-based crowdsensing solutions. *Mobile Information Systems* 2016(1), 1-26.
- Zavodnik, D. 1987. Spatial aggregations of the swarming jellyfish *Pelagia noctiluca* (Scyphozoa). *Marine Biology* 94(2), 265-269.
- Zuur, A. F., Ieno, E. N., Walker, N. J., Saveliev, A. A., Smith, G. M. 2009. *Mixed effects models and extensions in ecology with R* (Vol. 574). Springer.



CONCLUSIONES

CONCLUSIONES

- (i). Los afloramientos de medusas son fenómenos naturales recurrentes, cuyo aumento e intensificación debido a factores antrópicos y climáticos impactan significativamente en actividades económicas, la salud pública y el equilibrio ecológico. Dado que la ausencia de registros históricos sólidos limita su estudio, la ciencia ciudadana ofrece una alternativa eficiente para generar datos, aunque requiere protocolos claros y una validación rigurosa. Por ello, combinar observaciones ciudadanas con modelos ecológicos resulta clave para desarrollar sistemas de alerta temprana efectivos.
- (ii). El uso de redes neuronales artificiales aplicadas al procesamiento de comentarios de la aplicación Infomedusa demostró que los textos generados por usuarios pueden clasificarse con elevada exactitud respecto a la presencia o ausencia de medusas. Esto demuestra que la participación ciudadana, aun siendo no dirigida, aporta un caudal de información capaz de nutrir modelos de aprendizaje automático.
- (iii). La temperatura superficial del mar, la dirección y la velocidad del viento emergieron como predictores clave, aunque su influencia varía entre conjuntos de playas, lo que confirma que los factores locales modulan la señal ambiental regional. Los resultados sugieren que una integración en tiempo real de datos ambientales con el flujo de comentarios mejoraría la capacidad de emitir alertas de riesgo para bañistas y gestores, reforzando la utilidad pública de la plataforma y la confianza del usuario.
- (iv). Los modelos MaxEnt, alimentados solo con datos de presencia y variables ambientales, revelaron que la profundidad primaveral de la capa de mezcla explicó gran parte de la distribución estival de medusas en el litoral andaluz durante el año 2019, resaltando la importancia de los procesos oceanográficos previos a la temporada estival.
- (v). Otras variables, como la producción primaria neta de abril y la salinidad superficial en junio, actúan como moduladores secundarios, lo que refuerza la vinculación de la proliferación a la disponibilidad trófica y a la estabilidad de la columna de agua antes del verano.
- (vi). El enfoque basado en MaxEnt demuestra que los datos de ciencia ciudadana, combinados con reanálisis físico-biogeoquímicos, permiten cartografiar zonas de riesgo y priorizar recursos de gestión, sentando las bases para un sistema regional de alerta temprana escalable a otras costas mediterráneas.

(vii). Los sistemas basados en reglas difusas transforman la información lingüística de Infomedusa en modelos transparentes. Aunque su varianza explicada es menor que la de los GAM en la mayoría de sectores, estos sobresalen en Marbella, donde capturan mejor los umbrales críticos de viento.

(viii). Las reglas derivadas de estos sistemas confirman un patrón espacial: en los sectores oriental y central, los vientos perpendiculares a la costa favorecen la llegada de enjambres, mientras que en el sector occidental, la acumulación aumenta con vientos paralelos a la costa, modulados por su intensidad.

(ix). La facilidad de traducir las salidas de los sistemas basados en lógica difusa a frases comprensibles lo convierte en una herramienta idónea para servicios de socorrismo y gestores turísticos que necesitan actuar con escaso margen temporal. Integrar estos sistemas con mediciones ambientales en tiempo real permitiría activar alertas automáticas y adoptar medidas preventivas, reduciendo tanto el impacto sanitario como las pérdidas económicas asociadas a cierres improvisados de playas en la Costa del Sol.

(x). Los resultados obtenidos en esta Tesis Doctoral demuestran que combinar ciencia ciudadana con modelos estadísticos y de Inteligencia Artificial Explicable permite transformar observaciones dispersas en pronósticos fiables sobre las proliferaciones de medusas, ofreciendo una herramienta práctica para proteger la salud, el turismo y los ecosistemas costeros.



ANEXOS

Anexo 1

1 Introducción

En consonancia con lo expuesto en el Capítulo II, este anexo detalla el flujo de procesamiento de comentarios estructurándolo en varias secciones. El proceso incluye:

- Carga de librerías, lectura de datos y filtrado inicial.
- Generación de identificadores únicos (ID) para cada comentario obtenido de la aplicación Infomedusa.
- Tratamiento y normalización del texto.
- Separación de palabras.
- Creación del diccionario de palabras.
- Codificación *one-hot* de los comentarios.
- Análisis de frecuencia de palabras según la variable **Jellyfish**.
- Análisis final con diccionario filtrado.

2 Carga de librerías, lectura de datos y filtrado inicial

```
[ ]: library(tidyverse)
library(stringi)
library(stringr)
library(dplyr)
library(tidyr)
library(gdata)

# Definir el directorio de trabajo
setwd("C:/Users/jairo/Desktop/.../")

# Lectura del archivo CSV y filtrado de registros con información de medusas
df <- read.csv("C:/Users/jairo/Desktop/.../Comentarios.csv", sep=";")
df <- subset(df, Jellyfish != "NA")
```

3 Generación de identificadores (ID)

Se crea un identificador único para cada comentario a partir de la información de la playa, fecha y hora.

```
[ ]: df$Playa_nosp <- gsub(" ", "", df$Playa) # Playa sin espacios
df$Date <- substr(df$Fecha, start = 1, stop = 10) # Extracción de la fecha
df$Time <- substr(df$Fecha, start = 12, stop = 19) # Extracción de la hora
df$Date_nosp <- gsub("-", "", df$Date) # Fecha sin guiones
df$Time_nosp <- gsub(":", "", df$Time) # Hora sin dos puntos
df$IDbis <- str_c(df$Playa_nosp, "_", df$Date_nosp) # Unión parcial
df$ID <- str_c(df$IDbis, "_", df$Time_nosp) # Identificador completo
```

4 Tratamiento y normalización de los comentarios de Infomedusa

Se limpia y normaliza el texto de los comentarios:

- Conversión a mayúsculas y eliminación de acentos.
- Eliminación de enlaces, saltos de línea, signos de puntuación y dígitos.
- Ajuste de espacios y realización de reemplazos específicos.

```
[ ]: df$Comentario <- toupper(df$Comentario)
df$Comentario <- stri_trans_general(df$Comentario, "Latin-ASCII")
df$Comentario <- str_replace_all(df$Comentario, "http\\S*", "")
df$Comentario <- gsub("\n", " ", df$Comentario)
df$Comentario <- gsub("[[:punct:]]", "", df$Comentario)
df$Comentario <- gsub("[[:digit:]]", "", df$Comentario)

# Ajuste de signos de interrogación, exclamación y puntos
df$Comentario <- gsub("[?]+", "?", df$Comentario)
df$Comentario <- gsub("[?]+", "? ", df$Comentario)
df$Comentario <- gsub("[!]+", "!", df$Comentario)
df$Comentario <- gsub("[!]+", "! ", df$Comentario)
df$Comentario <- gsub("[.]+", ".", df$Comentario)
df$Comentario <- gsub("[.]+", ". ", df$Comentario)

# Añadir espacios al inicio y final
df$Comentario <- paste0(" ", df$Comentario, " ")

# Reemplazos específicos para eliminar palabras o patrones no deseados
df$Comentario <- gsub(" A ", " ", df$Comentario)
df$Comentario <- gsub(" AFORTINADAMENTE ", " ", df$Comentario)
df$Comentario <- gsub(" AGRADABLEAGUA ", " ", df$Comentario)
df$Comentario <- gsub(" AGRADABLENADA ", " ", df$Comentario)
df$Comentario <- gsub(" AGRADALE ", " ", df$Comentario)
df$Comentario <- gsub(" AGUS ", " ", df$Comentario)
df$Comentario <- gsub(" AGYA ", " ", df$Comentario)
df$Comentario <- gsub(" AHH ", " ", df$Comentario)
df$Comentario <- gsub(" AHO ", " ", df$Comentario)
df$Comentario <- gsub(" AI ", " ", df$Comentario)
df$Comentario <- gsub(" AIRECASI ", " ", df$Comentario)
df$Comentario <- gsub(" AKI ", " ", df$Comentario)
```

```

df$Comentario <- gsub(" AL ", " ", df$Comentario)
df$Comentario <- gsub(" ALBERQIILLA ", " ", df$Comentario)
df$Comentario <- gsub(" ALG ", " ", df$Comentario)
df$Comentario <- gsub(" ALGASAGUA ", " ", df$Comentario)
df$Comentario <- gsub(" ALGASALGUNA ", " ", df$Comentario)
df$Comentario <- gsub(" ALMALU ", " ", df$Comentario)
df$Comentario <- gsub(" ALMENOS ", " ", df$Comentario)
df$Comentario <- gsub(" ANIMALISTIC ", " ", df$Comentario)
df$Comentario <- gsub(" ANTE ", " ", df$Comentario)
df$Comentario <- gsub(" APERECIDO ", " ", df$Comentario)
df$Comentario <- gsub(" ASOMANDOHAACE ", " ", df$Comentario)
df$Comentario <- gsub(" ATRASEL ", " ", df$Comentario)
df$Comentario <- gsub(" AYERSIN ", " ", df$Comentario)
df$Comentario <- gsub(" BAJO ", " ", df$Comentario)
df$Comentario <- gsub(" BARRONAL ", " ", df$Comentario)
df$Comentario <- gsub(" BEACH ", " ", df$Comentario)
df$Comentario <- gsub(" BENAL ", " ", df$Comentario)
df$Comentario <- gsub(" BIENNO ", " ", df$Comentario)
df$Comentario <- gsub(" BIOLOLOGOS ", " ", df$Comentario)
df$Comentario <- gsub(" BRISITAESO ", " ", df$Comentario)
df$Comentario <- gsub(" BRIZA ", " ", df$Comentario)
df$Comentario <- gsub(" BUE ", " ", df$Comentario)
df$Comentario <- gsub(" BUENAFANTASTICO ", " ", df$Comentario)
df$Comentario <- gsub(" BUENASZ ", " ", df$Comentario)
df$Comentario <- gsub(" BUENATRASPARENTE ", " ", df$Comentario)
df$Comentario <- gsub(" C ", " ", df$Comentario)
df$Comentario <- gsub(" CALHONDA ", " ", df$Comentario)
df$Comentario <- gsub(" CM ", " ", df$Comentario)
df$Comentario <- gsub(" COJER ", " ", df$Comentario)
df$Comentario <- gsub(" COMOVEOQUE ", " ", df$Comentario)
df$Comentario <- gsub(" COMPIS ", " ", df$Comentario)
df$Comentario <- gsub(" CON ", " ", df$Comentario)
df$Comentario <- gsub(" CONTRAPESOEN ", " ", df$Comentario)
df$Comentario <- gsub(" CRISTALINASIN ", " ", df$Comentario)
df$Comentario <- gsub(" CRUSYSLNA ", " ", df$Comentario)
df$Comentario <- gsub(" CULAQUIER ", " ", df$Comentario)
df$Comentario <- gsub(" D ", " ", df$Comentario)
df$Comentario <- gsub(" DE ", " ", df$Comentario)
df$Comentario <- gsub(" DEDECTAR ", " ", df$Comentario)
df$Comentario <- gsub(" DESDE ", " ", df$Comentario)
df$Comentario <- gsub(" DESGRADABLES ", " ", df$Comentario)
df$Comentario <- gsub(" DETRASPLEASE ", " ", df$Comentario)
df$Comentario <- gsub(" DIAFRUTES ", " ", df$Comentario)
df$Comentario <- gsub(" DIASSIN ", " ", df$Comentario)
df$Comentario <- gsub(" DMAX ", " ", df$Comentario)
df$Comentario <- gsub(" DURANTE ", " ", df$Comentario)
df$Comentario <- gsub(" E ", " ", df$Comentario)

```



```

df$Comentario <- gsub(" ELCABO ", " ", df$Comentario)
df$Comentario <- gsub(" EN ", " ", df$Comentario)
df$Comentario <- gsub(" ENCASO ", " ", df$Comentario)
df$Comentario <- gsub(" ENFRENTA ", " ", df$Comentario)
df$Comentario <- gsub(" ENGA ", " ", df$Comentario)
df$Comentario <- gsub(" ENTRE ", " ", df$Comentario)
df$Comentario <- gsub(" ESPECTACULARNO ", " ", df$Comentario)
df$Comentario <- gsub(" ESRAR ", " ", df$Comentario)
df$Comentario <- gsub(" ESTOSS ", " ", df$Comentario)
df$Comentario <- gsub(" ESTUPENDALLEVA ", " ", df$Comentario)
df$Comentario <- gsub(" ESTUPIENDO ", " ", df$Comentario)
df$Comentario <- gsub(" EXCESION ", " ", df$Comentario)
df$Comentario <- gsub(" EXPECTACULAR ", " ", df$Comentario)
df$Comentario <- gsub(" EXPERTX ", " ", df$Comentario)
df$Comentario <- gsub(" FENOMOMAL ", " ", df$Comentario)
df$Comentario <- gsub(" FRESQUITANO ", " ", df$Comentario)
df$Comentario <- gsub(" FRESQUITOSACABAN ", " ", df$Comentario)
df$Comentario <- gsub(" H ", " ", df$Comentario)
df$Comentario <- gsub(" HACIA ", " ", df$Comentario)
df$Comentario <- gsub(" HASTA ", " ", df$Comentario)
df$Comentario <- gsub(" HILLS ", " ", df$Comentario)
df$Comentario <- gsub(" HOLEAJE ", " ", df$Comentario)
df$Comentario <- gsub(" HOYAGUA ", " ", df$Comentario)
df$Comentario <- gsub(" II ", " ", df$Comentario)
df$Comentario <- gsub(" IPOCA ", " ", df$Comentario)
df$Comentario <- gsub(" JN ", " ", df$Comentario)
df$Comentario <- gsub(" JO ", " ", df$Comentario)
df$Comentario <- gsub(" LELE ", " ", df$Comentario)
df$Comentario <- gsub(" LEVANTEMEDUSAS ", " ", df$Comentario)
df$Comentario <- gsub(" M ", " ", df$Comentario)
df$Comentario <- gsub(" MADUSA ", " ", df$Comentario)
df$Comentario <- gsub(" MANANAPARECE ", " ", df$Comentario)
df$Comentario <- gsub(" MARBESA ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSAAAAA ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSAAS ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSAQUE ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSASALGO ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSASEL ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSASESTA ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSASHACE ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSASHACIA ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSASHAY ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSASSE ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSASSOLO ", " ", df$Comentario)
df$Comentario <- gsub(" MEDUSASTEMPERATURA ", " ", df$Comentario)
df$Comentario <- gsub(" MENOSY ", " ", df$Comentario)
df$Comentario <- gsub(" MICHA ", " ", df$Comentario)

```

```

df$Comentario <- gsub(" MINISVALIDOS ", " ", df$Comentario)
df$Comentario <- gsub(" MTS ", " ", df$Comentario)
df$Comentario <- gsub(" MUCHAZISIMAS ", " ", df$Comentario)
df$Comentario <- gsub(" NADANDOO ", " ", df$Comentario)
df$Comentario <- gsub(" NARVAL ", " ", df$Comentario)
df$Comentario <- gsub(" NIZA ", " ", df$Comentario)
df$Comentario <- gsub(" OGIDO ", " ", df$Comentario)
df$Comentario <- gsub(" OLASNI ", " ", df$Comentario)
df$Comentario <- gsub(" OLASUN ", " ", df$Comentario)
df$Comentario <- gsub(" OLEAJENO ", " ", df$Comentario)
df$Comentario <- gsub(" OLEAJEPERO ", " ", df$Comentario)
df$Comentario <- gsub(" OLEJAE ", " ", df$Comentario)
df$Comentario <- gsub(" P ", " ", df$Comentario)
df$Comentario <- gsub(" PADDEL ", " ", df$Comentario)
df$Comentario <- gsub(" PARA ", " ", df$Comentario)
df$Comentario <- gsub(" PERFECTASIN ", " ", df$Comentario)
df$Comentario <- gsub(" PERFECTOEN ", " ", df$Comentario)
df$Comentario <- gsub(" PLAYAAGUA ", " ", df$Comentario)
df$Comentario <- gsub(" PLAYACUANDO ", " ", df$Comentario)
df$Comentario <- gsub(" PLAYASIN ", " ", df$Comentario)
df$Comentario <- gsub(" POR ", " ", df$Comentario)
df$Comentario <- gsub(" PORFI ", " ", df$Comentario)
df$Comentario <- gsub(" PQ ", " ", df$Comentario)
df$Comentario <- gsub(" PRLIN ", " ", df$Comentario)
df$Comentario <- gsub(" Q ", " ", df$Comentario)
df$Comentario <- gsub(" RECALMON ", " ", df$Comentario)
df$Comentario <- gsub(" SACARAASI ", " ", df$Comentario)
df$Comentario <- gsub(" SAM ", " ", df$Comentario)
df$Comentario <- gsub(" SEMANASIN ", " ", df$Comentario)
df$Comentario <- gsub(" SERVANDOAGUA ", " ", df$Comentario)
df$Comentario <- gsub(" SI ", " ", df$Comentario)
df$Comentario <- gsub(" SIMUCHAS ", " ", df$Comentario)
df$Comentario <- gsub(" SOBRE ", " ", df$Comentario)
df$Comentario <- gsub(" SUCIEDADEL ", " ", df$Comentario)
df$Comentario <- gsub(" TAMANOAGUA ", " ", df$Comentario)
df$Comentario <- gsub(" TAMI ", " ", df$Comentario)
df$Comentario <- gsub(" TEMPERARURA ", " ", df$Comentario)
df$Comentario <- gsub(" TRANSPARENTENO ", " ", df$Comentario)
df$Comentario <- gsub(" TRASPARENTE ", " ", df$Comentario)
df$Comentario <- gsub(" TROPE ", " ", df$Comentario)
df$Comentario <- gsub(" TURBIAUN ", " ", df$Comentario)
df$Comentario <- gsub(" VERITO ", " ", df$Comentario)
df$Comentario <- gsub(" VIENTONADA ", " ", df$Comentario)
df$Comentario <- gsub(" VIENTOUN ", " ", df$Comentario)
df$Comentario <- gsub(" X ", " ", df$Comentario)
df$Comentario <- gsub(" XA ", " ", df$Comentario)
df$Comentario <- gsub(" YADE ", " ", df$Comentario)

```

```
df$Comentario <- gsub(" Y ", " ", df$Comentario)
df$Comentario <- gsub(" LA ", " ", df$Comentario)
df$Comentario <- gsub(" EL ", " ", df$Comentario)
df$Comentario <- gsub(" LOS ", " ", df$Comentario)
df$Comentario <- gsub(" LAS ", " ", df$Comentario)

# Eliminar espacios extras (al inicio, final y dobles)
df$Comentario <- trim(df$Comentario, recode.factor = TRUE)
df$Comentario <- gsub("\\s+", " ", df$Comentario)

# Guardar el archivo procesado
write.csv(df, "C:/Users/jairo/Desktop/.../df_2.csv", row.names=FALSE)
```

5 Separación de palabras

Se determina el número máximo de palabras y se separa cada comentario en columnas independientes.

```
[ ]: ncols <- max(stringr::str_count(df$Comentario, " ")) + 1 # Número máximo de
      palabras
      column <- paste("word", 1:ncols, sep = "_") # Nombres para las columnas

df <- tidyr::separate(
  data = df,
  col = Comentario,
  sep = " ",
  into = column,
  remove = FALSE)
```

6 Creación del diccionario

A partir de las palabras separadas se genera un diccionario, se calculan las frecuencias y se filtran las palabras que aparecen menos de 10 veces. También se reconstruyen los comentarios sin las palabras filtradas.

```
[ ]: Diccionario_df <- df[, column]

Diccionario <- Diccionario_df %>%
  gather(key = nombre_columna, value = Diccionario_df) %>%
  filter(!is.na(Diccionario_df)) %>%
  select(Diccionario_df) %>%
  mutate(Diccionario_df = stringr::str_to_upper(Diccionario_df)) %>%
  group_by(Diccionario_df) %>%
  summarize(n = n()) %>%
  arrange(desc(n))
```

```

# Identificar las palabras que aparecen menos de 10 veces
Diccionario_delete <- Diccionario %>% filter(n < 10)
Diccionario_delete <- Diccionario_delete$Diccionario_df

# Reemplazar esas palabras por NA y reconstruir el comentario
Diccionario_m <- as.matrix(Diccionario_df)
Diccionario_m[Diccionario_m %in% Diccionario_delete] <- NA
Diccionario_df2 <- as.data.frame(Diccionario_m)

Diccionario_df2 <- Diccionario_df2 %>%
  unite("New_comentario", colmn, sep = " ", remove = FALSE, na.rm = TRUE)

# Filtrar y conservar solo palabras con 10 o más apariciones
Diccionario <- Diccionario %>% filter(n > 9)
write.table(Diccionario, row.names = FALSE, "Diccionario_2019.txt")

```

7 Codificación *one-hot*

Se genera un vector binario para cada comentario utilizando el diccionario filtrado; cada dígito indica la presencia (1) o ausencia (0) de la palabra correspondiente.

```

[ ]: Comentarios <- df$Comentario
Diccionario_obj <- Diccionario$Diccionario_df

df$Code <- sapply(Comentarios, FUN = function(x) {
  paste0(as.numeric(!is.na(match(Diccionario_obj, strsplit(x, ' ')[[1]]))),
  collapse = ""))

Database_2019 <- df[, c("ID", "Comentario", "Code", "Jellyfish")]
View(Database_2019)
write.table(Database_2019, row.names = FALSE, sep = ";", "Database_2019.txt")

```

8 Análisis de frecuencia de palabras asociadas a ocurrencia de medusas

Se analizan las frecuencias de palabras en dos subconjuntos: Uno con los comentarios con información de presencia (Jellyfish = 1) y otro con información de ausencias (Jellyfish = 0).

8.1 Frecuencia para comentarios con información de presencia de medusas

```

[ ]: Comentarios_2019_n1 <- subset(df, Jellyfish == 1)
ncols_n1 <- max(stringr::str_count(Comentarios_2019_n1$Comentario, " ")) + 1
column_n1 <- paste("word", 1:ncols_n1, sep = "_")

Comentarios_2019_n1 <- tidyr::separate(
  data = Comentarios_2019_n1,

```

```

col = Comentario,
sep = " ",
into = column_n1,
remove = FALSE)

Diccionario_df_n1 <- Comentarios_2019_n1[, column_n1]
Diccionario_n1 <- Diccionario_df_n1 %>%
  gather(key = nombre_columna, value = Diccionario_df_n1) %>%
  filter(!is.na(Diccionario_df_n1)) %>%
  select(Diccionario_df_n1) %>%
  mutate(Diccionario_df_n1 = stringr::str_to_upper(Diccionario_df_n1)) %>%
  unique() %>%
  arrange(Diccionario_df_n1)

Palabras_n1 <- Diccionario_df_n1 %>%
  gather(key = nombre_columna, value = Diccionario_df_n1) %>%
  filter(!is.na(Diccionario_df_n1)) %>%
  select(Diccionario_df_n1) %>%
  mutate(Diccionario_df_n1 = stringr::str_to_upper(Diccionario_df_n1)) %>%
  arrange(Diccionario_df_n1)

Lista_n1 <- Palabras_n1 %>%
  count(Diccionario_df_n1) %>%
  group_by(Diccionario_df_n1) %>%
  arrange(-n, Diccionario_df_n1)
Lista_n1$Diccionario_10 <- Lista_n1$Diccionario_df_n1
Lista_n1$n1 <- Lista_n1$n
Lista_n1 <- subset(Lista_n1, select = c("Diccionario_10", "n1"))

```

8.2 Frecuencia para comentarios con información de ausencia de medusas

```

[ ]: Comentarios_2019_n0 <- subset(df, Jellyfish == 0)
ncols_n0 <- max(stringr::str_count(Comentarios_2019_n0$Comentario, " ")) + 1
column_n0 <- paste("word", 1:ncols_n0, sep = "_")

Comentarios_2019_n0 <- tidyr::separate(
  data = Comentarios_2019_n0,
  col = Comentario,
  sep = " ",
  into = column_n0,
  remove = FALSE
)

Diccionario_df_n0 <- Comentarios_2019_n0[, column_n0]
Diccionario_n0 <- Diccionario_df_n0 %>%
  gather(key = nombre_columna, value = Diccionario_df_n0) %>%
  filter(!is.na(Diccionario_df_n0)) %>%

```

```

select(Diccionario_df_n0) %>%
mutate(Diccionario_df_n0 = stringr::str_to_upper(Diccionario_df_n0)) %>%
unique() %>%
arrange(Diccionario_df_n0)

Palabras_n0 <- Diccionario_df_n0 %>%
gather(key = nombre_columna, value = Diccionario_df_n0) %>%
filter(!is.na(Diccionario_df_n0)) %>%
select(Diccionario_df_n0) %>%
mutate(Diccionario_df_n0 = stringr::str_to_upper(Diccionario_df_n0)) %>%
arrange(Diccionario_df_n0)
Lista_n0 <- Palabras_n0 %>%
count(Diccionario_df_n0) %>%
group_by(Diccionario_df_n0) %>%
arrange(-n, Diccionario_df_n0)
Lista_n0$Diccionario_10 <- Lista_n0$Diccionario_df_n0
Lista_n0$n0 <- Lista_n0$n
Lista_n0 <- subset(Lista_n0, select = c("Diccionario_10", "n0"))

```

8.3 Unión de de tablas de frecuencia

```

[ ]: Lista_10 <- merge(x = Lista_n1, y = Lista_n0, all = TRUE)
Lista_10 <- Lista_10[-c(1),]
Lista_10[is.na(Lista_10)] <- 0
View(Lista_10)
write.table(Lista_10, row.names = FALSE, "Diccionario_2019_1_0.txt")

```

9 Análisis final con diccionario filtrado

Se recalcula la codificación utilizando únicamente las palabras que aparecen 10 o más veces y se genera la base final para el análisis.

```

[ ]: Comentarios <- Diccionario_df2$New_comentario
Diccionario_obj <- Diccionario$Diccionario_df

Diccionario_df2$Code <- sapply(Comentarios, FUN = function(x) {
  paste0(as.numeric(!is.na(match(Diccionario_obj, strsplit(x, ' ')[[1]]))),
  collapse = "")
})
Database_2019 <- Diccionario_df2[, c("ID", "New_comentario", "Code",
  "Jellyfish")]
View(Database_2019)
write.table(Database_2019, row.names = FALSE, sep = ";", "Database_2019.txt")

# Añadir columnas ID y Jellyfish al dataframe final
Diccionario_df2$ID <- df$ID
Diccionario_df2$Jellyfish <- df$Jellyfish

```


Anexo 2

1 Introducción

Tal como se describe en el Capítulo II, este anexo desarrolla un análisis de clasificación mediante un modelo de red neuronal Perceptrón Multicapa (MLP, *Multi-Layer Perceptron*) aplicado a un conjunto de datos. El flujo de trabajo se organiza en los siguientes pasos:

- **Importación de paquetes:** Se importan las librerías esenciales para la manipulación de datos (pandas, numpy), modelado y validación (scikit-learn) y visualización (matplotlib, seaborn).
- **Importación y partición de los datos:** Se leen los datos desde un archivo CSV, se separan las variables de entrada y la variable objetivo, y se dividen en conjuntos de entrenamiento y prueba (70% para entrenamiento y 30% para prueba).
- **Construcción y ajuste del modelo MLP:** Se define un clasificador MLP y se establece una grilla de hiperparámetros (incluyendo el tamaño de las capas ocultas, la función de activación y el número máximo de iteraciones). Se utiliza validación cruzada estratificada repetida junto con GridSearchCV para encontrar la combinación óptima de hiperparámetros que maximice el desempeño del modelo.
- **Evaluación de modelos y selección de los mejores:** Se analizan los 10 modelos con mejor rendimiento en la validación, evaluando métricas como precisión, recall, f1-score y se visualizan resultados relevantes como la matriz de confusión y la curva ROC.
- **Escenarios alternativos y ajustes tras sugerencias de los revisores del artículo de investigación:** Se plantean dos escenarios adicionales:
 - Optimización basada en *Recall*: Se ajusta el modelo utilizando *recall* como métrica de evaluación para reducir falsos negativos.
 - Optimización basada en *F-beta Score*: Se balancean los datos con técnicas como SMOTE y se utiliza *F-beta score* como métrica, buscando un equilibrio en el desempeño del clasificador.

2 Importación de los paquetes necesarios

Mediante el siguiente código, se importan los paquetes necesarios para llevar a cabo los análisis deseados.

```
[ ]: import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.model_selection import train_test_split
```



```

from sklearn.model_selection import GridSearchCV, RepeatedStratifiedKFold
from sklearn.neural_network import MLPClassifier
from sklearn.metrics import accuracy_score, classification_report
from sklearn.metrics import roc_curve, auc
from sklearn.metrics import make_scorer, recall_score, fbeta_score
from sklearn.metrics import confusion_matrix, ConfusionMatrixDisplay
from imblearn.over_sampling import SMOTE

```

3 Importación y partición de los datos

El siguiente código utiliza la ubicación del conjunto de datos para importarlos en Python. Posteriormente, se divide los datos en entrenamiento y prueba, con una proporción de 70% y 30%, respectivamente.

```

[ ]: # Lee los datos de entrada y salida
data = pd.read_csv('C:/Users/jairo/Desktop/.../Data_nn.csv')

# Separa las variables de entrada (X) de la variable de salida (y)
X = data.iloc[:, :-1]
y = data.iloc[:, -1]

# Divide los datos en conjuntos de entrenamiento y prueba (70/30)
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3,
↳ random_state=0)

```

4 Clasificador MLP (*Multi-Layer Perceptron*)

Este código define un modelo de redes neuronales MLP (*Multi-Layer Perceptron*) utilizando `MLPClassifier` de *scikit-learn*. Para ello, se define una grilla de parámetros con diversas configuraciones de la arquitectura de la red, incluyendo el número de neuronas en cada capa oculta, la función de activación utilizada en las capas ocultas y el número máximo de iteraciones para la optimización.

`RepeatedKFold` y `RepeatedStratifiedKFold` son técnicas de validación cruzada que permiten dividir los datos en conjuntos de entrenamiento y prueba, y luego repetir esta división varias veces para obtener una estimación más robusta del desempeño del modelo. La principal diferencia entre ellas es que `RepeatedStratifiedKFold` garantiza que la proporción de muestras en cada clase se mantenga constante en cada iteración de la validación cruzada, lo que es importante en problemas de clasificación desbalanceados. La estrategia de validación cruzada utilizada es `RepeatedStratifiedKFold`, que realiza una validación cruzada estratificada repetida en el conjunto de datos de entrenamiento. Esto se hace para evitar problemas de sobreajuste y para obtener una mejor estimación del rendimiento del modelo.

Por último, se realiza la búsqueda de hiperparámetros utilizando la clase `GridSearchCV` de *scikit-learn*. El modelo se ajusta con los datos de entrenamiento y se evalúa con la métrica de precisión (`accuracy`) utilizando la estrategia de validación cruzada especificada. El parámetro `n_jobs=-1` se utiliza para que la búsqueda de parámetros se realice en paralelo utilizando todos los núcleos de CPU disponibles.

```
[ ]: # Definir el modelo MLP
mlp = MLPClassifier(random_state=1)

# Definir la grilla de parámetros para la búsqueda
param_grid = {
    'hidden_layer_sizes': [[5, 5], [5, 10], [10, 5], [10, 10],
                           [10, 15], [15, 10], [15, 15],
                           [15, 20], [20, 15], [20, 20],
                           [20, 25], [25, 20], [25, 25],
                           [25, 30], [30, 25], [30, 30],
                           [5], [10], [15], [20], [30]],
    'activation': ['logistic', 'tanh', 'relu'],
    'max_iter': [500]}

# Definir la estrategia de validación cruzada con repetición
cv = RepeatedStratifiedKFold(n_splits=5, n_repeats=30, random_state=1)

# Realizar la búsqueda de parámetros con GridSearchCV
grid_search = GridSearchCV(mlp, param_grid, cv=cv, scoring='accuracy',
                             ↪n_jobs=-1)

# Ajustar el modelo con los datos de entrenamiento
grid_search.fit(X_train, y_train)
```

```
[ ]: # Obtener el mejor modelo y sus parámetros
best_model = grid_search.best_estimator_
best_params = grid_search.best_params_
```

`grid_search.best_params_` es un diccionario que contiene los valores de los hiperparámetros que obtuvieron la puntuación más alta durante la búsqueda de parámetros realizada por `GridSearchCV`. Es decir, son los valores óptimos de los hiperparámetros que se utilizarán para crear el modelo final.

Por ejemplo, si en el diccionario `param_grid` que se utilizó para la búsqueda de parámetros, tenías tres hiperparámetros: `hidden_layer_sizes`, `activation`, y `max_iter`, entonces `grid_search.best_params_` contendrá las combinaciones de valores óptimos para esos tres hiperparámetros.

De esta manera, `grid_search.best_params_` es muy útil para replicar el modelo final en el futuro, ya que contiene los valores óptimos de los hiperparámetros utilizados en la búsqueda. Además, puedes utilizar estos valores óptimos como punto de partida para ajustar aún más el modelo en el futuro, en caso de ser necesario.

```
[ ]: print(grid_search.best_score_)
print(grid_search.best_params_)
```

```
[ ]: # Guardamos la base de datos de resultados
pd.DataFrame(grid_search.
    ↪cv_results_)[['rank_test_score', 'mean_fit_time', 'mean_test_score',
    ↪'std_test_score', 'params']].to_csv('GridOptimization.csv')
```

4.1 Analizamos los 10 mejores modelos

Mediante el siguiente código se obtiene una vista general de los resultados de los 10 mejores modelos obtenidos en el ranking.

```
[ ]: # Obtener el ranking de los modelos según su rendimiento
ranking = grid_search.cv_results_['rank_test_score']

# Seleccionar los índices de los diez primeros modelos en el ranking
top10_indices = np.where(ranking < 11)[0]

# Recorrer los modelos seleccionados y evaluarlos con los datos de prueba
for i in top10_indices:
    model = grid_search.best_estimator_.set_params(**grid_search.
    ↪cv_results_['params'][i])
    model.fit(X_train, y_train)
    y_pred = model.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)
    report = classification_report(y_test, y_pred)

    print(f"Modelo {i+1} - Precisión: {accuracy:.3f}")
    print(report)
```

Obtenemos los hiperparámetros utilizados en la generación de estos 10 modelos para conocer sus arquitecturas.

```
[ ]: # Obtener el ranking de los modelos según su rendimiento
ranking = grid_search.cv_results_['rank_test_score']

# Seleccionar los índices de los diez primeros modelos en el ranking
top10_indices = np.where(ranking < 11)[0]

# Recorrer los modelos seleccionados y mostrar su arquitectura
for i in top10_indices:
    model_params = grid_search.cv_results_['params'][i]
    hidden_layers = model_params['hidden_layer_sizes']
    activation = model_params['activation']
    print(f"Modelo {i} - Hidden layers: {hidden_layers}, Activation: ↪
    ↪{activation}")
```

Obtenemos la matriz de confusión del mejor modelo.

```
[ ]: # Calcula la matriz de confusión
conf_mat = confusion_matrix(y_test, y_pred)

# Visualiza la matriz de confusión
sns.heatmap(conf_mat, annot=True, fmt='d', cmap=plt.cm.Blues)
plt.show()
```

Y por último, la curva ROC.

```
[ ]: # Calcula las probabilidades de las predicciones
y_pred_prob = MLP_60.predict_proba(X_test)[: ,1]

# Calcula la tasa de verdaderos positivos y la tasa de falsos positivos
fpr, tpr, thresholds = roc_curve(y_test, y_pred_prob)

# Calcula el área bajo la curva ROC
roc_auc = auc(fpr, tpr)

# Grafica la curva ROC
plt.figure()
plt.plot(fpr, tpr, color='darkorange', lw=2, label='ROC curve (area = %0.2f)' %
    roc_auc)
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic')
plt.legend(loc="lower right")
plt.show()
```

5 Modificaciones de la MLP tras sugerencias de los revisores

El revisor insiste en que el método para abordar el problema del balanceo no es correcto. El revisor argumenta que la métrica utilizada para evaluar el mejor modelo (**Accuracy**) no es la adecuada. Defiende que si queremos minimizar los falsos negativos, deberíamos utilizar la métrica **recall**, y si queremos una aproximación más equilibrada, deberíamos utilizar **F-beta score**.

Además nos recomienda utilizar la librería **imbalanced-learn** para abordar el problema del desbalanceo. Esta librería permite balancear artificialmente los datos.

Vamos a plantear dos escenarios diferentes siguiendo las recomendaciones del revisor: (1) Utilizar la métrica **Recall** para reducir los falsos negativos y así asegurar dónde están las “playas libres de medusas” (premiamos la seguridad); (2) Compensar el desequilibrio de datos y utilizar **F-beta score** como métrica en un escenario mucho más equilibrado.

5.1 Primer escenario: Recall en datos desequilibrados

En este primer escenario, se ejecuta el código de generación del clasificador MLP utilizando como métrica de evaluación **recall** para generar el ranking de los 10 mejores modelos.

```
[ ]: # Definir el modelo MLP
mlp = MLPClassifier(random_state=1)

# Definir la grilla de parámetros para la búsqueda
param_grid = {
    'hidden_layer_sizes': [[5, 5], [5, 10], [10, 5], [10, 10],
```

```

        [10, 15], [15, 10], [15, 15],
        [15, 20], [20, 15], [20, 20],
        [20, 25], [25, 20], [25, 25],
        [25, 30], [30, 25], [30, 30],
        [5], [10], [15], [20], [30]],
        'activation': ['logistic', 'tanh', 'relu'],
        'max_iter': [500]}

# Definir la estrategia de validación cruzada con repetición
cv = RepeatedStratifiedKFold(n_splits=5, n_repeats=30, random_state=1)

# Crear el scorer para Recall de la clase minoritaria (clase 1)
recall_scorer = make_scorer(recall_score, pos_label=1)

# Realizar la búsqueda de parámetros con GridSearchCV usando Recall
grid_search_recall = GridSearchCV(mlp, param_grid, cv=cv,
    ↪scoring=recall_scorer, n_jobs=-1)

# Ajustar el modelo con los datos de entrenamiento
grid_search_recall.fit(X_train, y_train)

# Obtener los mejores parámetros basados en Recall
cv_results = grid_search_recall.cv_results_

# Mostrar los diez mejores modelos basados en Recall
top_indices = np.argsort(cv_results['mean_test_score'])[::-1][:10]

top_models_cv = []
for rank, index in enumerate(top_indices, start=1):
    model_params = cv_results['params'][index]
    mean_recall = cv_results['mean_test_score'][index]
    top_models_cv.append((model_params, mean_recall))

```

Ahora obtenemos una lista con en el ranking, a partir de la cual se genera una tabla con las diferentes métricas de evaluación que podemos obtener de cada uno de ellos.

```

[ ]: from sklearn.metrics import classification_report, accuracy_score
import pandas as pd

# Evaluar los mejores modelos en los datos de prueba
top_models_test = []

for rank, (model_params, mean_recall) in enumerate(top_models_cv, start=1):
    # Crear el modelo con los mejores parámetros encontrados
    best_model = MLPClassifier(random_state=1, **model_params)
    best_model.fit(X_train, y_train)

```

```

# Evaluar el modelo con los datos de prueba
y_pred = best_model.predict(X_test)
accuracy = accuracy_score(y_test, y_pred)
report = classification_report(y_test, y_pred, output_dict=True)

recall_class_1 = report['1']['recall']
precision_class_1 = report['1']['precision']
f1_score_class_1 = report['1']['f1-score']

recall_class_0 = report['0']['recall']
precision_class_0 = report['0']['precision']
f1_score_class_0 = report['0']['f1-score']

# Almacenar los resultados
hidden_layers = model_params['hidden_layer_sizes']
neurons = hidden_layers if isinstance(hidden_layers, list) else [
    hidden_layers]
activation_function = model_params['activation']

top_models_test.append({
    'Model ranking': rank,
    'Hidden layers': len(neurons),
    'Neurons': ','.join(map(str, neurons)),
    'Activation function': activation_function,
    'Accuracy (%)': accuracy * 100,
    'Precision Class 0': precision_class_0,
    'Recall Class 0': recall_class_0,
    'F1-score Class 0': f1_score_class_0,
    'Precision Class 1': precision_class_1,
    'Recall Class 1': recall_class_1,
    'F1-score Class 1': f1_score_class_1})

# Convertir los resultados en un DataFrame de pandas
df_results = pd.DataFrame(top_models_test)

```

Por último, generamos la matriz de confusión de los cuatro mejores modelos para no limitarnos a evaluar el mejor modelo en términos de recall.

```

[ ]: # Evaluar los cuatro mejores modelos en los datos de prueba y obtener la matriz
    de confusión
confusion_matrices = []

for rank, (model_params, mean_recall) in enumerate(top_models_cv[:4], start=1):
    # Crear el modelo con los mejores parámetros encontrados
    best_model = MLPClassifier(random_state=1, **model_params)
    best_model.fit(X_train, y_train)

```

```

# Evaluar el modelo con los datos de prueba
y_pred = best_model.predict(X_test)
cm = confusion_matrix(y_test, y_pred)

# Almacenar la matriz de confusión
confusion_matrices.append({
    'Rank': rank,
    'Model Params': model_params,
    'Confusion Matrix': cm})

# Convertir los resultados en un DataFrame de pandas
df_confusion_matrices = pd.DataFrame(confusion_matrices)

# Mostrar las matrices de confusión
for idx, row in df_confusion_matrices.iterrows():
    print(f"Rank {row['Rank']} model:")
    print(f"Parameters: {row['Model Params']}")
    print(f"Confusion Matrix:\n{row['Confusion Matrix']}\n")

```

5.2 Segundo escenario: *F-beta score* con los datos equilibrados

En este escenario, se utiliza la biblioteca *imbalanced-learn* para sobremuestrear la clase minoritaria y obtener un conjunto de datos más equilibrado para ambas clases. Posteriormente, generamos el clasificador MLP utilizando la métrica de evaluación *F-beta score*.

```

[ ]: # Aplicar SMOTE para balancear los datos de entrenamiento
smote = SMOTE(random_state=1)
X_train_resampled, y_train_resampled = smote.fit_resample(X_train, y_train)

# Crear el scorer para F-beta Score
fbeta_scorer = make_scorer(fbeta_score, beta=0.5, pos_label=1) # Ajustar beta

# Definir el modelo MLP
mlp = MLPClassifier(random_state=1)

# Definir la grilla de parámetros para la búsqueda
param_grid = {
    'hidden_layer_sizes': [[5, 5], [5, 10], [10, 5], [10, 10],
                           [10, 15], [15, 10], [15, 15],
                           [15, 20], [20, 15], [20, 20],
                           [20, 25], [25, 20], [25, 25],
                           [25, 30], [30, 25], [30, 30],
                           [5], [10], [15], [20], [30]],
    'activation': ['logistic', 'tanh', 'relu'],
    'max_iter': [500]}

# Definir la estrategia de validación cruzada con repetición

```

```

cv = RepeatedStratifiedKFold(n_splits=5, n_repeats=30, random_state=1)

# Realizar la búsqueda de parámetros con GridSearchCV usando F-beta Score
grid_search_fbeta = GridSearchCV(mlp, param_grid, cv=cv, scoring=fbeta_scorer,
    ↪n_jobs=-1)

# Ajustar el modelo con los datos de entrenamiento balanceados
grid_search_fbeta.fit(X_train_resampled, y_train_resampled)

# Obtener el mejor modelo basado en F-beta Score
best_fbeta_model = grid_search_fbeta.best_estimator_

# Evaluar el modelo con los datos de prueba
y_pred = best_fbeta_model.predict(X_test)
accuracy = accuracy_score(y_test, y_pred)
report = classification_report(y_test, y_pred)

print(f"Modelo optimizado por F-beta Score - Precisión: {accuracy:.3f}")
print(report)

```

Obtenemos la matriz de confusión del mejor modelo.

```

[ ]: # Generar la matriz de confusión con los datos de prueba
cm = confusion_matrix(y_test, y_pred)

# Mostrar la matriz de confusión
disp = ConfusionMatrixDisplay(confusion_matrix=cm,
    display_labels=best_fbeta_model.classes_)
disp.plot(cmap=plt.cm.Blues)
plt.show()

```


Anexo 3

1 Introducción

Siguiendo la metodología expuesta en el Capítulo II, en este anexo se ajusta un modelo lineal generalizado mixto (GLMM, *Generalized Linear Mixed Model*) utilizando el paquete *lme4* de R. Se analiza la relación entre la presencia de medusas y variables ambientales (temperatura superficial del mar, dirección y velocidad del viento), incorporando un efecto aleatorio asociado a la variable **Set** (Conjunto de playas). Además, se muestran las predicciones y se visualizan los efectos fijos y aleatorios mediante funciones del paquete *effects*.

El flujo del análisis se estructura en los siguientes pasos:

- **Instalación y carga del paquete *lme4*:** Se asegura que el paquete esté instalado y se carga en el entorno.
- **Carga y preparación de los datos:** Se importa la base de datos y se transforma la variable **Set** a factor.
- **Ajuste del modelo GLMM:** Se ajusta un modelo binomial donde la presencia de medusas (*Jellyfish*) se modela en función de **SST**, **Wind_dir** y **Wind_speed**, con un intercepto aleatorio para cada **Set**.
- **Resumen y extracción de efectos:** Se obtiene el resumen del modelo, se extraen los efectos fijos y aleatorios, y se visualizan mediante gráficos.

2 Carga de librerías y datos

Se carga el archivo CSV que contiene la base de datos y se asegura que la variable **Set** se trate como un factor.

```
[ ]: library(effects)
      library(lme4)

df <- read.csv("C:/Users/jairo/Desktop/.../df.csv")
df$Set <- as.factor(df$Set)
```

3 Ajuste del modelo GLMM

Se ajusta un modelo GLMM utilizando la función *glmer()*. En este modelo, la variable respuesta es *Jellyfish* (presencia o ausencia, con distribución binomial) y se incluyen tres variables predictoras: **SST**, **Wind_dir** y **Wind_speed**. Además, se incorpora un efecto aleatorio en el intercepto asociado a **Set**.

```
[ ]: glmm_model <- glmer(Jellyfish ~ SST + Wind_dir + Wind_speed + (1|Set),  
                        family = binomial, data = df)
```

4 Resumen y extracción de efectos

Se muestra un resumen del modelo ajustado, lo que permite evaluar la significación de los parámetros y otros indicadores de ajuste.

```
[ ]: summary(glmm_model)
```

A continuación, se extraen los efectos fijos y los efectos aleatorios del modelo:

```
[ ]: fixed_effects <- fixef(glmm_model)  
     random_effects <- ranef(glmm_model)
```

5 Visualización de los efectos

Para visualizar los efectos del modelo se utiliza el paquete *effects*. Esto permite graficar el efecto marginal de cada predictor sobre la probabilidad de presencia de medusas, facilitando la interpretación del modelo.

```
[ ]: plot(allEffects(glmm_model))
```

Anexo 4

1 Introducción

En este anexo se presenta el flujo de trabajo seguido para el análisis exploratorio de los datos utilizados en el Capítulo III, el cual se estructura en las siguientes etapas:

- **Preparación y corrección de la base de datos:** Se importa la base de datos procesada previamente en R y se realizan ajustes para corregir errores de formato.
- **Geolocalización de las observaciones:** Se fusiona la base de datos original con una fuente externa que contiene las coordenadas de cada municipio. Este proceso permite asignar una ubicación geográfica precisa a cada registro.
- **Creación de subconjuntos de presencia y ausencia:** Dado que el modelo MaxEnt requiere datos de presencia únicamente, se generan subconjuntos que separan los registros en función de la variable de medusas (presencia, `Jellyfish = 1`; y ausencia `Jellyfish = 0`).
- **Visualización y ajuste espacial:** Se utilizan herramientas de visualización para representar los municipios en un mapa, diferenciando visualmente aquellos con datos de presencia, ausencia o ambos.
- **Exportación de registros para modelado:** Con el objetivo de preparar la información para el modelado con MaxEnt, se exportan los datos de presencia en archivos CSV organizados por mes y se generan capas ambientales en formato ESRI ASCII a partir de datos obtenidos de Copernicus.
- **Extracción y procesamiento de datos ambientales:** Se importan archivos NetCDF de variables ambientales y se realizan diversas comprobaciones. Posteriormente, se extraen y convierten las variables a archivos ASCII.
- **Análisis exploratorio de variables ambientales:** Finalmente, se lleva a cabo un análisis exploratorio mediante la aplicación de técnicas de reducción de dimensionalidad para identificar posibles correlaciones y agrupaciones entre las variables.

2 Carga de librerías

```
[ ]: import pandas as pd
import folium
import xarray as xr
import os
import matplotlib.pyplot as plt
import numpy as np
from sklearn.decomposition import PCA
from sklearn.preprocessing import StandardScaler
```

```
from mpl_toolkits.mplot3d import Axes3D
import plotly.graph_objects as go
from sklearn.cluster import KMeans
from statsmodels.stats.outliers_influence import variance_inflation_factor
```

3 Base de datos Infomedusa

Importación de la base de datos.

```
[ ]: df = pd.read_csv("C:/Users/jairo/Desktop/.../Comentarios_2019.csv",
    ↪encoding='iso-8859-1', sep=",")
```

3.1 Preparación de la base de datos de comentarios

```
[ ]: # Reformato de la variable correspondiente a la fecha
Fecha = pd.to_datetime(df.Fecha, format='%Y-%m-%d %H:%M:%S')
```

```
[ ]: # Seleccionar únicamente las variables de interés
df = df.loc[:, ['Fecha', 'Date', 'Time', 'Provincia', 'Municipio', 'Jellyfish']]
```

```
[ ]: # Quitar espacios al final de los municipios que me han dado problemas
df['Municipio'] = df['Municipio'].str.strip()
```

```
[ ]: # Se comprueba la existencia de valores faltantes en alguna de las columnas de
    ↪la base de datos
print(df.isnull().sum())
```

3.2 Geolocalización de los municipios

Debemos geolocalizar los municipios de nuestra base de datos para cruzarlos con los datos ambientales. No es suficiente con tener los nombres de cada uno de estos, también necesitamos conocer dónde se encuentran. Para ello hemos extraído una base de datos de internet con todos los municipios de Andalucía y las coordenadas de su ayuntamiento.

```
[ ]: # Extraigo las localizaciones de cada municipio de una base de datos externa
df_locations = pd.read_csv("C:/Users/jairo/Desktop/.../Municipios_Locations.
    ↪csv", delimiter=";", decimal=",")
```

```
[ ]: # Seleccionar las columnas de df_locations excluyendo la columna 'Provincia'
    ↪duplicada
columns_to_use = df_locations.columns.difference(df.columns).tolist() +
    ↪['Municipio']
# Realizar la fusión usando solo las columnas seleccionadas de df_locations
df = pd.merge(df, df_locations[columns_to_use], on='Municipio', how='left')
```

3.3 Creación de subconjunto de datos de presencia

Dado que los modelos MaxEnt admiten únicamente datos de presencia, vamos a generar un dataframe que contenga solo los valores donde Jellyfish = 1.

```
[ ]: # Filtrar el DataFrame para quedarse solo con los registros donde Jellyfish = 1
df_presence = df.loc[df['Jellyfish'] == 1]
num_observations = len(df_presence)
print(f"Número de observaciones: {num_observations}")
```

Trabajaremos con dos bases de datos. Por un lado, tenemos `df`, que corresponde a la base de datos al completo (datos de presencia y de ausencia). Por otro lado, tenemos `df_presence`, en el que se encuentran solo los datos de presencia. También vamos a crear un subconjunto de ausencias llamado `df_absence` que se usará para la validación de los modelos MaxEnt.

```
[ ]: # Filtrar el DataFrame para quedarse solo con los registros donde Jellyfish = 1
df_absence = df.loc[df['Jellyfish'] == 0]
num_observations = len(df_absence)
print(f"Número de observaciones: {num_observations}")
```

3.4 Representación de municipios en un mapa

Para diferenciar visualmente los municipios con datos de presencia, ausencia, y aquellos que tienen ambos en el mapa, vamos a asignar diferentes colores según el caso. Primero, determinemos la pertenencia de cada municipio a uno de los tres grupos: presencia solamente, ausencia solamente, o ambos. Luego, actualizaremos el bucle para añadir los marcadores con las características visuales correspondientes a cada grupo. Para nuestro caso, el código de color será el siguiente:

- Municipios con datos solo de **presencia**: azul.
- Municipios con datos solo de **ausencia**: rojo.
- Municipios con datos de **presencia y de ausencia**: verde.

```
[ ]: # Encuentra municipios únicos en cada DataFrame
municipios_presencia = set(df_presence['Municipio'].unique())
municipios_ausencia = set(df_absence['Municipio'].unique())
# Municipios con ambos datos (intersección)
municipios_ambos = municipios_presencia.intersection(municipios_ausencia)
# Actualiza los conjuntos para excluir los municipios con ambos datos
municipios_presencia_solo = municipios_presencia - municipios_ambos
municipios_ausencia_solo = municipios_ausencia - municipios_ambos
```

```
[ ]: # Crear un mapa de base
mapa = folium.Map(location=[37.5, -4.5], zoom_start=8)
# Añadir los marcadores de los municipios
for i, row in df.iterrows():
    if row['Municipio'] in municipios_ambos:
        # Municipios con datos de presencia y ausencia
        color = 'green'
        tooltip = f"{row['Municipio']} (Presencia y Ausencia)"
```

```

elif row['Municipio'] in municipios_presencia_solo:
    # Municipios con solo datos de presencia
    color = 'blue'
    tooltip = f"{row['Municipio']} (Solo Presencia)"
elif row['Municipio'] in municipios_ausencia_solo:
    # Municipios con solo datos de ausencia
    color = 'red'
    tooltip = f"{row['Municipio']} (Solo Ausencia)"
else:
    # Si el municipio no está en ninguna de las listas anteriores, usar un
    ↪color neutro
    color = 'grey'
    tooltip = f"{row['Municipio']} (Sin datos de Jellyfish)"
    folium.CircleMarker(location=[row['Latitud'], row['Longitud']], radius=6,
    ↪fill=True,
                                color=color, fill_opacity=0.7, tooltip=tooltip).
    ↪add_to(mapa)
# Mostrar el mapa
mapa

```

Se eliminan los registros situados al oeste de Tarifa para centrar el análisis en el mar de Alborán debido a limitaciones espaciales de Copernicus.

```

[ ]: # Lista de municipios a eliminar
municipios_eliminar = ["Ayamonte", "Isla Cristina", "Lepe", "Punta Umbría",
                        "Palos de la Frontera", "Almonte", "El Puerto de Santa
    ↪Maria",
                        "San Fernando", "Chiclana de la Frontera"]

# Filtrar los DataFrames para excluir filas cuyo Municipio está en la lista de
    ↪eliminación
df = df.loc[~df['Municipio'].isin(municipios_eliminar)]
df_presence = df_presence.loc[~df_presence['Municipio'].
    ↪isin(municipios_eliminar)]
df_absence = df_absence.loc[~df_absence['Municipio'].isin(municipios_eliminar)]

```

4 Datos ambientales

4.1 Importación de datos ambientales

Los datos ambientales van a ser obtenidos del paquete de Copernicus **Mediterranean Sea Physical Reanalysis Product MEDSEA_MULTIYEAR_PHY_006_004**. Dentro de este paquete, hay algunas capas promediadas mensualmente, que será lo que utilizemos. Estas son:

- **med-cmcc-tem-rean-m**: Sea water potential temperature at sea floor (bottomT [°C]) y Sea water potential temperature (thetao [°C])

Se determinó un *Depth range* desde 1 a 100 metros de profundidad.

- **med-cmcc-cur-rean-m**: Eastward sea water velocity (uo [m/s]) y Northward sea water velocity

(vo [m/s]).

Se determinó un *Depth range* de 1 a 100 metros de profundidad (Esta variable tenía un desplegable cuyos valores discretos fueron 1.02 y 104.94)

- **med-cmcc-ssh-rean**: Sea surface height above geoid (zos [m])
- **med-cmcc-mld-rean**: Ocean mixed layer thickness defined by sigma theta (mlotst [m])
- **med-cmcc-sal-rean**: Sea water salinity (so [0.001]).

Se determinó un *Depth range* de 1 a 100 metros de profundidad (Esta variable tenía un desplegable cuyos valores discretos fueron 1.02 y 104.94)

```
[ ]: # Ruta a la carpeta con los archivos .nc
ruta_carpeta = 'C:/Users/jairo/Desktop/.../Datos_copernicus'
# Lista para guardar los conjuntos de datos
datasets = []
# Recorrer todos los archivos .nc en la carpeta
for archivo in os.listdir(ruta_carpeta):
    if archivo.endswith('.nc'):
        ruta_archivo = os.path.join(ruta_carpeta, archivo)
        dataset = xr.open_dataset(ruta_archivo)
        datasets.append(dataset)
```

```
[ ]: # Con el siguiente código se verifica la integridad de cada conjunto de datos
print(datasets[0])
```

4.2 Corrección de las localizaciones de avistamientos de medusas

Para esta tarea se genera un script que identifica las coordenadas marinas más cercanas a cada ayuntamiento donde haya disponible algún dato ambiental extraído de Copernicus. Dado que todos los archivos de datos ambientales extraídos de Copernicus tienen la misma resolución espacial, temporal y límites, es suficiente emplear un archivo cualquiera como referencia.

```
[ ]: dataset = datasets[1]
latitudes_mar = dataset['latitude'].values
longitudes_mar = dataset['longitude'].values
mlotst_data = dataset['mlotst'].isel(time=0)
```

```
[ ]: def encontrar_punto_mar_mas_cercano(lat, lon, latitudes_mar, longitudes_mar, mlotst_data):
    # Inicializar la distancia mínima con un valor alto
    min_dist = np.inf
    closest_lat = None
    closest_lon = None
    # Iterar sobre todos los puntos con datos válidos en 'mlotst'
    for i in range(len(latitudes_mar)):
        for j in range(len(longitudes_mar)):
            # Verificar si el punto actual tiene un dato válido
            if not np.isnan(mlotst_data[i, j]):
                # Calcular la distancia euclidiana al municipio
```



```

        dist = np.sqrt((lat - latitudes_mar[i])**2 + (lon -
↳ longitudes_mar[j])**2)
        if dist < min_dist:
            min_dist = dist
            closest_lat = latitudes_mar[i]
            closest_lon = longitudes_mar[j]
    return closest_lat, closest_lon

```

```

[ ]: # Aplicando la función a df_presence
df_presence['Latitud_sea'], df_presence['Longitud_sea'] = zip(*df_presence.
↳ apply(
    lambda row: encontrar_punto_mar_mas_cercano(row['Latitud'],
↳ row['Longitud'], latitudes_mar, longitudes_mar, mlotst_data.values), axis=1))

```

```

[ ]: # Crear un mapa base centrado en una localización promedio para mejor
↳ visualización
mapa = folium.Map(location=[df_presence['Latitud_sea'].mean(),
↳ df_presence['Longitud_sea'].mean()], zoom_start=8)

# Añadir los marcadores de los municipios
for _, row in df_presence.iterrows():
    folium.Marker(
        location=[row['Latitud_sea'], row['Longitud_sea']],
        popup=row['Municipio'],
        icon=folium.Icon(color="blue", icon="info-sign"),
    ).add_to(mapa)

# Mostrar el mapa
mapa

```

4.3 Exportación de registros de presencia

```
[ ]: # Extraer el mes de la columna 'Fecha' y crear una nueva columna 'mes'
df_presence['mes'] = df_presence['Fecha'].dt.month
# Especificar la ruta de exportación base
ruta_exportacion_base = 'C:/Users/jairo/Desktop/.../Registros_jellyfish/'
# Crear un archivo .csv para cada mes (junio a septiembre)
for mes in range(6, 10):
    df_mes = df_presence[df_presence['mes'] == mes]
    df_maxent = df_mes[['Latitud_sea', 'Longitud_sea']]
    df_maxent.columns = ['Lat', 'Long']
    df_maxent.insert(0, 'Species', 'Jellyfish')
    # Guardar el DataFrame a un archivo .csv
    nombre_archivo_csv = ruta_exportacion_base + f'registros_jellyfish_{mes}'.
    ↪csv'
    df_maxent.to_csv(nombre_archivo_csv, index=False, header=True)
    print(f"Archivo guardado: {nombre_archivo_csv}")
```

4.4 Exportación de datos ambientales a archivo ESRI ASCII

4.4.1 Corrientes marinas

Estos datos necesitan unas modificaciones previas puesto que el paquete no da las componentes uo y vo. Haremos el módulo de las componentes para obtener la resultante.

```
[ ]: dataset_currents = datasets[0]
uo_values = dataset_currents['uo'].values
vo_values = dataset_currents['vo'].values
# Calcula la dirección del agua y conviértela a grados
direccion_agua_rad = np.arctan2(vo_values, uo_values)
direccion_agua_grados = np.degrees(direccion_agua_rad)
# Añade la dirección del agua como una nueva variable al dataset_currents
# Usamos .assign para evitar problemas de tipo, pasando directamente el arreglo ↪
↪NumPy
dataset_currents = dataset_currents.assign(direccion_agua=(("time", "depth", ↪
↪"latitude", "longitude"), direccion_agua_grados))
# Elimina las variables 'uo' y 'vo' para mantener solo la dirección del agua
dataset_currents = dataset_currents.drop_vars(['uo', 'vo'])
# Muestra la estructura del dataset para verificar
print(dataset_currents)
```

Convertimos y exportamos los 'asc'

```
[ ]: # Define el directorio donde guardar los archivos .asc
output_dir = "C:/Users/jairo/Desktop/.../Datos_ambientales/"
os.makedirs(output_dir, exist_ok=True)
# Define los valores NODATA y los parámetros de la cuadrícula
NODATA_value = -9999

# Itera sobre los 4 meses
```

```

for month_index in range(7): # 0 a 3 para Junio a Septiembre
    # Selecciona el valor más pequeño de profundidad
    min_depth_data = dataset_currents['direccion_agua'].isel(time=month_index,
↳ depth=0)
    # Calcula el valor medio de profundidad
    mean_depth_data = dataset_currents['direccion_agua'].isel(time=month_index).
↳ mean(dim='depth')
    # Define los parámetros comunes para los archivos .asc
    ncols = len(min_depth_data.longitude)
    nrows = len(min_depth_data.latitude)
    xllcorner = min_depth_data.longitude.values.min()
    yllcorner = min_depth_data.latitude.values.min()
    cellsize = np.abs(min_depth_data.latitude.values[1] - min_depth_data.
↳ latitude.values[0])
    # Crea un archivo .asc para el valor más pequeño de profundidad
    filename_min = os.path.join(output_dir,
↳ f"direccion_agua_min_depth_mes_{month_index + 3}.asc")
    min_depth_values = np.nan_to_num(min_depth_data.values, nan=NODATA_value)
    min_depth_values = min_depth_values[:, :-1]
    header = f"ncols          {ncols}\nnrows          {nrows}\n" \
            f"xllcorner      {xllcorner}\nyllcorner      {yllcorner}\n" \
            f"cellsize       {cellsize}\nNODATA_value {NODATA_value}\n"
    with open(filename_min, "w") as file:
        file.write(header)
        np.savetxt(file, min_depth_values, fmt="%1.2f")
    # Crea un archivo .asc para el valor medio de profundidad
    filename_mean = os.path.join(output_dir,
↳ f"direccion_agua_mean_depth_mes_{month_index + 3}.asc")
    mean_depth_values = np.nan_to_num(mean_depth_data.values, nan=NODATA_value)
    mean_depth_values = mean_depth_values[:, :-1]
    with open(filename_mean, "w") as file:
        file.write(header)
        np.savetxt(file, mean_depth_values, fmt="%1.2f")
print("Archivos .asc generados con éxito.")

```

4.4.2 Profundidad de capa mixta

```

[ ]: dataset_mld = datasets[1]

os.makedirs(output_dir, exist_ok=True)
# Define los parámetros necesarios para el encabezado del archivo .asc
NODATA_value = -9999
# Extrae los valores necesarios para el encabezado
ncols = len(dataset_mld.longitude)
nrows = len(dataset_mld.latitude)
xllcorner = dataset_mld.longitude.values.min()
yllcorner = dataset_mld.latitude.values.min()

```

```

cellsize = np.abs(dataset_mld.latitude.values[1] - dataset_mld.latitude.
↳values[0])

# Itera sobre los puntos temporales (meses)
for month_index, time_point in enumerate(dataset_mld.time.values):
    # Extrae los datos para el mes actual
    data_for_month = dataset_mld['mldst'].isel(time=month_index)
    # Reemplaza NaN por NODATA_value
    data_values = np.nan_to_num(data_for_month.values, nan=NODATA_value)
    data_values = data_values[:-1]
    # Prepara el texto del encabezado
    header = f"ncols      {ncols}\n" \
            f"nrows      {nrows}\n" \
            f"xllcorner  {xllcorner}\n" \
            f"yllcorner  {yllcorner}\n" \
            f"cellsize   {cellsize}\n" \
            f"NODATA_value {NODATA_value}\n"
    # Define el nombre del archivo basado en el mes
    month_str = str(time_point)[:7] # Extrae YYYY-MM del timestamp
    filename = os.path.join(output_dir, f"mld_{month_str}.asc")
    # Guarda el archivo .asc
    with open(filename, "w") as file:
        file.write(header)
        np.savetxt(file, data_values, fmt="%1.2f")
print("Archivos .asc generados con éxito.")

```

4.4.3 Salinidad

```

[ ]: dataset_salinity = datasets[2]

os.makedirs(output_dir, exist_ok=True)
# Define los parámetros necesarios para el encabezado del archivo .asc
NODATA_value = -9999
# Itera sobre los 4 puntos temporales (meses)
for month_index in range(7): # 0 a 6 para Marzo a Septiembre
    # Selecciona los datos para el valor más bajo de profundidad
    min_depth_data = dataset_salinity['so'].isel(time=month_index, depth=0)
    # Invierte las filas del array para el valor más bajo de profundidad
    min_depth_values = np.flipud(np.nan_to_num(min_depth_data.values,
↳nan=NODATA_value))
    # Calcula el valor medio de profundidad
    mean_depth_data = dataset_salinity['so'].isel(time=month_index).
↳mean(dim='depth')
    # Invierte las filas del array para el valor medio de profundidad
    mean_depth_values = np.flipud(np.nan_to_num(mean_depth_data.values,
↳nan=NODATA_value))
    # Prepara los parámetros comunes para los archivos .asc

```

```

ncols = len(dataset_salinity.longitude)
nrows = len(dataset_salinity.latitude)
xllcorner = dataset_salinity.longitude.values.min()
yllcorner = dataset_salinity.latitude.values.min()
cellsize = np.abs(dataset_salinity.latitude.values[1] - dataset_salinity.
↳latitude.values[0])
# Crea un archivo .asc para el valor más bajo de profundidad
filename_min = os.path.join(output_dir,
↳f"salinity_min_depth_month_{month_index + 3}.asc")
header = f"ncols      {ncols}\nnrows      {nrows}\n" \
        f"xllcorner    {xllcorner}\nyllcorner    {yllcorner}\n" \
        f"cellsize     {cellsize}\nNODATA_value {NODATA_value}\n"
data_values_min = np.nan_to_num(min_depth_data.values, nan=NODATA_value)
data_values_min = data_values_min[:-1]
with open(filename_min, "w") as file:
    file.write(header)
    np.savetxt(file, data_values_min, fmt="%1.2f")
# Crea un archivo .asc para el valor medio de profundidad
filename_mean = os.path.join(output_dir,
↳f"salinity_mean_depth_month_{month_index + 3}.asc")
data_values_mean = np.nan_to_num(mean_depth_data.values, nan=NODATA_value)
data_values_mean = data_values_mean[:-1]
with open(filename_mean, "w") as file:
    file.write(header)
    np.savetxt(file, data_values_mean, fmt="%1.2f")
print("Archivos .asc para la salinidad generados con éxito.")

```

4.4.4 Sea Surface Height

```

[ ]: dataset_ssh = datasets[3]

os.makedirs(output_dir, exist_ok=True)
# Define los parámetros necesarios para el encabezado del archivo .asc
NODATA_value = -9999
# Extrae los valores necesarios para el encabezado
ncols = len(dataset_ssh.longitude)
nrows = len(dataset_ssh.latitude)
xllcorner = dataset_ssh.longitude.values.min()
yllcorner = dataset_ssh.latitude.values.min()
cellsize = np.abs(dataset_ssh.latitude.values[1] - dataset_ssh.latitude.
↳values[0])

# Itera sobre los 4 puntos temporales (meses)
for month_index in range(7): # 0 a 6 para Marzo a Septiembre
    # Extrae los datos para el mes actual
    data_for_month = dataset_ssh['zos'].isel(time=month_index)
    # Reemplaza NaN por NODATA_value

```

```

data_values = np.nan_to_num(data_for_month.values, nan=NODATA_value)
# Invierte las filas del array para corregir el 'modo espejo'
data_values = np.flipud(data_values)
# Prepara el texto del encabezado
header = f"ncols          {ncols}\nnrows          {nrows}\n" \
         f"xllcorner      {xllcorner}\nyllcorner      {yllcorner}\n" \
         f"cellsize       {cellsize}\nNODATA_value {NODATA_value}\n"
# Define el nombre del archivo basado en el mes
filename = os.path.join(output_dir, f"sea_surface_height_month_{month_index_
↪+ 3}.asc")
# Guarda el archivo .asc
with open(filename, "w") as file:
    file.write(header)
    np.savetxt(file, data_values, fmt="%1.2f")
print("Archivos .asc para la altura de la superficie del mar generados con_
↪éxito.")

```

4.4.5 Temperatura

Para los valores de temperatura primero vamos a dividir el paquete en las dos variables que tenemos, fondo y potencial.

```

[ ]: # Dividir datasets[4] en dos datasets separados
dataset_bottomT = datasets[4].drop_vars(['thetao'])
dataset_thetao = datasets[4].drop_vars(['bottomT'])

```

Y ahora procedemos con la exportación

```

[ ]: # Define los parámetros necesarios para el encabezado del archivo .asc
ncols = len(dataset_bottomT.longitude)
nrows = len(dataset_bottomT.latitude)
xllcorner = dataset_bottomT.longitude.values.min()
yllcorner = dataset_bottomT.latitude.values.min()
cellsize = np.abs(dataset_bottomT.latitude.values[1] - dataset_bottomT.latitude.
↪values[0])
NODATA_value = -9999

# Itera sobre los 4 puntos temporales (meses)
for month_index in range(7): # 0 a 6 para Marzo a Septiembre
    # Selecciona los datos de 'bottomT' para el mes correspondiente
    month_data = dataset_bottomT['bottomT'].isel(time=month_index)
    # Prepara los datos y el encabezado del archivo .asc
    data_values = np.nan_to_num(month_data.values, nan=NODATA_value)
    data_values = data_values[:-1]
    header = f"ncols          {ncols}\nnrows          {nrows}\n" \
             f"xllcorner      {xllcorner}\nyllcorner      {yllcorner}\n" \
             f"cellsize       {cellsize}\nNODATA_value {NODATA_value}\n"
    # Crea el archivo .asc para el mes

```

```

filename = os.path.join(output_dir, f"bottomT_month_{month_index + 3}.asc")
with open(filename, "w") as file:
    file.write(header)
    np.savetxt(file, data_values, fmt="%1.2f")
print("Archivos .asc para bottomT generados con éxito.")

```

```

[ ]: # Define los parámetros necesarios para el encabezado del archivo .asc
NODATA_value = -9999

# Itera sobre los 4 puntos temporales (meses)
for month_index in range(7): # 0 a 6 para Marzo a Septiembre
    # Selecciona los datos para el valor más bajo de profundidad
    min_depth_data = dataset_thetao['thetao'].isel(time=month_index, depth=0)
    # Calcula el valor medio de profundidad
    mean_depth_data = dataset_thetao['thetao'].isel(time=month_index).
    ↪mean(dim='depth')
    # Prepara los parámetros comunes para los archivos .asc
    ncols = len(dataset_thetao.longitude)
    nrows = len(dataset_thetao.latitude)
    xllcorner = dataset_thetao.longitude.values.min()
    yllcorner = dataset_thetao.latitude.values.min()
    cellsize = np.abs(dataset_thetao.latitude.values[1] - dataset_thetao.
    ↪latitude.values[0])
    # Invierte las filas del array para ajustar la orientación
    min_depth_values = np.flipud(np.nan_to_num(min_depth_data.values,
    ↪nan=NODATA_value))
    mean_depth_values = np.flipud(np.nan_to_num(mean_depth_data.values,
    ↪nan=NODATA_value))
    # Crea el encabezado para los archivos .asc
    header = f"ncols          {ncols}\nnrows          {nrows}\n" \
            f"xllcorner      {xllcorner}\nyllcorner      {yllcorner}\n" \
            f"cellsize        {cellsize}\nNODATA_value {NODATA_value}\n"
    # Crea un archivo .asc para el valor más bajo de profundidad
    filename_min = os.path.join(output_dir,
    ↪f"thetao_min_depth_month_{month_index + 3}.asc")
    with open(filename_min, "w") as file:
        file.write(header)
        np.savetxt(file, min_depth_values, fmt="%1.2f")
    # Crea un archivo .asc para el valor medio de profundidad
    filename_mean = os.path.join(output_dir,
    ↪f"thetao_mean_depth_month_{month_index + 3}.asc")
    with open(filename_mean, "w") as file:
        file.write(header)
        np.savetxt(file, mean_depth_values, fmt="%1.2f")
print("Archivos .asc para thetato generados con éxito.")

```

4.4.6 Productividad primaria

```
[ ]: dataset_productivity = datasets[5]

# Define los parámetros necesarios para el encabezado del archivo .asc
NODATA_value = -9999

# Itera sobre los 4 puntos temporales (meses)
for month_index in range(7): # 0 a 6 para Marzo a Septiembre
    # Selecciona los datos para el valor más bajo de profundidad
    min_depth_data = dataset_productivity['nppv'].isel(time=month_index,
↳depth=0)
    # Invierte las filas del array para el valor más bajo de profundidad
    min_depth_values = np.flipud(np.nan_to_num(min_depth_data.values,
↳nan=NODATA_value))
    # Calcula el valor medio de profundidad
    mean_depth_data = dataset_productivity['nppv'].isel(time=month_index).
↳mean(dim='depth')
    # Invierte las filas del array para el valor medio de profundidad
    mean_depth_values = np.flipud(np.nan_to_num(mean_depth_data.values,
↳nan=NODATA_value))
    # Prepara los parámetros comunes para los archivos .asc
    ncols = len(dataset_productivity.longitude)
    nrows = len(dataset_productivity.latitude)
    xllcorner = dataset_productivity.longitude.values.min()
    yllcorner = dataset_productivity.latitude.values.min()
    cellsize = np.abs(dataset_productivity.latitude.values[1] -
↳dataset_productivity.latitude.values[0])
    # Crea un archivo .asc para el valor más bajo de profundidad
    filename_min = os.path.join(output_dir,
↳f"productivity_min_depth_month_{month_index + 3}.asc")
    header = f"ncols      {ncols}\nnrows      {nrows}\n" \
            f"xllcorner    {xllcorner}\nyllcorner    {yllcorner}\n" \
            f"cellsize      {cellsize}\nNODATA_value {NODATA_value}\n"
    data_values_min = np.nan_to_num(min_depth_data.values, nan=NODATA_value)
    data_values_min = data_values_min[:-1]
    with open(filename_min, "w") as file:
        file.write(header)
        np.savetxt(file, data_values_min, fmt="%1.2f")
    # Crea un archivo .asc para el valor medio de profundidad
    filename_mean = os.path.join(output_dir,
↳f"productivity_mean_depth_month_{month_index + 3}.asc")
    data_values_mean = np.nan_to_num(mean_depth_data.values, nan=NODATA_value)
    data_values_mean = data_values_mean[:-1]
    with open(filename_mean, "w") as file:
        file.write(header)
        np.savetxt(file, data_values_mean, fmt="%1.2f")
```



```
print("Archivos .asc para la productividad primaria generados con éxito.")
```

4.4.7 Clorofila

```
[ ]: dataset_phyto = datasets[6]

# Define los parámetros necesarios para el encabezado del archivo .asc
NODATA_value = -9999

# Itera sobre los 4 puntos temporales (meses)
for month_index in range(7): # 0 a 6 para Marzo a Septiembre
    # Selecciona los datos para el valor más bajo de profundidad
    min_depth_data = dataset_phyto['chl'].isel(time=month_index, depth=0)
    # Invierte las filas del array para el valor más bajo de profundidad
    min_depth_values = np.flipud(np.nan_to_num(min_depth_data.values,
↪nan=NODATA_value))
    mean_depth_data = dataset_phyto['chl'].isel(time=month_index).
↪mean(dim='depth')
    # Invierte las filas del array para el valor medio de profundidad
    mean_depth_values = np.flipud(np.nan_to_num(mean_depth_data.values,
↪nan=NODATA_value))
    # Prepara los parámetros comunes para los archivos .asc
    ncols = len(dataset_phyto.longitude)
    nrows = len(dataset_phyto.latitude)
    xllcorner = dataset_phyto.longitude.values.min()
    yllcorner = dataset_phyto.latitude.values.min()
    cellsize = np.abs(dataset_phyto.latitude.values[1] - dataset_phyto.latitude.
↪values[0])
    # Crea un archivo .asc para el valor más bajo de profundidad
    filename_min = os.path.join(output_dir,
↪f"phyto_min_depth_month_{month_index + 3}.asc")
    header = f"ncols      {ncols}\nnrows      {nrows}\n" \
             f"xllcorner    {xllcorner}\nyllcorner  {yllcorner}\n" \
             f"cellsize     {cellsize}\nNODATA_value {NODATA_value}\n"
    data_values_min = np.nan_to_num(min_depth_data.values, nan=NODATA_value)
    data_values_min = data_values_min[:-1]
    with open(filename_min, "w") as file:
        file.write(header)
        np.savetxt(file, data_values_min, fmt="%1.2f")
    # Crea un archivo .asc para el valor medio de profundidad
    filename_mean = os.path.join(output_dir,
↪f"phyto_mean_depth_month_{month_index + 3}.asc")
    data_values_mean = np.nan_to_num(mean_depth_data.values, nan=NODATA_value)
    data_values_mean = data_values_mean[:-1]
    with open(filename_mean, "w") as file:
        file.write(header)
        np.savetxt(file, data_values_mean, fmt="%1.2f")
```

```
print("Archivos .asc para el fitoplancton generados con éxito.")
```

5 Análisis exploratorio de datos ambientales

Antes de proceder con los modelos MaxEnt se debe realizar un exploratorio de correlación entre variables ambientales para evitar meter diferentes variables que se expliquen entre ellas. Procederemos importando todas las variables en el formato ASCII de nuevo en Python y procederemos a tratarlas.

5.1 Importación de variables ambientales

```
[ ]: # Define el directorio donde se encuentran los archivos .asc
asc_directory = "C:/Users/jairo/Desktop/.../Datos_ambientales/"

# Función para cargar archivos .asc
def cargar_datos_asc(archivo_asc):
    with open(archivo_asc, 'r') as f:
        header_data = [next(f) for i in range(6)]
        ncols = int(header_data[0].split()[1])
        nrows = int(header_data[1].split()[1])
        xllcorner = float(header_data[2].split()[1])
        yllcorner = float(header_data[3].split()[1])
        cellsize = float(header_data[4].split()[1])
        NODATA_value = float(header_data[5].split()[1])
        data = np.loadtxt(f)
        data[data == NODATA_value] = np.nan
    return data

# Cargar solo los archivos que no contienen "mean" en el nombre
data_dict = {}
for filename in os.listdir(asc_directory):
    if filename.endswith(".asc") and "mean" not in filename:
        file_path = os.path.join(asc_directory, filename)
        variable_name = filename.split(".")[0]
        data_dict[variable_name] = cargar_datos_asc(file_path)

# Convertir los datos a un DataFrame
df_filtered = pd.DataFrame({key: value.flatten() for key, value in data_dict.items()})

# Eliminar filas con NaN
df_filtered.dropna(inplace=True)

# Mostrar las primeras filas del DataFrame
print(df_filtered.head())
```

5.2 Estandarización de los datos ambientales

```
[ ]: # Estandarizar los datos
scaler = StandardScaler()
scaled_data = scaler.fit_transform(df_filtered)
# Mostrar una muestra de los datos estandarizados
print(scaled_data[:5, :])
```

5.3 Análisis de Componentes Principales

5.3.1 Cálculo del número óptimo de componentes principales

```
[ ]: # Aplicar PCA sin limitar el número de componentes
pca_full = PCA()
principal_components_full = pca_full.fit_transform(scaled_data)
# Mostrar la varianza explicada acumulada por cada componente
explained_variance_full = np.cumsum(pca_full.explained_variance_ratio_)
# Generar el nuevo scree plot
plt.figure(figsize=(8,6))
plt.plot(range(1, len(explained_variance_full) + 1), explained_variance_full,
        marker='o', linestyle='--')
plt.xlabel('Número de Componentes Principales')
plt.ylabel('Varianza Explicada Acumulada')
plt.title('Screeplot')
plt.grid()
plt.show()
```

```
[ ]: # Aplicar PCA con el número óptimo de componentes
pca_opt = PCA(n_components=10)
principal_components_opt = pca_opt.fit_transform(scaled_data)
# Crear un DataFrame con los componentes principales
pca_df_opt = pd.DataFrame(data=principal_components_opt, columns=[f'PC{i+1}']
        for i in range(10))
# Mostrar la varianza explicada
print("Varianza explicada por cada componente principal:", pca_opt.
        explained_variance_ratio_)
```

5.3.2 Visualización de los primeros componentes

```
[ ]: # Graficar las primeras dos componentes principales
plt.figure(figsize=(8,6))
plt.scatter(pca_df_opt['PC1'], pca_df_opt['PC2'])
plt.xlabel('Componente Principal 1')
plt.ylabel('Componente Principal 2')
plt.title('Análisis de Componentes Principales (PCA)')
plt.show()
```

La distribución es interesante, con algunos patrones y agrupamientos claros que se podrían analizar

más a fondo. Las dos primeras componentes capturan un 54% de la varianza, lo que es significativo, pero podría ser interesante explorar una visualización en 3D para incluir la tercera componente, ya que también explica un buen porcentaje de la varianza.

```
[ ]: # Crear la figura
fig = plt.figure(figsize=(8,6))
ax = fig.add_subplot(111, projection='3d')
# Graficar las tres primeras componentes principales
ax.scatter(pca_df_opt['PC1'], pca_df_opt['PC2'], pca_df_opt['PC3'], c='b',
           ↪marker='o')
# Etiquetas de los ejes
ax.set_xlabel('Componente Principal 1')
ax.set_ylabel('Componente Principal 2')
ax.set_zlabel('Componente Principal 3')
plt.title('Análisis de Componentes Principales (PCA) - 3D')
plt.show()
```

```
[ ]: # Crear un nuevo DataFrame solo con las componentes principales seleccionadas
df_reducido = pd.DataFrame(data=principal_components_opt[:, :3],
                           ↪columns=['PC1', 'PC2', 'PC3'])
```

He transformado las variables ambientales originales en un espacio de dimensiones reducidas, donde las tres primeras componentes capturan aproximadamente el 65% de la varianza total de tus datos.

Vamos a realizar un biplot de las dos primeras componentes junto con los autovectores de las variables más contribuyentes a los componentes principales

```
[ ]: # Crear un biplot
def biplot(score, coeff, labels=None):
    xs = score[:, 0]
    ys = score[:, 1]
    n = coeff.shape[0]
    scalex = 1.0 / (xs.max() - xs.min())
    scaley = 1.0 / (ys.max() - ys.min())
    plt.scatter(xs * scalex, ys * scaley)
    for i in range(n):
        plt.arrow(0, 0, coeff[i, 0], coeff[i, 1], color='r', alpha=0.5)
        if labels is None:
            plt.text(coeff[i, 0] * 1.15, coeff[i, 1] * 1.15, "Var" + str(i+1),
                    ↪color='g', ha='center', va='center')
        else:
            plt.text(coeff[i, 0] * 1.15, coeff[i, 1] * 1.15, labels[i],
                    ↪color='g', ha='center', va='center')
    plt.xlabel("Componente Principal 1")
    plt.ylabel("Componente Principal 2")
    plt.grid()

# Obtenemos las dos primeras componentes y los coeficientes de las variables
```

```
plt.figure(figsize=(8, 6))
biplot(principal_components_opt, np.transpose(pca_opt.components_[0:2, :]),
       labels=df_filtered.columns)
plt.show()
```

El biplot muestra tanto las observaciones (puntos azules) como las variables originales (vectores en rojo). Parece que hay demasiadas variables con etiquetas que se superponen, lo que dificulta la interpretación.

Para mejorar la visualización voy a reducir el número de variables mostradas, filtrando las más relevantes.

```
[ ]: # Obtener los loadings
loadings = pd.DataFrame(pca_opt.components_.T, columns=[f'PC{i+1}' for i in
               range(pca_opt.n_components_)], index=df_filtered.columns)
# Mostrar los loadings para las primeras dos componentes
print(loadings[['PC1', 'PC2', 'PC3']])
```

```
[ ]: # Obtener los loadings
loadings = pd.DataFrame(pca_opt.components_.T, columns=[f'PC{i+1}' for i in
               range(pca_opt.n_components_)], index=df_filtered.columns)
# Filtrar variables con una contribución significativa
threshold = 0.2
relevant_variables = loadings[(loadings['PC1'].abs() > threshold) |
                             (loadings['PC2'].abs() > threshold) |
                             (loadings['PC3'].abs() > threshold)]
# Mostrar las variables relevantes
print(relevant_variables)
```

Volvemos a graficar, ahora con menos variables.

```
[ ]: # Obtener los índices de las variables relevantes en el DataFrame original
indices_relevantes = [df_filtered.columns.get_loc(var) for var in
                      relevant_variables.index]
# Filtrar los loadings correspondientes a las variables relevantes
coeff_relevantes = pca_opt.components_[:, indices_relevantes]
# Crear el biplot con las variables relevantes
plt.figure(figsize=(8, 6))
biplot(principal_components_opt[:, 0:2], coeff_relevantes.T,
       labels=relevant_variables.index)
plt.show()
```

Esto sigue siendo un poco caótico. Vamos a tratar de darle una tercera dimensión a la gráfica para ver con más claridad. También vamos a hacerlo interactivo para poder realizar un diagnóstico más óptimo de la situación.

```
[ ]: # Crear una figura en 3D interactiva con un tamaño más grande
fig = go.Figure()
# Añadir las flechas correspondientes a las variables relevantes
```

```

for var in relevant_variables.index:
    fig.add_trace(go.Scatter3d(
        x=[0, relevant_variables.loc[var, 'PC1']],
        y=[0, relevant_variables.loc[var, 'PC2']],
        z=[0, relevant_variables.loc[var, 'PC3']],
        mode='lines+markers+text',
        marker=dict(size=4),
        line=dict(color='red', width=3),
        text=[None, var], # Añadir etiquetas al final de la flecha
        textposition="top center", # Posición de la etiqueta
        name=var))
# Ajustar los límites de los ejes
fig.update_layout(
    scene=dict(
        xaxis=dict(range=[-0.3, 0.3], title='PC1'),
        yaxis=dict(range=[-0.3, 0.3], title='PC2'),
        zaxis=dict(range=[-0.3, 0.3], title='PC3')),
    width=1000, # Ajustar el tamaño de la figura (más grande)
    height=1000,
    title="Three-dimensional plot of the PCA loadings",
    showlegend=False)
# Mostrar la figura
fig.show()

```

Análisis cluster k-means.

```

[ ]: # Obtener las coordenadas de las variables relevantes
coords = relevant_variables[['PC1', 'PC2', 'PC3']]
# Usar K-means para agrupar las variables
n_clusters = 4 # Ajustar
kmeans = KMeans(n_clusters=n_clusters)
kmeans.fit(coords)
# Añadir las etiquetas de los clusters al DataFrame de variables relevantes
relevant_variables['cluster'] = kmeans.labels_

```

```

[ ]: # Crear una lista de colores para los clusters
colors = ['red', 'green', 'blue', 'purple', 'orange', 'yellow']
# Crear una figura en 3D interactiva con un tamaño más grande
fig = go.Figure()
# Añadir las flechas correspondientes con colores según su cluster
for var in relevant_variables.index:
    cluster_color = colors[relevant_variables.loc[var, 'cluster']]
    fig.add_trace(go.Scatter3d(
        x=[0, relevant_variables.loc[var, 'PC1']],
        y=[0, relevant_variables.loc[var, 'PC2']],
        z=[0, relevant_variables.loc[var, 'PC3']],
        mode='lines+markers+text',
        marker=dict(size=4),

```

```

        line=dict(color=cluster_color, width=3),
        text=[None, var], # Añadir etiquetas al final de la flecha
        textposition="top center", # Posición de la etiqueta
        showlegend=False # Desactivar la leyenda
    ))
# Ajustar los límites de los ejes
fig.update_layout(
    scene=dict(
        xaxis=dict(range=[-0.3, 0.3], title='PC1'),
        yaxis=dict(range=[-0.3, 0.3], title='PC2'),
        zaxis=dict(range=[-0.3, 0.3], title='PC3')),
    width=800, # Ajustar el tamaño de la figura (más grande)
    height=800,
    title="Three-dimensional plot of the PCA loadings"
)
# Mostrar la figura
fig.show()

```

Para mejorar la calidad de la figura, voy a cambiar el nombre de las variables, así será mejor en el manuscrito final.

```

[ ]: # Listar las variables relevantes que serán representadas
variables_representadas = relevant_variables.index.tolist()
# Mostrar la lista de variables
print("Variables que serán representadas:")
for var in variables_representadas:
    print(var)

```

```

[ ]: nombre_amigable = {'Nombre original': 'Nombre deseado'} # Adaptar para cada
    ↪ variable

```

Generamos de nuevo la figura pero con los nuevos nombres de las variables.

```

[ ]: # Crear una lista de colores para los clusters
colors = ['red', 'green', 'blue', 'purple', 'orange', 'yellow']
# Crear una figura en 3D interactiva con un tamaño más grande
fig = go.Figure()
# Añadir las flechas correspondientes con colores según su cluster
for var in relevant_variables.index:
    cluster_color = colors[relevant_variables.loc[var, 'cluster']] # Color
    ↪ basado en el cluster
    nombre_var = nombre_amigable.get(var, var)
    fig.add_trace(go.Scatter3d(
        x=[0, relevant_variables.loc[var, 'PC1']],
        y=[0, relevant_variables.loc[var, 'PC2']],
        z=[0, relevant_variables.loc[var, 'PC3']],
        mode='lines+markers+text',
        marker=dict(size=4),

```

```

        line=dict(color=cluster_color, width=3),
        text=[None, nombre_var], # Usar el nombre amigable
        textposition="top center", # Posición de la etiqueta
        showlegend=False # Desactivar la leyenda))
# Ajustar los límites de los ejes
fig.update_layout(
    scene=dict(
        xaxis=dict(range=[-0.3, 0.3], title='PC1'),
        yaxis=dict(range=[-0.3, 0.3], title='PC2'),
        zaxis=dict(range=[-0.3, 0.3], title='PC3')),
    width=800, # Ajustar el tamaño de la figura (más grande)
    height=800,
    title="Three-dimensional plot of the PCA loadings")
# Mostrar la figura
fig.show()

```

Por último, veamos qué variables han quedado en cada cluster antes de continuar con la reducción de dimensionalidad.

```

[ ]: # Agrupar las variables por cluster y mostrar cuáles pertenecen a cada grupo
for cluster in range(n_clusters):
    print(f"Variables en el cluster {cluster}:")
    variables_en_cluster = relevant_variables[relevant_variables['cluster'] ==
    ↪cluster].index.tolist()
    print(variables_en_cluster)
    print("\n")

```

5.3.3 Análisis de los clusters para reducción de dimensionalidad

Para reducir esta multicolinealidad, se utiliza el VIF (Variance Inflation Factor). Este índice mide cuánto de la varianza de una variable explicativa es explicada por las demás variables del modelo. Si el VIF de una variable es mayor a un umbral (normalmente se usa 5 o 10), esa variable está altamente colineada con otras y debe ser eliminada.

Reducción de dimensionalidad del Clúster 0

```

[ ]: # Filtrar las variables del cluster 0
variables_cluster_0 = relevant_variables[relevant_variables['cluster'] == 0].
    ↪index.tolist()
# Crear un DataFrame con las variables del cluster 0
df_cluster_0 = df_filtered[variables_cluster_0]

```

```

[ ]: # Función para calcular el VIF de un conjunto de variables
def calcular_vif(df):
    vif_data = pd.DataFrame()
    vif_data['Variable'] = df.columns
    vif_data['VIF'] = [variance_inflation_factor(df.values, i) for i in
    ↪range(df.shape[1])]
    return vif_data

```



```

# Filtrar las variables del cluster 1
variables_cluster_0 = relevant_variables[relevant_variables['cluster'] == 0].
    ↪index.tolist()
# Crear un DataFrame con las variables del cluster 1
df_cluster_0 = df_filtered[variables_cluster_0]

# Iterar hasta que todas las variables tengan un VIF < 5 o queden 1-2 variables
while True:
    # Calcular el VIF para las variables actuales
    vif = calcular_vif(df_cluster_0)
    # Obtener el VIF más alto
    max_vif = vif['VIF'].max()
    # Mostrar el resultado de la iteración
    print(vif)
    # Si el VIF máximo es menor que 5 o solo quedan 1-2 variables, detener
    if max_vif < 5 or df_cluster_0.shape[1] <= 2:
        break
    # Eliminar la variable con el VIF más alto
    variable_a_eliminar = vif.loc[vif['VIF'].idxmax(), 'Variable']
    print(f"Eliminando la variable: {variable_a_eliminar} con VIF: {max_vif}")
    variables_cluster_0.remove(variable_a_eliminar)
    df_cluster_0 = df_filtered[variables_cluster_0]

# Mostrar las variables restantes y su VIF
print("Variables finales seleccionadas del cluster 0:")
print(vif)

```

Reducción de dimensionalidad del Clúster 1

```

[ ]: # Función para calcular el VIF de un conjunto de variables
def calcular_vif(df):
    vif_data = pd.DataFrame()
    vif_data['Variable'] = df.columns
    vif_data['VIF'] = [variance_inflation_factor(df.values, i) for i in
    ↪range(df.shape[1])]
    return vif_data
# Filtrar las variables del cluster 1
variables_cluster_1 = relevant_variables[relevant_variables['cluster'] == 1].
    ↪index.tolist()
# Crear un DataFrame con las variables del cluster 1
df_cluster_1 = df_filtered[variables_cluster_1]

# Iterar hasta que todas las variables tengan un VIF < 5 o queden 1-2 variables
while True:
    # Calcular el VIF para las variables actuales
    vif = calcular_vif(df_cluster_1)
    # Obtener el VIF más alto

```

```

max_vif = vif['VIF'].max()
# Mostrar el resultado de la iteración
print(vif)
# Si el VIF máximo es menor que 5 o solo quedan 1-2 variables, detener
if max_vif < 5 or df_cluster_1.shape[1] <= 2:
    break
# Eliminar la variable con el VIF más alto
variable_a_eliminar = vif.loc[vif['VIF'].idxmax(), 'Variable']
print(f"Eliminando la variable: {variable_a_eliminar} con VIF: {max_vif}")
variables_cluster_1.remove(variable_a_eliminar)
df_cluster_1 = df_filtered[variables_cluster_1]

# Mostrar las variables restantes y su VIF
print("Variables finales seleccionadas del cluster 1:")
print(vif)

```

Reducción de dimensionalidad del Clúster 2

```

[ ]: # Función para calcular el VIF de un conjunto de variables
def calcular_vif(df):
    vif_data = pd.DataFrame()
    vif_data['Variable'] = df.columns
    vif_data['VIF'] = [variance_inflation_factor(df.values, i) for i in
↳range(df.shape[1])]
    return vif_data
# Filtrar las variables del cluster 2
variables_cluster_2 = relevant_variables[relevant_variables['cluster'] == 2].
↳index.tolist()
# Crear un DataFrame con las variables del cluster 2
df_cluster_2 = df_filtered[variables_cluster_2]
# Iterar hasta que todas las variables tengan un VIF < 5 o queden 1-2 variables
while True:
    # Calcular el VIF para las variables actuales
    vif = calcular_vif(df_cluster_2)
    # Obtener el VIF más alto
    max_vif = vif['VIF'].max()
    # Mostrar el resultado de la iteración
    print(vif)
    # Si el VIF máximo es menor que 5 o solo quedan 1-2 variables, detener
    if max_vif < 5 or df_cluster_2.shape[1] <= 2:
        break
    # Eliminar la variable con el VIF más alto
    variable_a_eliminar = vif.loc[vif['VIF'].idxmax(), 'Variable']
    print(f"Eliminando la variable: {variable_a_eliminar} con VIF: {max_vif}")
    variables_cluster_2.remove(variable_a_eliminar)
    df_cluster_2 = df_filtered[variables_cluster_2]

# Mostrar las variables restantes y su VIF

```

```
print("Variables finales seleccionadas del cluster 2:")
print(vif)
```

Reducción de dimensionalidad del Clúster 3

```
[ ]: # Función para calcular el VIF de un conjunto de variables
def calcular_vif(df):
    vif_data = pd.DataFrame()
    vif_data['Variable'] = df.columns
    vif_data['VIF'] = [variance_inflation_factor(df.values, i) for i in
    ↪range(df.shape[1])]
    return vif_data
# Filtrar las variables del cluster 3
variables_cluster_3 = relevant_variables[relevant_variables['cluster'] == 3].
    ↪index.tolist()
# Crear un DataFrame con las variables del cluster 3
df_cluster_3 = df_filtered[variables_cluster_3]
# Iterar hasta que todas las variables tengan un VIF < 5 o queden 1-2 variables
while True:
    # Calcular el VIF para las variables actuales
    vif = calcular_vif(df_cluster_3)
    # Obtener el VIF más alto
    max_vif = vif['VIF'].max()
    # Mostrar el resultado de la iteración
    print(vif)
    # Si el VIF máximo es menor que 5 o solo quedan 1-2 variables, detener
    if max_vif < 5 or df_cluster_3.shape[1] <= 2:
        break
    # Eliminar la variable con el VIF más alto
    variable_a_eliminar = vif.loc[vif['VIF'].idxmax(), 'Variable']
    print(f"Eliminando la variable: {variable_a_eliminar} con VIF: {max_vif}")
    variables_cluster_3.remove(variable_a_eliminar)
    df_cluster_3 = df_filtered[variables_cluster_3]

# Mostrar las variables restantes y su VIF
print("Variables finales seleccionadas del cluster 3:")
print(vif)
```

5.4 Variables ambientales finales

Tras el procedimiento de reducción de multicolinealidad, hemos reducido la base de datos ambiental a las siguientes variables:

- Cluster 0: salinity_min_depth_month_6 y thetao_min_depth_month_7
- Cluster 1: productivity_min_depth_month_4 y bottomT_month_9
- Cluster 2: mld_2019-04 y sea_surface_height_month_8
- Cluster 3: direccion_agua_min_depth_mes_4 y phyto_min_depth_month_7

Anexo 5

1 Introducción

De acuerdo con el protocolo de validación expuesto en el Capítulo III, este anexo documenta la comparación entre las predicciones de MaxEnt y los registros empíricos de ausencia de medusas. El análisis se estructura en las siguientes etapas:

- **Generación y visualización de mapas MaxEnt:** Se importan los archivos ASCII generados por el modelo MaxEnt. Estos archivos se procesan y se representan como mapas de calor que muestran la probabilidad de presencia de medusas.
- **Construcción de mapas de calor a partir de datos de ausencia:** A partir de los registros de ausencia, se crea una malla regular que cubre el área de estudio. Se cuenta el número de observaciones de ausencia en cada celda de la grilla y, para suavizar las variaciones locales y reducir el ruido, se aplica un filtro gaussiano. El resultado es un mapa de densidad de ausencias.
- **Alineación y comparación espacial:** Se ajustan y alinean las grillas obtenidas de las predicciones de MaxEnt y de las densidades de ausencia, utilizando máscaras para eliminar celdas con valores faltantes (NaN) y asegurando que ambas tengan las mismas dimensiones espaciales. Se definen umbrales y se generan máscaras binarias para ambas variables.
- **Cuantificación de Coincidencias y Visualización Comparativa:** Se superponen las máscaras binarias para identificar las celdas donde coinciden las áreas de baja probabilidad (predichas por MaxEnt) y las de alta densidad de ausencia. Se cuantifica el número de coincidencias y se calcula el porcentaje respecto al total de celdas clasificadas como de alta densidad.

2 Carga de librerías

```
[ ]: import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
import geopandas as gpd
from matplotlib.colors import BoundaryNorm
from scipy.ndimage import gaussian_filter
from folium.plugins import HeatMap
from shapely.geometry import box
from scipy.ndimage import zoom
from scipy.ndimage import distance_transform_edt
from matplotlib.colors import ListedColormap
```

Importación de la base de datos.

```
[ ]: df = pd.read_csv("C:/Users/jairo/Desktop/.../Comentarios_2019.csv",  
    ↪encoding='iso-8859-1', sep=",")
```

3 Análisis de resultados obtenidos por MaxEnt

3.1 Generación de mapas MaxEnt

```
[ ]: # Función para cargar el archivo ASCII y procesar los datos  
def load_ascii(filepath):  
    with open(filepath, 'r') as f:  
        # Ignorar las primeras 6 líneas de metadatos  
        for _ in range(6):  
            next(f)  
        # Leer los datos en una matriz numpy  
        data = np.loadtxt(f)  
    return data  
  
# Función para crear un mapa de calor  
def plot_map(ax, data, month, cmap):  
    # Reemplazar los valores nulos (-9999) por NaN  
    data[data == -9999] = np.nan  
    # Definir la norma para mapear los valores de probabilidad a la paleta de  
    ↪colores  
    norm = BoundaryNorm(np.linspace(0, 1, cmap.N), cmap.N)  
    # Crear el mapa de calor y aplicar el colormap  
    heatmap = ax.imshow(data, cmap=cmap, norm=norm, origin='lower')  
    # Añadir el mes en la esquina superior izquierda  
    ax.text(0.05, 0.95, month, color='black', fontsize=14, ha='left', va='top',  
    ↪transform=ax.transAxes)  
    ax.set_xticks([])  
    ax.set_yticks([])  
    return heatmap  
  
# Cargar los archivos ASCII  
data1 = load_ascii('C:/Users/jairo/Desktop/.../Jellyfish_6.asc')  
data2 = load_ascii('C:/Users/jairo/Desktop/.../Jellyfish_7.asc')  
data3 = load_ascii('C:/Users/jairo/Desktop/.../Jellyfish_8.asc')  
data4 = load_ascii('C:/Users/jairo/Desktop/.../Jellyfish_9.asc')  
# Aplicar el flip solo una vez y asignar a nuevas variables  
flipped_data1 = np.flipud(data1)  
flipped_data2 = np.flipud(data2)  
flipped_data3 = np.flipud(data3)  
flipped_data4 = np.flipud(data4)  
  
# Crear la figura y los subgráficos
```

```

fig, axs = plt.subplots(2, 2, figsize=(10, 5))
# Crear los mapas de calor con los datos invertidos y añadir el mes en la
↪esquina
heatmap1 = plot_map(axs[0, 0], flipped_data1, 'June', plt.get_cmap('jet'))
heatmap2 = plot_map(axs[0, 1], flipped_data2, 'July', plt.get_cmap('jet'))
heatmap3 = plot_map(axs[1, 0], flipped_data3, 'August', plt.get_cmap('jet'))
heatmap4 = plot_map(axs[1, 1], flipped_data4, 'September', plt.get_cmap('jet'))
# Añadir una barra de color pequeña a la derecha de los gráficos
cbar_ax = fig.add_axes([0.92, 0.15, 0.02, 0.30]) # Barra de color vertical a
↪la derecha de todos
cbar = fig.colorbar(heatmap1, cax=cbar_ax, orientation='vertical')
cbar.set_label('Probability of jellyfish', fontsize=9)
cbar.set_ticks([0, 0.25, 0.5, 0.75, 1]) # Ajustar los ticks de la barra de
↪color
cbar.ax.tick_params(labelsize=10)
# Ajustar el espaciado entre las figuras
plt.subplots_adjust(wspace=0.1, hspace=0.1) # Ajustar espacio entre las figuras
plt.show()

```

3.2 Validación de resultados obtenidos por MaxEnt

Se genera un mapa de calor de las ausencias de medusas con el fin de utilizarlo como fuente de verdad para comparar con las predicciones generadas por el modelo MaxEnt.

```

[ ]: # Aplicando la función a df_presence
df['Latitud_sea'], df['Longitud_sea'] = zip(*df.apply(
    lambda row: encontrar_punto_mar_mas_cercano(row['Latitud'],
↪row['Longitud'], latitudes_mar, longitudes_mar, mlotst_data.values), axis=1))

```

Se delimita el área de estudio y se recorta el shapefile de la península ibérica para que solo abarque el mar, dejando las zonas terrestres en negro. Luego, se extraen las observaciones de ausencia de medusas (Jellyfish = 0), y se distribuyen en una grilla regular.

La densidad de las ausencias se calcula contando cuántas observaciones caen en cada celda de la grilla. Para suavizar la representación, se aplica un filtro gaussiano, lo que permite extender la influencia de cada punto de ausencia a celdas cercanas. Finalmente, el mapa de calor se visualiza utilizando el colormap invertido YlGnBu_r, donde los colores más claros indican zonas de mayor densidad de ausencias.

Mapa de España obtenido de: <https://www.marineregions.org/gazetteer.php?p=details&id=7124>.
 FAO. 2019. Aquatic sciences and fisheries information system. Geographic authority list. ASFIS-7 (Rev. 3). Rome

3.2.1 Mapa de calor ausencias en junio

```

[ ]: # Paso 1: Cargar el shapefile terrestre que cubre la península
gdf_terrestre = gpd.read_file('C:/Users/jairo/Desktop/.../europecountries.shp')
gdf_terrestre = gdf_terrestre.to_crs(epsg=4326) # Asegurarse de que esté en
↪WGS84

```

```

# Definir los límites del Mar de Alborán
bounds_alboran = box(-5.5, 35.94, -1.625, 37.31)
# Crear un GeoDataFrame con los límites del área de estudio
gdf_alboran = gpd.GeoDataFrame([1], geometry=[bounds_alboran], crs="EPSG:4326")

# Paso 2: Recortar el shapefile terrestre al área de interés (Mar de Alborán)
gdf_terrestre_recortado = gpd.clip(gdf_terrestre, gdf_alboran)

# Paso 3: Filtrar el DataFrame para obtener solo las ausencias (Jellyfish == 0)
↳ en junio
df_junio_ausencias = df[(df['Jellyfish'] == 0) & (df['Date'].str.
↳ contains('2019-06'))]

# Paso 4: Crear una grilla regular sobre el Mar de Alborán
grid_size = 0.05 # Ajustar el tamaño de las celdas de la grilla (en grados)
x_min, x_max, y_min, y_max = -5.5, -1.625, 35.94, 37.31
# Crear una grilla regular de puntos (centro de cada celda)
x = np.arange(x_min, x_max, grid_size)
y = np.arange(y_min, y_max, grid_size)
xv, yv = np.meshgrid(x, y)
# Crear una grilla vacía para almacenar los conteos de ausencias
grilla = np.zeros_like(xv, dtype=float)

# Paso 5: Contar las ausencias en cada celda de la grilla
for i in range(len(df_junio_ausencias)):
    lat = df_junio_ausencias.iloc[i]['Latitud']
    lon = df_junio_ausencias.iloc[i]['Longitud']
    # Encontrar la celda correspondiente
    ix = np.searchsorted(x, lon) - 1
    iy = np.searchsorted(y, lat) - 1
    if 0 <= ix < len(x) and 0 <= iy < len(y):
        grilla[iy, ix] += 1 # Sumar una ausencia en la celda correspondiente

# Paso 6: Aplicar un filtro gaussiano para suavizar el heatmap
grilla_suavizada = gaussian_filter(grilla, sigma=1)

# Paso 7: Graficar la península en negro como una capa por encima y el heatmap
↳ de ausencias en la grilla
fig, ax = plt.subplots(figsize=(10, 10))
# Graficar el heatmap sobre la grilla
c = ax.pcolormesh(x, y, grilla_suavizada, cmap='YlGnBu_r', shading='auto',
↳ zorder=1)
# Añadir la barra de color
cb = fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
cb.set_label('Densidad de Ausencias de Medusas')
# Graficar la península recortada en negro por encima del heatmap
gdf_terrestre_recortado.plot(ax=ax, color='black', zorder=2)

```

```

# Ajustar los límites del mapa a la región de interés
ax.set_xlim([-5.5, -1.625])
ax.set_ylim([35.94, 37.31])
# Añadir título y etiquetas
plt.title("Mapa de calor de ausencias de medusas en junio", fontsize=15)
plt.xlabel("Longitud")
plt.ylabel("Latitud")
# Mostrar el mapa
plt.show()
fig.savefig('heatmap_ausencias_junio.png', dpi=300, bbox_inches='tight')

```

Mapa de calor de presencias en Junio Bajo petición de los revisores, generamos mapa de calor para las presencias y así poder comparar con los resultados de otros mapas.

```

[ ]: # Paso 1: Cargar el shapefile terrestre que cubre la península
gdf_terrestre = gpd.read_file('C:/Users/jairo/Desktop/.../europecountries.shp')
gdf_terrestre = gdf_terrestre.to_crs(epsg=4326) # Asegurarse de que esté en
↳ WGS84
# Definir los límites del Mar de Alborán
bounds_alboran = box(-5.5, 35.94, -1.625, 37.31)
# Crear un GeoDataFrame con los límites del área de estudio
gdf_alboran = gpd.GeoDataFrame([1], geometry=[bounds_alboran], crs="EPSG:4326")

# Paso 2: Recortar el shapefile terrestre al área de interés (Mar de Alborán)
gdf_terrestre_recortado = gpd.clip(gdf_terrestre, gdf_alboran)

# Paso 3: Filtrar el DataFrame para obtener solo las ausencias (Jellyfish == 0)
↳ en junio
df_junio_presencias = df[(df['Jellyfish'] == 1) & (df['Date'].str.
↳ contains('2019-06'))]

# Paso 4: Crear una grilla regular sobre el Mar de Alborán
grid_size = 0.05 # Ajustar el tamaño de las celdas de la grilla (en grados)
x_min, x_max, y_min, y_max = -5.5, -1.625, 35.94, 37.31
# Crear una grilla regular de puntos (centro de cada celda)
x = np.arange(x_min, x_max, grid_size)
y = np.arange(y_min, y_max, grid_size)
xv, yv = np.meshgrid(x, y)
# Crear una grilla vacía para almacenar los conteos de ausencias
grilla = np.zeros_like(xv, dtype=float)

# Paso 5: Contar las ausencias en cada celda de la grilla
for i in range(len(df_junio_presencias)):
    lat = df_junio_presencias.iloc[i]['Latitud']
    lon = df_junio_presencias.iloc[i]['Longitud']
    # Encontrar la celda correspondiente
    ix = np.searchsorted(x, lon) - 1

```



```

    iy = np.searchsorted(y, lat) - 1
    if 0 <= ix < len(x) and 0 <= iy < len(y):
        grilla[iy, ix] += 1 # Sumar una ausencia en la celda correspondiente

# Paso 6: Aplicar un filtro gaussiano para suavizar el heatmap
grilla_suavizada = gaussian_filter(grilla, sigma=1)

# Paso 7: Graficar la península en negro como una capa por encima y el heatmap
↳ de ausencias en la grilla
fig, ax = plt.subplots(figsize=(10, 10))
# Graficar el heatmap sobre la grilla
c = ax.pcolormesh(x, y, grilla_suavizada, cmap='YlGnBu_r', shading='auto',
↳ zorder=1)
# Añadir la barra de color
cb = fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
cb.set_label('Densidad de Presencias de Medusas')
# Graficar la península recortada en negro por encima del heatmap
gdf_terrestre_recortado.plot(ax=ax, color='black', zorder=2)
# Ajustar los límites del mapa a la región de interés
ax.set_xlim([-5.5, -1.625])
ax.set_ylim([35.94, 37.31])
# Añadir título y etiquetas
plt.title("Mapa de calor de presencias de medusas en junio", fontsize=15)
plt.xlabel("Longitud")
plt.ylabel("Latitud")
# Mostrar el mapa
plt.show()
fig.savefig('heatmap_presencias_junio.png', dpi=300, bbox_inches='tight')

```

Análisis numérico para junio Se cargan los datos de MaxEnt desde un archivo ASCII para poder analizar las probabilidades de presencia de medusas. Primero, se convierten los valores que representan “NoData” (-9999) en NaN para que sean tratados adecuadamente en los cálculos posteriores. Luego, se ajustan las dimensiones de la grilla de ausencias suavizada para que coincida con las de MaxEnt, utilizando el factor de redimensionamiento apropiado. De esta manera, ambas grillas podrán compararse y analizarse juntas en los pasos posteriores.

```

[ ]: # Cargar los datos de MaxEnt desde el archivo ASCII
ruta_maxent = 'C:/Users/jairo/Desktop/.../Jellyfish.asc'
data_maxent = np.loadtxt(ruta_maxent, skiprows=6) # Saltar las primeras 6
↳ líneas de cabecera
# Reemplazar los -9999 (valor de NoData en MaxEnt) con NaN
data_maxent_clean = np.where(data_maxent == -9999, np.nan, data_maxent)
# Obtener las dimensiones de la grilla de MaxEnt
shape_maxent = data_maxent_clean.shape
print(f"Dimensiones de MaxEnt: {shape_maxent}")
# Dimensiones de la grilla suavizada (ausencias)
shape_grilla_suavizada = grilla_suavizada.shape

```

```

print(f"Dimensiones de la grilla suavizada: {shape_grilla_suavizada}")
# Redimensionar la grilla suavizada para que coincida con MaxEnt
factor_x = shape_maxent[1] / shape_grilla_suavizada[1]
factor_y = shape_maxent[0] / shape_grilla_suavizada[0]
grilla_suavizada_resized = zoom(grilla_suavizada, (factor_y, factor_x))
print(f"Dimensiones de la grilla suavizada ajustada: {grilla_suavizada_resized.
↪shape}")

```

En este paso, se corrige la visualización de los datos de MaxEnt invirtiendo verticalmente la matriz para que las coordenadas geográficas sean correctas. A continuación, se generan dos gráficos en paralelo: - En el primer gráfico se muestra el mapa de calor de las áreas de baja probabilidad de presencia de medusas según MaxEnt. - En el segundo gráfico se visualizan las áreas de alta densidad de ausencias de medusas en la grilla suavizada. De esta manera se puede comparar visualmente las áreas de baja probabilidad y alta densidad de ausencias.

```

[ ]: # Invertir los datos del MaxEnt verticalmente para corregir el problema
data_maxent_clean_flipped = np.flipud(data_maxent_clean)
# Crear una figura con dos subgráficos
fig, ax = plt.subplots(1, 2, figsize=(15, 7))
# Graficar el mapa de calor de MaxEnt invertido
c1 = ax[0].imshow(data_maxent_clean_flipped, cmap='Reds', extent=[-5.5, -1.625, ↪
↪35.94, 37.31], origin='lower')
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
fig.colorbar(c1, ax=ax[0], fraction=0.02, pad=0.04)
# Graficar el mapa de calor de densidad de ausencias (grilla suavizada)
c2 = ax[1].imshow(grilla_suavizada_resized, cmap='Blues', extent=[-5.5, -1.625, ↪
↪35.94, 37.31], origin='lower')
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
fig.colorbar(c2, ax=ax[1], fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.suptitle("Comparación de áreas de baja probabilidad (MaxEnt) y alta ↪
↪densidad de ausencias", fontsize=16)
plt.tight_layout()
plt.show()

```

Se realiza un recuento de NaN para verificar que las áreas correspondientes a tierra firme son la misma en ambas bases.

Ahora se deben convertir todas las celdas de la grilla de fuente de verdad en NaN donde corresponda, puesto que estas son las que representan tierra firme.

```

[ ]: # Aplicar los NaN de data_maxent_clean_flipped a grilla_suavizada_resized
grilla_suavizada_resized[np.isnan(data_maxent_clean_flipped)] = np.nan

```

```
[ ]: # Crear máscaras para NaN y valores válidos
mask_nan_maxent = np.isnan(data_maxent_clean_flipped)
mask_nan_ausencias = np.isnan(grilla_suavizada_resized)
# Graficar las posiciones NaN y valores válidos con etiquetas claras
fig, ax = plt.subplots(1, 2, figsize=(15, 5))
# Graficar el mapa de posiciones NaN en MaxEnt
ax[0].imshow(mask_nan_maxent, cmap='gray', extent=[-5.5, -1.625, 35.94, 37.31],
    ↪origin='lower')
ax[0].set_title('Posiciones de NaN en MaxEnt (Blanco = NaN)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar el mapa de posiciones NaN en Densidad de Ausencias
ax[1].imshow(mask_nan_ausencias, cmap='gray', extent=[-5.5, -1.625, 35.94, 37.
    ↪31], origin='lower')
ax[1].set_title('Posiciones de NaN en Densidad de Ausencias (Blanco = NaN)')
ax[1].set_xlabel('Longitud')
plt.tight_layout()
plt.show()
```

Se genera una máscara donde sólo nos quedaremos con los datos de interés, que en este caso son los que están pegados a la costa, a una distancia máxima de 5 casillas de grilla.

```
[ ]: # Crear una máscara booleana donde los valores válidos son True y los NaN son
    ↪False
mask_valid_maxent = ~np.isnan(data_maxent_clean_flipped)
# Calcular la distancia desde las celdas con datos válidos
distancia_a_datos = distance_transform_edt(mask_valid_maxent)
# Definir un umbral de distancia en celdas (5 en este caso)
umbral_distancia = 5
# Crear una nueva máscara que mantenga las celdas dentro del buffer de
    ↪distancia y convierta el resto a NaN
mask_buffer = distancia_a_datos <= umbral_distancia
# Aplicar la máscara: celdas fuera del buffer se convierten en NaN
data_maxent_filtrada = np.where(mask_buffer, data_maxent_clean_flipped, np.nan)
# Verificar la cantidad de NaN en el resultado final
n_nan = np.isnan(data_maxent_filtrada).sum()
print(f"Cantidad de NaN después de aplicar el filtro: {n_nan}")
# Graficar las posiciones NaN después de aplicar el filtro de distancia
plt.imshow(np.isnan(data_maxent_filtrada), cmap='gray', extent=[-5.5, -1.625,
    ↪35.94, 37.31], origin='lower')
plt.title('Posiciones de NaN después de aplicar el buffer de distancia
    ↪(Revisado)')
plt.xlabel('Longitud')
plt.ylabel('Latitud')
plt.show()
```

Se aplica la máscara en la fuente de verdad.

```
[ ]: # Graficar la grilla suavizada para visualizar la distribución de densidad de
      ↪ausencias
fig, ax = plt.subplots(figsize=(8, 6))
c = ax.imshow(grilla_suavizada_resized, cmap='Blues', extent=[-5.5, -1.625, 35.
      ↪94, 37.31], origin='lower')
ax.set_title('Mapa de densidad de ausencias (grilla suavizada)')
ax.set_xlabel('Longitud')
ax.set_ylabel('Latitud')
# Añadir la barra de color
fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.show()
```

```
[ ]: # Aplicar la máscara a la grilla suavizada
grilla_filtrada = np.where(mask_buffer == 1, grilla_suavizada_resized, np.nan)
# Graficar la grilla filtrada
fig, ax = plt.subplots(figsize=(8, 6))
c = ax.imshow(grilla_filtrada, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.
      ↪31], origin='lower')
ax.set_title('Mapa de densidad de ausencias filtrado (grilla suavizada)')
ax.set_xlabel('Longitud')
ax.set_ylabel('Latitud')
# Añadir la barra de color
fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
plt.show()
```

En este paso, se comparan las áreas de baja probabilidad de presencia de medusas (según MaxEnt) con las áreas de alta densidad de ausencias observadas.

1. Definimos los umbrales para lo que consideramos baja probabilidad en MaxEnt y alta densidad de ausencias.
2. Creamos máscaras para estas áreas usando los umbrales definidos, asegurándonos de que solo se comparen las áreas con datos válidos.
3. Creamos una máscara base que diferenciará las zonas por encima (en negro) y por debajo (en azul claro) de las áreas con datos.
4. Calculamos las coincidencias entre las áreas de baja probabilidad y alta ausencia.
5. Finalmente, graficamos las tres áreas en paralelo: (i) Áreas de baja probabilidad (MaxEnt) en rojo; (ii) Áreas de alta densidad de ausencias en azul; (iii) Coincidencias entre ambas en verde. De esta manera, podemos visualizar las coincidencias entre las predicciones de baja probabilidad y las áreas observadas de alta ausencia.

```
[ ]: # Definir los umbrales para baja probabilidad de MaxEnt y alta densidad de
      ↪ausencias
threshold_probabilidad_baja = 0.49 # Umbral de baja probabilidad en MaxEnt
threshold_ausencia_alta = 0.1 # Umbral de alta densidad de ausencias

areas_baja_probabilidad = np.where(data_maxent_clean_flipped <
      ↪threshold_probabilidad_baja, 1, 0)
```

```

areas_alta_ausencia = np.where(grilla_filtrada > threshold_ausencia_alta, 1, 0)
valid_mask = ~np.isnan(data_maxent_clean_flipped) & ~np.isnan(grilla_filtrada)
areas_baja_probabilidad = np.where(valid_mask, areas_baja_probabilidad, np.nan)
areas_alta_ausencia = np.where(valid_mask, areas_alta_ausencia, np.nan)
coincidencias = np.logical_and(areas_baja_probabilidad == 1,
    ↪ areas_alta_ausencia == 1)
cantidad_coincidencias = np.sum(coincidencias)
total_areas_baja_probabilidad = np.sum(areas_baja_probabilidad == 1)
total_areas_alta_ausencia = np.sum(areas_alta_ausencia == 1)
porcentaje_coincidencia = (cantidad_coincidencias / total_areas_alta_ausencia)
    ↪ * 100
print(f"Coincidencias: {cantidad_coincidencias}")
print(f"Total áreas de baja probabilidad: {total_areas_baja_probabilidad}")
print(f"Total áreas de alta ausencia: {total_areas_alta_ausencia}")
print(f"Porcentaje de coincidencia: {porcentaje_coincidencia:.2f}%")
fig, ax = plt.subplots(1, 3, figsize=(18, 6))

# Graficar las áreas de baja probabilidad (MaxEnt)
ax[0].imshow(areas_baja_probabilidad, cmap='Reds', extent=[-5.5, -1.625, 35.94,
    ↪ 37.31], origin='lower')
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar las áreas de alta densidad de ausencias
ax[1].imshow(areas_alta_ausencia, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.
    ↪ 31], origin='lower')
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
# Graficar las coincidencias
ax[2].imshow(coincidencias, cmap='Purples', extent=[-5.5, -1.625, 35.94, 37.
    ↪ 31], origin='lower')
ax[2].set_title('Coincidencias entre baja probabilidad y alta ausencia')
ax[2].set_xlabel('Longitud')
plt.tight_layout()
plt.show()

```

```

[ ]: # Definir los umbrales para baja probabilidad de MaxEnt y alta densidad de
    ↪ ausencias
threshold_probabilidad_baja = 0.49 # Umbral de baja probabilidad en MaxEnt
threshold_ausencia_alta = 0.1 # Umbral de alta densidad de ausencias

# Paso 1: Crear una máscara para las áreas de baja probabilidad en MaxEnt
areas_baja_probabilidad = np.where(data_maxent_clean_flipped <
    ↪ threshold_probabilidad_baja, 1, 0)

# Paso 2: Crear una máscara para las áreas de alta densidad de ausencias

```

```

areas_alta_ausencia = np.where(grilla_filtrada > threshold_ausencia_alta, 1, 0)

# Paso 3: Aplicar la máscara para asegurarnos de que solo comparamos las áreas
↳válidas (donde no hay NaN)
valid_mask = ~np.isnan(data_maxent_clean_flipped) & ~np.isnan(grilla_filtrada)
# Filtrar solo las áreas válidas
areas_baja_probabilidad = np.where(valid_mask, areas_baja_probabilidad, np.nan)
areas_alta_ausencia = np.where(valid_mask, areas_alta_ausencia, np.nan)
# Crear una máscara base donde se diferencien las zonas por "encima" y "debajo"
base_mask = np.where(np.isnan(data_maxent_clean_flipped), 2, 1) # 2: encima
↳(negro), 1: debajo (azul claro)

# Paso 4: Comparar las áreas con ambos umbrales y máscara
coincidencias = np.logical_and(areas_baja_probabilidad == 1,
↳areas_alta_ausencia == 1)
# Paso 4.1: No dejar valores en NaN, convertir en 0
coincidencias_mask = np.full_like(coincidencias, 0) # Iniciar todo en 0
coincidencias_mask[coincidencias] = 1 # Marcar solo las coincidencias
# Calcular la cantidad de coincidencias
cantidad_coincidencias = np.sum(coincidencias) # Cuenta las coincidencias
↳válidas
total_areas_baja_probabilidad = np.sum(areas_baja_probabilidad == 1)
total_areas_alta_ausencia = np.sum(areas_alta_ausencia == 1)
# Calcular el porcentaje de coincidencias sobre las áreas de alta ausencia
porcentaje_coincidencia = (cantidad_coincidencias / total_areas_alta_ausencia)
↳* 100
print(f"Coincidencias: {cantidad_coincidencias}")
print(f"Total áreas de baja probabilidad: {total_areas_baja_probabilidad}")
print(f"Total áreas de alta ausencia: {total_areas_alta_ausencia}")
print(f"Porcentaje de coincidencia: {porcentaje_coincidencia:.2f}%")

# Paso 5: Graficar las áreas de coincidencia
fig, ax = plt.subplots(1, 3, figsize=(15, 5), sharey=True)
# Crear un colormap para las áreas "encima" (negro) y "debajo" (azul claro)
cmap_background = ListedColormap(['lightblue', 'black'])
# Graficar la base para todas las gráficas (azul claro y negro)
for i in range(3):
    ax[i].imshow(base_mask, cmap=cmap_background, extent=[-5.5, -1.625, 35.94,
↳37.31], origin='lower', zorder=1)
# Graficar las áreas de baja probabilidad (MaxEnt)
ax[0].imshow(areas_baja_probabilidad, cmap='Reds', extent=[-5.5, -1.625, 35.94,
↳37.31], origin='lower', zorder=2)
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar las áreas de alta densidad de ausencias

```

```

ax[1].imshow(areas_alta_ausencia, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.
↳31], origin='lower', zorder=2)
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
# Graficar las coincidencias, donde 0 es transparente y 1 es la coincidencia en
↳morado
ax[2].imshow(coincidencias_mask, cmap='Greens', extent=[-5.5, -1.625, 35.94, 37.
↳31], origin='lower', zorder=2, alpha=0.8)
ax[2].set_title('Coincidencias')
ax[2].set_xlabel('Longitud')
plt.subplots_adjust(wspace=0.2, hspace=0.3) # Ajustar el espaciado entre
↳columnas (wspace) y filas (hspace)
plt.tight_layout()
plt.show()

```

3.2.2 Mapa de calor ausencias en julio

```

[ ]: # Paso 1: Cargar el shapefile terrestre que cubre la península
gdf_terrestre = gpd.read_file('C:/Users/jairo/Desktop/.../europecountries.shp')
gdf_terrestre = gdf_terrestre.to_crs(epsg=4326) # Asegurarse de que esté en
↳WGS84
# Definir los límites del Mar de Alborán
bounds_alboran = box(-5.5, 35.94, -1.625, 37.31)
# Crear un GeoDataFrame con los límites del área de estudio
gdf_alboran = gpd.GeoDataFrame([1], geometry=[bounds_alboran], crs="EPSG:4326")
# Paso 2: Recortar el shapefile terrestre al área de interés (Mar de Alborán)
gdf_terrestre_recortado = gpd.clip(gdf_terrestre, gdf_alboran)
# Paso 3: Filtrar el DataFrame para obtener solo las ausencias (Jellyfish == 0)
↳en junio
df_julio_ausencias = df[(df['Jellyfish'] == 0) & (df['Date'].str.
↳contains('2019-07'))]
# Paso 4: Crear una grilla regular sobre el Mar de Alborán
grid_size = 0.05 # Ajustar el tamaño de las celdas de la grilla (en grados)
x_min, x_max, y_min, y_max = -5.5, -1.625, 35.94, 37.31
# Crear una grilla regular de puntos (centro de cada celda)
x = np.arange(x_min, x_max, grid_size)
y = np.arange(y_min, y_max, grid_size)
xv, yv = np.meshgrid(x, y)
# Crear una grilla vacía para almacenar los conteos de ausencias
grilla = np.zeros_like(xv, dtype=float)
# Paso 5: Contar las ausencias en cada celda de la grilla
for i in range(len(df_julio_ausencias)):
    lat = df_julio_ausencias.iloc[i]['Latitud']
    lon = df_julio_ausencias.iloc[i]['Longitud']
    # Encontrar la celda correspondiente
    ix = np.searchsorted(x, lon) - 1

```



```

    iy = np.searchsorted(y, lat) - 1
    if 0 <= ix < len(x) and 0 <= iy < len(y):
        grilla[iy, ix] += 1 # Sumar una ausencia en la celda correspondiente
# Paso 6: Aplicar un filtro gaussiano para suavizar el heatmap
grilla_suavizada = gaussian_filter(grilla, sigma=1)
# Paso 7: Graficar la península en negro como una capa por encima y el heatmap
↳ de ausencias en la grilla
fig, ax = plt.subplots(figsize=(10, 10))
# Graficar el heatmap sobre la grilla
c = ax.pcolormesh(x, y, grilla_suavizada, cmap='YlGnBu_r', shading='auto',
↳ zorder=1)
# Añadir la barra de color
cb = fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
cb.set_label('Densidad de Ausencias de Medusas')
# Graficar la península recortada en negro por encima del heatmap
gdf_terrestre_recortado.plot(ax=ax, color='black', zorder=2)
# Ajustar los límites del mapa a la región de interés
ax.set_xlim([-5.5, -1.625])
ax.set_ylim([35.94, 37.31])
# Añadir título y etiquetas
plt.title("Mapa de calor de ausencias de medusas en julio", fontsize=15)
plt.xlabel("Longitud")
plt.ylabel("Latitud")
plt.show()
fig.savefig('heatmap_ausencias_julio.png', dpi=300, bbox_inches='tight')

```

Mapa de calor de presencias para julio

```

[ ]: # Paso 1: Cargar el shapefile terrestre que cubre la península
gdf_terrestre = gpd.read_file('C:/Users/jairo/Desktop/.../europecountries.shp')
gdf_terrestre = gdf_terrestre.to_crs(epsg=4326) # Asegurarse de que esté en
↳ WGS84
# Definir los límites del Mar de Alborán
bounds_alboran = box(-5.5, 35.94, -1.625, 37.31)
# Crear un GeoDataFrame con los límites del área de estudio
gdf_alboran = gpd.GeoDataFrame([1], geometry=[bounds_alboran], crs="EPSG:4326")
# Paso 2: Recortar el shapefile terrestre al área de interés (Mar de Alborán)
gdf_terrestre_recortado = gpd.clip(gdf_terrestre, gdf_alboran)
# Paso 3: Filtrar el DataFrame para obtener solo las ausencias (Jellyfish == 0)
↳ en junio
df_julio_presencias = df[(df['Jellyfish'] == 1) & (df['Date'].str.
↳ contains('2019-07'))]
# Paso 4: Crear una grilla regular sobre el Mar de Alborán
grid_size = 0.05 # Ajustar el tamaño de las celdas de la grilla (en grados)
x_min, x_max, y_min, y_max = -5.5, -1.625, 35.94, 37.31
# Crear una grilla regular de puntos (centro de cada celda)
x = np.arange(x_min, x_max, grid_size)

```



```

y = np.arange(y_min, y_max, grid_size)
xv, yv = np.meshgrid(x, y)
# Crear una grilla vacía para almacenar los conteos de ausencias
grilla = np.zeros_like(xv, dtype=float)
# Paso 5: Contar las ausencias en cada celda de la grilla
for i in range(len(df_julio_presencias)):
    lat = df_julio_presencias.iloc[i]['Latitud']
    lon = df_julio_presencias.iloc[i]['Longitud']
    # Encontrar la celda correspondiente
    ix = np.searchsorted(x, lon) - 1
    iy = np.searchsorted(y, lat) - 1
    if 0 <= ix < len(x) and 0 <= iy < len(y):
        grilla[iy, ix] += 1 # Sumar una ausencia en la celda correspondiente
# Paso 6: Aplicar un filtro gaussiano para suavizar el heatmap
grilla_suavizada = gaussian_filter(grilla, sigma=1)
# Paso 7: Graficar la península en negro como una capa por encima y el heatmap
↳ de ausencias en la grilla
fig, ax = plt.subplots(figsize=(10, 10))
# Graficar el heatmap sobre la grilla
c = ax.pcolormesh(x, y, grilla_suavizada, cmap='YlGnBu_r', shading='auto',
↳ zorder=1)
# Añadir la barra de color
cb = fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
cb.set_label('Densidad de Presencias de Medusas')
# Graficar la península recortada en negro por encima del heatmap
gdf_terrestre_recortado.plot(ax=ax, color='black', zorder=2)
# Ajustar los límites del mapa a la región de interés
ax.set_xlim([-5.5, -1.625])
ax.set_ylim([35.94, 37.31])
# Añadir título y etiquetas
plt.title("Mapa de calor de presencias de medusas en julio", fontsize=15)
plt.xlabel("Longitud")
plt.ylabel("Latitud")
# Mostrar el mapa
plt.show()
fig.savefig('heatmap_presencias_julio.png', dpi=300, bbox_inches='tight')

```

Análisis numérico para julio

```

[ ]: # Cargar los datos de MaxEnt desde el archivo ASCII
ruta_maxent = 'C:/Users/jairo/Desktop/.../Jellyfish.asc'
data_maxent = np.loadtxt(ruta_maxent, skiprows=6) # Saltar las primeras 6
↳ líneas de cabecera

# Reemplazar los -9999 (valor de NoData en MaxEnt) con NaN
data_maxent_clean = np.where(data_maxent == -9999, np.nan, data_maxent)
# Obtener las dimensiones de la grilla de MaxEnt

```

```

shape_maxent = data_maxent_clean.shape
print(f"Dimensiones de MaxEnt: {shape_maxent}")
# Dimensiones de la grilla suavizada (ausencias)
shape_grilla_suavizada = grilla_suavizada.shape
print(f"Dimensiones de la grilla suavizada: {shape_grilla_suavizada}")
# Redimensionar la grilla suavizada para que coincida con MaxEnt
factor_x = shape_maxent[1] / shape_grilla_suavizada[1]
factor_y = shape_maxent[0] / shape_grilla_suavizada[0]
grilla_suavizada_resized = zoom(grilla_suavizada, (factor_y, factor_x))
print(f"Dimensiones de la grilla suavizada ajustada: {grilla_suavizada_resized.
↪shape}")

```

```

[ ]: # Invertir los datos del MaxEnt verticalmente para corregir el problema
data_maxent_clean_flipped = np.flipud(data_maxent_clean)
# Crear una figura con dos subgráficos
fig, ax = plt.subplots(1, 2, figsize=(15, 7))
# Graficar el mapa de calor de MaxEnt invertido
c1 = ax[0].imshow(data_maxent_clean_flipped, cmap='Reds', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
fig.colorbar(c1, ax=ax[0], fraction=0.02, pad=0.04)
# Graficar el mapa de calor de densidad de ausencias (grilla suavizada)
c2 = ax[1].imshow(grilla_suavizada_resized, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
fig.colorbar(c2, ax=ax[1], fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.suptitle("Comparación de áreas de baja probabilidad (MaxEnt) y alta
↪densidad de ausencias", fontsize=16)
plt.tight_layout()
plt.show()

```

```

[ ]: # Aplicar los NaN de data_maxent_clean_flipped a grilla_suavizada_resized
grilla_suavizada_resized[np.isnan(data_maxent_clean_flipped)] = np.nan

```

```

[ ]: # Crear máscaras para NaN y valores válidos
mask_nan_maxent = np.isnan(data_maxent_clean_flipped)
mask_nan_ausencias = np.isnan(grilla_suavizada_resized)
# Graficar las posiciones NaN y valores válidos con etiquetas claras
fig, ax = plt.subplots(1, 2, figsize=(15, 5))
# Graficar el mapa de posiciones NaN en MaxEnt
ax[0].imshow(mask_nan_maxent, cmap='gray', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[0].set_title('Posiciones de NaN en MaxEnt (Blanco = NaN)')

```

```

ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar el mapa de posiciones NaN en Densidad de Ausencias
ax[1].imshow(mask_nan_ausencias, cmap='gray', extent=[-5.5, -1.625, 35.94, 37.
↪31], origin='lower')
ax[1].set_title('Posiciones de NaN en Densidad de Ausencias (Blanco = NaN)')
ax[1].set_xlabel('Longitud')
plt.tight_layout()
plt.show()

```

```

[ ]: # Crear una máscara booleana donde los valores válidos son True y los NaN son
↪False
mask_valid_maxent = ~np.isnan(data_maxent_clean_flipped)
# Calcular la distancia desde las celdas con datos válidos
distancia_a_datos = distance_transform_edt(mask_valid_maxent)
# Definir un umbral de distancia en celdas (5 en este caso)
umbral_distancia = 5
# Crear una nueva máscara que mantenga las celdas dentro del buffer de
↪distancia y convierta el resto a NaN
mask_buffer = distancia_a_datos <= umbral_distancia
# Aplicar la máscara: celdas fuera del buffer se convierten en NaN
data_maxent_filtrada = np.where(mask_buffer, data_maxent_clean_flipped, np.nan)
# Verificar la cantidad de NaN en el resultado final
n_nan = np.isnan(data_maxent_filtrada).sum()
print(f"Cantidad de NaN después de aplicar el filtro: {n_nan}")
# Graficar las posiciones NaN después de aplicar el filtro de distancia
plt.imshow(np.isnan(data_maxent_filtrada), cmap='gray', extent=[-5.5, -1.625,
↪35.94, 37.31], origin='lower')
plt.title('Posiciones de NaN después de aplicar el buffer de distancia
↪(Revisado)')
plt.xlabel('Longitud')
plt.ylabel('Latitud')
plt.show()

```

```

[ ]: # Graficar la grilla suavizada para visualizar la distribución de densidad de
↪ausencias
fig, ax = plt.subplots(figsize=(8, 6))
c = ax.imshow(grilla_suavizada_resized, cmap='Blues', extent=[-5.5, -1.625, 35.
↪94, 37.31], origin='lower')
ax.set_title('Mapa de densidad de ausencias (grilla suavizada)')
ax.set_xlabel('Longitud')
ax.set_ylabel('Latitud')
# Añadir la barra de color
fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.show()

```

```
[ ]: # Aplicar la máscara a la grilla suavizada
grilla_filtrada = np.where(mask_buffer == 1, grilla_suavizada_resized, np.nan)
# Graficar la grilla filtrada
fig, ax = plt.subplots(figsize=(8, 6))
c = ax.imshow(grilla_filtrada, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.
↳31], origin='lower')
ax.set_title('Mapa de densidad de ausencias filtrado (grilla suavizada)')
ax.set_xlabel('Longitud')
ax.set_ylabel('Latitud')
# Añadir la barra de color
fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.show()
```

```
[ ]: # Definir los umbrales para baja probabilidad de MaxEnt y alta densidad de
↳ausencias
threshold_probabilidad_baja = 0.49 # Umbral de baja probabilidad en MaxEnt
threshold_ausencia_alta = 0.1 # Umbral de alta densidad de ausencias

# Paso 1: Crear una máscara para las áreas de baja probabilidad en MaxEnt
↳usando la matriz filtrada (tras la máscara)
areas_baja_probabilidad = np.where(data_maxent_clean_flipped <
↳threshold_probabilidad_baja, 1, 0)

# Paso 2: Crear una máscara para las áreas de alta densidad de ausencias,
↳aplicando el umbral de alta ausencia
areas_alta_ausencia = np.where(grilla_filtrada > threshold_ausencia_alta, 1, 0)

# Paso 3: Aplicar la máscara para asegurarnos de que solo comparamos las áreas
↳válidas (donde no hay NaN)
valid_mask = ~np.isnan(data_maxent_clean_flipped) & ~np.isnan(grilla_filtrada)

# Filtrar solo las áreas válidas
areas_baja_probabilidad = np.where(valid_mask, areas_baja_probabilidad, np.nan)
areas_alta_ausencia = np.where(valid_mask, areas_alta_ausencia, np.nan)

# Paso 4: Comparar las áreas con ambos umbrales y máscara
coincidencias = np.logical_and(areas_baja_probabilidad == 1,
↳areas_alta_ausencia == 1)
# Calcular la cantidad de coincidencias
cantidad_coincidencias = np.sum(coincidencias)
total_areas_baja_probabilidad = np.sum(areas_baja_probabilidad == 1)
total_areas_alta_ausencia = np.sum(areas_alta_ausencia == 1)
# Calcular el porcentaje de coincidencias sobre las áreas de alta ausencia
porcentaje_coincidencia = (cantidad_coincidencias / total_areas_alta_ausencia)
↳* 100
```

```

print(f"Coincidencias: {cantidad_coincidencias}")
print(f"Total áreas de baja probabilidad: {total_areas_baja_probabilidad}")
print(f"Total áreas de alta ausencia: {total_areas_alta_ausencia}")
print(f"Porcentaje de coincidencia: {porcentaje_coincidencia:.2f}%")

# Paso 5: Graficar las áreas de coincidencia
fig, ax = plt.subplots(1, 3, figsize=(18, 6))
# Graficar las áreas de baja probabilidad (MaxEnt)
ax[0].imshow(areas_baja_probabilidad, cmap='Reds', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar las áreas de alta densidad de ausencias
ax[1].imshow(areas_alta_ausencia, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
# Graficar las coincidencias
ax[2].imshow(coincidencias, cmap='Purples', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[2].set_title('Coincidencias entre baja probabilidad y alta ausencia')
ax[2].set_xlabel('Longitud')
plt.tight_layout()
plt.show()

```

```

[ ]: # Definir los umbrales para baja probabilidad de MaxEnt y alta densidad de ausencias
threshold_probabilidad_baja = 0.49 # Umbral de baja probabilidad en MaxEnt
threshold_ausencia_alta = 0.1 # Umbral de alta densidad de ausencias

# Paso 1: Crear una máscara para las áreas de baja probabilidad en MaxEnt
areas_baja_probabilidad = np.where(data_maxent_clean_flipped < threshold_probabilidad_baja, 1, 0)

# Paso 2: Crear una máscara para las áreas de alta densidad de ausencias
areas_alta_ausencia = np.where(grilla_filtrada > threshold_ausencia_alta, 1, 0)

# Paso 3: Aplicar la máscara para asegurarnos de que solo comparamos las áreas válidas (donde no hay NaN)
valid_mask = ~np.isnan(data_maxent_clean_flipped) & ~np.isnan(grilla_filtrada)
# Filtrar solo las áreas válidas
areas_baja_probabilidad = np.where(valid_mask, areas_baja_probabilidad, np.nan)
areas_alta_ausencia = np.where(valid_mask, areas_alta_ausencia, np.nan)
# Crear una máscara base donde se diferencien las zonas por "encima" y "debajo"
base_mask = np.where(np.isnan(data_maxent_clean_flipped), 2, 1) # 2: encima (negro), 1: debajo (azul claro)

```

```

# Paso 4: Comparar las áreas con ambos umbrales y máscara
coincidencias = np.logical_and(areas_baja_probabilidad == 1,
    ↪ areas_alta_ausencia == 1)
# Paso 4.1: No dejar valores en NaN, convertir en 0
coincidencias_mask = np.full_like(coincidencias, 0) # Iniciar todo en 0
coincidencias_mask[coincidencias] = 1 # Marcar solo las coincidencias
# Calcular la cantidad de coincidencias
cantidad_coincidencias = np.sum(coincidencias) # Cuenta las coincidencias
    ↪ válidas
total_areas_baja_probabilidad = np.sum(areas_baja_probabilidad == 1)
total_areas_alta_ausencia = np.sum(areas_alta_ausencia == 1)
# Calcular el porcentaje de coincidencias sobre las áreas de alta ausencia
porcentaje_coincidencia = (cantidad_coincidencias / total_areas_alta_ausencia)
    ↪ * 100
print(f"Coincidencias: {cantidad_coincidencias}")
print(f"Total áreas de baja probabilidad: {total_areas_baja_probabilidad}")
print(f"Total áreas de alta ausencia: {total_areas_alta_ausencia}")
print(f"Porcentaje de coincidencia: {porcentaje_coincidencia:.2f}%")

# Paso 5: Graficar las áreas de coincidencia
fig, ax = plt.subplots(1, 3, figsize=(15, 5), sharey=True)
# Crear un colormap para las áreas "encima" (negro) y "debajo" (azul claro)
cmap_background = ListedColormap(['lightblue', 'black'])
# Graficar la base para todas las gráficas (azul claro y negro)
for i in range(3):
    ax[i].imshow(base_mask, cmap=cmap_background, extent=[-5.5, -1.625, 35.94,
    ↪ 37.31], origin='lower', zorder=1)
# Graficar las áreas de baja probabilidad (MaxEnt)
ax[0].imshow(areas_baja_probabilidad, cmap='Reds', extent=[-5.5, -1.625, 35.94,
    ↪ 37.31], origin='lower', zorder=2)
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar las áreas de alta densidad de ausencias
ax[1].imshow(areas_alta_ausencia, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.
    ↪ 31], origin='lower', zorder=2)
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
# Graficar las coincidencias, donde 0 es transparente y 1 es la coincidencia en
    ↪ morado
ax[2].imshow(coincidencias_mask, cmap='Greens', extent=[-5.5, -1.625, 35.94, 37.
    ↪ 31], origin='lower', zorder=2, alpha=0.8)
ax[2].set_title('Coincidencias')
ax[2].set_xlabel('Longitud')

```

```
plt.subplots_adjust(wspace=0.2, hspace=0.3) # Ajustar el espaciado entre
↳ columnas (wspace) y filas (hspace)
plt.savefig('comparacion_probabilidad_ausencias_07.png', dpi=300,
↳ bbox_inches='tight')
plt.tight_layout()
plt.show()
```

3.2.3 Mapa de calor ausencias en agosto

```
[ ]: # Paso 1: Cargar el shapefile terrestre que cubre la península
gdf_terrestre = gpd.read_file('C:/Users/jairo/Desktop/.../europcountries.shp')
gdf_terrestre = gdf_terrestre.to_crs(epsg=4326) # Asegurarse de que esté en
↳ WGS84
# Definir los límites del Mar de Alborán
bounds_alboran = box(-5.5, 35.94, -1.625, 37.31)
# Crear un GeoDataFrame con los límites del área de estudio
gdf_alboran = gpd.GeoDataFrame([1], geometry=[bounds_alboran], crs="EPSG:4326")
# Paso 2: Recortar el shapefile terrestre al área de interés (Mar de Alborán)
gdf_terrestre_recortado = gpd.clip(gdf_terrestre, gdf_alboran)
# Paso 3: Filtrar el DataFrame para obtener solo las ausencias (Jellyfish == 0)
↳ en agosto
df_agosto_ausencias = df[(df['Jellyfish'] == 0) & (df['Date'].str.
↳ contains('2019-08'))]
# Paso 4: Crear una grilla regular sobre el Mar de Alborán
grid_size = 0.05 # Ajustar el tamaño de las celdas de la grilla (en grados)
x_min, x_max, y_min, y_max = -5.5, -1.625, 35.94, 37.31
# Crear una grilla regular de puntos (centro de cada celda)
x = np.arange(x_min, x_max, grid_size)
y = np.arange(y_min, y_max, grid_size)
xv, yv = np.meshgrid(x, y)
# Crear una grilla vacía para almacenar los conteos de ausencias
grilla = np.zeros_like(xv, dtype=float)
# Paso 5: Contar las ausencias en cada celda de la grilla
for i in range(len(df_agosto_ausencias)):
    lat = df_agosto_ausencias.iloc[i]['Latitud']
    lon = df_agosto_ausencias.iloc[i]['Longitud']
    # Encontrar la celda correspondiente
    ix = np.searchsorted(x, lon) - 1
    iy = np.searchsorted(y, lat) - 1
    if 0 <= ix < len(x) and 0 <= iy < len(y):
        grilla[iy, ix] += 1 # Sumar una ausencia en la celda correspondiente

# Paso 6: Aplicar un filtro gaussiano para suavizar el heatmap
grilla_suavizada = gaussian_filter(grilla, sigma=1)
# Paso 7: Graficar la península en negro como una capa por encima y el heatmap
↳ de ausencias en la grilla
fig, ax = plt.subplots(figsize=(10, 10))
```



```

# Graficar el heatmap sobre la grilla
c = ax.pcolormesh(x, y, grilla_suavizada, cmap='YlGnBu_r', shading='auto',
↳zorder=1)
# Añadir la barra de color
cb = fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
cb.set_label('Densidad de Ausencias de Medusas')
# Graficar la península recortada en negro por encima del heatmap
gdf_terrestre_recortado.plot(ax=ax, color='black', zorder=2)
# Ajustar los límites del mapa a la región de interés
ax.set_xlim([-5.5, -1.625])
ax.set_ylim([35.94, 37.31])
# Añadir título y etiquetas
plt.title("Mapa de calor de ausencias de medusas en agosto", fontsize=15)
plt.xlabel("Longitud")
plt.ylabel("Latitud")
# Mostrar el mapa
plt.show()
fig.savefig('heatmap_ausencias_agosto.png', dpi=300, bbox_inches='tight')

```

Mapa de calor de presencias para agosto

```

[ ]: # Paso 1: Cargar el shapefile terrestre que cubre la península
gdf_terrestre = gpd.read_file('C:/Users/jairo/Desktop/.../europecountries.shp')
gdf_terrestre = gdf_terrestre.to_crs(epsg=4326) # Asegurarse de que esté en
↳WGS84
# Definir los límites del Mar de Alborán
bounds_alboran = box(-5.5, 35.94, -1.625, 37.31)
# Crear un GeoDataFrame con los límites del área de estudio
gdf_alboran = gpd.GeoDataFrame([1], geometry=[bounds_alboran], crs="EPSG:4326")
# Paso 2: Recortar el shapefile terrestre al área de interés (Mar de Alborán)
gdf_terrestre_recortado = gpd.clip(gdf_terrestre, gdf_alboran)
# Paso 3: Filtrar el DataFrame para obtener solo las ausencias (Jellyfish == 0)
↳en agosto
df_agosto_presencias = df[(df['Jellyfish'] == 1) & (df['Date'].str.
↳contains('2019-08'))]
# Paso 4: Crear una grilla regular sobre el Mar de Alborán
grid_size = 0.05 # Ajustar el tamaño de las celdas de la grilla (en grados)
x_min, x_max, y_min, y_max = -5.5, -1.625, 35.94, 37.31
# Crear una grilla regular de puntos (centro de cada celda)
x = np.arange(x_min, x_max, grid_size)
y = np.arange(y_min, y_max, grid_size)
xv, yv = np.meshgrid(x, y)
# Crear una grilla vacía para almacenar los conteos de ausencias
grilla = np.zeros_like(xv, dtype=float)
# Paso 5: Contar las ausencias en cada celda de la grilla
for i in range(len(df_agosto_presencias)):
    lat = df_agosto_presencias.iloc[i]['Latitud']

```



```

lon = df_agosto_presencias.iloc[i]['Longitud']
# Encontrar la celda correspondiente
ix = np.searchsorted(x, lon) - 1
iy = np.searchsorted(y, lat) - 1
if 0 <= ix < len(x) and 0 <= iy < len(y):
    grilla[iy, ix] += 1 # Sumar una ausencia en la celda correspondiente
# Paso 6: Aplicar un filtro gaussiano para suavizar el heatmap
grilla_suavizada = gaussian_filter(grilla, sigma=1)
# Paso 7: Graficar la península en negro como una capa por encima y el heatmap
↳ de ausencias en la grilla
fig, ax = plt.subplots(figsize=(10, 10))
# Graficar el heatmap sobre la grilla
c = ax.pcolormesh(x, y, grilla_suavizada, cmap='YlGnBu_r', shading='auto',
↳ zorder=1)
# Añadir la barra de color
cb = fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
cb.set_label('Densidad de Presencias de Medusas')
# Graficar la península recortada en negro por encima del heatmap
gdf_terrestre_recortado.plot(ax=ax, color='black', zorder=2)
# Ajustar los límites del mapa a la región de interés
ax.set_xlim([-5.5, -1.625])
ax.set_ylim([35.94, 37.31])
# Añadir título y etiquetas
plt.title("Mapa de calor de presencias de medusas en agosto", fontsize=15)
plt.xlabel("Longitud")
plt.ylabel("Latitud")
# Mostrar el mapa
plt.show()
fig.savefig('heatmap_presencias_agosto.png', dpi=300, bbox_inches='tight')

```

Análisis numérico para agosto

```

[ ]: # Cargar los datos de MaxEnt desde el archivo ASCII
ruta_maxent = 'C:/Users/jairo/Desktop/.../Jellyfish.asc'
data_maxent = np.loadtxt(ruta_maxent, skiprows=6) # Saltar las primeras 6
↳ líneas de cabecera
# Reemplazar los -9999 (valor de NoData en MaxEnt) con NaN
data_maxent_clean = np.where(data_maxent == -9999, np.nan, data_maxent)
# Obtener las dimensiones de la grilla de MaxEnt
shape_maxent = data_maxent_clean.shape
print(f"Dimensiones de MaxEnt: {shape_maxent}")
# Dimensiones de la grilla suavizada (ausencias)
shape_grilla_suavizada = grilla_suavizada.shape
print(f"Dimensiones de la grilla suavizada: {shape_grilla_suavizada}")
# Redimensionar la grilla suavizada para que coincida con MaxEnt
factor_x = shape_maxent[1] / shape_grilla_suavizada[1]
factor_y = shape_maxent[0] / shape_grilla_suavizada[0]

```

```
grilla_suavizada_resized = zoom(grilla_suavizada, (factor_y, factor_x))
print(f"Dimensiones de la grilla suavizada ajustada: {grilla_suavizada_resized.
↳shape}")
```

```
[ ]: # Invertir los datos del MaxEnt verticalmente para corregir el problema
data_maxent_clean_flipped = np.flipud(data_maxent_clean)
# Crear una figura con dos subgráficos
fig, ax = plt.subplots(1, 2, figsize=(15, 7))
# Graficar el mapa de calor de MaxEnt invertido
c1 = ax[0].imshow(data_maxent_clean_flipped, cmap='Reds', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
fig.colorbar(c1, ax=ax[0], fraction=0.02, pad=0.04)
# Graficar el mapa de calor de densidad de ausencias (grilla suavizada)
c2 = ax[1].imshow(grilla_suavizada_resized, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
fig.colorbar(c2, ax=ax[1], fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.suptitle("Comparación de áreas de baja probabilidad (MaxEnt) y alta
↳densidad de ausencias", fontsize=16)
plt.tight_layout()
plt.show()
```

```
[ ]: # Aplicar los NaN de data_maxent_clean_flipped a grilla_suavizada_resized
grilla_suavizada_resized[np.isnan(data_maxent_clean_flipped)] = np.nan
```

```
[ ]: # Crear máscaras para NaN y valores válidos
mask_nan_maxent = np.isnan(data_maxent_clean_flipped)
mask_nan_ausencias = np.isnan(grilla_suavizada_resized)
# Graficar las posiciones NaN y valores válidos con etiquetas claras
fig, ax = plt.subplots(1, 2, figsize=(15, 5))
# Graficar el mapa de posiciones NaN en MaxEnt
ax[0].imshow(mask_nan_maxent, cmap='gray', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[0].set_title('Posiciones de NaN en MaxEnt (Blanco = NaN)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar el mapa de posiciones NaN en Densidad de Ausencias
ax[1].imshow(mask_nan_ausencias, cmap='gray', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[1].set_title('Posiciones de NaN en Densidad de Ausencias (Blanco = NaN)')
ax[1].set_xlabel('Longitud')
plt.tight_layout()
```

```
plt.show()
```

```
[ ]: # Crear una máscara booleana donde los valores válidos son True y los NaN son
      ↪ False
mask_valid_maxent = ~np.isnan(data_maxent_clean_flipped)
# Calcular la distancia desde las celdas con datos válidos
distancia_a_datos = distance_transform_edt(mask_valid_maxent)
# Definir un umbral de distancia en celdas (5 en este caso)
umbral_distancia = 5
# Crear una nueva máscara que mantenga las celdas dentro del buffer de
      ↪ distancia y convierta el resto a NaN
mask_buffer = distancia_a_datos <= umbral_distancia
# Aplicar la máscara: celdas fuera del buffer se convierten en NaN
data_maxent_filtrada = np.where(mask_buffer, data_maxent_clean_flipped, np.nan)
# Verificar la cantidad de NaN en el resultado final
n_nan = np.isnan(data_maxent_filtrada).sum()
print(f"Cantidad de NaN después de aplicar el filtro: {n_nan}")
# Graficar las posiciones NaN después de aplicar el filtro de distancia
plt.imshow(np.isnan(data_maxent_filtrada), cmap='gray', extent=[-5.5, -1.625,
      ↪ 35.94, 37.31], origin='lower')
plt.title('Posiciones de NaN después de aplicar el buffer de distancia
      ↪ (Revisado)')
plt.xlabel('Longitud')
plt.ylabel('Latitud')
plt.show()
```

```
[ ]: # Graficar la grilla suavizada para visualizar la distribución de densidad de
      ↪ ausencias
fig, ax = plt.subplots(figsize=(8, 6))
c = ax.imshow(grilla_suavizada_resized, cmap='Blues', extent=[-5.5, -1.625, 35.
      ↪ 94, 37.31], origin='lower')
ax.set_title('Mapa de densidad de ausencias (grilla suavizada)')
ax.set_xlabel('Longitud')
ax.set_ylabel('Latitud')
# Añadir la barra de color
fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.show()
```

```
[ ]: # Aplicar la máscara a la grilla suavizada
grilla_filtrada = np.where(mask_buffer == 1, grilla_suavizada_resized, np.nan)
# Graficar la grilla filtrada
fig, ax = plt.subplots(figsize=(8, 6))
c = ax.imshow(grilla_filtrada, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.
      ↪ 31], origin='lower')
ax.set_title('Mapa de densidad de ausencias filtrado (grilla suavizada)')
ax.set_xlabel('Longitud')
```

```

ax.set_ylabel('Latitud')
# Añadir la barra de color
fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.show()

```

```

[ ]: # Definir los umbrales para baja probabilidad de MaxEnt y alta densidad de
    ↪ ausencias
threshold_probabilidad_baja = 0.49 # Umbral de baja probabilidad en MaxEnt
threshold_ausencia_alta = 0.1 # Umbral de alta densidad de ausencias

# Paso 1: Crear una máscara para las áreas de baja probabilidad en MaxEnt
    ↪ usando la matriz filtrada (tras la máscara)
areas_baja_probabilidad = np.where(data_maxent_clean_flipped <
    ↪ threshold_probabilidad_baja, 1, 0)

# Paso 2: Crear una máscara para las áreas de alta densidad de ausencias,
    ↪ aplicando el umbral de alta ausencia
areas_alta_ausencia = np.where(grilla_filtrada > threshold_ausencia_alta, 1, 0)

# Paso 3: Aplicar la máscara para asegurarnos de que solo comparamos las áreas
    ↪ válidas (donde no hay NaN)
valid_mask = ~np.isnan(data_maxent_clean_flipped) & ~np.isnan(grilla_filtrada)
# Filtrar solo las áreas válidas
areas_baja_probabilidad = np.where(valid_mask, areas_baja_probabilidad, np.nan)
areas_alta_ausencia = np.where(valid_mask, areas_alta_ausencia, np.nan)

# Paso 4: Comparar las áreas con ambos umbrales y máscara
coincidencias = np.logical_and(areas_baja_probabilidad == 1,
    ↪ areas_alta_ausencia == 1)
# Calcular la cantidad de coincidencias
cantidad_coincidencias = np.sum(coincidencias)
total_areas_baja_probabilidad = np.sum(areas_baja_probabilidad == 1)
total_areas_alta_ausencia = np.sum(areas_alta_ausencia == 1)
# Calcular el porcentaje de coincidencias sobre las áreas de alta ausencia
porcentaje_coincidencia = (cantidad_coincidencias / total_areas_alta_ausencia)
    ↪ * 100
print(f"Coincidencias: {cantidad_coincidencias}")
print(f"Total áreas de baja probabilidad: {total_areas_baja_probabilidad}")
print(f"Total áreas de alta ausencia: {total_areas_alta_ausencia}")
print(f"Porcentaje de coincidencia: {porcentaje_coincidencia:.2f}%")

# Paso 5: Graficar las áreas de coincidencia
fig, ax = plt.subplots(1, 3, figsize=(18, 6))
# Graficar las áreas de baja probabilidad (MaxEnt)

```

```

ax[0].imshow(areas_baja_probabilidad, cmap='Reds', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar las áreas de alta densidad de ausencias
ax[1].imshow(areas_alta_ausencia, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
# Graficar las coincidencias
ax[2].imshow(coincidencias, cmap='Purples', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[2].set_title('Coincidencias entre baja probabilidad y alta ausencia')
ax[2].set_xlabel('Longitud')
plt.tight_layout()
plt.show()

```

```

[ ]: # Definir los umbrales para baja probabilidad de MaxEnt y alta densidad de ausencias
threshold_probabilidad_baja = 0.49 # Umbral de baja probabilidad en MaxEnt
threshold_ausencia_alta = 0.1 # Umbral de alta densidad de ausencias

# Paso 1: Crear una máscara para las áreas de baja probabilidad en MaxEnt
areas_baja_probabilidad = np.where(data_maxent_clean_flipped < threshold_probabilidad_baja, 1, 0)

# Paso 2: Crear una máscara para las áreas de alta densidad de ausencias
areas_alta_ausencia = np.where(grilla_filtrada > threshold_ausencia_alta, 1, 0)

# Paso 3: Aplicar la máscara para asegurarnos de que solo comparamos las áreas válidas (donde no hay NaN)
valid_mask = ~np.isnan(data_maxent_clean_flipped) & ~np.isnan(grilla_filtrada)
# Filtrar solo las áreas válidas
areas_baja_probabilidad = np.where(valid_mask, areas_baja_probabilidad, np.nan)
areas_alta_ausencia = np.where(valid_mask, areas_alta_ausencia, np.nan)
# Crear una máscara base donde se diferencien las zonas por "encima" y "debajo"
base_mask = np.where(np.isnan(data_maxent_clean_flipped), 2, 1) # 2: encima (negro), 1: debajo (azul claro)

# Paso 4: Comparar las áreas con ambos umbrales y máscara
coincidencias = np.logical_and(areas_baja_probabilidad == 1, areas_alta_ausencia == 1)

# Paso 4.1: No dejar valores en NaN, convertir en 0
coincidencias_mask = np.full_like(coincidencias, 0) # Iniciar todo en 0
coincidencias_mask[coincidencias] = 1 # Marcar solo las coincidencias

```

```

# Calcular la cantidad de coincidencias
cantidad_coincidencias = np.sum(coincidencias) # Cuenta las coincidencias
↳válidas
total_areas_baja_probabilidad = np.sum(areas_baja_probabilidad == 1)
total_areas_alta_ausencia = np.sum(areas_alta_ausencia == 1)
# Calcular el porcentaje de coincidencias sobre las áreas de alta ausencia
porcentaje_coincidencia = (cantidad_coincidencias / total_areas_alta_ausencia)
↳* 100
print(f"Coincidencias: {cantidad_coincidencias}")
print(f"Total áreas de baja probabilidad: {total_areas_baja_probabilidad}")
print(f"Total áreas de alta ausencia: {total_areas_alta_ausencia}")
print(f"Porcentaje de coincidencia: {porcentaje_coincidencia:.2f}%")

# Paso 5: Graficar las áreas de coincidencia
fig, ax = plt.subplots(1, 3, figsize=(15, 5), sharey=True)
# Crear un colormap para las áreas "encima" (negro) y "debajo" (azul claro)
cmap_background = ListedColormap(['lightblue', 'black'])
# Graficar la base para todas las gráficas (azul claro y negro)
for i in range(3):
    ax[i].imshow(base_mask, cmap=cmap_background, extent=[-5.5, -1.625, 35.94,
↳37.31], origin='lower', zorder=1)
# Graficar las áreas de baja probabilidad (MaxEnt)
ax[0].imshow(areas_baja_probabilidad, cmap='Reds', extent=[-5.5, -1.625, 35.94,
↳37.31], origin='lower', zorder=2)
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar las áreas de alta densidad de ausencias
ax[1].imshow(areas_alta_ausencia, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.
↳31], origin='lower', zorder=2)
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
# Graficar las coincidencias, donde 0 es transparente y 1 es la coincidencia en
↳morado
ax[2].imshow(coincidencias_mask, cmap='Greens', extent=[-5.5, -1.625, 35.94, 37.
↳31], origin='lower', zorder=2, alpha=0.8)
ax[2].set_title('Coincidencias')
ax[2].set_xlabel('Longitud')
plt.subplots_adjust(wspace=0.2, hspace=0.3) # Ajustar el espaciado entre
↳columnas (wspace) y filas (hspace)
plt.savefig('comparacion_probabilidad_ausencias_08.png', dpi=300,
↳bbox_inches='tight')
plt.tight_layout()
plt.show()

```

3.2.4 Mapa de calor ausencias en septiembre

```
[ ]: # Paso 1: Cargar el shapefile terrestre que cubre la península
gdf_terrestre = gpd.read_file('C:/Users/jairo/Desktop/.../europecountries.shp')
gdf_terrestre = gdf_terrestre.to_crs(epsg=4326) # Asegurarse de que esté en
↳WGS84
# Definir los límites del Mar de Alborán
bounds_alboran = box(-5.5, 35.94, -1.625, 37.31)
# Crear un GeoDataFrame con los límites del área de estudio
gdf_alboran = gpd.GeoDataFrame([1], geometry=[bounds_alboran], crs="EPSG:4326")
# Paso 2: Recortar el shapefile terrestre al área de interés (Mar de Alborán)
gdf_terrestre_recortado = gpd.clip(gdf_terrestre, gdf_alboran)
# Paso 3: Filtrar el DataFrame para obtener solo las ausencias (Jellyfish == 0)
↳en septiembre
df_septiembre_ausencias = df[(df['Jellyfish'] == 0) & (df['Date'].str.
↳contains('2019-09'))]
# Paso 4: Crear una grilla regular sobre el Mar de Alborán
grid_size = 0.05 # Ajustar el tamaño de las celdas de la grilla (en grados)
x_min, x_max, y_min, y_max = -5.5, -1.625, 35.94, 37.31
# Crear una grilla regular de puntos (centro de cada celda)
x = np.arange(x_min, x_max, grid_size)
y = np.arange(y_min, y_max, grid_size)
xv, yv = np.meshgrid(x, y)
# Crear una grilla vacía para almacenar los conteos de ausencias
grilla = np.zeros_like(xv, dtype=float)
# Paso 5: Contar las ausencias en cada celda de la grilla
for i in range(len(df_septiembre_ausencias)):
    lat = df_septiembre_ausencias.iloc[i]['Latitud']
    lon = df_septiembre_ausencias.iloc[i]['Longitud']
    # Encontrar la celda correspondiente
    ix = np.searchsorted(x, lon) - 1
    iy = np.searchsorted(y, lat) - 1
    if 0 <= ix < len(x) and 0 <= iy < len(y):
        grilla[iy, ix] += 1 # Sumar una ausencia en la celda correspondiente
# Paso 6: Aplicar un filtro gaussiano para suavizar el heatmap
grilla_suavizada = gaussian_filter(grilla, sigma=1)
# Paso 7: Graficar la península en negro como una capa por encima y el heatmap
↳de ausencias en la grilla
fig, ax = plt.subplots(figsize=(10, 10))
# Graficar el heatmap sobre la grilla
c = ax.pcolormesh(x, y, grilla_suavizada, cmap='YlGnBu_r', shading='auto',
↳zorder=1)
# Añadir la barra de color
cb = fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
cb.set_label('Densidad de Ausencias de Medusas')
# Graficar la península recortada en negro por encima del heatmap
gdf_terrestre_recortado.plot(ax=ax, color='black', zorder=2)
```



```

# Ajustar los límites del mapa a la región de interés
ax.set_xlim([-5.5, -1.625])
ax.set_ylim([35.94, 37.31])
# Añadir título y etiquetas
plt.title("Mapa de calor de ausencias de medusas en septiembre", fontsize=15)
plt.xlabel("Longitud")
plt.ylabel("Latitud")
# Mostrar el mapa
plt.show()
fig.savefig('heatmap_ausencias_septiembre.png', dpi=300, bbox_inches='tight')

```

Mapa de calor de presencias para septiembre

```

[ ]: # Paso 1: Cargar el shapefile terrestre que cubre la península
gdf_terrestre = gpd.read_file('C:/Users/jairo/Desktop/.../europecountries.shp')
gdf_terrestre = gdf_terrestre.to_crs(epsg=4326) # Asegurarse de que esté en
↳ WGS84
# Definir los límites del Mar de Alborán
bounds_alboran = box(-5.5, 35.94, -1.625, 37.31)
# Crear un GeoDataFrame con los límites del área de estudio
gdf_alboran = gpd.GeoDataFrame([1], geometry=[bounds_alboran], crs="EPSG:4326")
# Paso 2: Recortar el shapefile terrestre al área de interés (Mar de Alborán)
gdf_terrestre_recortado = gpd.clip(gdf_terrestre, gdf_alboran)
# Paso 3: Filtrar el DataFrame para obtener solo las ausencias (Jellyfish == 0)
↳ en septiembre
df_septiembre_presencias = df[(df['Jellyfish'] == 1) & (df['Date'].str.
↳ contains('2019-09'))]
# Paso 4: Crear una grilla regular sobre el Mar de Alborán
grid_size = 0.05 # Ajustar el tamaño de las celdas de la grilla (en grados)
x_min, x_max, y_min, y_max = -5.5, -1.625, 35.94, 37.31
# Crear una grilla regular de puntos (centro de cada celda)
x = np.arange(x_min, x_max, grid_size)
y = np.arange(y_min, y_max, grid_size)
xv, yv = np.meshgrid(x, y)
# Crear una grilla vacía para almacenar los conteos de ausencias
grilla = np.zeros_like(xv, dtype=float)
# Paso 5: Contar las ausencias en cada celda de la grilla
for i in range(len(df_septiembre_presencias)):
    lat = df_septiembre_presencias.iloc[i]['Latitud']
    lon = df_septiembre_presencias.iloc[i]['Longitud']
    # Encontrar la celda correspondiente
    ix = np.searchsorted(x, lon) - 1
    iy = np.searchsorted(y, lat) - 1
    if 0 <= ix < len(x) and 0 <= iy < len(y):
        grilla[iy, ix] += 1 # Sumar una ausencia en la celda correspondiente
# Paso 6: Aplicar un filtro gaussiano para suavizar el heatmap
grilla_suavizada = gaussian_filter(grilla, sigma=1)

```



```

# Paso 7: Graficar la península en negro como una capa por encima y el heatmap
↳ de ausencias en la grilla
fig, ax = plt.subplots(figsize=(10, 10))
# Graficar el heatmap sobre la grilla
c = ax.pcolormesh(x, y, grilla_suavizada, cmap='YlGnBu_r', shading='auto',
↳ zorder=1)
# Añadir la barra de color
cb = fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
cb.set_label('Densidad de Presencias de Medusas')
# Graficar la península recortada en negro por encima del heatmap
gdf_terrestre_recortado.plot(ax=ax, color='black', zorder=2)
# Ajustar los límites del mapa a la región de interés
ax.set_xlim([-5.5, -1.625])
ax.set_ylim([35.94, 37.31])
# Añadir título y etiquetas
plt.title("Mapa de calor de presencias de medusas en septiembre", fontsize=15)
plt.xlabel("Longitud")
plt.ylabel("Latitud")
# Mostrar el mapa
plt.show()
fig.savefig('heatmap_presencias_septiembre.png', dpi=300, bbox_inches='tight')

```

Análisis numérico para septiembre

```

[ ]: # Cargar los datos de MaxEnt desde el archivo ASCII
ruta_maxent = 'C:/Users/jairo/Desktop/.../Jellyfish.asc'
data_maxent = np.loadtxt(ruta_maxent, skiprows=6) # Saltar las primeras 6
↳ líneas de cabecera
# Reemplazar los -9999 (valor de NoData en MaxEnt) con NaN
data_maxent_clean = np.where(data_maxent == -9999, np.nan, data_maxent)
# Obtener las dimensiones de la grilla de MaxEnt
shape_maxent = data_maxent_clean.shape
print(f"Dimensiones de MaxEnt: {shape_maxent}")
# Dimensiones de la grilla suavizada (ausencias)
shape_grilla_suavizada = grilla_suavizada.shape
print(f"Dimensiones de la grilla suavizada: {shape_grilla_suavizada}")
# Redimensionar la grilla suavizada para que coincida con MaxEnt
factor_x = shape_maxent[1] / shape_grilla_suavizada[1]
factor_y = shape_maxent[0] / shape_grilla_suavizada[0]
grilla_suavizada_resized = zoom(grilla_suavizada, (factor_y, factor_x))
print(f"Dimensiones de la grilla suavizada ajustada: {grilla_suavizada_resized.
↳ shape}")

```

```

[ ]: # Invertir los datos del MaxEnt verticalmente para corregir el problema
data_maxent_clean_flipped = np.flipud(data_maxent_clean)
# Crear una figura con dos subgráficos
fig, ax = plt.subplots(1, 2, figsize=(15, 7))
# Graficar el mapa de calor de MaxEnt invertido

```

```

c1 = ax[0].imshow(data_maxent_clean_flipped, cmap='Reds', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
fig.colorbar(c1, ax=ax[0], fraction=0.02, pad=0.04)
# Graficar el mapa de calor de densidad de ausencias (grilla suavizada)
c2 = ax[1].imshow(grilla_suavizada_resized, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
fig.colorbar(c2, ax=ax[1], fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.suptitle("Comparación de áreas de baja probabilidad (MaxEnt) y alta densidad de ausencias", fontsize=16)
plt.tight_layout()
plt.show()

```

```

[ ]: # Aplicar los NaN de data_maxent_clean_flipped a grilla_suavizada_resized
grilla_suavizada_resized[np.isnan(data_maxent_clean_flipped)] = np.nan

```

```

[ ]: # Crear máscaras para NaN y valores válidos
mask_nan_maxent = np.isnan(data_maxent_clean_flipped)
mask_nan_ausencias = np.isnan(grilla_suavizada_resized)
# Graficar las posiciones NaN y valores válidos con etiquetas claras
fig, ax = plt.subplots(1, 2, figsize=(15, 5))
# Graficar el mapa de posiciones NaN en MaxEnt
ax[0].imshow(mask_nan_maxent, cmap='gray', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[0].set_title('Posiciones de NaN en MaxEnt (Blanco = NaN)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar el mapa de posiciones NaN en Densidad de Ausencias
ax[1].imshow(mask_nan_ausencias, cmap='gray', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower')
ax[1].set_title('Posiciones de NaN en Densidad de Ausencias (Blanco = NaN)')
ax[1].set_xlabel('Longitud')
plt.tight_layout()
plt.show()

```

```

[ ]: # Crear una máscara booleana donde los valores válidos son True y los NaN son False
mask_valid_maxent = ~np.isnan(data_maxent_clean_flipped)
# Calcular la distancia desde las celdas con datos válidos
distancia_a_datos = distance_transform_edt(mask_valid_maxent)
# Definir un umbral de distancia en celdas (5 en este caso)
umbral_distancia = 5

```

```

# Crear una nueva máscara que mantenga las celdas dentro del buffer de
↳ distancia y convierta el resto a NaN
mask_buffer = distancia_a_datos <= umbral_distancia
# Aplicar la máscara: celdas fuera del buffer se convierten en NaN
data_maxent_filtrada = np.where(mask_buffer, data_maxent_clean_flipped, np.nan)
# Verificar la cantidad de NaN en el resultado final
n_nan = np.isnan(data_maxent_filtrada).sum()
print(f"Cantidad de NaN después de aplicar el filtro: {n_nan}")
# Graficar las posiciones NaN después de aplicar el filtro de distancia
plt.imshow(np.isnan(data_maxent_filtrada), cmap='gray', extent=[-5.5, -1.625,
↳ 35.94, 37.31], origin='lower')
plt.title('Posiciones de NaN después de aplicar el buffer de distancia
↳ (Revisado)')
plt.xlabel('Longitud')
plt.ylabel('Latitud')
plt.show()

```

```

[ ]: # Graficar la grilla suavizada para visualizar la distribución de densidad de
↳ ausencias
fig, ax = plt.subplots(figsize=(8, 6))
c = ax.imshow(grilla_suavizada_resized, cmap='Blues', extent=[-5.5, -1.625, 35.
↳ 94, 37.31], origin='lower')
ax.set_title('Mapa de densidad de ausencias (grilla suavizada)')
ax.set_xlabel('Longitud')
ax.set_ylabel('Latitud')
# Añadir la barra de color
fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.show()

```

```

[ ]: # Aplicar la máscara a la grilla suavizada
grilla_filtrada = np.where(mask_buffer == 1, grilla_suavizada_resized, np.nan)
# Graficar la grilla filtrada
fig, ax = plt.subplots(figsize=(8, 6))
c = ax.imshow(grilla_filtrada, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.
↳ 31], origin='lower')
ax.set_title('Mapa de densidad de ausencias filtrado (grilla suavizada)')
ax.set_xlabel('Longitud')
ax.set_ylabel('Latitud')
# Añadir la barra de color
fig.colorbar(c, ax=ax, fraction=0.02, pad=0.04)
# Mostrar el mapa
plt.show()

```

```

[ ]: # Definir los umbrales para baja probabilidad de MaxEnt y alta densidad de
↳ ausencias
threshold_probabilidad_baja = 0.49 # Umbral de baja probabilidad en MaxEnt

```

```

threshold_ausencia_alta = 0.1 # Umbral de alta densidad de ausencias

# Paso 1: Crear una máscara para las áreas de baja probabilidad en MaxEnt,
↳ usando la matriz filtrada (tras la máscara)
areas_baja_probabilidad = np.where(data_maxent_clean_flipped <
↳ threshold_probabilidad_baja, 1, 0)

# Paso 2: Crear una máscara para las áreas de alta densidad de ausencias,
↳ aplicando el umbral de alta ausencia
areas_alta_ausencia = np.where(grilla_filtrada > threshold_ausencia_alta, 1, 0)

# Paso 3: Aplicar la máscara para asegurarnos de que solo comparamos las áreas,
↳ válidas (donde no hay NaN)
valid_mask = ~np.isnan(data_maxent_clean_flipped) & ~np.isnan(grilla_filtrada)
# Filtrar solo las áreas válidas
areas_baja_probabilidad = np.where(valid_mask, areas_baja_probabilidad, np.nan)
areas_alta_ausencia = np.where(valid_mask, areas_alta_ausencia, np.nan)

# Paso 4: Comparar las áreas con ambos umbrales y máscara
coincidencias = np.logical_and(areas_baja_probabilidad == 1,
↳ areas_alta_ausencia == 1)
# Calcular la cantidad de coincidencias
cantidad_coincidencias = np.sum(coincidencias)
total_areas_baja_probabilidad = np.sum(areas_baja_probabilidad == 1)
total_areas_alta_ausencia = np.sum(areas_alta_ausencia == 1)
# Calcular el porcentaje de coincidencias sobre las áreas de alta ausencia
porcentaje_coincidencia = (cantidad_coincidencias / total_areas_alta_ausencia)
↳ * 100
print(f"Coincidencias: {cantidad_coincidencias}")
print(f"Total áreas de baja probabilidad: {total_areas_baja_probabilidad}")
print(f"Total áreas de alta ausencia: {total_areas_alta_ausencia}")
print(f"Porcentaje de coincidencia: {porcentaje_coincidencia:.2f}%")

# Paso 5: Graficar las áreas de coincidencia
fig, ax = plt.subplots(1, 3, figsize=(18, 6))
# Graficar las áreas de baja probabilidad (MaxEnt)
ax[0].imshow(areas_baja_probabilidad, cmap='Reds', extent=[-5.5, -1.625, 35.94,
↳ 37.31], origin='lower')
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar las áreas de alta densidad de ausencias
ax[1].imshow(areas_alta_ausencia, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.
↳ 31], origin='lower')
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')

```

```

# Graficar las coincidencias
ax[2].imshow(coincidencias, cmap='Purples', extent=[-5.5, -1.625, 35.94, 37.
↳31], origin='lower')
ax[2].set_title('Coincidencias entre baja probabilidad y alta ausencia')
ax[2].set_xlabel('Longitud')
plt.tight_layout()
plt.show()

```

```

[ ]: # Definir los umbrales para baja probabilidad de MaxEnt y alta densidad de
↳ausencias
threshold_probabilidad_baja = 0.49 # Umbral de baja probabilidad en MaxEnt
threshold_ausencia_alta = 0.1 # Umbral de alta densidad de ausencias

# Paso 1: Crear una máscara para las áreas de baja probabilidad en MaxEnt
areas_baja_probabilidad = np.where(data_maxent_clean_flipped <
↳threshold_probabilidad_baja, 1, 0)

# Paso 2: Crear una máscara para las áreas de alta densidad de ausencias
areas_alta_ausencia = np.where(grilla_filtrada > threshold_ausencia_alta, 1, 0)

# Paso 3: Aplicar la máscara para asegurarnos de que solo comparamos las áreas
↳válidas (donde no hay NaN)
valid_mask = ~np.isnan(data_maxent_clean_flipped) & ~np.isnan(grilla_filtrada)
# Filtrar solo las áreas válidas
areas_baja_probabilidad = np.where(valid_mask, areas_baja_probabilidad, np.nan)
areas_alta_ausencia = np.where(valid_mask, areas_alta_ausencia, np.nan)
# Crear una máscara base donde se diferencien las zonas por "encima" y "debajo"
base_mask = np.where(np.isnan(data_maxent_clean_flipped), 2, 1) # 2: encima
↳(negro), 1: debajo (azul claro)

# Paso 4: Comparar las áreas con ambos umbrales y máscara
coincidencias = np.logical_and(areas_baja_probabilidad == 1,
↳areas_alta_ausencia == 1)

# Paso 4.1: No dejar valores en NaN, convertir en 0
coincidencias_mask = np.full_like(coincidencias, 0) # Iniciar todo en 0
coincidencias_mask[coincidencias] = 1 # Marcar solo las coincidencias
# Calcular la cantidad de coincidencias
cantidad_coincidencias = np.sum(coincidencias) # Cuenta las coincidencias
↳válidas

total_areas_baja_probabilidad = np.sum(areas_baja_probabilidad == 1)
total_areas_alta_ausencia = np.sum(areas_alta_ausencia == 1)
# Calcular el porcentaje de coincidencias sobre las áreas de alta ausencia
porcentaje_coincidencia = (cantidad_coincidencias / total_areas_alta_ausencia)
↳* 100

print(f"Coincidencias: {cantidad_coincidencias}")
print(f"Total áreas de baja probabilidad: {total_areas_baja_probabilidad}")

```

```

print(f"Total áreas de alta ausencia: {total_areas_alta_ausencia}")
print(f"Porcentaje de coincidencia: {porcentaje_coincidencia:.2f}%")

# Paso 5: Graficar las áreas de coincidencia
fig, ax = plt.subplots(1, 3, figsize=(15, 5), sharey=True)
# Crear un colormap para las áreas "encima" (negro) y "debajo" (azul claro)
cmap_background = ListedColormap(['lightblue', 'black'])
# Graficar la base para todas las gráficas (azul claro y negro)
for i in range(3):
    ax[i].imshow(base_mask, cmap=cmap_background, extent=[-5.5, -1.625, 35.94, 37.31], origin='lower', zorder=1)
# Graficar las áreas de baja probabilidad (MaxEnt)
ax[0].imshow(areas_baja_probabilidad, cmap='Reds', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower', zorder=2)
ax[0].set_title('Áreas de baja probabilidad (MaxEnt)')
ax[0].set_xlabel('Longitud')
ax[0].set_ylabel('Latitud')
# Graficar las áreas de alta densidad de ausencias
ax[1].imshow(areas_alta_ausencia, cmap='Blues', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower', zorder=2)
ax[1].set_title('Áreas de alta densidad de ausencias')
ax[1].set_xlabel('Longitud')
# Graficar las coincidencias, donde 0 es transparente y 1 es la coincidencia en morado
ax[2].imshow(coincidencias_mask, cmap='Greens', extent=[-5.5, -1.625, 35.94, 37.31], origin='lower', zorder=2, alpha=0.8)
ax[2].set_title('Coincidencias')
ax[2].set_xlabel('Longitud')
plt.subplots_adjust(wspace=0.2, hspace=0.3) # Ajustar el espaciado entre columnas (wspace) y filas (hspace)
plt.savefig('comparacion_probabilidad_ausencias_09.png', dpi=300, bbox_inches='tight')
plt.tight_layout()
plt.show()

```


Anexo 6

Listado de publicaciones

1. Castro-Gutiérrez, J., Gutiérrez-Estrada, J. C., Báez, J. C. 2024. Using artificial neural networks and citizen science data to assess jellyfish presence along coastal areas. *Journal of Applied Ecology* 61(9), 2244-2257. (**Artículo 1**).
2. Castro-Gutiérrez, J., Gutiérrez-Estrada, J. C., Bellido, J. J., Báez, J. C. 2025. Distribution modelling of jellyfish in Spanish coastal areas: An approach based on the maximum entropy principle. *Ocean & Coastal Management* 266, 107694. (**Artículo 2**).
3. Castro-Gutierrez, J., Gutiérrez-Estrada, J. C., Aroba, J., Pulido-Calvo, I., Peregrín, A., Báez, J. C., Bellido, J. J., Souviron-Priego, L. 2022. Estimation of jellyfish abundance in the south-eastern Spanish coastline by using an explainable artificial intelligence model based on fuzzy logic. *Estuarine, Coastal and Shelf Science* 277, 108062. (**Artículo 3**).

Artículo 1

Título: Using artificial neural networks and citizen science data to assess jellyfish presence along coastal areas.

Autores: Jairo Castro-Gutiérrez, Juan Carlos Gutiérrez-Estrada y José Carlos Báez.

Revista: *Journal of Applied Ecology*.

Volúmen: 61.

Número del fascículo: 9.

Páginas: 2244-2257.

Año: 2024.

DOI: 10.1111/1365-2664.14734.

Índice de impacto JCR (“*Journal Citation Reports*”) (2023): 5.0.

Recibido el 19 de octubre de 2023. Aceptado el 8 de julio de 2024. Versión final publicada en línea el 24 de julio de 2024. Número completo en línea publicado el 3 de septiembre de 2024.

Categoría JCR	Clasificación en la categoría	Cuartil en la categoría
Ecology	24/197	Q1

Artículo 2

Título: Distribution modelling of jellyfish in Spanish coastal areas: An approach based on the maximum entropy principle.

Autores: Jairo Castro-Gutiérrez, Juan Carlos Gutiérrez-Estrada, Juan José Bellido y José Carlos Báez.

Revista: *Ocean & Coastal Management*.

Volúmen: 266.

Número del artículo: 107694.

Año: 2025.

DOI: 10.1016/j.ocecoaman.2025.107694.

Índice de impacto JCR (“*Journal Citation Reports*”) (2023): 4.8.

Recibido el 17 de diciembre de 2024. Revisado el 2 de abril de 2025. Aceptado el 9 de abril de 2025. Versión final disponible en línea el 15 de abril de 2025.

Categoría JCR	Clasificación en la categoría	Cuartil en la categoría
Oceanography	3/65	Q1

Artículo 3

Título: Estimation of jellyfish abundance in the south-eastern Spanish coastline by using an explainable artificial intelligence model based on fuzzy logic

Autores: Jairo Castro-Gutierrez, Juan Carlos Gutiérrez-Estrada, Javier Aroba, Inmaculada Pulido-Calvo, Antonio Peregrín, José Carlos Báez, Juan José Bellido y Lucrecia Souviron-Priego.

Revista: *Estuarine, Coastal and Shelf Science*.

Volúmen: 277.

Número de artículo: 108062.

Año: 2022.

DOI: 10.1016/j.ecss.2022.108062.

Índice de impacto JCR (“*Journal Citation Reports*”) (2022): 2.8.

Recibido el 13 de junio de 2022. Revisado el 1 de septiembre de 2022. Aceptado el 2 de septiembre de 2022. Disponible en línea el 9 de septiembre de 2022. Versión final publicada en línea el 14 de septiembre de 2022.

Categoría JCR	Clasificación en la categoría	Cuartil en la categoría
Marine & Freshwater Biology	19/106	Q1



CSIC
CONSEJO SUPERIOR DE INVESTIGACIONES CIENTÍFICAS

