



CENTRO DE INVESTIGACIONES BIOLÓGICAS  
DEL NOROESTE, S.C.

---

Programa de Estudios de Posgrado

MODELO DE REDES NEURONALES ARTIFICIALES DE LA  
PRESENCIA DE DELFINES MEDIANTE MONITOREO ACÚSTICO  
PASIVO EN EL CANAL DE CERRALVO, B.C.S., MÉXICO.

## T E S I S

Que para obtener el grado de

Doctora en Ciencias

Uso, Manejo y Preservación de Recursos Naturales  
Orientación en Biología Marina

P r e s e n t a

Haidé Cruz Villagrán

La Paz, Baja California Sur, agosto de 2026

## ACTA DE LIBERACIÓN DE TESIS

En la Ciudad de La Paz, B. C. S., siendo las **15:00** horas del día **16** del mes de **julio** del año **2026**, se procedió por las personas abajo firmantes, integrantes de la Comisión Revisora de Tesis avalada por la Dirección de Estudios de Posgrado y Formación de Recursos Humanos del Centro de Investigaciones Biológicas del Noroeste, S. C., a liberar la Tesis de Grado titulada:

**"Modelo de redes neuronales artificiales de la presencia de delfines mediante monitoreo acústico pasivo en el Canal de Cerralvo, B.C.S., México "**


Presentada por la alumna:

**Haidé Cruz Villagrán**

Aspirante al Grado de DOCTOR/A EN CIENCIAS EN EL USO, MANEJO Y PRESERVACIÓN DE LOS RECURSOS NATURALES CON ORIENTACIÓN EN **BIOLOGÍA MARINA**

Después de intercambiar opiniones las personas integrantes de la Comisión manifestaron su **APROBACIÓN DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

### LA COMISIÓN REVISORA

| Grado y nombre                       | Estatus           | Firma                                                                                 |
|--------------------------------------|-------------------|---------------------------------------------------------------------------------------|
| Dr. Eduardo Romero Vivas             | Director de Tesis |  |
| Dr. Braulio León López               | Co-Tutor          |  |
| Dr. Joaquín Gutiérrez Jagüey         | Co-Tutor          |  |
| Dra. Aurora Paniagua Mendoza         | Co-Tutora         |  |
| Dr. Fernando Daniel Von Borstel Luna | Co-Tutor          |  |

  
**Dra. Alejandra Nieto Garibay,**

**Directora de Estudios de Posgrado y Formación de Recursos Humanos**



La Paz, Baja California Sur, a 16 de julio de 2026

Los miembros del comité de tesis de la estudiante Haidé Cruz Villagrán del Programa de Doctorado en Ciencias en el Uso, Manejo y Preservación de los Recursos Naturales, revisamos el contenido de la tesis y otorgamos el Vo.Bo. dado que la tesis no representa un plagio de otro documento como lo muestra el reporte de similitud realizado:

- Herramienta antiplagio:  
iThenticate
- Filtros utilizados:  
Bibliografía  
Texto citado
- Porcentajes de similitud:  
16% similitud general  
Se muestra captura de pantalla



Página 2 de 74 - Descripción general de integridad

## 16% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas

### Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado

### Fuentes principales

- 14% Fuentes de Internet
- 8% Publicaciones
- 0% Trabajos entregados (trabajos del estudiante)

### Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

**Director**

Dr. Eduardo Romero Vivas

**Estudiante**

Haidé Cruz Villagrán

**Personal técnico de asesoría en el análisis**

Tec. Susana Luna García

## **Conformación de Comités**

### **Comité Tutorial**

Dr. Eduardo Romero Vivas  
Centro de Investigaciones Biológicas del Noroeste S.C.  
Director de Tesis

Dr. Braulio León López  
Centro de Investigaciones Biológicas del Noroeste S.C.  
Co-Tutor de Tesis

Dr. Joaquín Gutiérrez Jagüey  
Centro de Investigaciones Biológicas del Noroeste S.C.  
Co-Tutor de Tesis

Dra. Aurora Paniagua Mendoza  
Centro de Investigaciones Biológicas del Noroeste S.C.  
Co-Tutora de Tesis

Dr. Fernando Daniel Von Borstel Luna  
Centro de Investigaciones Biológicas del Noroeste S.C.  
Co-Tutor de Tesis

### **Comité Revisor de Tesis**

Dr. Eduardo Romero Vivas  
Dr. Braulio León López  
Dr. Joaquín Gutiérrez Jagüey  
Dra. Aurora Paniagua Mendoza  
Dr. Fernando Daniel Von Borstel Luna

### **Jurado de Examen**

Dr. Eduardo Romero Vivas  
Dr. Braulio León López  
Dr. Joaquín Gutiérrez Jagüey  
Dra. Aurora Paniagua Mendoza  
Dr. Fernando Daniel Von Borstel Luna

### **Suplentes**

Dra. Patricia Cortés Calva  
Dra. Gracia Alicia Gómez Anduro

## Resumen

Comprender los factores que determinan la presencia y distribución de los cetáceos es fundamental para el estudio de su ecología, especialmente en ambientes marinos donde la observación directa resulta limitada. En este estudio se empleó el monitoreo acústico pasivo (PAM) en combinación con redes neuronales artificiales para modelar la presencia de delfines (familia Delphinidae) en el Canal de Cerralvo, Golfo de California, México. Se analizaron diez variables, incluyendo descriptores ambientales tanto físicos como bióticos, y proponiendo una variable denominada coocurrencia acústica interespecífica de cetáceos (CAIC). Definida como la detección acústica simultánea de diferentes especies, independientemente de su proximidad espacial o interacción directa. Los datos se obtuvieron entre noviembre de 2022 y diciembre de 2023 mediante 452 horas de grabaciones acústicas. El modelo con mejor desempeño alcanzó una exactitud del 81.7% y se identificó la CAIC, la velocidad del viento, la concentración de clorofila a, la relación entre la distancia del equipo de grabación y la costa, y el periodo del día como las variables con mayor influencia sobre la presencia de delfines. Los análisis de importancia de variables mostraron que la CAIC ejerció la mayor contribución positiva al modelo. La ballena azul (*Balaenoptera musculus*) y el cachalote (*Physeter macrocephalus*) fueron las especies detectadas con mayor frecuencia de manera simultánea con delfines. Estos resultados demuestran el potencial de PAM y de las redes neuronales para modelar las relaciones ecológicas complejas, además de destacar la relevancia de la CAIC como un factor asociado al uso compartido del hábitat por los delfines.

**Palabras clave:** espacio acústico, redes neuronales artificiales, monitoreo acústico pasivo, delfines, Canal de Cerralvo

ORCID: 0000-0003-4298-9833

Vo. Bo. Director de Tesis



Dr. Eduardo Romero Vivas

## Summary

Understanding the factors that determine cetacean presence and distribution is essential for studying their ecology, particularly in marine environments where direct observation is limited. In this study, passive acoustic monitoring (PAM) was combined with artificial neural networks to model the presence of dolphins (family Delphinidae) in the Cerralvo Channel, Gulf of California, Mexico. Ten variables were analyzed, including biotic and abiotic descriptors, and a novel variable called interspecific acoustic cetacean cooccurrence (IACC) was proposed. It was defined as the simultaneous acoustic detection of different cetacean species, regardless of their spatial proximity or direct interaction. Data were collected between November 2022 and December 2023, yielding 452 hours of acoustic recordings. The best-performing model achieved an accuracy of 81.7%, identifying IACC, wind speed, chlorophyll a concentration, the relative position of the equipment to the coast, and diel pattern as the variables with the greatest influence for detecting dolphin presence. Variable importance analyses showed that IACC made the strongest positive contribution to the model. Blue whales (*Balaenoptera musculus*) and sperm whales (*Physeter macrocephalus*) were the most frequently detected species simultaneously with dolphins. These results demonstrate the potential of PAM and artificial neural networks for modeling complex ecological relationships, highlighting the importance of IACC for studying habitat use.

**Keywords:** acoustic space, artificial neural networks, passive acoustic monitoring, dolphins, Cerralvo Channel

ORCID: 0000-0003-4298-9833

Vo. Bo. Director de Tesis



Dr. Eduardo Romero Vivas

**Dedicatoria**

A la memoria de mi papá, quien con su amor, ejemplo y enseñanzas sembró en mí, los valores que me han acompañado toda la vida. Aunque hoy no estés presente físicamente, tu presencia vive en cada uno de mis logros. Gracias por creer en mí y siempre apoyarme.

A mi mamá, por su amor incondicional, su fortaleza y el apoyo que me ha brindado en cada etapa de mi vida. Gracias por impulsarme a perseguir mis sueños y acompañarme siempre con paciencia y cariño. Gracias por brindarme tu apoyo en momentos difíciles y por celebrar conmigo cada logro.

A mi hermana Claudia, por su amor, apoyo, motivación, por siempre recordarme, incluso en los momentos más difíciles, que siempre hay razones para seguir adelante. Gracias por caminar conmigo y por comprender todo lo que implicó este proceso.

A la memoria de mi mejor amigo Helio, que partió durante este proceso. Gracias por tu lealtad, alegría y por esa infinita paz que siempre irradiabas. Fuiste un maestro de vida y aunque no pudiste acompañarme hasta el final, este logro también lleva un pedacito de ti.

## **Agradecimientos**

Al Centro de Investigaciones Biológicas del Noroeste S.C. (CIBNOR), por permitirme realizar mis estudios de Posgrado. A la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) por la beca otorgada (400665) a lo largo del doctorado.

Agradezco a mi director, el Dr. Eduardo Romero Vivas por compartir su conocimiento, por guiarme, por la confianza, paciencia y las valiosas enseñanzas durante el desarrollo de esta investigación.

A todos los miembros de mi comité tutorial, el Dr. Braulio León López, la Dra. Aurora Paniagua Mendoza, el Dr. Joaquín Gutiérrez Jagúey y el Dr. Fernando Daniel Von Borstel Luna por todo su apoyo, por el tiempo que me dedicaron, por todas las sugerencias y valiosas aportaciones, las cuales enriquecieron este trabajo.

A la Dirección de Estudios de Posgrado y Formación de Recursos Humanos y a todo su personal por el apoyo y disposición en la gestión de trámites.

Al capitán Juan de Dios “cubano” por todo el apoyo logístico durante el proyecto.

Agradezco infinitamente a mi familia, que siempre me han apoyado en cada uno de mis proyectos y etapas de vida. Gracias a mis padres por brindarme la educación, valores y las herramientas que me han permitido para llegar hasta aquí. A mi hermana Claudia por todo tu apoyo, amor incondicional, por tu protección y por siempre motivarme a seguir adelante. Tu compañía y confianza en mí han sido un gran impulso durante este camino.

A mis amigos que fueron piezas clave en este proceso. Gracias por su apoyo, sus palabras de aliento y por siempre estar presentes tanto en momentos de alegría como en los de mayor desafío.

## Contenido

|                                                                              |             |
|------------------------------------------------------------------------------|-------------|
| <b>Resumen .....</b>                                                         | <b>i</b>    |
| <b>Summary .....</b>                                                         | <b>ii</b>   |
| <b>Dedicatoria .....</b>                                                     | <b>iii</b>  |
| <b>Agradecimientos .....</b>                                                 | <b>iv</b>   |
| <b>Contenido .....</b>                                                       | <b>v</b>    |
| <b>Lista de figuras .....</b>                                                | <b>vii</b>  |
| <b>Lista de tablas .....</b>                                                 | <b>viii</b> |
| <b>Abreviaturas .....</b>                                                    | <b>ix</b>   |
| <b>1. INTRODUCCIÓN .....</b>                                                 | <b>1</b>    |
| <b>2. ANTECEDENTES .....</b>                                                 | <b>5</b>    |
| <b>3. JUSTIFICACIÓN .....</b>                                                | <b>8</b>    |
| <b>4. HIPÓTESIS .....</b>                                                    | <b>9</b>    |
| <b>5. OBJETIVOS .....</b>                                                    | <b>10</b>   |
| 5.1 Objetivo general .....                                                   | 10          |
| 5.2 Objetivos particulares .....                                             | 10          |
| <b>6. MATERIAL Y MÉTODOS .....</b>                                           | <b>11</b>   |
| 6.1 Área de estudio .....                                                    | 11          |
| 6.2 Confirmación de especies mediante monitoreo visual y acústico .....      | 12          |
| 6.3 Monitoreo acústico de presencia de cetáceos .....                        | 12          |
| 6.4 Análisis de la detección de delfines y otros cetáceos .....              | 13          |
| 6.5 Selección de variables para el modelo de redes neuronales .....          | 15          |
| 6.6 Modelo de Redes Neuronales Artificiales (ANN) .....                      | 17          |
| 6.6.1 Preprocesamiento de datos .....                                        | 17          |
| 6.6.2 Diseño del Modelo de Redes Neuronales Artificiales .....               | 18          |
| 6.7 Evaluación y selección del modelo .....                                  | 20          |
| 6.8 Validación del conjunto de datos .....                                   | 21          |
| 6.9 Análisis de contribución de las variables .....                          | 21          |
| 6.10 Análisis de sensibilidad e interpretabilidad .....                      | 22          |
| <b>7. RESULTADOS .....</b>                                                   | <b>24</b>   |
| 7.1 Confirmación de especies mediante monitoreo visual y acústico .....      | 24          |
| 7.2 Monitoreo acústico de presencia de cetáceos .....                        | 24          |
| 7.3 Variables físicas y bióticas explicativas .....                          | 26          |
| 7.4 Modelo de Red Neuronal para la presencia de delfines (Delphinidae) ..... | 28          |
| 7.5 Evaluación del modelo .....                                              | 29          |
| 7.6 Validación del conjunto de datos .....                                   | 31          |
| 7.7 Análisis de contribución de las variables .....                          | 32          |
| 7.8 Análisis de sensibilidad e interpretabilidad .....                       | 33          |
| <b>8. DISCUSIÓN .....</b>                                                    | <b>35</b>   |
| 8.1 Consideraciones finales .....                                            | 40          |
| <b>9. CONCLUSIONES .....</b>                                                 | <b>42</b>   |
| <b>10. LITERATURA CITADA .....</b>                                           | <b>43</b>   |
| <b>11. ANEXOS .....</b>                                                      | <b>50</b>   |
| Anexo A. Confirmación de especies mediante monitoreo visual y acústico ..... | 50          |

|                                                                                                                                                                        |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Anexo B. Referencias bibliográficas para identificación de llamadas acústicas de diferentes ...                                                                        | 52 |
| Anexo C. Funciones utilizadas en las diferentes configuraciones.....                                                                                                   | 1  |
| Anexo D. configuraciones probadas para el modelo de redes neuronales .....                                                                                             | 1  |
| Anexo E.-Artículo publicado.-Cetaceans and vessels overlap assessment within a migration corridor using passive acoustic monitoring.....                               | 2  |
| Anexo F.-Artículo publicado.-A Machine Learning Approach to Assess the Relevance of Interspecific Acoustic Cetacean Co-Occurrence When Modeling Species Presence ..... | 12 |
| Anexo G.-Artículo publicado.-Year-Round Passive Acoustic Detection of Sperm Whales in the Cerralvo Channel Within the Gulf of California, Mexico .....                 | 24 |

## Lista de figuras

|                                                                                                                                                                                                                                                                                                                                                                                                                      |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Figura 1.</b> Área de estudio: Canal de Cerralvo, GC, México. Polígono rojo: monitoreo de confirmación de especies durante el periodo invernal; polígono negro: monitoreo el resto del año. Los círculos de colores representan los sitios en los que se colocó el equipo de grabación (en el sitio F hubo tres despliegues).....                                                                                 | 11 |
| <b>Figura 2.</b> Perfiles de velocidad del sonido mediante datos de temperatura obtenidos de la NOAA durante 2022. ....                                                                                                                                                                                                                                                                                              | 13 |
| <b>Figura 3.</b> Representación del registro de eventos de detección y eventos de no detección (512 points FFT, Hanning window 50 % overlap). ....                                                                                                                                                                                                                                                                   | 14 |
| <b>Figura 4.</b> Espectrograma con la representación de un evento de CAIC mostrando la detección simultánea de (A) silbidos, (B) clics de delfines con (C) clics de cachalotes (512 points FFT, Hanning window 50 % overlap). ....                                                                                                                                                                                   | 15 |
| <b>Figura 5.</b> Modelo genérico de una red neuronal con algoritmo de retropropagación. ....                                                                                                                                                                                                                                                                                                                         | 19 |
| <b>Figura 6.</b> Perfiles de velocidad del sonido mediante datos de temperatura obtenidos <i>in situ</i> . Cada color corresponde a los diferentes despliegues. ....                                                                                                                                                                                                                                                 | 25 |
| <b>Figura 7.</b> Detecciones acústicas de delfines con y sin coocurrencia acústica interespecífica de cetáceos (CAIC) durante los ocho despliegues. Las barras positivas representan las detecciones con CAIC, mientras que las barras negativas corresponden a las detecciones sin CAIC. ....                                                                                                                       | 26 |
| <b>Figura 8.</b> Distribución de las variables explicativas a lo largo del periodo de monitoreo (noviembre 2022- diciembre 2023). ....                                                                                                                                                                                                                                                                               | 27 |
| <b>Figura 9.</b> Detecciones durante el día y la noche a lo largo del periodo de monitoreo (noviembre 2022- diciembre 2023). ....                                                                                                                                                                                                                                                                                    | 28 |
| <b>Figura 10.</b> Mejor red neuronal artificial de la presencia de delfines. Configuración de la red: cinco variables explicativas, 15 neuronas en la capa oculta, función de activación ReLU, función de transferencia sigmoide. ....                                                                                                                                                                               | 29 |
| <b>Figura 11.</b> Matriz de confusión del modelo que mejor describió la presencia de delfines. FN (falsos negativos), FP (falsos positivos), TN (verdaderos negativos) y TP (verdaderos positivos). ....                                                                                                                                                                                                             | 30 |
| <b>Figura 12.</b> Curva de características operativas del receptor (ROC). La diagonal gris representa el desempeño de un clasificador aleatorio; la curva azul representa el desempeño del modelo. ...                                                                                                                                                                                                               | 30 |
| <b>Figura 13.</b> Validación del modelo mediante el método validación cruzada por exclusión de grupo. ....                                                                                                                                                                                                                                                                                                           | 31 |
| <b>Figura 14.</b> a) Valores de importancia relativa calculados mediante el método de Garson; b) valores de importancia calculados mediante el método de Olden. Clorofila a (Chl-a), velocidad del viento (windspeed), relación distancia del equipo de grabación a la costa (coast), día/noche (daynight) y coocurrencia acústica interespecífica de cetáceos (CAIC). ....                                          | 32 |
| <b>Figura 15.</b> Gráficas de Expectativa Condicional Individual (ICE) y Dependencia Parcial (PDP) para las variables: a) clorofila a (Chl-a), b) velocidad del viento, c) relación distancia del equipo de grabación a la costa, d) periodo del día (día/noche) y e) coocurrencia acústica interespecífica de cetáceos (CAIC). Las marcas naranjas representan los valores observados en el conjunto de datos. .... | 34 |

**Lista de tablas**

|                                                                                                                                           |    |
|-------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Tabla 1.</b> Variables explicativas consideradas para el modelo de redes neuronales.....                                               | 16 |
| <b>Tabla 2.</b> Despliegues colocados en los diferentes sitios a lo largo del periodo de monitoreo (noviembre 2022 - diciembre 2023)..... | 25 |

## Abreviaturas

|                    |                                                                                                        |
|--------------------|--------------------------------------------------------------------------------------------------------|
| °C                 | Grado Celcius                                                                                          |
| ANN                | Artificial Neural Networks (redes neuronales artificiales)                                             |
| AUC                | Area Under the Curve (área bajo la curva)                                                              |
| BP                 | Back Propagation (retropropagación)                                                                    |
| CAIC               | Coocurrencia Acústica Interespecífica de Cetáceos                                                      |
| Chl-a              | Clorofila a                                                                                            |
| CTD                | Conductivity, Temperature and Depth (conductividad, temperatura y profundidad)                         |
| dB                 | Decibelio                                                                                              |
| ERDDAP             | Environmental Research Division's Data Access Program                                                  |
| GC                 | Golfo de California                                                                                    |
| h                  | Hora                                                                                                   |
| HP                 | Horsepower (caballo de fuerza)                                                                         |
| ICE                | Individual Conditional Expectation (expectativa condicional individual)                                |
| kHz                | Kilohercio                                                                                             |
| km/h               | Kilómetros por hora                                                                                    |
| LDA                | Linear Discriminant Analysis (Análisis discriminante lineal)                                           |
| LOGO               | Leave-One-Group-Out (validación cruzada por exclusión de grupo)                                        |
| m                  | Metro                                                                                                  |
| mg m <sup>-3</sup> | Miligramos por metro cúbico                                                                            |
| MODIS              | Moderate Resolution Imaging Spectroradiometer (espectrorradiómetro de imágenes de resolución moderada) |
| PAM                | Passive Acoustic Monitoring (monitoreo acústico pasivo)                                                |
| PDP                | Partial Dependence Plots (gráficas de dependencia parcial)                                             |
| PSU                | Practical Salinity Units (unidades prácticas de salinidad)                                             |
| ROC                | Receiver Operating Characteristic (curva de características operativas del receptor)                   |
| SNR                | Signal-to-Noise Ratio (relación señal a ruido)                                                         |
| SST                | Sea Surface Temperature (temperatura superficial del mar)                                              |
| V                  | Voltio                                                                                                 |
| μPa                | Micropascal                                                                                            |

## 1. INTRODUCCIÓN

La familia Delphinidae (delfines oceánicos) pertenece al parvorden Odontoceti, el cual forma parte del infraorden Cetacea. Los delfines constituyen el grupo con mayor diversidad de especies dentro de los mamíferos marinos, agrupados en 18 géneros con aproximadamente 38 especies descritas, (Society for Marine Mammalogy, 2026), distribuidas en todos los océanos y mares del mundo, desde regiones ecuatoriales hasta zonas polares; sin embargo, su mayor diversidad se concentra en latitudes tropicales y templadas (Rice, 1998).

Muchas especies de delfines habitan en aguas oceánicas profundas, lo que ha limitado su estudio. No obstante, en mares tropicales, particularmente en el Pacífico Oriental Tropical, las especies de delfines han sido ampliamente estudiadas, lo que ha permitido identificar patrones en su distribución asociados a condiciones oceanográficas específicas (Au y Perryman, 1985). Por ejemplo, se ha documentado que algunas especies, como el delfín moteado (*Stenella attenuata*), el delfín tornillo (*Stenella longirostris*) y el delfín de dientes rugosos (*Steno bredanensis*), prefieren áreas con una capa de mezcla estable y una termoclina somera (Au y Perryman, 1985). En contraste, otras especies como el delfín común (*Delphinus delphis*), el delfín listado (*Stenella coeruleoalba*), el calderón de aletas cortas (*Globicephala macrorhynchus*) y el delfín cabeza de melón (*Peponocephala electra*) se asocian con zonas más variables, caracterizadas por la presencia de surgencias (Jefferson y LeDuc, 2018). Esta variabilidad ecológica, caracterizada por el dinamismo de múltiples factores bióticos y abióticos, influyen directa o indirectamente en los patrones de ocupación de un determinado hábitat, así como el desplazamiento hacia áreas con condiciones óptimas para la alimentación, la reproducción u otras actividades esenciales (Forcada, 2018). Conocer los patrones de presencia y uso de hábitat de los delfines es fundamental para comprender la ecología de estos organismos, así como para identificar posibles amenazas tanto ambientales como antropogénicas (Redfern et al., 2006).

Para los cetáceos, el uso del sonido constituye el principal medio sensorial y desempeña un papel fundamental en su ecología y comportamiento. Debido a su completa adaptación al medio acuático y a las limitaciones visuales impuestas por las propiedades físicas del océano, como la turbidez y la disminución de la luz con la profundidad, estos organismos dependen en gran medida de la información acústica para llevar a cabo funciones esenciales como la comunicación, la alimentación y la navegación (Au, 2000). En particular, los delfines producen una amplia variedad

de señales acústicas, que generalmente se agrupan en tres tipos: clics (chasquidos) de ecolocalización, pulsos en ráfaga y silbidos (tonales) (Herzing, 2000). En términos generales, estas vocalizaciones pueden estar asociadas a funciones sociales; sin embargo, los clics se utilizan principalmente en procesos de ecolocalización, permitiéndoles detectar, localizar y caracterizar objetos en su entorno (Au, 2000; Herzing, 2000).

Debido al alto grado de desarrollo del sentido acústico en los cetáceos y a la importancia del sonido en su ecología, el uso de herramientas acústicas se ha consolidado como una estrategia eficaz para su estudio (Todd et al., 2020). En particular, el monitoreo acústico pasivo (PAM, *Passive Acoustics Monitoring*) permite registrar de manera continua y no invasiva las señales emitidas por los cetáceos. Esta metodología presenta ventajas importantes con respecto a los métodos visuales, cuya probabilidad de detección está limitada por los sesgos de percepción y disponibilidad. El primero se refiere a los individuos que, aun encontrándose en la superficie, no son detectados por los observadores; el segundo depende del tiempo que los animales permanecen sumergidos y de la duración de estos eventos (Marsh y Sinclair, 1989). En este contexto, las técnicas acústicas permiten detectar especies de hábitos crípticos o con patrones de buceo profundo y prolongado, como el cachalote (*Physeter macrocephalus*) y los zifios (familia Ziphiidae) (Tepsich et al., 2014).

Una de las principales ventajas del PAM es su capacidad para detectar animales en un mayor rango de distancia que con métodos visuales, así como la posibilidad de operar de forma continua durante largos periodos, siendo un monitoreo menos afectado por las condiciones ambientales (Marques et al., 2013). Además, al registrar múltiples fuentes de sonido, permite no solo identificar la presencia de una especie en particular, sino también analizar el contexto acústico en el que ocurre dicha especie, incluyendo la detección simultánea de otras especies.

En ecosistemas marinos, donde pueden estar presentes simultáneamente diversas especies de cetáceos, la detección acústica de las mismas ofrece una oportunidad para explorar procesos ecológicos complejos como la coexistencia y el uso compartido de hábitat (Guerrero et al., 2023). En este sentido, el análisis del entorno acústico permite no sólo identificar la presencia de los delfines, sino también comprender el contexto biológico en el que ocurre, incluyendo la presencia de otras especies de cetáceos.

Cuando individuos de dos o más especies son vistos en asociaciones cercanas, que incluso pueden considerarse parte del mismo grupo, generalmente es el resultado de una atracción compartida hacia condiciones ecológicas favorables (Stensland et al., 2003; Syme et al., 2021). Estos eventos pueden representar beneficios ecológicos (Alexander, 1974), como una mayor protección frente a depredadores, ventajas en la obtención de alimento y posibles ventajas sociales o reproductivas (Krause y Ruxton, 2002). No obstante, también pueden implicar costos, como un aumento en la competencia por los recursos, mayor riesgo de detección por parte de depredadores, y una mayor probabilidad de transmisión de enfermedades (Alexander, 1974; Krause y Ruxton, 2002). Lo anterior refleja la complejidad de las interacciones entre el entorno y las diferentes especies, por lo cual resulta fundamental incluirlas en los estudios ecológicos.

El uso compartido de un área no necesariamente representa interacciones directas entre las especies involucradas; sin embargo, sí refleja interacciones ecológicas mediadas por el entorno. Aunque existe una amplia literatura que documenta asociaciones entre distintas especies de cetáceos, la mayoría de estos estudios se basa principalmente en métodos con registros visuales y de comportamiento, lo que restringe la comprensión de estas relaciones debido a las limitaciones de los métodos visuales.

La integración de dichas asociaciones en modelos ecológicos, junto con variables físicas y bióticas, representa una oportunidad para mejorar la comprensión de los factores que influyen en la presencia de los delfines. Para ello, es necesaria la implementación de técnicas analíticas avanzadas y flexibles.

En este contexto, las redes neuronales artificiales (ANN, *Artificial Neural Networks*), representan una herramienta altamente eficiente para el análisis de sistemas ecológicos complejos, mostrando un desempeño superior en comparación con modelos convencionales en diversas aplicaciones (Lek y Guégan, 1999). Su capacidad para modelar relaciones complejas entre múltiples variables y relaciones no lineales, ha impulsado su creciente aceptación dentro del campo de la ecología marina, donde los procesos ecológicos suelen estar influenciados por factores con alta variabilidad espacio-temporal (Redfern et al., 2006). En contraste, las técnicas estadísticas tradicionales pueden presentar limitaciones en este tipo de contextos, particularmente ante la presencia de no linealidad y la multicolinealidad entre variables predictoras o descriptoras.

Bajo este enfoque, el presente estudio describe la presencia de delfines mediante monitoreo acústico pasivo durante el periodo comprendido entre noviembre de 2022 y diciembre de 2023. Asimismo, se propone la generación de un modelo ecológico descriptivo basado en redes neuronales, integrando variables físicas y bióticas incluyendo la presencia de otros cetáceos, como factores explicativos de la presencia de los delfines. Este enfoque permite abordar de manera integral la complejidad del sistema, incorporando tanto las condiciones ambientales como el contexto biológico en el que ocurre la presencia de delfines.

## 2. ANTECEDENTES

El Golfo de California (GC) es una de las regiones con mayor diversidad de cetáceos a nivel mundial. Este sistema marino se distingue por ser uno de los ecosistemas más productivos en el mundo (Álvarez-Borrego, 2012), debido a su ubicación geográfica y características oceanográficas que favorecen los procesos de surgencias y una alta disponibilidad de nutrientes (Lluch-Cota et al., 2007). Estas condiciones sustentan complejas redes tróficas que promueven la presencia de una amplia gama de megafauna, incluidos los cetáceos. En particular, la costa suroeste del GC se caracteriza por su diversidad de cetáceos con aproximadamente 31 especies de las 89 reportadas a nivel global (Urbán-Ramírez, 2010), incluidas 13 de las 38 especies de delfínidos reportadas globalmente.

En la parte más sureña del GC se localiza el Canal de Cerralvo, entre la Isla Cerralvo y las localidades de La Ventana y El Sargento. En los últimos años se ha dado un incremento en las actividades turísticas de la zona, siendo el principal atractivo los safaris marinos que incluye actividades como el avistamiento de cetáceos, nado con fauna marina, buceo autónomo, buceo libre, entre otras.

Para el Canal de Cerralvo, los esfuerzos dirigidos al estudio de cetáceos son escasos. Urbán-Ramírez et al., (2012) publicaron dentro de un compendio más amplio de la zona de Los Cabos, un estudio sobre los cetáceos de la costa suroccidental del GC en el que publican los registros alrededor de la Isla Cerralvo y en donde también resaltan que “...prácticamente no existen estudios sobre el estado de conservación de las poblaciones de cetáceos en dicha región que identifiquen y evalúen los impactos potenciales de las actividades humanas...” (Urbán-Ramírez et al., 2012).

Algunas de las especies de cetáceos que se registraron en dicho estudio son: ballena azul (*Balaenoptera musculus*), ballena de aleta (*Balaenoptera physalus*), ballena gris (*Eschrichtius robustus*), ballena minke (*Balaenoptera acutorostrata*), rorcual tropical (*Balaenoptera edeni*), ballena jorobada (*Megaptera novaeangliae*), orca (*Orcinus orca*), tursión (*Tursiops truncatus*), delfín común rostro corto (*Delphinus delphis*), delfín común rostro largo (*Delphinus delphis bairdii*), orca falsa (*Pseudorca crassidens*), calderón de aletas cortas (*Globicephala macrorhynchus*), delfín moteado (*Stenella attenuata*), zifio de Cuvier (*Ziphius cavirostris*), cachalote enano (*Kogia sima*) y cachalote (Urbán-Ramírez et al., 2012). Es importante destacar que, a más de una década

de la publicación del estudio mencionado, siguen siendo escasos los estudios en esta región a pesar del aumento de las actividades turísticas no extractivas con cetáceos, y de que todos los mamíferos marinos en México se encuentran protegidos por la Norma Oficial Mexicana NOM-059 (SEMARNAT, 2010).

En el GC, un estudio que incorporó información acústica y empleó redes neuronales artificiales para modelar la presencia de tursiones en la Bahía de La Paz, México, fue el realizado por Gauger (2021). El estudio evaluó la influencia de variables directas e indirectas, incluyendo factores físicos, bióticos y antropogénicos, con el objetivo de identificar aquellas con mayor contribución a la presencia de la especie. Los resultados permitieron describir los principales factores asociados con la presencia de tursiones, destacando la sensibilidad y capacidad de respuesta de la especie ante cambios en las condiciones ambientales. Estos hallazgos resaltan el potencial de las ANN como herramientas para modelar patrones ecológicos complejos en cetáceos.

A nivel global, las redes neuronales también han sido empleadas para modelar la presencia de cetáceos. Lin et al., (2021) desarrollaron una ANN para predecir la presencia y ausencia del delfín jorobado del Indo-Pacífico (*Sousa chinensis*), utilizando ocho variables ambientales. El desempeño del modelo fue comparado con un Análisis Discriminante Lineal (LDA, *Linear Discriminant Analysis*), obteniendo la ANN una mayor precisión de clasificación (74%) en comparación con el LDA (67%). Los autores concluyeron que las redes neuronales artificiales constituyen una herramienta eficiente para analizar y predecir patrones de uso de hábitat en cetáceos, particularmente cuando las relaciones entre las variables ambientales y la presencia de las especies son complejas y no lineales.

En conjunto, los estudios realizados en el GC han demostrado que diversas variables físicas, bióticas y temporales influyen en la presencia y distribución de los delfines. Asimismo, estudios recientes han evidenciado el potencial de las ANN para modelar patrones ecológicos complejos en cetáceos y mejorar la capacidad predictiva y descriptiva de los modelos de presencia. Sin embargo, la mayoría de los estudios se han centrado en evaluar variables ambientales o antropogénicas, mientras que la contribución de la presencia de otros cetáceos como variable explicativa ha recibido menor atención. En particular, se desconoce en qué medida la presencia acústica de otras especies de cetáceos, en conjunto con variables físicas y bióticas, contribuye a

describir la presencia de delfines en el Canal de Cerralvo. Por ello resulta relevante desarrollar modelos ecológicos que integren estas variables y permitan una mejor comprensión de los factores asociados con la presencia de delfines en esta región.

### 3. JUSTIFICACIÓN

Diversos estudios han documentado las asociaciones entre diferentes especies de cetáceos, las cuales pueden estar relacionadas con el uso compartido de áreas de alimentación, respuestas similares a las condiciones ambientales o interacciones ecológicas entre especies. Estas observaciones sugieren que la presencia de una especie podría aportar información sobre las condiciones que favorecen la presencia de otras especies dentro de una comunidad ecológica.

A pesar de ello, la mayoría de los modelos ecológicos utilizados para describir la presencia de cetáceos han considerado principalmente variables físicas y bióticas del ambiente, mientras que la información derivada de la ocurrencia de otras especies generalmente ha sido analizada de manera independiente. En consecuencia, aún existe un conocimiento limitado sobre la contribución que la presencia de otros cetáceos puede tener en la descripción de los patrones de presencia de los delfines.

El Canal de Cerralvo alberga una alta diversidad de cetáceos y constituye una zona de importancia ecológica dentro del GC, donde múltiples especies coinciden espacial y temporalmente. Por ello, representa un escenario adecuado para evaluar si la presencia de otras especies de cetáceos aporta información complementaria a la proporcionada por las variables físicas y bióticas comúnmente utilizadas para describir la presencia de delfines.

El presente estudio busca contribuir al conocimiento de las variables asociadas con la presencia de delfines mediante la integración de información sobre la presencia de otros cetáceos y las variables ecológicas observadas. Los resultados permitirán ampliar la comprensión de los patrones de presencia de estas especies y aportar elementos para el desarrollo de modelos ecológicos que incorporen una perspectiva más integral.

#### **4. HIPÓTESIS**

Si existe una relación entre la presencia de delfines y la de otros cetáceos, entonces esta relación tendrá una mayor contribución que las variables físicas y bióticas de un modelo ecológico descriptivo.

## **5. OBJETIVOS**

### **5.1 Objetivo general**

Evaluar la contribución de la presencia de otros cetáceos, en conjunto con variables físicas y bióticas, en la presencia de delfines mediante un modelo ecológico.


### **5.2 Objetivos particulares**

1. Detectar la presencia de delfines y otros cetáceos en el Canal de Cerralvo y caracterizar las variables físicas y bióticas.
2. Generar un modelo ecológico descriptivo de presencia de delfines que incluya variables físicas, bióticas y de presencia de otros cetáceos.
3. Evaluar la contribución de la presencia de otros cetáceos en conjunto con las variables físicas y bióticas en la presencia de delfines.
4. Interpretación ecológica de las variables con mayor contribución en el modelo de presencia de delfines.

## 6. MATERIAL Y MÉTODOS

### 6.1 Área de estudio

El Canal de Cerralvo se encuentra entre la Isla Cerralvo ( $24^{\circ} 12' N$ ,  $109^{\circ} 48' O$ ) y la costa oriental de la península de Baja California Sur (Fig. 1). El canal tiene aproximadamente 13 km de ancho y alcanza profundidades de hasta 500 m. Debido a su cercanía a la entrada del GC, esta zona se considera un área de transición biogeográfica, influenciada por la interacción de distintas masas de agua superficiales (Álvarez-Borrego, 1983). En la entrada del GC convergen tres masas de agua: las aguas frías de la Corriente de California, caracterizadas por una baja salinidad ( $\leq 34.6$  PSU, *Practical Salinity Units*), que fluyen hacia el sur a lo largo de la costa oeste de la península de Baja California; las aguas templadas del Pacífico Oriental Tropical, con salinidad media (34.65-34.85 PSU), que fluye en la zona del sureste; y las aguas de alta salinidad propias del GC ( $\geq 34.9$  PSU) (Álvarez-Borrego y Schwartzlose, 1979).



**Figura 1.** Área de estudio: Canal de Cerralvo, GC, México. Polígono rojo: monitoreo de confirmación de especies durante el periodo invernal; polígono negro: monitoreo el resto del año. Los círculos de colores representan los sitios en los que se colocó el equipo de grabación (en el sitio F hubo tres despliegues).


## **6.2 Confirmación de especies mediante monitoreo visual y acústico**

Se realizaron monitoreos visuales con binoculares y grabaciones acústicas (utilizando equipo de grabación con hidrófono fuera de borda) (características descritas en 6.3) durante el periodo de julio de 2022 a septiembre de 2023. Los monitoreos se realizaron a bordo de una embarcación tipo panga de 24 pies con motor fuera de borda de 150 HP, con un esfuerzo de monitoreo de 6 horas por día. La finalidad de estos monitoreos fue confirmar que las especies observadas o detectadas acústicamente correspondieran a aquellas previamente reportadas en el área de estudio (ver Anexo A).

## **6.3 Monitoreo acústico de presencia de cetáceos**

Se realizaron grabaciones mediante monitoreo acústico pasivo (PAM) durante el periodo de noviembre de 2022 a diciembre de 2023. Los datos se obtuvieron utilizando un equipo de grabación autónomo, el cual generó registros continuos con una duración aproximada de 50 horas por despliegue. El equipo de grabación autónomo consistió en un hidrófono omnidireccional Electrolaer E1 (Electrolaer S.A. de C.V., CDMX) (sensibilidad -201 dB re 1 V/ $\mu$ Pa) conectado a una grabadora digital SONY (rango de frecuencia de 6 a 22 000 Hz, filtro pasa altas de 30 dB, frecuencia de muestreo de 44.1 kHz).

Para generar el perfil de temperatura e identificar el canal de propagación acústica, se obtuvieron los datos de temperatura, profundidad y salinidad de la National Oceanic and Atmospheric Administration (NOAA, 2024), y se determinó que la profundidad de 7 m era la más adecuada para la colocación del equipo de grabación autónomo (Fig. 2). Posteriormente, durante los despliegues se tomaron los datos temperatura y profundidad *in situ* en intervalos desde 1 m hasta una profundidad de 50 m para corroborar que la profundidad adecuada para la colocación del equipo continuara siendo la misma. A lo largo del periodo de monitoreo, el equipo de grabación autónomo fue reubicado debido a causas logísticas, instalándose en diferentes boyas.



**Figura 2.** Perfiles de velocidad del sonido mediante datos de temperatura obtenidos de la NOAA durante 2022.


#### 6.4 Análisis de la detección de delfines y otros cetáceos

Las grabaciones fueron analizadas a través de espectrogramas (512-puntos FFT, ventana Hann, 50% overlap) en el software Audacity (Version 3.7.3. The Audacity Project Muse Group & contributors).

Las señales acústicas producidas por los delfines presentan una alta similitud entre especies, lo que dificulta su diferenciación sin confirmación visual (Oswald et al., 2021). Por esta razón, las detecciones acústicas de delfines se clasificaron únicamente a nivel taxonómico de familia: Delphinidae.

Únicamente se consideraron señales con una relación señal a ruido (SNR, *Signal-to-Noise Ratio*)  $\geq 8$  dB, con el fin de asegurar que las detecciones fueran claramente distinguibles del ruido de fondo. Cada detección acústica fue clasificada como un evento, de acuerdo a la metodología utilizada por Gauger et al., (2022), la cual establece que una detección se considera un evento

independiente cuando transcurre un intervalo de al menos 10 minutos sin señales adicionales de la misma especie o grupo taxonómico; en este caso aplicado a señales de delfines (Fig. 3).




**Figura 3.** Representación del registro de eventos de detección y eventos de no detección (512 points FFT, Hanning window 50 % overlap).

En el presente trabajo se propone el concepto de “coocurrencia acústica interespecífica de cetáceos” (CAIC), definida como la detección simultánea de señales acústicas emitidas por dos o más especies de cetáceos dentro de un mismo espacio acústico activo. Este enfoque permite explorar la coexistencia de especies desde una dimensión acústica.

En este estudio el espacio acústico se refiere al conjunto de señales que son registradas con suficiente claridad para ser visualizadas en espectrogramas y clasificadas de manera confiable como vocalizaciones de cetáceos. Este espacio corresponde al rango efectivo de detección determinado por las características de propagación del sonido y las características del sistema de registro (equipo de grabación autónomo).

La coocurrencia acústica interespecífica de cetáceos (CAIC) se registró cuando, durante un mismo evento de detección de delfines, se detectaron señales acústicas correspondientes a una o más especies adicionales de cetáceos. En la Fig. 4 se presenta un espectrograma mostrando un evento de detección de CAIC con delfines y cachalotes. Para la identificación de otras especies de

cetáceos, se elaboró un catálogo basado en las señales acústicas previamente publicadas de los cetáceos presentes en la región.



**Figura 4.** Espectrograma con la representación de un evento de CAIC mostrando la detección simultánea de (A) silbidos, (B) clics de delfines con (C) clics de cachalotes (512 points FFT, Hanning window 50 % overlap).

En el caso de los misticetos y cachalotes, cuyas señales acústicas son específicas de cada especie y han sido previamente descritas, fue posible realizar la clasificación hasta el nivel de especie. Sin embargo. Cuando se detectó una señal con características propias de misticetos, pero que no coincidía con ninguna de las descripciones disponibles, fue clasificada como *Balaenoptera spp*, indicando su asignación al grupo de los rorcuales sin una identificación específica.

### 6.5 Selección de variables para el modelo de redes neuronales

A partir de una revisión bibliográfica (Anexo B), se seleccionaron variables ecológicas (Tabla 1) que pueden influir, de manera directa o indirecta en la presencia de delfines, incluida la coocurrencia acústica interespecífica de cetáceos (CAIC), las cuales fueron incorporadas en los modelos de redes neuronales (ANN).

**Tabla 1.** Variables explicativas consideradas para el modelo de redes neuronales.

| Variable                                                    | Nomenclatura               | Unidades           | Rango         | Fuente                          |
|-------------------------------------------------------------|----------------------------|--------------------|---------------|---------------------------------|
| Coocurrencia<br>Acústica<br>Interespecífica de<br>Cetáceos  | CAIC                       | detecciones        | 0 o 1         | Grabaciones                     |
| Clorofila a                                                 | Chl-a                      | mg m <sup>-3</sup> | 0.114 a 1.30  | Copernicus Marine<br>Service    |
| Temperatura<br>superficial del mar                          | SST                        | °C                 | 15 a 32       | Copernicus Marine<br>Service    |
| Velocidad del<br>viento                                     | windspeed                  | km/h               | 0 a 35        | Visual Crossing<br>Weather Data |
| Dirección del<br>viento                                     | winddir_sin<br>winddir_cos | grados             | -1 a 1        | Visual Crossing<br>Weather Data |
| Nivel de marea                                              | tide                       | m                  | -0.25 a 1.23  | Fishing Points App              |
| Cobertura de nubes                                          | cloudcover                 | %                  | 0 a 100       | Visual Crossing<br>Weather Data |
| Relación distancia<br>del equipo de<br>grabación a la costa | coast                      | -                  | 0.447 a 0.522 | Google Earth tools              |
| Día/noche                                                   | daynight                   | detecciones        | 0 o 1         | NOAA Solar calculator           |

Los datos de temperatura superficial del mar (SST, *Sea Surface Temperature*) se obtuvieron a partir de imágenes satelitales disponibles en el portal ERDDAP, administrado por la National Oceanic and Atmospheric Administration (NOAA, 2022-2023), correspondientes a los días en que se realizaron las grabaciones. Las imágenes satelitales utilizadas provienen del sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) a bordo del satélite Aqua y tienen una resolución espacial de 1 km.

Las imágenes satelitales de clorofila a (Chl-a) también se obtuvieron del portal ERDDAP (NOAA, 2022;2023), con una resolución espacial aproximada de 1.4 km. Para la extracción de los valores de SST y Chl-a correspondientes a cada posición geográfica de monitoreo, se emplearon las librerías “raster” y “ncdf4” del software de código abierto R Studio (versión 2023.06.1+524).

La velocidad del viento, dirección del viento y cobertura de nubosidad se obtuvieron del portal Visual Crossing Weather Data Services (Visual Crossing, 2024). La dirección del viento se descompuso en seno y coseno (winddir\_sin y winddir\_cos).

Debido a problemas logísticos con las boyas en las cuales se colocó el equipo, este tuvo que instalarse en sitios ligeramente diferentes entre los distintos despliegues. Por esta razón, se incorporó al modelo la variable denominada relación distancia del equipo de grabación a la costa (coast), calculada como el cociente entre la distancia del equipo a la costa peninsular y la distancia del equipo a la Isla Cerralvo. Es importante destacar, que esta métrica representa la posición relativa del equipo dentro del Canal de Cerralvo durante cada despliegue y no corresponde a la ubicación de los cetáceos detectados.

Para la variable día/noche (daynight), se utilizaron las horas del amanecer y atardecer obtenidas a partir de la calculadora solar del Global Monitoring Laboratory de la National Oceanic and Atmospheric Administration (NOAA, 2022-2023). Para la fase “día” se definió como el intervalo entre amanecer y atardecer, mientras que la fase “noche” correspondió al periodo entre atardecer y amanecer, incluyendo los crepúsculos.

## **6.6 Modelo de Redes Neuronales Artificiales (ANN)**

### **6.6.1 Preprocesamiento de datos**

Se realizó el preprocesamiento correspondiente para cada tipo de variable, para posteriormente integrarlas en el modelo de redes neuronales.

Las variables de Chl-a y SST se transformaron inicialmente a escala logarítmica de base 10 (1), debido a que no siguen una distribución normal (Zar, 2010). En el caso de la Chl-a, sus valores varían en un orden de magnitud. Posteriormente, ambas variables se normalizaron en un rango de 0 a 1 (Eq. 2), utilizando los valores máximos y mínimos del conjunto de datos de cada variable (Han et al., 2012).

$$z_l = \log_{10}(z) \vee z = \{Chl - a, SST\} \quad (1)$$

La dirección del viento, originalmente expresada en grados, fue convertida a radianes con el fin de evitar la discontinuidad presente en el límite  $0^\circ/360^\circ$ . Posteriormente, se descompuso en sus componentes vectoriales seno (componente norte-sur) y coseno (componente este-oeste) (Mardia y Jupp, 2000), generando dos nuevas variables: winddir\_sin y winddir\_cos. Finalmente, ambas fueron normalizadas en un rango de 0 a 1 (2).

Las variables de relación distancia del equipo de grabación autónomo a la costa (coast), nivel de marea (tide) y cobertura de nubes (cloudcover) únicamente fueron normalizadas.

$$x' = \frac{x - xmin}{xmax - xmin} \vee x = \left\{ \begin{array}{l} Chl - a, \\ SST, \\ windspeed, \\ winddir_{sin}, \\ winddir_{cos}, \\ coast, \\ tide, \\ cloudcover \end{array} \right\} \quad (2)$$

Las variables binarias daynight (1=día, 0= noche) y CAIC (1=detección, 0= no detección) se mantuvieron en sus valores originales (0 y 1).

### 6.6.2 Diseño del Modelo de Redes Neuronales Artificiales

Con los datos de los registros acústicos, se generó un conjunto balanceado de datos con una proporción 50/50 entre eventos de detección de delfines y no detección. Este conjunto se dividió aleatoriamente en tres subconjuntos: a) entrenamiento (70%); b) validación (15%) y c) prueba (15%).


Se construyó un modelo de red neuronal del tipo perceptrón multicapa, entrenado mediante el algoritmo de retropropagación (BP, *Backpropagation*). Este algoritmo (BP) se utiliza para entrenar a la red e intenta minimizar el error; para cada paso que va hacia adelante, el algoritmo retrocede para ajustar los parámetros de la red (Rumelhart et al., 1986). Este modelo opera bajo un esquema de aprendizaje supervisado, en el cual la variable de salida, en este caso, la detección o no detección de delfines, guía el proceso de aprendizaje ajustando los pesos de las conexiones entre neuronas (Samarasinghe, 2006; Greener et al., 2022).

El perceptrón multicapa (Fig.5) está conformado por una capa de entrada, una o más capas ocultas y una capa de salida. La capa de entrada está constituida por un conjunto de nodos, donde cada uno representa una variable explicativa del modelo (Tabla 1). Cada nodo recibe un valor numérico correspondiente a una observación específica, en este caso se generó una lista con todas las combinaciones posibles de las 10 variables explicativas, cada combinación con mínimo tres variables, lo que resultó en 968 combinaciones (3) (Feller, 1968), que se probaron

secuencialmente en la capa de entrada durante el proceso de entrenamiento. Los nodos de la capa de entrada se conectan con las neuronas de la capa oculta (círculos verdes) mediante enlaces ponderados (líneas azules).

$$C_k^n = \frac{n!}{k! (n - k)!} \quad (3)$$

en donde  $n$  es el número total de variables,  $k$  representa el número mínimo de variables y el signo “!” es el operador factorial.



**Figura 5.** Modelo genérico de una red neuronal con algoritmo de retropropagación.

Estas conexiones representan los pesos sinápticos que vinculan las variables de entradas con las neuronas de la capa oculta. Para probar las 968 combinaciones previamente mencionadas, se asignó una semilla que configura el generador de números aleatorios para que empiece siempre en el mismo punto el entrenamiento, es decir, que en cada iteración se le asigne el mismo peso a la variable en turno en las combinaciones. Estos pesos constituyen los principales parámetros ajustables de la red neuronal, y su optimización es lo que se entiende como el proceso de entrenamiento de la red (Greener et al., 2022), a través de diferentes funciones (Anexo C).

Posteriormente, en la capa oculta, cada neurona calcula una suma ponderada ( $\Sigma$ ) de las entradas recibidas; hasta este punto, el procesamiento es de carácter lineal, sin embargo, cada neurona oculta aplica posteriormente una función de transferencia no lineal ( $f$ ), lo que permite al modelo capturar relaciones complejas entre las variables (4) (Rosenblatt, 1958). En esta capa se probaron diferentes configuraciones para obtener el mejor modelo. Se probó con 5, 10, 15 y 20 neuronas en una sola capa oculta. También se probaron diferentes funciones de transferencia que introducen no linealidad (Anexo C).

$$y = f\left(\sum_{i=1}^n (w_i x_i) + b\right) \quad (4)$$

en donde  $x_i$  representa el valor de una variable de entrada ( $n$  variables),  $w_i$  representa el peso asociado a esa entrada,  $b$  corresponde al sesgo y  $f$  representa la función de transferencia no lineal que recibe un valor de entrada y produce un único valor de salida.

Finalmente, las salidas de las neuronas ocultas son transmitidas a la capa de salida a través de un segundo conjunto de ponderaciones, donde se incluyen mediante una nueva sumatoria ( $\Sigma$ ) y la aplicación de otra función de transferencia ( $f$ ). Esto constituye la salida de la red, indicando la clase a la que pertenece cada entrada (Samarasinghe, 2006).

Se evaluó mediante funciones de pérdida que cuantifican la diferencia entre la salida y el valor real. En este modelo se probaron las funciones de error cuadrático medio (MSE) y entropía cruzada (crossentropy), esta última utilizada más en problemas de clasificación binaria (Greender et al., 2022).

## 6.7 Evaluación y selección del modelo

Existen diversas métricas para evaluar el desempeño de un modelo de redes neuronales. En el presente estudio, se utilizó la exactitud (5), la cual mide la proporción de predicciones correctas respecto al total de casos evaluados (Powers, 2011). De este modo, esta métrica indica la frecuencia con la que el modelo clasifica correctamente tanto las instancias positivas como las negativas. Se seleccionó el modelo con la métrica de exactitud más cercana a uno.

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

donde  $TP$  representa los verdaderos positivos,  $TN$  los verdaderos negativos;  $FP$  los falsos positivos y  $FN$  los falsos negativos.

Para evaluar el rendimiento del modelo, se generó la gráfica ROC (ROC, *Receiver Operating Characteristic*). En esta gráfica, el eje X representa la tasa de falsos positivos o probabilidad de falsa alarma (fall-out) ( $FPR=FP/FP+TN$ ), mientras que el eje Y corresponde a la tasa de verdaderos positivos o sensibilidad (recall) ( $TPR=TP/TP+FN$ ). Cada punto sobre la curva refleja un umbral de probabilidad distinto empleado por el modelo para realizar la clasificación.

Asimismo, se calculó el valor del área bajo la curva (AUC, *Area Under the Curve*), que cuantifica el área bajo la curva ROC. Un valor de AUC cercano a 1, indica que el modelo presenta una alta capacidad para clasificar correctamente.

### 6.8 Validación del conjunto de datos

La validación del modelo se llevó a cabo mediante un esquema de validación cruzada por exclusión de grupo (LOGO, *Leave-One-Group-Out*). En este enfoque, los datos se dividieron en grupos, de tal manera que en cada iteración se excluyeron todas las observaciones pertenecientes a un grupo del conjunto de entrenamiento, utilizándose únicamente como conjunto de prueba. Este procedimiento se repitió hasta que cada grupo fue utilizado una vez como conjunto de validación. Esta estrategia permite evaluar de manera robusta la capacidad de generalización del modelo, al considerar la variabilidad entre grupos y evitar la dependencia entre datos de entrenamiento y prueba (Stone, 1974).

### 6.9 Análisis de contribución de las variables

Para evaluar la importancia de las variables en el modelo se implementaron dos métodos: el de importancia relativa de Garson (Garson, 1991) y el método basado en la conexión de pesos de Olden (Olden y Jackson, 2002).

El método de Garson (6) permite estimar la contribución relativa (CR) de cada variable de entrada a la salida del modelo, distribuyendo los pesos de conexión entre las capas de forma que se cuantifique la influencia de cada variable explicativa sobre la predicción final.

$$CR = \frac{\sum_{j=1}^{n_h} |w_{ij} w_{jo}|}{\sum_{i=1}^{n_v} \sum_{j=1}^{n_h} |w_{ij} w_{jo}|} \quad (6)$$

en donde  $w_{ij}$  representa el peso entre variable de entrada  $i$  y neurona oculta  $j$ ,  $w_{jo}$  representa el peso entre la neurona oculta  $j$  y la salida,  $n_h$  es el número de neuronas ocultas y  $n_v$  es el número de variables de entrada.

Por otro lado, el método de Olden (7) se basa en el análisis directo de los pesos sinápticos de la red neuronal. Este método evalúa la importancia y contribución absoluta (CA) de cada variable de entrada considerando tanto la magnitud como el signo de los pesos entre las capas, lo que permite identificar no sólo las variables que tienen mayor influencia, sino también si su efecto es positivo o negativo sobre la salida del modelo.

$$CA = \sum_{i=1}^{n_h} (w_{ij} w_{jo}) \quad (7)$$

en donde  $w_{ij}$  representa el peso entre variable de entrada  $i$  y neurona oculta  $j$ ,  $w_{jo}$  representa el peso entre la neurona oculta  $j$  y la salida,  $n_h$  es el número de neuronas ocultas.

### 6.10 Análisis de sensibilidad e interpretabilidad

Con el objetivo de interpretar el comportamiento interno del modelo y analizar la influencia de las variables sobre la probabilidad de detección de delfines, se emplearon dos métodos de interpretabilidad: las gráficas de expectativas condicionales individuales (ICE, *Individual Conditional Expectation*) y las gráficas de dependencia parcial (PDP, *Partial Dependence Plots*).

Las gráficas ICE permiten examinar la respuesta del modelo individualmente, es decir, para cada observación del conjunto de datos. Para ello, se modifica el valor de una de las variables explicativas a lo largo de su rango, manteniendo las demás variables constantes, obteniendo así una predicción. La superposición de múltiples curvas ICE permite evaluar la variabilidad en las respuestas individuales (Mohlnar, 2025).

Por otro lado, las gráficas PDP describen el efecto promedio de una variable explicativa sobre la salida del modelo, manteniendo constantes las demás variables. Para cada variable se calcula la

predicción del modelo a lo largo del rango de valores observados de dicha variable y posteriormente se promedian todas las observaciones del conjunto de datos. Las PDP permiten identificar tendencias generales en relación a una variable y la respuesta del modelo (Mohlner, 2025).

## **7. RESULTADOS**

### **7.1 Confirmación de especies mediante monitoreo visual y acústico**


Se realizaron 18 salidas que incluyeron tanto monitoreos con esfuerzo dirigido, así como monitoreos oportunistas durante actividades turísticas, combinando observación con monitoreo acústico mediante un equipo de grabación. En total, se obtuvieron 77 grabaciones que sumaron aproximadamente 10 horas.

Se registró la detección de las siguientes especies de delfines: tursiones, delfín común, delfín moteado y orca, en 15 de las 18 salidas realizadas, lo que representa el 83 % del total de los monitoreos. También se registraron tres especies de misticetos: ballena azul, ballena de aleta y ballena de Bryde. Se registró la presencia de cachalote. De estas especies, la ballena azul y la ballena de aleta fueron detectadas únicamente mediante señales acústicas, mientras que las demás especies contaron con confirmación tanto visual como acústica.

### **7.2 Monitoreo acústico de presencia de cetáceos**

El equipo de grabación autónomo se colocó en nueve ocasiones (despliegues) entre noviembre de 2022 y diciembre de 2023 (Tabla 2), acumulando 452 horas de grabaciones. Sin embargo, durante el mes de agosto se presentaron problemas logísticos que impidieron el correcto análisis de las grabaciones por lo que se excluyó de los análisis.

Los perfiles de velocidad del sonido generados a partir de los datos tomados *in situ* (Fig. 6) confirmaron que la profundidad idónea para la colocación del equipo de grabación autónomo fue a 7 m por debajo de la superficie del mar.




**Figura 6.** Perfiles de velocidad del sonido mediante datos de temperatura obtenidos *in situ*. Cada color corresponde a los diferentes despliegues.

**Tabla 2.** Despliegues colocados en los diferentes sitios a lo largo del periodo de monitoreo (noviembre 2022 - diciembre 2023).

| Sitio | Despliegue | Fecha          | Sitio | Despliegue | Fecha          |
|-------|------------|----------------|-------|------------|----------------|
| A     | 1          | 27-29 Nov 2022 | E     | 5          | 07-09 Jun 2023 |
| B     | 2          | 29-31 Ene 2023 | F     | 6          | 21-23 Jul 2023 |
| C     | 3          | 08-10 Mar 2023 | F     | 7          | 21-23 Sep 2023 |
| D     | 4          | 12-14 May 2023 | F     | 8          | 21-23 Dic 2023 |

A partir del análisis de estas grabaciones, se registraron 198 eventos de detección de delfines. Las detecciones variaron entre los diferentes despliegues (Fig. 7). En la porción superior del eje x se presentan todos los eventos registrados de CAIC y por debajo únicamente las detecciones de delfines, sin CAIC. En los despliegues 3 y 6 se registró una mayor diversidad de especies coocurrentes, destacando principalmente la presencia de cachalotes, seguida por ballena azul y ballena de aleta. La ballena de Bryde únicamente se detectó durante el despliegue 4. En contraste, en el despliegue 8 no hubo detecciones con CAIC.



**Figura 7.** Detecciones acústicas de delfines con y sin coocurrencia acústica interespecífica de cetáceos (CAIC) durante los ocho despliegues. Las barras positivas representan las detecciones con CAIC, mientras que las barras negativas corresponden a las detecciones sin CAIC.

### 7.3 Variables físicas y bióticas explicativas


Con el fin de analizar el comportamiento de las variables explicativas a lo largo del periodo de monitoreo, se generaron las gráficas correspondientes a cada variable (Fig. 8).

En el caso de la clorofila (Chl-a), temperatura superficial del mar (SST), velocidad del viento (windspeed), dirección del viento (winddir\_sin y winddir\_cos), cobertura de nubes (cloudcover) y nivel de marea (tide) se presentan como promedios de los valores registrados durante los días en que el equipo de grabación autónomo permaneció grabando.

La clorofila presenta valores relativamente altos al inicio del periodo, correspondientes a la temporada fría dentro del GC, seguidos de una disminución hacia la primavera y verano y un incremento notable en el último despliegue. En el caso de la SST, muestra una tendencia estacional, con valores mínimos en invierno (despliegues 1-3) y máximos en la temporada -cálida (despliegues 5-7).


En cuanto a la velocidad del viento (windspeed), se observa un incremento gradual desde el primer despliegue hasta el cuarto, en donde alcanza su máximo valor, seguido de una disminución hacia el despliegue seis. La dirección del viento presenta variaciones a lo largo del periodo, con un cambio más marcado en el tercer despliegue.

La cobertura de nubes (cloudcover) muestra también alta variabilidad con alto porcentaje de nubosidad durante los despliegues 2, 3 y 8, mientras que en los demás despliegues se detectan valores más bajos. Finalmente, el nivel de marea (tide) presenta variaciones a lo largo del periodo, con valores más bajos en los despliegues 1 a 5 y un incremento progresivo del 5 al 8.



**Figura 8.** Distribución de las variables explicativas a lo largo del periodo de monitoreo (noviembre 2022- diciembre 2023).

En cuanto a la variable día/noche, el número de detecciones fue mayor durante la noche (n=116) en comparación con el día (n=82). Mensualmente, los registros durante el día superaron a los registros durante la noche en la mayoría de los despliegues analizados, con diferencias notables en 2 y 4 (Fig. 9). En contraste, sólo en el despliegue 1 se observó un mayor número de registros durante el día. La prueba de Wilcoxon pareada indicó que estas diferencias son significativas (V=4.5, p=0.037), lo que evidencia un patrón general de mayor actividad durante la noche en comparación con el día.




**Figura 9.** Detecciones durante el día y la noche a lo largo del periodo de monitoreo (noviembre 2022- diciembre 2023).

#### 7.4 Modelo de Red Neuronal para la presencia de delfines (Delphinidae)

A partir de las 968 posibles combinaciones de variables, se probaron diferentes configuraciones de redes (Anexo D). La configuración que alcanzó la mayor exactitud (81.7%) consistió en una red con una sola capa oculta con 15 neuronas, empleando la función de transferencia ReLU en la capa oculta y la función sigmoide en la capa de salida. La función de desempeño fue el error medio cuadrático (MSE, *medium square error*) obteniendo un valor de 0.17. El modelo fue entrenado utilizando el algoritmo de gradiente conjugado escalado.

Este modelo incluyó las variables: clorofila (Chl-a), velocidad de viento (windspeed), relación distancia del equipo de grabación autónomo a la costa (coast), día/noche (daynight) y coocurrencia acústica (CAIC) como las variables de entrada que mejor describen la presencia de delfines en el área (Fig. 10).



**Figura 10.** Mejor red neuronal artificial de la presencia de delfines. Configuración de la red: cinco variables explicativas, 15 neuronas en la capa oculta, función de activación ReLU, función de transferencia sigmoide.


### 7.5 Evaluación del modelo

La matriz de confusión mostró una exactitud global de clasificación del 81.7%. El modelo identificó correctamente el 61% de los verdaderos negativos (TN) y el 20% de los verdaderos positivos (TP), mientras que generó un 18.3% de falsos negativos (FN) y no produjo falsos positivos (FP) (Fig. 11). El desempeño del modelo difirió entre clases. Para la clase negativa (no detección), se alcanzó una especificidad del 100%, lo que indica que no se generaron falsos positivos. En contraste, la sensibilidad para la clase positiva (detección) fue del 52%, lo que refleja que casi la mitad de los casos positivos reales fueron clasificados erróneamente como negativos. En general, el modelo mostró un comportamiento conservador, minimizando los falsos positivos a costa de omitir una proporción considerable de verdaderos positivos.

|              |   |                        |                        |                |
|--------------|---|------------------------|------------------------|----------------|
| Predicciones | 0 | <b>TN</b> 37<br>61.70% | <b>FN</b> 11<br>18.30% | 77.1%          |
|              | 1 | <b>FP</b> 0<br>0%      | <b>TP</b> 12<br>20%    | 100%           |
|              |   | 100%<br>0              | 52.2%<br>47.8%         | 81.7%<br>18.3% |
|              |   | 0                      | 1                      |                |
|              |   | Observaciones          |                        |                |

**Figura 11.** Matriz de confusión del modelo que mejor describió la presencia de delfines. FN (falsos negativos), FP (falsos positivos), TN (verdaderos negativos) y TP (verdaderos positivos).

La curva ROC (Fig. 12) muestra la tasa de falsos positivos en el eje X, y la tasa de verdaderos positivos en el eje Y. La línea gris en diagonal representa el desempeño de una clasificación aleatoria; un modelo útil debe encontrarse por arriba de esta línea. La curva azul representa el desempeño del modelo, en este caso, se mantiene por encima de la diagonal lo cual indica que el modelo tiene capacidad de clasificación mejor que el azar. El punto inicial, con un TPR de 0.6, sugiere que el modelo es capaz de identificar el 60% de los casos positivos desde etapas tempranas del umbral. El área bajo la curva (AUC) fue de 0.782, lo cual sugiere un buen poder predictivo global, es decir que el modelo distingue correctamente eventos positivos y negativos




**Figura 12.** Curva de características operativas del receptor (ROC). La diagonal gris representa el desempeño de un clasificador aleatorio; la curva azul representa el desempeño del modelo.

## 7.6 Validación del conjunto de datos

En general, el desempeño en entrenamiento se mantuvo relativamente estable entre todos los grupos. El error cuadrático medio de entrenamiento mostró una variación limitada, con valores medianos consistentes alrededor de 0.16 (Fig. 13a). De manera similar, la exactitud en entrenamiento se mantuvo alta y estable (entre 75% y 78% aproximadamente) (Fig. 13c), lo que indica que el modelo logra ajustarse adecuadamente a los datos de entrenamiento.

En contraste, el desempeño en el conjunto de prueba mostró una fuerte dependencia del tamaño de los grupos. Para grupos pequeños a intermedios, el MSE de prueba se mantuvo bajo, comparable al error de entrenamiento (Fig. 13b), lo que sugiere una buena capacidad de generalización cuando se excluye un número limitado de observaciones. Sin embargo, a medida que el tamaño del grupo aumentó, el MSE de prueba presentó la mayor variabilidad, evidenciada por rangos intercuartílicos más amplios y la presencia de valores extremos.




**Figura 13.** Validación del modelo mediante el método validación cruzada por exclusión de grupo.

## 7.7 Análisis de contribución de las variables

De acuerdo con el análisis de contribución relativa de variables mediante el método de Garson (Fig. 14a), los resultados indican que la velocidad del viento (0.26) fue la más influyente, seguida por la CAIC (0.25), lo que sugiere que el modelo se basó principalmente en estos factores para discriminar entre la presencia de delfines y la ausencia de detección. La concentración de clorofila (Chl-a) (0.19) presentó una contribución moderada, mientras que la relación distancia del equipo de grabación autónomo a la costa (0.17) mostró una influencia intermedia. Finalmente, día/noche (daynight) (0.10) fue la variable menos influyente.

Por otro lado, el método de Olden, que considera tanto la magnitud como el signo, permite identificar no solo la importancia sino también la dirección del efecto de cada variable (Fig. 14b). Los resultados indican que la CAIC presentó un efecto fuertemente positivo, siendo el de mayor influencia sobre la presencia de delfines (2.48). La variable día/noche (daynight) mostró una contribución positiva baja (0.11). En contraste, la velocidad del viento (-1.87) y la concentración de clorofila (Chl-a) (-1.31) se asociaron con una menor probabilidad de presencia de delfines a valores más altos. La relación distancia del equipo de grabación autónomo a la costa (-0.54) presentó un efecto negativo de menor magnitud.



**Figura 14.** a) Valores de importancia relativa calculados mediante el método de Garson; b) valores de importancia calculados mediante el método de Olden. Clorofila a (Chl-a), velocidad del viento (windspeed), relación distancia del equipo de grabación a la costa (coast), día/noche (daynight) y coocurrencia acústica interespecífica de cetáceos (CAIC).

## 7.8 Análisis de sensibilidad e interpretabilidad


Los análisis de interpretabilidad mediante gráficas ICE y PDP (Fig. 15) evidenciaron una marcada estratificación en las probabilidades de detección, determinada principalmente por la presencia de CAIC. A través de todas las variables explicativas analizadas, se identificaron dos patrones de respuesta claramente diferenciados en función de la presencia o ausencia de esta variable.

En el caso de la clorofila (Chl-a), las probabilidades de detección de delfines se mantuvieron elevadas ( $>0.90$ ) y prácticamente constantes cuando la CAIC estuvo presente. En contraste, en ausencia de CAIC, las probabilidades disminuyeron conforme aumentó la concentración de Chl-a, mostrando además una mayor dispersión entre las curvas ICE (Fig. 15a).

La velocidad del viento presentó un patrón no lineal. Cuando la CAIC = 1, la probabilidad de detección se mantuvo relativamente estable a velocidades bajas y moderadas, pero disminuyó a valores elevados ( $>15$  km/h). Por otro lado, cuando la CAIC = 0, la probabilidad comenzó a decrecer desde velocidades bajas ( $\sim 5$  km/h), incrementándose ligeramente hasta aproximadamente 20 km/h y disminuyendo nuevamente a velocidades superiores (Fig. 15b).

La tasa de distancia del equipo de grabación autónomo a la costa (coast) mostró una relación negativa moderada con la probabilidad de detección, cuyo efecto se volvió secundario en presencia de la CAIC (Fig. 15c). Por su parte, la variable de día/noche, ejerció únicamente un efecto menor sobre la probabilidad de detección (Fig. 15d).

En contraste, la CAIC evidenció una fuerte relación positiva con la probabilidad de detección, incrementándose desde aproximadamente 0.4 en ausencia de esta condición hasta valores cercanos a 0.95 cuando está presente, tal como lo muestran tanto los análisis ICE como PDP (Fig. 15e). Estos resultados confirman la CAIC como la variable explicativa con mayor influencia dentro del modelo.



**Figura 15.** Gráficas de Expectativa Condicional Individual (ICE) y Dependencia Parcial (PDP) para las variables: a) clorofila a (Chl-a), b) velocidad del viento, c) relación distancia del equipo de grabación a la costa, d) periodo del día (día/noche) y e) coocurrencia acústica interespecífica de cetáceos (CAIC). Las marcas naranjas representan los valores observados en el conjunto de datos.

## 8. DISCUSIÓN

Durante el periodo de monitoreo en embarcación para la confirmación de especies, se registró la presencia de delfines en 83% de las salidas realizadas. Además, se registraron tres especies de misticetos (ballena azul, ballena de aleta y ballena de Bryde) además de cachalote. La ballena azul y la ballena de aleta fueron identificadas exclusivamente mediante registros acústicos, mientras que las demás especies contaron con confirmación tanto visual como acústica. Es importante destacar que todas estas especies han sido previamente reportadas para la región (Urbán-Ramírez et al., 2012), lo que respalda la consistencia de los resultados obtenidos y confirma la importancia ecológica del área como hábitat para cetáceos.

A lo largo del monitoreo con equipo de grabación autónomo, se detectó la presencia de delfines en todos los despliegues, aunque sin evidenciar un patrón temporal o estacional claramente definido (Fig. 7). Los mayores registros se obtuvieron en los despliegues 1, 4 y 6, correspondientes a noviembre de 2022, mayo y julio de 2023 respectivamente.

Debido a la similitud de las características acústicas de las especies de delfines, en este trabajo no se diferenciaron a nivel de especie. Sin embargo, los resultados reportados por Pardo y colaboradores (2013), permiten plantear algunas inferencias sobre la posible composición específica de los registros acústicos. En dicho estudio se documentaron un mayor de avistamientos de tursiones durante julio de 2008, lo que coincide con el periodo del despliegue 6. En consecuencia, es posible que parte de las detecciones registradas en dicho despliegue correspondan a esta especie.

Por otra parte, el despliegue 1 (noviembre 2022), realizado durante la temporada fría del GC, presentó el mayor número de eventos de detección de delfines. Aunque Pardo y colaboradores (2013) reportaron la mayor frecuencia de avistamientos de delfín común en enero de 2008, ambos meses corresponden a la temporada fría. Por ello, se podría plantear que una proporción de las detecciones registradas durante el despliegue 1 podría corresponder a esta especie.

Asimismo, se registraron eventos de CAIC casi en todos los despliegues a excepción del despliegue 8 correspondiente al mes de diciembre. Este resultado contrasta con el patrón esperado para el GC, donde durante la temporada fría aumenta la presencia de especies migratorias como la

ballena azul (Paniagua-Mendoza et al., 2017). Sin embargo, la ausencia de eventos de CAIC no implica necesariamente una menor presencia, sino únicamente que, durante el periodo de grabación, no se registró la codetección. Entre las especies que, si tuvieron registro de CAIC, el cachalote y la ballena azul presentaron el mayor número de detecciones compartidas con delfines. La posible relevancia ecológica de estas detecciones será abordada en la sección de interpretación ecológica del modelo.

Las redes neuronales artificiales han demostrado ser herramientas eficientes para modelar relaciones ecológicas complejas con comportamientos no lineales (Lin et al., 2021), debido a su flexibilidad analítica y a su capacidad para aprender interacciones que no han sido especificadas previamente (Frasier, 2021). Además, permiten evaluar simultáneamente múltiples variables y sus efectos sobre una respuesta biológica (Özesmi y Özesmi, 1999), facilitando la comprensión de como los delfines responden ante distintas condiciones ambientales, así como ante la coocurrencia acústica (CAIC) propuesta en este trabajo.

En el presente estudio, el modelo que alcanzó la mayor exactitud incluyó cinco de las diez variables seleccionadas con base en su relevancia ecológica para la presencia de delfines. Estas variables fueron la concentración de clorofila (Chl-a), la velocidad del viento (windspeed), la relación distancia del equipo de grabación autónomo a la costa (coast), el día/noche (daynight) y la coocurrencia acústica interespecífica de cetáceos (CAIC) (Fig. 10). El modelo obtuvo una exactitud de 81.7% y un error cuadrático medio (MSE) de 0.17, lo que indica un desempeño descriptivo robusto y una adecuada capacidad para representar la relación entre las variables y la presencia de delfines en el área de estudio. Lo anterior sugiere que la detección de delfines está determinada por la interacción entre procesos físicos y biológicos, es decir, lo que coincide con el carácter multifactorial del uso de hábitat en cetáceos (Redfern et al., 2006)

La validación cruzada mediante el método (LOGO) permitió evaluar la estabilidad y capacidad de generalización del modelo ANN bajo diferentes particiones de los datos (Fig. 13). En general, los resultados mostraron un desempeño relativamente consistente en el conjunto de entrenamiento, mientras que el conjunto de prueba presentó una mayor variabilidad conforme al número de grupos evaluados. Estos resultados sugieren que el modelo fue capaz de aprender patrones recurrentes presentes en los datos sin presentar fluctuaciones extremas durante la fase de

entrenamiento. En general, la validación LOGO evidenció que el modelo presenta una capacidad descriptiva robusta, y que el tamaño de muestra fue suficiente.

La capacidad de clasificación observada mediante la curva ROC resultó superior al azar ( $AUC = 0.782$ ), lo que indica un buen desempeño descriptivo, sugiriendo que el modelo presenta una adecuada capacidad para discriminar entre eventos de detección y no detección.

El método de Olden identificó la CAIC como la variable con mayor influencia en la explicación de la detección de delfines (Fig. 14), seguida por la velocidad de viento, lo cual es consistente con los patrones observados en los análisis ICE y PDP (Fig. 15). La mayor probabilidad de detección registrada cuando  $CAIC = 1$  sugiere que la presencia simultánea de señales acústicas de diferentes especies de cetáceos constituye un indicador de condiciones ecológicas favorables para el uso compartido de hábitat. Este efecto no necesariamente refleja interacciones físicas directas entre especies, sino una asociación derivada de su respuesta compartida.

Entre las demás variables, la velocidad del viento resultó una de las más influyente de acuerdo con el método de Garson, lo que indica que, junto con la CAIC, aportó la mayor proporción a la capacidad descriptiva del modelo. La dirección del signo, estimada mediante el método de Olden, mostró un efecto negativo marcado, sugiriendo que mayores velocidades de viento se asocian con una menor probabilidad de detección de delfines. Los análisis ICE y PDP revelaron una relación no lineal pronunciada, con un rango intermedio seguido de una disminución abrupta a valores elevados. Este patrón podría estar relacionado con el incremento del ruido por condiciones de viento intenso, lo que genera mayor oleaje y turbulencia y potencialmente reduce la detectabilidad de las vocalizaciones (Edwards et al., 2024).

La variable día/noche fue identificada con influencia positiva sobre la presencia de delfines, aunque con baja importancia relativa en comparación con otras variables. Este resultado coincide con que los cetáceos son considerados especies catemerales (Mann y Karniski, 2017). Sin embargo, se han documentado variaciones en la actividad entre especies de delfines. Por ejemplo, Norris y Dohl (1980) documentaron que los delfines tornillo presentan mayor actividad durante la noche y descansan durante el día. Otros estudios sobre patrones de vocalización han mostrado resultados contrastantes, por ejemplo, los delfines de Guiana (*Sotalia guianensis*) presentan mayor actividad durante la noche (Deconto y Monteiro-Filho, 2016), los tursiones, durante las

primeras horas del día (Gauger et al., 2022), y en algunos casos, los delfines comunes muestran picos de actividad durante el crepúsculo (Goold, 2000), o incluso sin un patrón definido. La actividad acústica asociada al ciclo día/noche puede variar entre especies, pero el modelo empleado en este estudio no permite diferenciarlas, lo cual podría explicar que los análisis ICE y PDP muestren efectos menores, con escasos cambios en la probabilidad de detección entre día y noche. Esto sugiere que las variaciones en el día y noche, desempeñan un papel limitado en estructuración de los patrones de detección en comparación con factores espaciales y de coocurrencia.

Las variables de concentración de clorofila (Chl-a) y relación distancia del equipo de grabación autónomo a la costa (coast), mostraron una influencia negativa en el modelo. La fuerte relación negativa con Chl-a podría indicar que una elevada productividad primaria no necesariamente se traduce en una mayor presencia de delfines en el área de estudio. Los análisis ICE y PDP para Chl-a evidenciaron una probabilidad de detección consistentemente alta cuando CAIC está presente, lo que sugiere que los gradientes de productividad desempeñan un papel limitado una vez que se establecen condiciones favorables de coocurrencia acústica. En contraste, la disminución en la probabilidad de detección con el incremento de Chl-a no implica necesariamente que los delfines eviten zonas productivas. La clorofila constituye un indicador de la productividad primaria pero no de la disponibilidad inmediata de presas. Este proceso requiere una transferencia energética a través de la red trófica, por lo que la respuesta de los depredadores superiores como los delfines suele presentar un desfase respecto a los valores de productividad primario (Lambert et al., 2022). Este tipo de complejidad ha sido documentado en estudios sobre asociaciones entre delfines y su hábitat (Díaz-Torres et al., 2022; Kusuma et al., 2025).

La variable relación distancia del equipo de grabación a la costa (coast), mostró una contribución relativamente baja al modelo. Aunque los diferentes sitios de despliegue no estaban ampliamente separados en términos espaciales, correspondieron a distintos periodos temporales, lo que pudo haber ejercido una mayor influencia sobre las detecciones de delfines que la distancia a la costa en sí misma. Por lo tanto, la baja contribución de esta variable podría estar reflejando variabilidad estacional más que un efecto espacial directo.

Los resultados indicaron que el mayor registro de CAIC involucró cachalotes y ballenas azules. Los mysticetos y odontocetos pueden coocurrir en áreas relativamente restringidas donde la distribución de presas específicas lo permite (Sigurðsson et al., 2026). La presencia de un grupo puede estar asociada indirectamente con la alimentación sobre las presas del otro. Por ejemplo, los euphausíidos o krill (Euphausiacea) son consumidos tanto por peces como por mysticetos, mientras que dichos peces constituyen presas de algunos odontocetos. En este contexto, las vocalizaciones de ambos grupos pueden ser detectadas aun cuando los individuos no se encuentren en proximidad espacial, ni interactúen directamente o necesariamente se perciban entre sí.

Aunque la coocurrencia física no está explícitamente incorporada en el modelo, se han documentado asociaciones entre delfines y otras especies, lo que resalta la relevancia ecológica de compartir un mismo espacio. La coocurrencia de cachalotes y delfines ha sido reportada en contextos de alimentación (Smultea et al., 2014; Wilson, 2013). En el GC, esta asociación ha sido vinculada con la presencia del calamar gigante (Jaquet y Gendron, 2002). En este sentido, ambos taxa podrían estar explorando poblaciones de presas similares o espacialmente cercanas (Ruiz-Cooley et al., 2004; Gallo-Reynoso et al., 2009). Asimismo, la concentración de presas en zonas como el Canal de Cerralvo podrían favorecer una mayor codetección acústica.

A escala global, no se han reportado casos de interacciones directas entre ballenas azules y delfines; sin embargo, en el Parque Nacional Bahía de Loreto si se han observado estas coocurrencias (Paniagua-Mendoza, pers. Comm., 2025). El Canal de Cerralvo es parte de la ruta migratoria de la ballena azul, donde también se han registrado diversas especies de delfines. En términos de niveles tróficos, es posible que ambos taxa compartan indirectamente recursos, ya que las presas de los delfines pueden depender del mismo zooplancton que consumen las ballenas azules, lo que favorecería una amplia zona de coocurrencia. Es importante resaltar que la presencia de ballena azul se registró en 7 de los 8 despliegues. Aunque esta especie es reconocida por realizar migraciones estacionales entre sus áreas de alimentación en la costa occidental de Norteamérica y el GC, donde utiliza zonas como Bahía de Loreto durante el invierno para alimentarse y reproducirse (Gendron, 2002), su presencia durante gran parte del periodo de muestreo en el Canal de Cerralvo apoya la idea de que el sur del GC podría representar un rol ecológico más importante del que se ha reconocido hasta ahora (Paniagua-Mendoza, et al., 2017).

Estos resultados abren una línea de investigación para evaluar factores oceanográficos y ecológicos que determinen su presencia en el área.

Esta situación también podría aplicarse a especies como la ballena de Bryde y la ballena de aleta, las cuales se alimentan de presas comunes con algunos delfines del GC, incluyendo la sardina del Pacífico (*Sardinops sagax*) (Pardo et al., 2013). Para estas especies, existen reportes de coocurrencia física con delfines, principalmente en contextos de alimentación (Baker y Madon, 2007; Bauer et al., 2015). Por lo tanto, es probable que la CAIC entre mysticetos y delfines esté asociada principalmente a la disponibilidad de alimento, incluso a escalas espaciales amplias.

El contexto de coocurrencia física documentado en estudios previos aporta evidencia sobre posibles interacciones cuando dos o más especies de cetáceos se encuentran en proximidad. No obstante, el uso del espacio acústico como un entorno ecológico permite modelar la presencia de manera más integradora. En este sentido, el concepto de CAIC no implica necesariamente interacción física, ni percepción mutua entre especies, sino una conexión ecológica derivada del uso compartido del espacio acústico dentro de una región geográfica determinada.

### **8.1 Consideraciones finales**

Este estudio aporta una nueva aproximación al estudio de la ecología de los delfines y cetáceos en general, mediante la propuesta e integración del concepto de Coocurrencia Acústica Interspecífica de Cetáceos (CAIC), como un indicador ecológico del uso compartido del espacio acústico. Establece una base metodológica y conceptual para futuros estudios que incorporen información acústica de múltiples especies con el fin de profundizar en la comprensión de la dinámica ecológica de los cetáceos. No obstante, existen algunas limitaciones metodológicas que representan oportunidades para futuros estudios, entre ellas la de arreglos de hidrófonos que permitan estimar la direccionalidad y localización de las señales acústicas; el análisis de vocalizaciones asociadas a comportamientos específicos para profundizar en el uso de hábitat y la incorporación de más periodos de muestreo que permitan comparar entre diferentes temporadas.

Derivado de este trabajo resultaron tres artículos de investigación. El primero titulado “Cetaceans and vessels overlap assessment within a migration corridor using passive acoustic monitoring” (Cruz-Villagran et al., 2025), proporcionó información sobre la presencia, los patrones diurnos y

el traslape de embarcaciones en el área. El segundo artículo titulado “A Machine Learning Approach to Assess the Relevance of Interspecific Acoustic Cetacean Co-Occurrence When Modeling Species Presence” (Cruz-villagran et al., 2026a), engloba el presente estudio resaltando la importancia del uso de las redes neuronales artificiales y el monitoreo acústico pasivo para modelar relaciones ecológicas complejas, resaltando también la importancia de la coocurrencia acústica interespecífica de cetáceos. El tercer artículo titulado “Year-Round Passive Acoustic Detection of Sperm Whales in the Cerralvo Channel Within the Gulf of California, Mexico” (Cruz-Villagran et al., 2026b) evidenció la detección acústica del cachalote a lo largo de un año en la región sur del Golfo de California.

## 9. CONCLUSIONES

En general, los resultados demuestran que la CAIC, constituye una variable ecológicamente relevante para explicar la probabilidad de detección de delfines, confirmando la hipótesis planteada. Su incorporación dentro del modelo permitió identificar patrones de uso compartido del espacio acústico entre distintas especies de cetáceos, evidenciando que la presencia de delfines se encuentra asociada a condiciones ambientales que también favorecen la ocurrencia de otros odontocetos y misticetos. Aunque las codetecciones con otros cetáceos no implican necesariamente interacciones directas entre las especies, si reflejan una coincidencia espacial y temporal dentro de un mismo hábitat, resultado de respuestas comunes a procesos ecológicos que estructuran la distribución de los cetáceos.

Desde una perspectiva conceptual, este estudio propone la CAIC como un indicador ecológico derivado del PAM, y que incorpora información ecológica de los cetáceos, ampliando el marco teórico del modelado ecológico únicamente con variables ambientales.

Finalmente, la integración del PAM con redes neuronales demostró ser una herramienta robusta para modelar la presencia de delfines a partir de relaciones ecológicas complejas.

## 10. LITERATURA CITADA

- Alexander, R.D. (1974). The Evolution of Social Behavior. *Annual Review Ecology, Evolution, and Systematics*, 5, 325-383. <https://doi.org/10.1146/annurev.es.05.110174.001545>
- Álvarez-Borrego, S. y Schwartzlose, R. (1979). Water Masses of the Gulf of California. *Ciencias Marinas*, 6(1), 43-63. <https://doi.org/10.7773/cm.v6i1.350>
- Álvarez-Borrego, S. (1983). Gulf of California. En Ketchum, B (Ed), *Estuaries and Enclosed Seas* (pp. 427-449). Elsevier
- Álvarez-Borrego, S. (2012). Phytoplankton biomass and production in the Gulf of California: A review. *Botánica Marina*, 55(1), 119-128. <https://doi.org/10.1515/BOT.2011.105>
- Au, D.W.K., y Perryman, W.L. (1985). Dolphin habitats in the Eastern Tropical Pacific. *Fishery Bulletin*, 83(4), 623-643.
- Au, W.W.L. (2000). Hearing in Whales and Dolphins: An Overview. En: Au, W.W.L., Fay, R.R., Popper, A.N. (eds), *Hearing by Whales and Dolphins*. Springer Handbook of Auditory Research, vol 12 (pp. 1-42). Springer. [https://doi.org/10.1007/978-1-4612-1150-1\\_1](https://doi.org/10.1007/978-1-4612-1150-1_1)
- Baker, A.N., y Madon, B. (2007). Bryde's whales (*Balaenoptera cf. brydei* Olsen 1913) in the Hauraki Gulf and northeastern New Zealand waters. *Science for Conservation*, 272. <http://doi.org/10.5281/zenodo.6482778>
- Bauer, R. K., Fromentin, J.M., Demarcq, H., Brisset, B., y Bonhommeau, S. (2015). Co-occurrence and habitat use of fin whales, striped dolphins and Atlantic bluefin tuna in the Northwestern Mediterranean Sea. *PLOS ONE*, 10(10): e0139218. <https://doi.org/10.1371/journal.pone.0139218>
- Bishop. C.M. (2006). *Pattern recognition and machine learning*. New York. Springer. <https://doi.org/10.1007/978-0-387-45528-0>
- Cruz-Villagran, H., Leon-Lopez, B., Paniagua-Mendoza, A., y Romero-Vivas, E. (2025). Cetaceans and vessels overlap assessment within a migration corridor using passive acoustic monitoring. *Regional Studies in Marine Science*, 86, 104203. <https://doi.org/10.1016/j.rsma.2025.104203>
- Cruz-Villagran, H., Gutiérrez-Jagüey, J., Von Borstel, F. D., Leon-Lopez, B., Paniagua-Mendoza, A. y Romero-Vivas, E. (2026a). A Machine Learning Approach to Assess the Relevance of Interspecific Acoustic Cetacean Co-Occurrence When Modeling Species Presence. *Marine Mammal Science* 42, no. 2: e70165. <https://doi.org/10.1111/mms.70165>
- Cruz-Villagran, H., Leon-Lopez, B., y Romero-Vivas, E. (2026b). Year-Round Passive Acoustic Detection of Sperm Whales in the Cerralvo Channel Within the Gulf of California, Mexico. *Aquatic Conservation: Marine and Freshwater Ecosystems* 36, no. 6: e70410. <https://doi.org/10.1002/aqc.70410>.
- Deconto, L. S., y Monteiro-Filho, E. L. A. (2016). Day and night sounds of the Guiana dolphin, *Sotalia guianensis* (Cetacea: Delphinidae) in southeastern Brazil. *Acta Ethologica*, 19(1), 61–68. <https://doi.org/10.1007/s10211-015-0223-y>
- Díaz-Torres, E. R., Marín-Enríquez, E., Corgos, A., Olivos-Ortiz, A., y Ortega-Ortiz, C. D. (2022). Influence of environmental variability on the distribution and abundance of the pantropical spotted dolphin (*Stenella attenuata*) in the Mexican Central Pacific. *Ciencias Marinas*, 48(1). <https://doi.org/10.7773/cm.y2022.3215>
- Edwards, J. E., Buijse, A. D., Winter, H. V., y Bijleveld, A. I. (2024). Gone with the wind: Environmental variation influences detection efficiency in a coastal acoustic telemetry array. *Animal Biotelemetry*, 12(21). <https://doi.org/10.1186/s40317-024-00378-x>

- Feller, W. (1968). An introduction to probability theory and its applications (3a ed., Vol. 1). Wiley
- Fishing Points App (2022). Fishing Points: maps, forecast, tides y species. Disponible en: <https://fishingpoints.app/>
- Forcada, J. (2018). Distribution. En Würsig, B., Thewissen, J.G.M y Koyacs, K.M (eds). Marine Mammal Encyclopedia. 3<sup>rd</sup> edition, (pp. 259-262). Academic Press
- Frasier, K. E. (2021). A machine learning pipeline for classification of cetacean echolocation clicks in large underwater acoustic datasets. PLOS Computational Biology, 17(12), e1009613. <https://doi.org/10.1371/journal.pcbi.1009613>
- Gallo-Reynoso, J.P., Égido-Villarreal, J., y Coria-Galindo, E.M. (2009). Sperm whale distribution and diving behaviour in relation to presence of jumbo squid in Guaymas Basin, Mexico. Marine Biodiversity Records, 2, e139. <https://doi.org/10.1017/S1755267209990571>
- Garson, G. (1991). Interpreting neural-network connection weights. Artificial Intelligence Expert, 6(4), 46-51
- Gauger, M.F.W. (2021). Modelado de la presencia de tursiones (*Tursiops truncatus*) en la Ensenada de La Paz, México, a partir de monitoreo acústico pasivo. Tesis doctoral. Centro de Investigaciones Biológicas del Noroeste, S.C. 117 pp.
- Gauger, M.F. W, Romero-Vivas, E., Peck, M.A., Balart, E.F., y Caraveo-Patiño J. (2022). Seasonal and diel influences on bottlenose dolphin acoustic detection determined by whistles in a coastal lagoon in the southwestern Gulf of California. PeerJ, 10:e13246 <https://doi.org/10.7717/peerj.13246>
- Gendron, D. (2002). Ecología poblacional de la ballena azul (*Balaenoptera musculus*), de la Península de Baja California. Tesis doctoral, Centro de Investigación Científica y de Educación Superior de Ensenada.
- Goldbogen, J.A., Stimpert, A.K., DeRuiter, S.L., Calambokidis, J., Friedlaender, A.S., Schorr, G.S., Moretti, D.J., Tyack, P.L. y Southall, B.L. (2014). Using accelerometers to determine the calling behavior of tagged baleen whales. Journal of Experimental Biology, 217(14), 2449–2455. <https://doi.org/10.1242/jeb.103259>
- Goold, J. C. (2000). A diel pattern in vocal activity of short beaked common dolphins, *Delphinus delphis*. Marine Mammal Science, 16(1), 240–244. <https://doi.org/10.1111/j.1748-7692.2000.tb00915.x>
- Greener, J.G., Kandathil, S.M., Moffat, L. and Jones, D.T. (2022). A guide to machine learning for biologists. Nature Reviews Molecular Cell Biology, 23, 40–55. <https://doi.org/10.1038/s41580-021-00407-0>
- Guerrero, M. J., Bedoya, C. L., López, J. D., Daza, J. M., y Isaza, C. (2023). Acoustic animal identification using unsupervised learning. Methods in Ecology and Evolution, 14(6), 1500–1514. <https://doi.org/10.1111/2041-210X.14103>
- Hagan, M.T. y Menhaj, M.B. (1994). Training feedforward networks with the Marquardt algorithm. IEEE Transactions on Neural Networks, 5(6), 989–993. <https://doi.org/10.1109/72.329697>
- Han, J., Kamber, M., y Pei, J. (2012). Data mining: Concepts and techniques (3a ed). Morgan Kaufmann
- Helble, T.A., Henderson, E.E., Ierley, G.R. and Martin, S.W. (2016). Swim track kinematics and calling behavior attributed to Bryde's whales on the Navy's Pacific Missile Range Facility. The Journal of the Acoustical Society of America, 140(6). <https://doi.org/10.1121/1.4967754>.

- Herzing, D.L. (2000). Acoustics and Social Behavior of Wild Dolphins: Implications for a Sound Society. En: Au, W.W.L., Fay, R.R., y Popper, A.N. (eds) *Hearing by Whales and Dolphins*. Springer Handbook of Auditory Research, vol 12. (pp. 225-272) Springer, New York. [https://doi.org/10.1007/978-1-4612-1150-1\\_5](https://doi.org/10.1007/978-1-4612-1150-1_5)
- Jaquet, N., y Gendron, D. (2002). Distribution and relative abundance of sperm whales in relation to key environmental features, squid landings and the distribution of other cetacean species in the Gulf of California, Mexico. *Marine Biology*, 141(3), 591–601. <https://doi.org/10.1007/s00227-002-0839-0>
- Jefferson, T.A., y LeDuc, R.G. (2018). Delphinids, Overview. En Würsig, B., Thewissen, J.G.M y Koyacs, K.M (Eds). *Encyclopedia of Marine Mammals*. 3<sup>rd</sup> ed. (pp.242-246). Academic Press.
- Krause, J., y Ruxton, G.D. (2002) *Living in Groups*. Oxford University Press
- Kusuma, A. H., Efendi, E., Mayagues, H., Yudha, I. G., y Hasani, Q. (2025). Correlation of sea surface temperature and chlorophyll concentrations with presence of dolphins in Kiluan Bay, Lampung. *Jurnal Perikanan Unram*, 15(3), 1256–1266. <https://doi.org/10.29303/jp.v15i3.1522>
- Lambert, C., Authier, M., Blanchard, A., Dorémus, G., Laran, S., Van Canneyt, O., Spitz, J. (2022). Delayed response to environmental conditions and infra-seasonal dynamics of the short-beaked common dolphin distribution. *Roya Society Open Science*. 30;9(11): 220379. <https://doi.org/10.1098/rsos.220379>. PMID: 36465685; PMCID: PMC9709568
- Legendre, A.M. (1805). *Nouvelles méthodes pour la détermination des orbites des comètes*. Firmin Didot.
- Lek, S., y Guégan, J.F. (1999). Artificial neural networks as a tool in ecological modelling, an introduction. *Ecological Modelling*, 120(2–3), 65–73. [https://doi.org/10.1016/S0304-3800\(99\)00092-7](https://doi.org/10.1016/S0304-3800(99)00092-7)
- Levenberg, K. (1944). A method for the solution of certain non-linear problems in least squares. *Quarterly of Applied Mathematics*, 2(2), 164–168. <https://doi.org/10.1090/qam/10666>
- Lluch-Cota, S.E., Aragón-Noriega, E.A., Arreguín-Sánchez, F., Aurióles-Gamboa, D., Bautista-Romero, J.J., Brusca, R.C., Cervantes-Duarte, R., Cortés-Altamirano, R., Del-Monte-Luna, P., Esquivel-Herrera, A., Fernández, G., Hendrickx, M.E., Hernández-Vázquez, S., Herrera-Cervantes, H., Kahru, M., Lavín, M.F., Lluch-Belda, D., Lluch-Cota, D.B., López-Martínez, J., Marinone, S.G., Nevárez-Martínez, M.O., Ortega-García, S., Palacios-Hernández, E., Parés-Sierra, A., Ponce-Díaz, G., Ramírez-Rodríguez, M., Salinas-Zavala, C.A., Sierra-Beltrán, A.P. (2007). The Gulf of California: Review of ecosystem status and sustainability challenges. *Progress in Oceanography*, 73(1), 1–26. <https://doi.org/10.1016/j.pocean.2007.01.013>
- Lin, M., Liu, M., Lek, S., Dong, L., Zhang, P., Gozlan, R. E., y Li, S. (2021). Modelling habitat suitability of the Indo-Pacific humpback dolphin using neural network: The Influence of shipping. *Ecological Informatics*, 62. <http://doi.org/10.1016/j.ecoinf.2021.101274>
- Mann, J., y Karniski, C. (2017). Diving beneath the surface: long-term studies of dolphins and whales. *Journal of Mammalogy*, 98(3), 621-630. <https://doi.org/10.1093/jmammal/gyx036>
- Mardia, K.V., y Jupp, P.E. (2000). *Directional statistics*. John Wiley y Sons. <https://doi.org/10.1002/9780470316979>
- Marsh, H., y Sinclair, D.F. (1989). Correcting for visibility bias in strip transect aerial surveys of aquatic fauna. *Journal of Wildlife Management*, 53:1017-1024

- Marques, T. A., Thomas, L., Martin, S. W., Mellinger, D. K., Ward, J. A., Moretti, D. J., Harris, D. y Tyack, P.L. (2013). Estimating animal population density using passive acoustics. *Biological Reviews*, 88, 287–309. <https://doi.org/10.1111/brv.12001>
- Mellinger, D.K. and Clark, C.W. (2003). Blue whale (*Balaenoptera musculus*) sounds from the North Atlantic', *The Journal of the Acoustical Society of America*, 114(2), 1108–1119. <https://doi.org/10.1121/1.1593066>
- Mellinger, D.K., Stafford, K.M. and Fox, C.G. (2004). Seasonal occurrence of sperm whale (*Physeter macrocephalus*) sounds in the Gulf of Alaska, 1999–2001. *Marine Mammal Science*, 20(1), 48–62. <https://doi.org/10.1111/j.1748-7692.2004.tb01140.x>
- Mohlnar, C. (2025). Interpretable Machine Learning (Third Edition): A Guide for Making Black Box Models Explainable. <https://christophm.github.io/interpretable-ml-book/>
- Nair, V. y Hinton, G.E. (2010). Rectified Linear Units Improve Restricted Boltzman Machines. En J.Fürnkranz y T. Joachims (eds.), *Proceedings of the 27th International Conference on Machine Learning*. (ICML-10) (págs. 807-814)
- National Oceanic and Atmospheric Administration (NOAA), Global Monitoring Laboratory (2022). Solar Calculator. Disponible en: <https://gml.noaa.gov/grad/solcalc/>
- National Oceanic and Atmospheric Administration (NOAA). (2023). ERDDAP: Environmental Research Division's Data Access Program. <https://www.ncei.noaa.gov/erddap>
- National Oceanic and Atmospheric Administration (NOAA). (2024). National Centers for Environmental Information (NCEI): Metadata. Disponible en: <https://www.ncei.noaa.gov/access/metadata>
- Norris, K.S., y Dohl, T.P. (1980). Behavior of the hawaiian spinner dolphin, *Stenella longirostris*. *Fishery Bulletin* 77(4)
- Olden, J.D., y Jackson, D.A. (2002). Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks. *Ecological Modelling*, 154, 135–150. [https://doi.org/10.1016/S0304-3800\(02\)00064-9](https://doi.org/10.1016/S0304-3800(02)00064-9)
- Oleson, E.M., Barlow, J., Gordon, J., Hildebrand, J.A. y Rankin, S. (2003). Low frequency calls of Bryde's whales. *Marine Mammal Science*, 19(2), 407–419. <https://doi.org/10.1111/j.1748-7692.2003.tb01119.x>
- Oswald, J. N., Walmsley, S. F., Casey, C., Fregosi, S., Southall, B., y Janik, V.M. (2021). Species Information in Whistle Frequency Modulation Patterns of Common Dolphins. *Philosophical Transactions, the Royal Society* 25, no. 1836: 20210046. <https://doi.org/10.1098/rstb.2021.0046>
- Özesmi, S. L., y Özesmi, U. (1999). An artificial neural network approach to spatial habitat modeling with interspecific interaction. *Ecological Modeling*, 116(1), 15–31. [https://doi.org/10.1016/S0304-3800\(98\)00149-5](https://doi.org/10.1016/S0304-3800(98)00149-5)
- Paniagua-Mendoza, A., Gendron, D., Romero-Vivas, E., y Hildebrand, J.A. (2017). Seasonal acoustic behavior of the blue whales (*Balaenoptera musculus*) in the Gulf of California. *Marine Mammal Science*, 35(2), 520-543. <https://doi.org/10.1111/mms.12550>
- Pardo, M., Silverberg, N., Gendron, D., Beier, E., y Palacios, D. (2013). Role of environmental seasonality in the turnover of a cetacean community in the southwestern Gulf of California. *Marine Ecology Progress Series*, 487, 245–260. <https://doi.org/10.3354/meps10217>
- Powers, D.M.W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63. <https://doi.org/10.9735/2229-3981>

- Redfern, J., Ferguson, M., Becker, E., Hyrenbach, K., Good, C., Barlow, J., Kaschner, K., Baumgartner, M., Forney, K., Ballance, L., Fauchald, P., Halpin, P., Hamazaki, T., Pershing, A., Qian, S., Read, A., Reilly, S., Torres, L., y Werne, F. (2006). Techniques for cetacean habitat modeling. *Marine Ecology Progress Series*, 310, 271–295. <https://doi.org/10.3354/meps310271>
- Rice, D.W. (1998). *Marine Mammals of the World: Systematics and Distribution*. The Society for Marine Mammalogy. Spec. Pub. 4. (pp. 97-120) Allen Press.
- Rice, A.N., Palmer, K.J., Tielens, J.T., Muirhead, C.A. and Clark, C.W. (2014). Potential Bryde's whale (*Balaenoptera edeni*) calls recorded in the northern Gulf of Mexico. *The Journal of the Acoustical Society of America*, 135(5), 3066–3076. <https://doi.org/10.1121/1.4870057>.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>
- Ruiz-Cooley, R., Gendron, D., Aguíñiga, S., Mesnick, S., y Carriquiry, J. (2004). Trophic relationships between sperm whales and jumbo squid using stable isotopes of C and N. *Marine Ecology Progress Series*, 277, 275–283. <https://doi.org/10.3354/meps277275>
- Rumelhart, D.E., Hinton, G.E. y Williams, R.J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>
- Samarasinghe, S. (2006). *Neural Networks for Applied Sciences and Engineering. From Fundamentals to Complex Recognition*. Auerbach Publications
- Sciacca, V., Caruso, F., Beranzoli, L., Chierici, F., De Domenico, E., Embriaco, D., Favali, P., Giovanetti, G., Larosa, G., Marinaro, G., Papale, E., Pavan, G., Pellegrino, C. y Riccobene, G. (2015). Annual acoustic presence of fin whale (*Balaenoptera physalus*) offshore eastern Sicily, Central Mediterranean Sea. *PLOS ONE*, 10(11), e0141838. <https://doi.org/10.1371/journal.pone.0141838>
- Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT). (2010). Norma Oficial Mexicana NOM-059-SEMARNAT-2010, Protección ambiental. Especies nativas de México de flora y fauna silvestres. Categorías de riesgo y especificaciones para su inclusión, exclusión o cambio. Lista de especies en riesgo. Diario Oficial de la Federación, 30 de diciembre de 2010.
- Shannon, C.E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, vol. 27, no. 3, pp. 379-423. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>.
- Sigurðsson, G.M., Víkingsson, G., Chosson, V. et al. (2026). Spatiotemporal co-occurrence of whales and capelin on the east Greenland shelf during autumn. *Marine Biology*, 173(15). <https://doi.org/10.1007/s00227-025-04778-2>
- Širović, A., Oleson, E.M., Buccowich, J., Rice, A. y Bayless, A.R. (2017). Fin whale song variability in southern California and the Gulf of California. *Scientific Reports*, 7, 10126. <https://doi.org/10.1038/s41598-017-09979-4>
- Smultea, M. A., Bacon, C. E., Lomac-MacNair, K., Visser, F., y Bredvik, J. (2014). Rare mixed-species associations between sperm whales and Risso's and northern right whale dolphins off the Southern California Bight: Kleptoparasitism and social parasitism? *Northwestern Naturalist*, 95(1), 43–49. <https://doi.org/10.1898/NWN13-11.1>
- Society for Marine Mammalogy. (2026). List of Marine Mammal Species and Subspecies. Recuperado de: <https://marinemammalscience.org/science-and-publications/list-marine-mammal-species-subspecies/>

- Stensland, E., Angerbjörn, A. y Berggren, P. (2003). Mixed species groups in mammals, *Mammal Review*, 33, 205–223. <https://doi.org/10.1046/j.1365-2907.2003.00022.x>
- Stone, M. (1974). Cross-Validatory Choice and Assessment of Statistical Predictions. *Journal of the Royal Statistical Society: Series B (Methodological)* 36(2), 111–147
- Syme, J., Kiszka, J.J. y Parra, G.J. (2021). Dynamics of Cetacean Mixed-Species Groups: A Review and Conceptual Framework for Assessing Their Functional Significance, *Frontiers in Marine Science*, 8:678173. <https://doi.org/10.3389/fmars.2021.678173>
- Tepsich, P., Rosso, M., Halpin, P.N., y Moulins, A. (2014). Habitat preferences of two deep-diving cetacean species in the northern Ligurian Sea. *Marine Ecology Progress Series*, 508, 247-260. <https://doi.org/10.3354/meps10851>
- Thompson, P.O., Findley, L.T., Vidal, O. y Cummings, W.C. (1996). Underwater sounds of blue whales, *Balaenoptera musculus*, in the Gulf of California, Mexico. *Marine Mammal Science*, 12(2), 288–293. <https://doi.org/10.1111/j.1748-7692.1996.tb00578.x>
- Todd, N. R. E., Cronin, M., Luck, C., Bennison, A., Jessopp, M., y Kavanagh, A. S. (2020). Using passive acoustic monitoring to investigate the occurrence of cetaceans in a protected marine area in northwest Ireland. *Estuarine, Coastal and Shelf Science*, 232, 106509. <https://doi.org/10.1016/j.ecss.2019.106509>
- Urbán-Ramírez, J. (2010). Marine Mammals of the Gulf of California. En Brusca, R.C (ed). *The Gulf of California. Biodiversity and Conservation*. (PP. 189-209). The University of Arizona Press. <https://doi.org/10.2307/j.ctt181hwrc>
- Urbán-Ramírez, J., Cárdenas-Hinojosa, G. y Gómez-Gallardo, Al. (2012). Los cetáceos de la costa suroccidental del Golfo de California. En Gaster, P., Arispe, O. Ivanova, A. (eds). *Los Cabos. Prospectiva de un paraíso natural y turístico*. (pp. 105-127). San Diego State University Press. Institute for Regional Studies of the Californias
- Redfern, J.V., Ferguson, M.C., Becker, E.A., Hyrenbach, K.D., Good, C., Barlow, J., Kaschner, K., Baumgartner, M.F., Forney, K.A., Balance, L.T., Fauchald, P., Halpin, P., Hamazaki, T., Pershing, A.J., Qian, S.S., Read, A., Reilly, S.B., Torres, L., y Werner, F. (2006) Techniques for cetacean–habitat modeling. *Marine Ecology Progress Series*. 310, 271-295. <https://doi.org/10.3354/meps310271>
- Verhulst, P.F. (1838). Notice sur la loi que la population poursuit dans son accroissement. *Correspondance Mathématique et Physique*, 10, 113–121
- Viloria-Gómora, L., Romero-Vivas, E. y Urbán, J.R. (2015). Calls of Bryde’s whale (*Balaenoptera edeni*) recorded in the Gulf of California (L). *The Journal of the Acoustical Society of America*, 138(5), 2722–2725. <https://doi.org/10.1121/1.4932032>
- Viloria-Gómora, L., Urbán, J.R., Leon-Lopez, B. y Romero-Vivas, E. (2021). Geographic variation in Bryde’s whale BE4 calls in the Gulf of California: An insight to population dynamics. *Frontiers in Marine Science*, 8, 651469. <https://doi.org/10.3389/fmars.2021.651469>
- Visual Crossing. (2024). Weather API y Data for Developers. Disponible en: <https://www.visualcrossing.com/weather/weather-data-services>
- Watkins, W.A. (1980). Acoustics and the behavior of sperm whales. En: Busnel, R.-G. and Fish, J.F. (eds) *Animal Sonar Systems*. NATO Advanced Study Institutes Series, vol. 28. New York: Plenum Press, pp. 283–290. [https://doi.org/10.1007/978-1-4684-7254-7\\_11](https://doi.org/10.1007/978-1-4684-7254-7_11)
- Weilgart, L.S. y Whitehead, H. (1988). Distinctive vocalizations from mature male sperm whales (*Physeter macrocephalus*). *Canadian Journal of Zoology*, 66(9), 1931–1937. <https://doi.org/10.1139/z88-282>

- Wilson, A. (2013). Short Note: Repeated non-agonistic interactions between a bottlenose dolphin (*Tursiops truncatus*) and sperm whales (*Physeter macrocephalus*) in Azorean Waters. *Aquatic Mammals*, 39(1), 89–96. <https://doi.org/10.1578/AM.39.1.2013.89>
- Whitehead, H. y Weilgart, L. (1990). Click rates from sperm whales. *The Journal of the Acoustical Society of America*, 87(4), 1798–1806. <https://doi.org/10.1121/1.399376>
- Zar, J.H. (2010). *Biostatistical analysis* (5a ed.). Pearson Education

## 11. ANEXOS


### **Anexo A. Confirmación de especies mediante monitoreo visual y acústico**

La metodología del monitoreo de confirmación de especies consistió en grabaciones cada 30 minutos con una duración de cinco minutos cada una. En caso de avistamiento de cetáceos, se registró la especie, se tomaron fotografías y se registró la posición geográfica, así como la presencia de otros cetáceos en las proximidades, en caso de existir. Asimismo, se realizaron grabaciones con el equipo de grabación móvil en el sitio del avistamiento. Una vez finalizado el avistamiento, se continuó con el ciclo de trabajo, consistente en grabaciones cada 30 minutos. De manera ocasional, se realizaron salidas turísticas, en las cuales no fue posible realizar la metodología sistematizada de las grabaciones cada 30 minutos. Sin embargo, se registraron las especies observadas, se tomaron fotografías, se anotaron variables ambientales, y se realizaron grabaciones durante el momento del avistamiento.

Los resultados de las detecciones acústicas y visuales por especie, registradas en distintas fechas entre julio de 2022 y septiembre de 2023, se presentan en la Fig. A1. Se observa una alta variabilidad en el número de especies registradas por salida, destacando fechas como el 9 de agosto de 2022, el 8 de marzo y 7 de junio de 2023, que corresponden a los días con mayor número de detecciones.

Entre las especies más frecuentemente detectadas se encuentra el tursión, el cachalote y la ballena azul, las cuales fueron registradas en múltiples fechas. Por otro lado, especies como la orca y el delfín moteado sólo se registró un evento de detección.

Se observa que una proporción importante de las detecciones corresponde a registros sin confirmación visual (gráficas con patrón de puntos), lo que resalta la relevancia del monitoreo acústico para la detección de delfines.



**Figura A1.** Registros totales del monitoreo visual y acústico de confirmación de especies con equipo de grabación autónomo entre julio de 2022 y septiembre de 2023.

**Tabla A1.** Salidas de monitoreo visual y acústico de confirmación de especies durante el periodo de julio 2022 a septiembre 2023

| Fecha     | Esfuerzo (h) | No. de grabaciones | Tiempo       | Ciclo de trabajo |
|-----------|--------------|--------------------|--------------|------------------|
|           |              |                    | de grabación |                  |
| 23-Jul-22 | 6:00         | 1                  | 0:02:00      | oportunista      |
| 9-Aug-22  | 6:00         | 5                  | 0:08:00      | oportunista      |
| 19-Aug-22 | 6:00         | 1                  | 0:02:00      | oportunista      |
| 21-Aug-22 | 6:00         | 1                  | 0:01:00      | oportunista      |
| 17-Sep-22 | 6:00         | 2                  | 0:05:00      | oportunista      |
| 16-Oct-22 | 6:00         | 2                  | 0:06:08      | oportunista      |
| 21-Oct-22 | 6:00         | 1                  | 4:38:40      | 5 min c/ 30 min  |
| 23-Nov-22 | 6:00         | 6                  | 0:24:00      | 5 min c/ 30 min  |
| 27-Nov-22 | 6:00         | 1                  | 0:04:00      | oportunista      |
| 7-Dec-22  | 6:00         | 1                  | 0:05:13      | oportunista      |
| 29-Jan-23 | 6:00         | 4                  | 0:21:00      | 5 min c/ 30 min  |

|              |                |           |                |                 |
|--------------|----------------|-----------|----------------|-----------------|
| 25-Feb-23    | 6:00           | 3         | 0:07:00        | 5 min c/ 30 min |
| 8-Mar-23     | 6:00           | 7         | 0:37:00        | 5 min c/ 30 min |
| 12-May-23    | 6:00           | 4         | 0:20:00        | 5 min c/ 30 min |
| 7-Jun-23     | 6:00           | 10        | 0:50:00        | oportunista     |
| 21-Jul-23    | 6:00           | 9         | 0:45:00        | 5 min c/ 30 min |
| 12-Ago-23    | 6:00           | 9         | 0:34:03        | oportunista     |
| 21-Sep-23    | 6:00           | 10        | 0:47:51        | 5 min c/ 30 min |
| <b>Total</b> | <b>108 hrs</b> | <b>77</b> | <b>9:57:55</b> |                 |




## Anexo B. Referencias bibliográficas para identificación de llamadas acústicas de diferentes

**Tabla A2.** Referencias bibliográficas para identificación de llamadas acústicas de diferentes especies de cetáceos

| Especie                      | Artículo                                                                                                                  | Autores                     |
|------------------------------|---------------------------------------------------------------------------------------------------------------------------|-----------------------------|
|                              | Swim track kinematics and calling behavior attributed to Bryde's whales on the Navy's Pacific Missile Range Facility      | Helble et al., 2016         |
|                              | Potential Bryde's whale ( <i>Balaenoptera edeni</i> ) calls recorded in the northern Gulf of Mexico                       | Rice et al., 2014           |
| <i>Balaenoptera edeni</i>    | Low frequency calls of Bryde's whales                                                                                     | Oleson et al., 2003         |
|                              | Calls of Bryde's whale ( <i>Balaenoptera edeni</i> ) recorded in the Gulf of California (L)                               | Viloria-Gómora et al., 2015 |
|                              | Geographic Variation in Bryde's Whale Be4 Calls in the Gulf of California: An Insight to Population Dynamics              | Viloria-Gómora et al., 2021 |
|                              | Annual Acoustic Presence of Fin Whale ( <i>Balaenoptera physalus</i> ) Offshore Eastern Sicily, Central Mediterranean Sea | Sciacca et al., 2015        |
| <i>Balaenoptera physalus</i> | Using accelerometers to determine the calling behavior of tagged baleen whales                                            | Goldbogen et al., 2014      |
|                              | Fin whale song variability in southern California and the Gulf of California                                              | Sirovic et al., 2017        |

|                               |                                                                                                                                            |                                                |
|-------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------|
| <i>Balaenoptera musculus</i>  | Underwater sounds of blue whales,<br><i>Balaenoptera musculus</i> ,<br>in the Gulf of California, Mexico                                   | Thompson et al., 1996                          |
|                               | Blue whale ( <i>Balaenoptera musculus</i> ) sounds<br>from the North Atlantic                                                              | Mellinger y Clark, 2003                        |
| <i>Physeter macrocephalus</i> | Seasonal occurrence of sperm whale ( <i>Physeter macrocephalus</i> ) sounds in the gulf of alaska,<br>1999-2001 "                          | Melliner et al., 2004                          |
|                               | Click rates from sperm whales.                                                                                                             | Whitehead y Weilgart,<br>1990                  |
|                               | Acoustics and the behavior of sperm whales<br>Distinctive vocalizations from mature male<br>sperm whales ( <i>Physeter macrocephalus</i> ) | Watkins, 1980<br>Weilgart y Whitehead,<br>1988 |

## Anexo C. Funciones utilizadas en las diferentes configuraciones

| Modelo de RN                         | Función                             | Abreviación                                                                       | Fórmula                                                                                                                                                                                           | Descripción                                                                                                                                                                                                               | Referencia                               |
|--------------------------------------|-------------------------------------|-----------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------|
| Función de activación capa oculta    | Unidad Lineal Rectificada           |  | $f(x) = \max(0, x)$<br>x: valor de la entrada                                                                                                                                                     | Proporciona no linealidad al modelo. Da como resultado el máximo entre su entrada y cero. Para entradas postivas, la salida de la función es igual a la entrada. paras alidas negativas, la salida de la función es cero. | Nair & Hinton, 2010                      |
|                                      | Sigmoidea tangnete hiperbólica      |  | $\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$<br>e: número de Euler<br>x: valor de la entrada                                                                                                    | Proporciona no linealidad, comprime el valor de entrada en un rando de salida acotado entre -1 y 1. Rango de salida centrado a cero ayuda a optimizar el entrenamiento.                                                   | Rumelhart et al., 1986                   |
| Función de activación capa de salida | Logarítmica sigmoidea               |  | $f(x) = \frac{1}{1 + e^{-x}}$<br>e: número de Euler<br>x: valor de la entrada                                                                                                                     | Se usa en problmeas de clasificación binaria ya que comprime las entradas en el rango entre 0 y 1.                                                                                                                        | Verhulst, 1838<br>Rumelhart et al., 1986 |
| Función de entrenamiento             | Descenso de gradiente               | traingd                                                                           | $dX = \frac{lr * dperf}{dX}$<br>lr: tasa de aprendizaje<br>dperf: derivada del rendimiento                                                                                                        | Los pesos y sesgos se actualizan en la dirección del gradiente negativo de la función de pérdida.                                                                                                                         | Rumelhart et al., 1986                   |
|                                      | Descenso de gradiente con momento   | traingdx                                                                          | $dX = \frac{mc * dXprev + lr * dperf}{dX}$<br>mc: coeficiente de momento<br>dprev: cambio anterior del peso o sesgo<br>jX: matriz jacobiana del rendimiento                                       | Ajusta los pesos y sesgos de acuerdo al momento del gradiente descendente y a la tasa de aprendizaje adaptativa.                                                                                                          | Hagan y Menhaj, 1994                     |
|                                      | Optimización de Levenberg-Marquardt | trainlm                                                                           | $jj = jX * jX$<br>$je = jX * E$<br>$dX = -(jj + I * \mu) / je$<br>E: errores<br>I: matriz de identidad<br>mu: valor adaptativo                                                                    | Ajusta los pesos y sesgos para minimizar el error, de manera similar a traingd pero con mayor robustez y rapidez.                                                                                                         | Levenberg, 1944                          |
| Función de pérdida                   | Error cuadrático medio              | mse                                                                               | $L = \frac{1}{n} \sum_{i=1}^n (y_i + \hat{y}_i)^2$<br>n: número de datos<br>y <sub>i</sub> : valor real<br>ŷ <sub>i</sub> : valor predicho                                                        | Mide la diferencia promedio al cuadrado entre los valores reales y los predichos. Valores más bajos implican un mejor ajuste del modelo.                                                                                  | Legendre, 1805<br>Bishop, 2006           |
|                                      | Entropía cruzada                    | crossentropy                                                                      | $L = - \sum_{i=1}^c y_i \log(\hat{y}_i)$<br>C: número de clases<br>y <sub>i</sub> : es 1 si la clase es la correcta y 0 en caso contrario<br>ŷ <sub>i</sub> : probabilidad predicha por el modelo | Mide la diferencia entre la distribución de probabilidad predicha por un modelo y la distribución real. Un valor más bajo indica un mejor rendimiento del modelo.                                                         | Shannon, 1948<br>Bishop, 2006            |

## Anexo D. configuraciones probadas para el modelo de redes neuronales

**Tabla A4.** Ejemplos de las diferentes configuraciones probadas para el modelo de redes neuronales

| 10 neuronas, ReLU, crossentropy, traingdx, sigmoid   |                                                                              |          |           |        |          |        |
|------------------------------------------------------|------------------------------------------------------------------------------|----------|-----------|--------|----------|--------|
|                                                      | VariableSet                                                                  | Accuracy | Precision | Recall | F1_score | MSE    |
| 712                                                  | chl, cloudcover, windspeed, coast, tide, cooccurrence                        | 0.8167   | 0.8966    | 0.7647 | 0.8254   | 0.4226 |
| 951                                                  | chl, cloudcover, windspeed, coast, tide, winddir_sin, daynight, cooccurrence | 0.8000   | 0.9231    | 0.7059 | 0.8000   | 0.4227 |
| 882                                                  | chl, cloudcover, windspeed, coast, tide, daynight, cooccurrence              | 0.7667   | 0.8571    | 0.7059 | 0.7742   | 0.4235 |
| 808                                                  | sst, chl, cloudcover, windspeed, tide, daynight, cooccurrence                | 0.7667   | 0.9167    | 0.6471 | 0.7586   | 0.4258 |
| 805                                                  | sst, chl, cloudcover, windspeed, tide, winddir_sin, cooccurrence             | 0.7833   | 0.8621    | 0.7353 | 0.7937   | 0.4281 |
| 734                                                  | chl, cloudcover, coast, tide, daynight, cooccurrence                         | 0.7667   | 0.8846    | 0.6765 | 0.7667   | 0.4302 |
| 222                                                  | chl, cloudcover, winddir_sin, cooccurrence                                   | 0.8000   | 0.9583    | 0.6765 | 0.7931   | 0.4347 |
| 802                                                  | sst, chl, cloudcover, windspeed, coast, daynight, cooccurrence               | 0.7333   | 0.9091    | 0.5882 | 0.7143   | 0.4359 |
| 484                                                  | chl, cloudcover, tide, winddir_sin, cooccurrence                             | 0.7833   | 0.9200    | 0.6765 | 0.7797   | 0.4369 |
| 799                                                  | sst, chl, cloudcover, windspeed, coast, winddir_sin, cooccurrence            | 0.7833   | 0.8889    | 0.7059 | 0.7869   | 0.4369 |
| 10 neuronas, ReLU, mse, traingd, sigmoid             |                                                                              |          |           |        |          |        |
|                                                      | VariableSet                                                                  | Accuracy | Precision | Recall | F1_score | MSE    |
| 468                                                  | chl, cloudcover, windspeed, winddir_sin, cooccurrence                        | 0.7667   | 0.8000    | 0.6897 | 0.7407   | 0.1494 |
| 222                                                  | chl, cloudcover, winddir_sin, cooccurrence                                   | 0.7000   | 0.7895    | 0.5172 | 0.6250   | 0.1504 |
| 624                                                  | sst, chl, windspeed, coast, winddir_sin, cooccurrence                        | 0.7500   | 0.7333    | 0.7586 | 0.7458   | 0.1540 |
| 721                                                  | chl, cloudcover, windspeed, tide, winddir_sin, cooccurrence                  | 0.7500   | 0.7692    | 0.6897 | 0.7273   | 0.1550 |
| 594                                                  | sst, chl, cloudcover, windspeed, winddir_sin, cooccurrence                   | 0.6833   | 0.6923    | 0.6207 | 0.6545   | 0.1571 |
| 478                                                  | chl, cloudcover, coast, winddir_sin, cooccurrence                            | 0.6667   | 0.6957    | 0.5517 | 0.6154   | 0.1586 |
| 805                                                  | sst, chl, cloudcover, windspeed, tide, winddir_sin, cooccurrence             | 0.7333   | 0.7826    | 0.6207 | 0.6923   | 0.1586 |
| 715                                                  | chl, cloudcover, windspeed, coast, winddir_sin, cooccurrence                 | 0.6833   | 0.6563    | 0.7241 | 0.6885   | 0.1608 |
| 356                                                  | sst, chl, windspeed, coast, cooccurrence                                     | 0.7000   | 0.7391    | 0.5862 | 0.6538   | 0.1633 |
| 8                                                    | sst, chl, cooccurrence                                                       | 0.7333   | 0.7826    | 0.6207 | 0.6923   | 0.1645 |
| 10 neuronas, tansig, crossentropy, traingdx, sigmoid |                                                                              |          |           |        |          |        |
|                                                      | VariableSet                                                                  | Accuracy | Precision | Recall | F1_score | MSE    |
| 764                                                  | chl, tide, winddir_sin, winddir_cos, daynight, cooccurrence                  | 0.8000   | 0.9259    | 0.7143 | 0.8065   | 0.5142 |
| 526                                                  | chl, winddir_sin, winddir_cos, daynight, cooccurrence                        | 0.7833   | 0.8929    | 0.7143 | 0.7937   | 0.5144 |
| 652                                                  | sst, chl, winddir_sin, winddir_cos, daynight, cooccurrence                   | 0.7833   | 0.8929    | 0.7143 | 0.7937   | 0.5084 |
| 755                                                  | chl, windspeed, tide, winddir_sin, winddir_cos, cooccurrence                 | 0.7667   | 0.7838    | 0.8286 | 0.8056   | 0.5199 |
| 258                                                  | chl, winddir_sin, winddir_cos, cooccurrence                                  | 0.7667   | 0.8621    | 0.7143 | 0.7813   | 0.5045 |
| 848                                                  | sst, chl, tide, winddir_sin, winddir_cos, daynight, cooccurrence             | 0.7667   | 0.8889    | 0.6857 | 0.7742   | 0.5271 |
| 519                                                  | chl, coast, winddir_sin, winddir_cos, cooccurrence                           | 0.7500   | 0.8125    | 0.7429 | 0.7761   | 0.5138 |
| 736                                                  | chl, cloudcover, coast, winddir_sin, winddir_cos, cooccurrence               | 0.7500   | 0.8125    | 0.7429 | 0.7761   | 0.5051 |
| 63                                                   | chl, winddir_cos, cooccurrence                                               | 0.7500   | 0.8333    | 0.7143 | 0.7692   | 0.5274 |
| 509                                                  | chl, windspeed, winddir_sin, winddir_cos, cooccurrence                       | 0.7500   | 0.8571    | 0.6857 | 0.7619   | 0.5056 |
| 15 neuronas, ReLU, mse, trainlm, sigmoid             |                                                                              |          |           |        |          |        |
|                                                      | VariableSet                                                                  | Accuracy | Precision | Recall | F1_score | MSE    |
| 817                                                  | chl, cloudcover, coast, tide, winddir_cos, cooccurrence                      | 0.7000   | 0.6512    | 0.9032 | 0.7568   | 0.2058 |
| 831                                                  | sst, chl, cloudcover, coast, winddir_sin, winddir_cos, cooccurrence          | 0.7000   | 0.6512    | 0.9032 | 0.7568   | 0.2017 |
| 88                                                   | sst, cloudcover, windspeed, cooccurrence                                     | 0.7000   | 0.6585    | 0.8710 | 0.7500   | 0.1846 |
| 174                                                  | chl, cloudcover, coast, tide, winddir_cos                                    | 0.7000   | 0.6585    | 0.8710 | 0.7500   | 0.2260 |
| 527                                                  | sst, chl, winddir_sin, cooccurrence                                          | 0.7000   | 0.6585    | 0.8710 | 0.7500   | 0.1837 |
| 571                                                  | sst, chl, cloudcover, tide, winddir_sin, winddir_cos, cooccurrence           | 0.7000   | 0.6585    | 0.8710 | 0.7500   | 0.1775 |
| 122                                                  | cloudcover, coast, tide, winddir_cos, cooccurrence                           | 0.7000   | 0.6667    | 0.8387 | 0.7429   | 0.1874 |
| 589                                                  | chl, cloudcover, windspeed, coast, tide, winddir_cos, cooccurrence           | 0.7000   | 0.6667    | 0.8387 | 0.7429   | 0.1896 |
| 47                                                   | sst, windspeed, coast, tide, winddir_sin, daynight, cooccurrence             | 0.7000   | 0.6757    | 0.8065 | 0.7353   | 0.1904 |
| 15 neuronas, tansig, crossentropy, traingdx, sigmoid |                                                                              |          |           |        |          |        |
|                                                      | VariableSet                                                                  | Accuracy | Precision | Recall | F1_score | MSE    |
| 495                                                  | chl, windspeed, coast, tide, cooccurrence                                    | 0.8000   | 0.6897    | 0.8696 | 0.7692   | 0.4413 |
| 514                                                  | chl, coast, tide, winddir_sin, cooccurrence                                  | 0.8000   | 0.6897    | 0.8696 | 0.7692   | 0.4218 |
| 630                                                  | sst, chl, windspeed, tide, winddir_sin, cooccurrence                         | 0.8000   | 0.6897    | 0.8696 | 0.7692   | 0.4803 |
| 746                                                  | chl, windspeed, coast, tide, winddir_sin, cooccurrence                       | 0.8000   | 0.7037    | 0.8261 | 0.7600   | 0.4190 |
| 576                                                  | windspeed, winddir_sin, winddir_cos, daynight, cooccurrence                  | 0.8000   | 0.7200    | 0.7826 | 0.7500   | 0.5071 |
| 49                                                   | chl, windspeed, cooccurrence                                                 | 0.8000   | 0.8235    | 0.6087 | 0.7000   | 0.4723 |
| 94                                                   | windspeed, tide, cooccurrence                                                | 0.8000   | 0.8235    | 0.6087 | 0.7000   | 0.5340 |
| 299                                                  | windspeed, coast, tide, cooccurrence                                         | 0.8000   | 0.8235    | 0.6087 | 0.7000   | 0.5197 |
| 133                                                  | sst, chl, windspeed, cooccurrence                                            | 0.7833   | 0.6667    | 0.8696 | 0.7547   | 0.4642 |
| 384                                                  | sst, chl, winddir_sin, winddir_cos, cooccurrence                             | 0.7833   | 0.6786    | 0.8261 | 0.7451   | 0.4425 |