

UNIVERSIDAD CATÓLICA DE LA SANTÍSIMA CONCEPCIÓN
FACULTAD DE INGENIERÍA- FACULTAD DE CIENCIAS
MAGÍSTER EN MEDIO AMBIENTE



**DESARROLLO DE UN MODELO DE APRENDIZAJE AUTOMÁTICO PARA DETECCIÓN
DE PECES POR ACÚSTICA PASIVA**
DIEGO IGNACIO SEPÚLVEDA PINTO

**INFORME DE PROYECTO DE TÍTULO PARA OPTAR AL GRADO DE
MAGISTER EN MEDIO AMBIENTE**

Profesor Guía : Dr. Iván Hinojosa.

Profesor Informante : Dra Daniela Mennickent.
Interno

Profesor Informante : Dra Julie Patris.
Externo

Concepción, marzo de 2026

Dedicatoria

A las personas que me han acompañado en el camino.

Agradecimientos

Agradezco a mi comisión evaluadora, a las doctoras Daniela y Julie quienes han sido un pilar fundamental en el proceso del proyecto, por sus consejos tan acertados y por la buena onda. Mención honrosa a Iván Hinojosa, quien ha sido un guía muy importante y cercano para abordar este desafío.

A mi familia por su apoyo incondicional. A Cote por su amor y compañía.

A los amigos, les agradezco la compañía, y la motivación que me dan siempre.

A la dirección de postgrado por su apoyo a través de la beca de actividad final de grado, así como al cuerpo docente del programa de Magíster en Medioambiente de la Universidad Católica de la Santísima Concepción.

Resumen

El ruido submarino antropogénico representa una presión ambiental creciente sobre los ecosistemas marinos, alterando el paisaje sonoro y afectando procesos ecológicos clave en numerosas especies. En este contexto, el monitoreo acústico pasivo (PAM) se ha consolidado como una herramienta eficiente para estudiar la biodiversidad marina a partir de registros sonoros; sin embargo, su aplicación se ha concentrado principalmente en mamíferos marinos, existiendo una brecha metodológica y tecnológica significativa para el caso de los peces. Esta brecha limita además la efectividad de los instrumentos regulatorios vigentes en Chile, que carecen de protocolos estandarizados para evaluar el impacto acústico sobre fauna ictiológica.

El presente trabajo tuvo como objetivo desarrollar un modelo de detección basado en algoritmos de aprendizaje automático para identificar señales acústicas de peces en registros submarinos, como insumo para el diagnóstico ambiental. Para ello, se utilizaron grabaciones obtenidas con un hidrófono calibrado instalado en la bahía de Cumberland, Isla Robinson Crusoe, Archipiélago de Juan Fernández. Los registros fueron segmentados y etiquetados manualmente en tres categorías: señales individuales de peces, coros de peces y otras fuentes acústicas, conformando un dataset de 9.000 fragmentos de entrenamiento y 3.600 de validación. A partir de estos datos se extrajeron coeficientes cepstrales en escala Mel (MFCC) y valores de energía RMS calibrados, seleccionando mediante análisis VIP las 17 características más relevantes como entrada a un modelo de clasificación basado en HistGradient Boosting. Los resultados muestran un desempeño satisfactorio del modelo, con una precisión superior al 80% y un F1-score de 80,5% para la detección de coros de peces. La aplicación del modelo a series temporales continuas permitió identificar patrones diarios de ocurrencia de coros consistentes con ciclos de actividad de tipo circadiano, y detectar diferencias estacionales en los horarios de actividad acústica entre enero y abril. Se concluye que la integración de PAM y aprendizaje automático constituye una herramienta viable, replicable y de bajo impacto para el monitoreo acústico de peces en contextos locales, con potencial de aplicación en procesos de evaluación y gestión ambiental marina en Chile

Abstract

Anthropogenic underwater noise represents a growing environmental pressure on marine ecosystems, altering the soundscape and affecting key ecological processes across numerous species. In this context, passive acoustic monitoring (PAM) has emerged as an efficient tool for studying marine biodiversity through acoustic recordings; however, its application has been largely focused on marine mammals, leaving a significant methodological and technological gap for fish. This gap also limits the effectiveness of current regulatory instruments in Chile, which lack standardized protocols for assessing acoustic impacts on fish fauna.

The objective of this study was to develop a detection model based on machine learning algorithms to identify fish acoustic signals in underwater recordings, as an input for environmental assessment. Acoustic data were collected using a calibrated hydrophone deployed in Cumberland Bay, Robinson Crusoe Island, Juan Fernández Archipelago. Recordings were segmented and manually labeled into three categories: individual fish sounds, fish choruses, and other acoustic sources, generating a dataset of 9,000 training fragments and 3,600 for validation. Mel-frequency cepstral coefficients (MFCCs) and calibrated RMS energy values were extracted from each segment, and the 17 most relevant features were selected through VIP analysis as input to a HistGradient Boosting classification model. Results demonstrate satisfactory model performance, with precision above 80% and an F1-score of 80.5% for fish chorus detection. Application of the model to continuous time series revealed daily occurrence patterns of fish choruses consistent with circadian activity cycles, and seasonal differences in acoustic activity schedules between January and April. It is concluded that the integration of PAM and machine learning constitutes a viable, replicable, and low-impact tool for acoustic fish monitoring in local contexts, with potential for application in marine environmental assessment and management processes in Chile.

Índice de Contenidos

1. Introducción	7
1.1. Descripción del problema ambiental	8
2. Objetivos	10
2.1. Objetivo general	10
2.2. Objetivos específicos	10
3. Antecedentes	10
3.1. Relación del problema ambiental con la sociedad	10
3.2. Impactos ambientales identificados	11
3.3. Normativa nacional e internacional relacionada con el problema ambiental	13
4. Metodología	15
4.1. Adquisición y preprocesamiento de datos	15
4.2. Extracción de características acústicas	17
4.3. MFCC (Coeficientes Cepstrales en Escala Mel)	17
4.4. RMS calibrado	17
4.5. Vector final de características	18
4.6. Entrenamiento del modelo	18
4.7. Evaluación y métricas	18
4.8. Guardado del modelo	19
5. Resultados	19
6. Necesidades para la implementación de medidas	23
7. Análisis crítico	24
8. Conclusiones — Recomendaciones	26
9. Referencias Bibliográficas	28

Índice de Tablas

Tabla 1	Síntesis de impactos ambientales asociados al ruido submarino y a la limitada implementación de PAM para peces.	13
Tabla 2	Normativas y guías relevantes.	15
Tabla 3	Ejemplo de 20 primeros segundos de audio etiquetado para entrenamiento/validación.	17

Índice de Figuras

Fig. 1	Mapa de ubicación geográfica del hidrófono utilizado para obtención de datos in situ.	16
Fig. 2	Espectrogramas de señales de interés para clasificación con ejemplos de las señales de sonido correspondientes a las clases 0 = otro, 1 = pez y 2 = coro.	19
Fig. 3	Análisis VIP de características extraídas.	20
Fig. 4	Análisis PCA de data etiquetada.	20
Fig. 5	Métricas de validación por clase, eje X = Clases 0, 1 y 2.	21
Fig. 6	Lectura de serie de tiempo desde el 13 al 26 de enero de 2025, utilizando el modelo entrenado.	22
Fig. 7	Lectura de serie de tiempo desde el 21 al 25 de abril de 2025, utilizando el modelo entrenado.	22

1. Introducción

El paisaje sonoro marino es la suma de sonidos biológicos (biofonía), abióticos (geofonía) y antropogénicos (antropofonía). Esto constituye un componente funcional y cuantificable de los ecosistemas oceánicos que influye en procesos ecológicos claves, como la comunicación, orientación, reproducción y asentamiento de numerosas especies (Pijanowski et al., 2011; Farina, 2014). Durante las últimas décadas, la intensidad y la extensión del ruido antropogénico submarino han aumentado de forma sostenida por actividades como el transporte marítimo, la exploración de recursos y la construcción costera, transformando el paisaje sonoro en lo que algunos autores denominan el «*soundscape of the Anthropocene*» y generando impactos medibles sobre múltiples taxones marinos. Esta alteración ha motivado llamados explícitos a integrar la dimensión acústica dentro de la gestión y evaluación ambiental marina (Duarte et al., 2021).

En Chile, el ruido submarino está regulado mediante el Sistema de Evaluación de Impacto Ambiental (SEIA), administrado por el Servicio de Evaluación Ambiental (SEA) en conjunto con el Ministerio del Medioambiente (MMA). El instrumento técnico específico que operacionaliza esta regulación es el Criterio de Evaluación en el SEIA: «*Predicción y Evaluación de Impactos por Ruido Submarino*» (SEA, 2022). Este documento exige a los titulares de proyectos que generen emisiones sonoras submarinas —como obras portuarias, actividades de construcción costera u operaciones de energía offshore— presentar modelaciones acústicas, líneas de base sonoras, identificación de fauna sensible en el área de influencia y estrategias de mitigación y monitoreo. Sin embargo, en la práctica, los criterios y herramientas disponibles se han desarrollado principalmente para mamíferos marinos; no existe aún un protocolo estandarizado para la evaluación del impacto sobre peces, lo que representa una limitación concreta en la efectividad del sistema regulatorio frente a esta fauna.

El uso del monitoreo acústico pasivo (PAM) en las costas chilenas es aún incipiente. Los trabajos disponibles se han orientado principalmente al estudio de mamíferos marinos —como el registro de presencia estacional de ballena sei en el Archipiélago de Juan Fernández (Buchan et al., 2024)— y a caracterizaciones generales del paisaje sonoro en islas oceánicas (Carrasco et al., 2021). No existe, hasta la fecha, una red sistemática de monitoreo PAM focalizado en peces en el país, lo que limita tanto la disponibilidad de datos de referencia como la posibilidad de implementar herramientas de diagnóstico acústico en procesos regulatorios a corto plazo. Este vacío subraya la necesidad urgente de desarrollar metodologías validadas localmente que puedan integrarse al marco normativo existente.

La técnica con la que se estudia este tipo de datos es el monitoreo acústico pasivo (PAM), el cual se ha consolidado como una técnica eficiente para registrar sonidos submarinos y describir la ocurrencia y distribución de especies sin observación visual directa. En mamíferos marinos, PAM y sus herramientas analíticas están ya relativamente desarrolladas y se utilizan para modelar distribuciones espaciales y temporales con aplicaciones en conservación y mitigación (Frasier et al., 2021; Haver et al., 2018). No obstante, en el caso de los peces, la adopción de PAM en programas de gestión y evaluación ambiental todavía está en una fase emergente, pese a que muchos peces emplean el sonido para funciones ecológicas críticas (Popper & Hawkins, 2019; Bolgan et al., 2025).

A una escala más global, las revisiones recientes señalan una brecha tecnológica y metodológica: por un lado, la mayor parte del esfuerzo de desarrollo de detectores y modelos automatizados se ha volcado sobre cetáceos. Por otra parte, los trabajos orientados a peces están creciendo pero aún son escasos y su adopción dentro de la gestión pesquera y ambiental es limitada (Haver et al., 2018; Frasier et al., 2021; Sousa et al., 2024; Bolgan et al., 2025). Esta laguna impide transformar los registros acústicos de peces en herramientas de diagnóstico y gestión con la misma madurez y confianza que hoy se aplica a mamíferos marinos.

En la zona de estudio se encontró la presencia de coros de peces. Los coros de peces son sonidos colectivos producidos por individuos de una o más especies durante comportamientos reproductivos o agregativos que constituyen una fuente de información ecológica relevante: permiten inferir la presencia, la actividad reproductiva, la distribución temporal y, en algunos casos, la abundancia relativa de poblaciones (Bolgan et al., 2025). La revisión de Bolgan y colaboradores sobre monitoreo de coros sugiere que PAM puede aportar datos sobre la distribución espacio-temporal, uso de hábitat y actividad de desove, lo que lo posiciona como una prometedora herramienta para el manejo y la conservación si se desarrollan detectores y protocolos robustos y contextualizados (Bolgan et al., 2025).

De este modo, en este trabajo se presenta el proceso de desarrollo de un sistema analítico que permite detectar y cuantificar actividad acústica de peces mediante el entrenamiento de un modelo de aprendizaje automático de clasificación, utilizando datos adquiridos mediante PAM en la bahía de Cumberland de la Isla Robinson Crusoe del Archipiélago de Juan Fernández.

1.1. Descripción del problema ambiental

Existe una brecha metodológica y tecnológica en el monitoreo acústico pasivo (PAM) aplicado a peces, ya que las herramientas y modelos existentes se han desarrollado principalmente para mamíferos marinos y no consideran la especificidad acústica local ni la variabilidad de los paisajes sonoros marinos. Esto limita la capacidad de detectar y cuantificar señales biológicas de peces de forma automatizada, afectando el desarrollo de diagnósticos ambientales basados en bioacústica marina.

Durante las últimas décadas, el ruido submarino antropogénico ha aumentado de manera sostenida debido al transporte marítimo, la construcción costera y el desarrollo industrial, alterando profundamente la estructura y función de los paisajes sonoros marinos (Duarte et al., 2021). Esta intensificación del ruido ha demostrado generar impactos negativos en múltiples taxa, afectando su comportamiento, fisiología e incluso supervivencia, y motivando llamados a incorporar la dimensión acústica dentro de la gestión y evaluación ambiental de ecosistemas marinos (Duarte et al., 2021).

En este contexto, el monitoreo acústico pasivo (PAM) se ha consolidado como una herramienta fundamental para registrar y analizar la ocurrencia y distribución de especies a partir de sonidos, sin necesidad de observación visual directa. Estudios recientes en Chile, como los de Carrasco et al. (2021), evidencian diferencias marcadas en los registros del paisaje sonoro entre sitios y estaciones en la isla Robinson Crusoe, reflejando patrones asociados a la biología y actividad de especies marinas. Sin embargo, en otros entornos como Rapa Nui, no se observaron diferencias entre sitios, aunque se reportaron mayores niveles de sonido nocturno vinculados a la actividad de camarones chasqueadores (Carrasco et al., 2021). Estas observaciones sugieren que los paisajes sonoros poseen una alta especificidad espacial y temporal, lo que subraya la necesidad de abordajes analíticos contextualizados para comprender los componentes biológicos y físicos del sonido submarino (Radford et al., 2010).

Pese a la creciente relevancia del paisaje sonoro como descriptor ecológico, el desarrollo metodológico del PAM se ha concentrado históricamente en mamíferos marinos, particularmente cetáceos, debido a la claridad de sus señales y a la existencia de bases de datos extensas que facilitan la detección automatizada (Haver et al., 2018; Frasier et al., 2021). En contraste, la bioacústica de peces sigue siendo un campo emergente. Aunque existen avances recientes en el seguimiento de coros de peces y su aplicación para la ecología y manejo de recursos, su adopción en contextos de gestión pesquera o evaluación ambiental sigue siendo limitada, marcando una brecha significativa respecto al desarrollo alcanzado en mamíferos marinos (Sousa et al., 2024; Bolgan et al., 2025).

La revisión de Popper y Hawkins (2019) destaca además la alta sensibilidad de los peces a la perturbación acústica y la urgencia de generar criterios de exposición específicos para este grupo, reforzando la necesidad de herramientas de diagnóstico que permitan discriminar entre fuentes acústicas y evaluar impactos del ruido antropogénico sobre la fauna ictiológica.

Otro aspecto crítico radica en que los paisajes sonoros son fuertemente específicos del sitio. Factores como la topografía local, los procesos oceanográficos, la composición biológica y la ubicación del hidrófono modulan los niveles, el espectro y la composición de las fuentes acústicas, generando alta variabilidad espacial incluso dentro de un mismo hábitat (McKenna et al., 2021; Merchant et al., 2022). Esta idiosincrasia local implica que los modelos o algoritmos desarrollados en una región no son necesariamente transferibles a otra, y que los avances metodológicos en PAM deben ser diseñados y validados con datos representativos del área de estudio, evitando extrapolaciones inapropiadas (Merchant et al., 2022).

En Chile, la información acústica disponible se ha enfocado principalmente en mamíferos marinos, como la documentación de la presencia estacional de ballena sei en el archipiélago de Juan Fernández (Buchan et al., 2024). Sin embargo, los antecedentes específicos para peces son escasos. Esta falta de implementaciones PAM focalizadas en peces representa una brecha crítica, considerando su potencial para informar diagnósticos ambientales, programas de monitoreo y conservación de la biodiversidad marina. En este contexto, algunos trabajos han incorporado ampliamente técnicas de *machine learning* (ML) para automatizar la detección y clasificación de sonidos de peces, permitiendo el análisis eficiente de grandes volúmenes de datos acústicos. Diversos estudios han aplicado métodos clásicos de ML como Random Forest, SVM, k-NN, árboles de decisión y naive Bayes para identificar y clasificar vocalizaciones de peces en grabaciones continuas (Sattar et al., 2016; Chérubin et al., 2020; Laplante et al., 2022). Estos enfoques han demostrado ser herramientas efectivas para el monitoreo acústico, especialmente cuando se combinan con una adecuada selección de características.

En este contexto, Mouy et al. (2024) compararon un enfoque basado en Random Forest con un modelo de *deep learning*, mostrando que, aunque el método de ML presentó un rendimiento inferior, sigue siendo relevante como técnica interpretable y de menor complejidad computacional para la detección de sonidos de peces. De forma similar, Barroso et al. (2025) emplearon múltiples algoritmos supervisados de ML, incluyendo naive Bayes, Random Forest, árboles de decisión y multilayer perceptron (MLP), junto con selección óptima de características y técnicas de *explainable artificial intelligence*, para clasificar sonidos pulsados de distintas especies en un arrecife subtropical, destacando la utilidad de estos métodos para la interpretación y generalización de modelos acústicos.

Si bien los métodos de ML han sido ampliamente utilizados, algunos estudios han incorporado *deep learning* para mejorar el rendimiento. Ibrahim et al. (2018) aplicaron una red neuronal profunda tras un preprocesamiento con *wavelet denoising* para clasificar vocalizaciones de *grouper*, y posteriormente ampliaron estos enfoques hacia algoritmos más robustos de detección y clasificación automática (Ibrahim et al., 2024). Asimismo, Mouy et al. (2024) demostraron que las CNN pueden superar a los métodos clásicos de ML cuando se dispone de grandes conjuntos de datos etiquetados.

En conjunto, la literatura muestra que los métodos de *machine learning* tradicionales continúan desempeñando un papel clave en el desarrollo de herramientas automatizadas de PAM por su eficiencia, interpretabilidad y flexibilidad, mientras que el *deep learning* se presenta como una alternativa complementaria cuando las condiciones de datos lo permiten, lo cual puede ser una directriz sobre cómo continuar este trabajo a través de técnicas de data augmentation o etiquetado de una base de datos más grande.

A partir de este panorama, el presente trabajo se plantea ante una doble problemática:

- La falta de herramientas automatizadas y validadas localmente para la detección y clasificación de señales acústicas de peces, lo que limita su integración en la gestión ambiental y en los estudios de biodiversidad.
- La necesidad de adaptar y validar modelos de *machine learning* a contextos acústicos locales, dada la especificidad espacial y temporal de los paisajes sonoros marinos.

2. Objetivos

2.1. Objetivo general

Desarrollar un modelo de detección basado en algoritmos de aprendizaje automático para identificar señales de peces en registros submarinos, como insumo para el diagnóstico ambiental.

2.2. Objetivos específicos

- Recopilar y procesar grabaciones submarinas de hidrófonos, generando un dataset etiquetado en categorías relevantes.
- Extraer y analizar características acústicas (MFCC, RMS) que permitan discriminar entre las categorías definidas.
- Diseñar y entrenar un modelo de clasificación multicategoría (Gradient Boosting) basado en las características extraídas.
- Validar el desempeño del modelo mediante métricas de precisión, recall y F1-score, utilizando grabaciones independientes de las empleadas en el entrenamiento.

3. Antecedentes

3.1. Relación del problema ambiental con la sociedad

El paisaje sonoro marino, entendido como una expresión viva de las interacciones ecológicas y humanas en el océano, constituye también una dimensión cultural y social del ambiente. Su alteración no solo representa una pérdida ecológica, sino que implica transformaciones profundas en la manera en que las comunidades costeras perciben, habitan y se relacionan con su entorno marino. En las últimas décadas, el aumento sostenido del ruido antropogénico generado por el transporte marítimo, la explotación de recursos y la expansión industrial ha modificado de forma estructural los paisajes acústicos oceánicos, fenómeno que Duarte et al. (2021) describen como parte del «*soundscape of the Anthropocene*». Esta transformación sonora del océano no ocurre en un vacío ecológico: se inscribe en una trama social compleja, donde el deterioro de la calidad acústica afecta tanto los procesos biológicos como los servicios ecosistémicos y las prácticas humanas que dependen de ellos.

Desde una perspectiva socioambiental, la contaminación acústica marina constituye un problema emergente que afecta directamente la sostenibilidad de las actividades económicas y culturales vinculadas al mar. La pesca artesanal, por ejemplo, depende de la salud de poblaciones de peces cuya distribución y comportamiento reproductivo pueden verse alterados por la presencia de ruido submarino (Popper & Hawkins, 2019). Estas modificaciones pueden repercutir en la disponibilidad del recurso, comprometiendo la seguridad alimentaria y la estabilidad económica de comunidades costeras que históricamente han sostenido su identidad en torno a la pesca y la recolección marina.

En Chile, el Servicio de Evaluación Ambiental (SEA) ha avanzado en la incorporación del ruido submarino dentro del SEIA a través del criterio técnico de evaluación publicado en 2022 (SEA, 2022).

Sin embargo, este instrumento presenta una limitación relevante: los criterios de identificación de fauna sensible y los umbrales de impacto establecidos han sido desarrollados principalmente con base en la literatura científica disponible para mamíferos marinos, sin contemplar criterios específicos para peces. Un ejemplo concreto de esta limitación es la dificultad que enfrentan los titulares de proyectos costeros para justificar umbrales de afectación acústica sobre poblaciones de peces cuando no existen líneas de base acústicas ni detectores automatizados validados localmente. Esto genera una brecha de gobernanza: la regulación existe, pero carece de las herramientas técnicas necesarias para aplicarse de manera efectiva a la fauna ictiológica.

El caso del Archipiélago de Juan Fernández, declarado Reserva de la Biosfera por la UNESCO, ejemplifica con claridad esta relación entre ambiente sonoro, territorio y comunidad. En este contexto, las alteraciones acústicas no solo modifican el comportamiento de la fauna marina, sino que también alteran la experiencia sensorial y simbólica de los habitantes del territorio, quienes reconocen el sonido del mar como parte constitutiva de su paisaje cultural. Merchant et al. (2022) subrayan que los paisajes sonoros poseen una dimensión social y perceptual que debe ser incorporada en los procesos de evaluación ambiental, ya que representan una forma de conocimiento sensible del entorno que contribuye a la identidad y cohesión comunitaria.

En términos más amplios, la creciente conciencia sobre el valor del paisaje sonoro en la planificación territorial y en la educación ambiental abre nuevas oportunidades para la democratización del conocimiento ecológico. El desarrollo de sistemas de monitoreo acústico accesibles y contextualizados —como los modelos de aprendizaje automático aplicados a bioacústica marina— permite generar datos que no solo sirven a la ciencia, sino que también fortalecen los procesos participativos de gestión y conservación.

En síntesis, la problemática del ruido submarino y la falta de herramientas de monitoreo bioacústico no pueden abordarse únicamente desde la biología o la ingeniería, sino desde una perspectiva integral que reconozca la dimensión social del sonido y su papel en la construcción del territorio. Incorporar el paisaje sonoro en las políticas públicas, en la educación ambiental y en los mecanismos de evaluación ambiental no solo contribuiría a la conservación de la biodiversidad marina, sino también al fortalecimiento del vínculo entre las comunidades humanas y los ecosistemas que las sustentan.

3.2. Impactos ambientales identificados

La literatura revisada describe múltiples impactos ambientales asociados a la alteración del paisaje sonoro marino por ruido antropogénico y a la limitada implementación de herramientas de monitoreo acústico dirigidas a peces. A continuación, se sintetizan los principales efectos reportados, con sus respectivas referencias.

- Enmascaramiento de señales y pérdida de información acústica: El ruido producido por actividades humanas (por ejemplo, tráfico marítimo y maquinaria costera) puede enmascarar señales biológicas relevantes para la comunicación, orientación y comportamiento de organismos marinos, reduciendo la capacidad de transmisión y recepción de esas señales (Duarte et al., 2021).
- Cambios en comportamiento y actividad reproductiva / coros de peces: Algunas revisiones indican que el ruido puede inducir alteraciones en comportamiento, desplazamientos e interrupción de actividades reproductivas, afectando la ocurrencia y sincronía de coros de peces. Estos coros constituyen una fuente de información ecológica relevante, por lo que su modificación tendría implicancias ecológicas directas (Popper & Hawkins, 2019; Duarte et al., 2021; Bolgan et al., 2025).

- Efectos fisiológicos y potenciales consecuencias demográficas: Se ha documentado que la exposición al ruido produce respuestas fisiológicas en peces (estrés, alteraciones sensoriales) que podrían, en escenarios prolongados o intensos, afectar la dinámica poblacional (Popper & Hawkins, 2019; Duarte et al., 2021).
- Alteración de servicios ecosistémicos y riesgo para recursos pesqueros: Los efectos en distribución y éxito reproductivo de especies afectadas por ruido pueden tener repercusiones en la disponibilidad del recurso pesquero, lo que impacta la pesca artesanal y comercial, con potenciales efectos socioeconómicos para las comunidades costeras (Popper & Hawkins, 2019; Sousa et al., 2024; Bolgan et al., 2025).
- Pérdida de resolución ecológica en monitoreo y diagnóstico ambiental: Debido a la escasez de implementaciones PAM focalizadas en peces, la capacidad de generar indicadores acústicos útiles para la gestión ambiental queda limitada (Haver et al., 2018; Bolgan et al., 2025).
- Variabilidad espacial que complica la evaluación y la extrapolación: Los paisajes sonoros son altamente dependientes del contexto local (topografía, procesos oceanográficos, composición biológica, ubicación del hidrófono), lo que genera gran variabilidad espacial y dificulta la transferencia de modelos o criterios de una región a otra sin validación in situ (McKenna et al., 2021; Merchant et al., 2022).
- Barreras tecnológicas y de datos para la detección automática: En el uso de *machine learning* y *deep learning* para detección acústica de peces, se reportan barreras como la necesidad de grandes volúmenes de datos etiquetados y la carga de anotación manual, lo que limita la disponibilidad operativa de detectores robustos (Mouy et al., 2024; Bolgan et al., 2025).

Tabla 1. Síntesis de impactos ambientales asociados al ruido submarino y a la limitada implementación de PAM para peces.

Impacto	Descripción	Referencias
Enmascaramiento acústico	Ruido antropogénico interfiere la transmisión de señales biológicas	Duarte et al., 2021
Cambios de comportamiento y reproductivos	Alteración en comunicación, desplazamientos o interrupción de coros reproductivos	Popper & Hawkins, 2019; Duarte et al., 2021; Bolgan et al., 2025
Respuestas fisiológicas y riesgo poblacional	Estrés u otras respuestas sensoriales con potencial efecto demográfico	Popper & Hawkins, 2019; Duarte et al., 2021
Impacto en servicios ecosistémicos / pesca	Riesgos sobre disponibilidad de recurso pesquero y servicios socioeconómicos	Popper & Hawkins, 2019; Sousa et al., 2024; Bolgan et al., 2025
Limitaciones en diagnóstico	Falta de detectores validados para peces reduce capacidad de monitoreo	Haver et al., 2018; Bolgan et al., 2025
Variabilidad espacial y transferencia	Especificidad local dificulta extrapolación de modelos	McKenna et al., 2021; Merchant et al., 2022
Barreras tecnológicas	Necesidad de datos etiquetados y demanda intensiva de anotación manual en Machine Learning y deep learning	Mouy et al., 2024; Bolgan et al., 2025

3.3. Normativa nacional e internacional relacionada con el problema ambiental

Marco normativo nacional (Chile)

Ley N° 19.300 — Bases Generales del Medio Ambiente

La Ley N° 19.300 establece las bases legales del régimen ambiental chileno, su objetivo general y las atribuciones de los órganos del Sistema de Evaluación de Impacto Ambiental (SEIA). En particular, el artículo 81 define atribuciones del Servicio de Evaluación Ambiental (SEA), entre ellas la administración del SEIA y la elaboración de criterios y guías técnicas que orienten la evaluación ambiental de proyectos (Ley N° 19.300). Esta base legal entrega el mandato para que el SEA formule criterios técnicos vinculantes aplicables en la evaluación de impactos ambientales, incluyendo los relativos a emisiones sonoras y su predicción y evaluación.

Criterio de evaluación SEIA: «Predicción y evaluación de impactos por ruido submarino» (SEA, 2022)

El SEA publicó un Documento Técnico/Criterio de Evaluación titulado *Predicción y evaluación de impactos por ruido submarino*, cuyo propósito es uniformar lineamientos técnicos para la predicción y evaluación de impactos acústicos submarinos en el marco del SEIA. El documento describe la información mínima que deben presentar los titulares: descripción de emisiones, área de influencia, identificación de fauna sensible, metodologías de modelación y evaluación de impactos, e incorpora ejemplos y criterios de aplicación. En la práctica, este instrumento exige a los titulares modelaciones acústicas, líneas de base acústicas y estrategias de mitigación o monitoreo en proyectos cuya ejecución implique emisión de ruido submarino (SEA, 2022).

Una limitación relevante de este criterio es que los umbrales de evaluación y los protocolos de identificación de fauna sensible se han desarrollado fundamentalmente con base en la literatura disponible para mamíferos marinos. Para los peces, el criterio reconoce la necesidad de identificación

de fauna sensible, pero no proporciona umbrales de exposición ni protocolos de monitoreo específicos, lo que dificulta la aplicación homogénea del instrumento cuando los proyectos se ubican en áreas con alta riqueza ictiológica. Por ejemplo, un proyecto de infraestructura portuaria en una zona costera de alta biodiversidad de peces actualmente no cuenta con una metodología estandarizada para evaluar el impacto acústico sobre esa fauna, más allá de referencias cualitativas a la literatura científica.

Ministerio del Medio Ambiente (MMA) — lineamientos y recursos sobre ruido submarino

El Ministerio del Medio Ambiente dispone de recursos informativos y técnicos sobre ruido, incluyendo una sección específica sobre ruido submarino donde se presenta la aplicabilidad del criterio SEA y enlaces a documentos técnicos y guías para la evaluación de impactos por ruido y vibraciones en el SEIA (MMA, 2022). Estas páginas oficiales resumen la naturaleza vinculante del criterio del SEA y orientan a profesionales y titulares sobre la información requerida en procesos de evaluación ambiental.

Normativa e instrumentos internacionales relevantes

Convenios multilaterales de los que Chile es Parte:

- Convenio sobre la Diversidad Biológica (CBD): Chile figura entre las Partes del CBD; este convenio establece obligaciones generales para la conservación y uso sostenible de la biodiversidad, marco dentro del cual las políticas nacionales deben considerar amenazas que afecten la biodiversidad marina (CBD, 1992).
- Convención de las Naciones Unidas sobre el Derecho del Mar (UNCLOS): Chile es parte de UNCLOS, el marco jurídico que regula las actividades en los espacios marinos y obliga a los Estados a proteger y preservar el medio marino (ONU, 1982).

A nivel sectorial, la Organización Marítima Internacional (IMO) ha publicado guías técnicas destinadas a reducir el ruido radiado bajo el agua por buques comerciales (MEPC.1/Circ.833, 2014; MEPC.1/Circ.906, 2023). Estas guías no son instrumentos jurídicamente vinculantes por sí mismos, pero constituyen orientación internacional reconocida para diseñadores, astilleros, armadores y autoridades marítimas sobre medidas de mitigación del ruido generado por el transporte marítimo.

Vacíos, desafíos regulatorios y oportunidades

La literatura científica y las revisiones recientes señalan que la mayoría de las herramientas y bases de datos desarrolladas internacionalmente se han concentrado en mamíferos marinos; la falta de metodologías estandarizadas aplicables a peces dificulta la aplicación homogénea de criterios de protección en cada evaluación ambiental. Esto plantea la oportunidad de complementar el marco técnico con protocolos y estándares de monitoreo acústico de peces para mejorar la toma de decisiones en el SEIA.

Tabla 2. Normativas y guías relevantes.

Ámbito	Instrumento	Tipo	Relevancia
--------	-------------	------	------------

Nacional (Chile)	Ley N°19.300 (Bases del Medio Ambiente), artículo 81 (atribuciones SEA)	Ley orgánica	Mandato legal para evaluación ambiental y elaboración de criterios técnicos
Nacional (Chile)	Criterio SEIA: Predicción y Evaluación de Impactos por Ruido Submarino (SEA, 2022)	Documento técnico (vinculante en SEIA)	Lineamientos técnicos para modelación, líneas de base, identificación de fauna sensible y evaluación de impactos acústicos (SEA, 2022)
Nacional (Chile)	MMA — recursos y guías sobre ruido submarino	Portal gubernamental / guías técnicas	Difusión y orientación técnica para aplicadores y titulares en SEIA (MMA, 2022)
Internacional	Convenio sobre la Diversidad Biológica (CBD)	Tratado multilateral (Chile, Parte)	Marco de conservación y uso sostenible de la biodiversidad marina (CBD, 1992)
Internacional	UNCLOS (Convención del Derecho del Mar)	Tratado multilateral (Chile, Parte)	Marco jurídico para la protección del medio marino (ONU, 1982)
Internacional / sectorial	IMO — Guidelines (MEPC.1/Circ.833; MEPC.1/Circ.906 revisada 2023)	Directrices técnicas (no vinculantes)	Recomendaciones para reducción del ruido radiado por buques (IMO, 2014; 2023)

4. Metodología

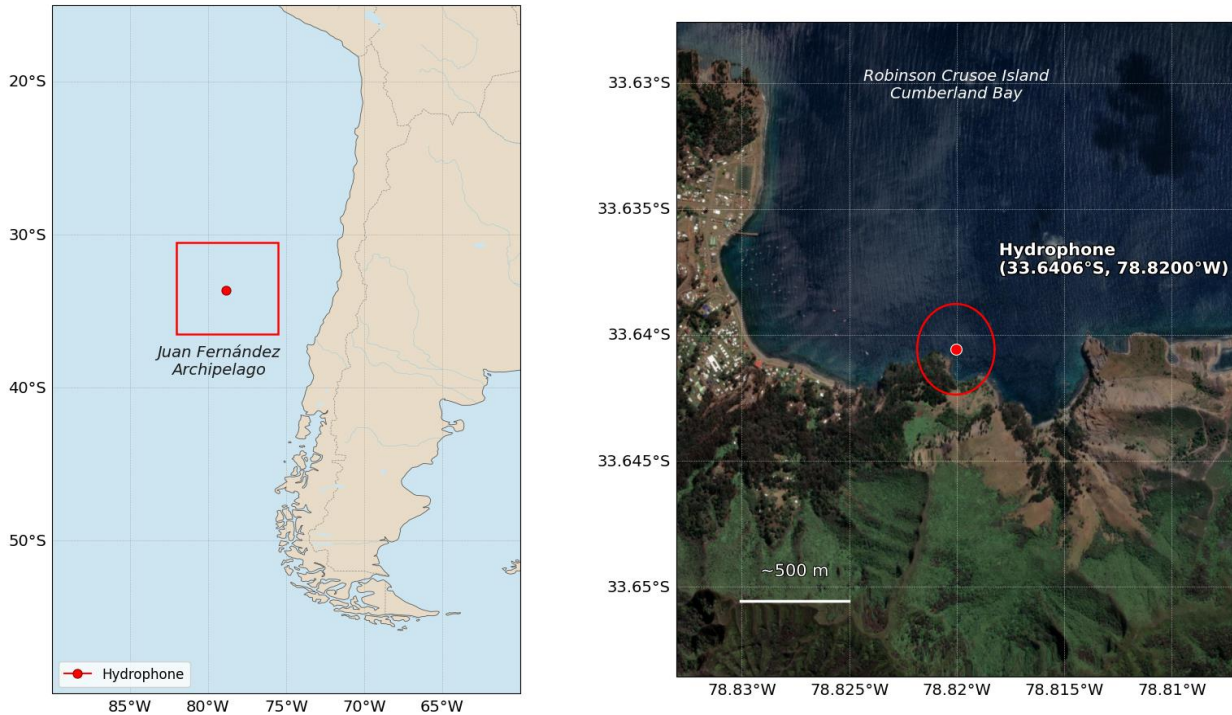
El proyecto se ha desarrollado en cuatro fases principales: (1) adquisición y preprocesamiento de datos, (2) etiquetado y construcción del dataset, (3) entrenamiento del modelo y (4) validación.

4.1. Adquisición y preprocesamiento de datos

Se obtuvieron datos acústicos de un hidrófono modelo Soundtrap ST600HF ubicado en la Bahía de Cumberland, Isla Robinson Crusoe, del archipiélago de Juan Fernández (Fig. 1). El instrumento captó datos almacenándolos en formato WAV, en archivos de 30 minutos de duración, durante los meses de enero y abril de 2025. El Soundtrap ST600HF opera en un rango de frecuencias de 20 Hz a 150 kHz con una sensibilidad de $-172,5$ dB re $1V/\mu Pa$ y una tasa de muestreo configurable; en este estudio se empleó una tasa de muestreo de 96 kHz. Cada archivo de audio fue procesado mediante un flujo de trabajo automatizado en Python, que incluyó los siguientes pasos:

- Resamplero: todos los registros se ajustaron a 44,1 kHz para asegurar consistencia temporal en las señales.
- Filtrado de banda: se aplicó un filtro pasabanda con corte inferior de 400 Hz y superior de 1.200 Hz, restringiendo el análisis a las frecuencias dominantes de los coros de peces y reduciendo ruido de fondo. Este rango de frecuencias fue determinado mediante inspección manual de los espectrogramas, identificando las bandas de mayor actividad biológica en la zona de estudio.
- Suavizado: se empleó un filtro Savitzky-Golay con ventana de 5 muestras y polinomio de orden 2, con el fin de suavizar fluctuaciones breves y mejorar la calidad de las características extraídas.

- Fragmentación temporal: los audios se dividieron en fragmentos de 2 segundos para garantizar la homogeneidad de las muestras y facilitar la extracción de características.



[Fig. 1. Mapa de ubicación geográfica del hidrófono utilizado para obtención de datos *in situ*.]

Respecto al etiquetado y construcción del dataset: mediante el software Audacity (v3.7.7) se inspeccionaron visualmente espectrogramas de cada archivo de audio. El proceso de anotación consistió en identificar y etiquetar manualmente fragmentos de 2 segundos, clasificándolos en tres categorías: Clase 0 (Otro), Clase 1 (Pez) y Clase 2 (Coro de peces) como se ejemplifica en la tabla 3. La distinción entre clases se basó en criterios acústicos definidos a priori: los coros de peces (Clase 2) se identificaron por la presencia de señales espectralmente concentradas en la banda de 400–1.200 Hz y amplitud notoriamente superior al ruido de fondo; las señales individuales de peces (Clase 1) correspondieron a pulsos o llamadas de menor duración y amplitud, visibles en el espectrograma pero sin formar un patrón colectivo evidente; y la categoría Otro (Clase 0) incluyó fragmentos dominados por ruido abiótico, antropofonía (principalmente embarcaciones), ruido de fondo u otras fuentes no biológicas. Esta distinción está sujeta al criterio de la persona que etiqueta, quien debe conocer y saber diferenciar las señales para etiquetado. El resultado fue un dataset de 9.000 fragmentos etiquetados para entrenamiento y 3.600 para validación.

Tabla 3. Ejemplo de 20 primeros segundos de audio etiquetado para entrenamiento/validación.

Tiempo (mm:ss)	Etiqueta
00:02	0
00:04	1

00:06	1
00:08	1
00:10	1
00:12	0
00:14	0
00:16	2
00:18	2
00:20	2

4.2. Extracción de características acústicas

En este estudio, cada fragmento de audio se procesó para calcular dos tipos de características bioacústicas que alimentan el modelo de aprendizaje automático: MFCC (Mel-Frequency Cepstral Coefficients) y RMS (Root Mean Square) calibrado.

4.3. MFCC (Coeficientes Cepstrales en Escala Mel)

Los MFCC son una representación espectral del sonido que refleja la percepción auditiva humana, destacándose por su capacidad para capturar las propiedades relevantes de la señal de audio en tareas de reconocimiento de patrones acústicos. Como señalan Rabiner y Schafer (2007), el cálculo de los MFCC implica primero la aplicación de la Transformada de Fourier de corto tiempo (STFT) para obtener la información espectral del fragmento de audio. Posteriormente, se calcula la potencia espectral, se aplica un banco de filtros Mel para simular la sensibilidad del oído humano a diferentes frecuencias y se toma el logaritmo de la energía de cada banda. Finalmente, se aplica la Transformada Discreta del Coseno (DCT) sobre los logaritmos de energía para obtener los coeficientes MFCC (Davis & Mermelstein, 1980).

En este trabajo se extrajeron 40 coeficientes MFCC por fragmento, decisión que responde a una práctica consolidada en la literatura de clasificación acústica biológica. En el contexto específico de sonidos de peces, Malfante et al. (2018) emplearon un conjunto amplio de características que incluía coeficientes cepstrales en escala Mel como componente central para clasificar cuatro tipos distintos de sonidos de peces en registros submarinos continuos, argumentando que un número elevado de coeficientes iniciales permite capturar la diversidad espectral de señales biológicas complejas antes de aplicar criterios de selección. Esto es consistente con lo reportado por revisiones recientes sobre clasificación bioacústica, que confirman que los MFCC son la característica más utilizada en más del 50% de los estudios del área, siendo frecuente la extracción de entre 20 y 40 coeficientes como punto de partida para análisis supervisados (Fonseca et al., 2022). En este trabajo, la extracción de 40 coeficientes garantizó una representación espectral suficientemente amplia del paisaje sonoro local antes de aplicar criterios de selección, evitando descartar a priori información potencialmente discriminante entre las clases definidas.

4.4. RMS calibrado

La energía de cada fragmento se cuantificó mediante el valor RMS (Root Mean Square), que representa la raíz cuadrada de la media de los cuadrados de las muestras de audio. Este valor proporciona una medida objetiva de la amplitud de la señal y es ampliamente usado en análisis de audio y bioacústica (Zölzer, 2008). Para una representación consistente y comparable entre diferentes grabaciones, el RMS se convierte a decibelios y se calibra mediante un valor de referencia específico del instrumento. En este estudio, el valor de referencia utilizado fue $RMS_{ref} = 188,5 \text{ dB re } 1 \mu\text{Pa}$, obtenido de las especificaciones técnicas publicadas por Ocean Instruments para el hidrófono Soundtrap ST600HF.

4.5. Vector final de características

El vector final de entrada al modelo se construyó a partir de un proceso de selección orientado a maximizar la eficiencia computacional sin sacrificar capacidad discriminativa. Para ello se aplicó un análisis de importancia de variables mediante el índice VIP (Variable Importance in Projection), con un umbral de corte de $VIP > 0,8$, valor ampliamente empleado en la literatura como criterio de selección de características relevantes en modelos de clasificación, ya que permite retener variables con contribución predictiva demostrada mientras se excluyen aquellas con aporte marginal (Akarachantachote et al., 2014; Farrés et al., 2015). Del análisis resultaron 19 coeficientes MFCC con índice VIP superior a 0,8. Sin embargo, con el objetivo de reducir aún más la dimensionalidad del vector y mejorar la velocidad de lectura del modelo en series temporales continuas, se optó por retener únicamente los 16 primeros coeficientes en el ranking VIP, dado que el RMS calibrado — incluido como variable independiente por su relevancia energética demostrada— ocupaba la posición 17 del listado ordenado por importancia. El vector final quedó así compuesto por 16 coeficientes MFCC seleccionados más el RMS calibrado, totalizando 17 características. Los índices MFCC seleccionados (base 0: 1, 2, 3, 4, 5, 11, 12, 13, 14, 16, 17, 19, 20, 21, 28, 29) corresponden a coeficientes distribuidos entre el orden bajo y medio del espectro cepstral, capturando tanto la envolvente espectral general de la señal como patrones de energía de resolución intermedia, lo que resulta coherente con las diferencias acústicas esperadas entre coros de peces, señales individuales y otras fuentes acústicas.

4.6. Entrenamiento del modelo

Se entrenó un modelo HistGradientBoostingClassifier de scikit-learn utilizando las 17 características por fragmento. Los hiperparámetros del modelo se definieron mediante un proceso iterativo de ajuste manual y evaluación de métricas de validación, resultando en la siguiente configuración: 80 iteraciones ($max_iter=80$), profundidad máxima de árbol de 5 ($max_depth=5$), tasa de aprendizaje de 0,2 ($learning_rate=0.2$), tamaño mínimo de hoja de 10 muestras ($min_samples_leaf=10$) y semilla aleatoria 42 para reproducibilidad ($random_state=42$). La profundidad máxima de 5 y el tamaño mínimo de hoja de 10 se establecieron para evitar el sobreajuste (overfitting), dado el tamaño moderado del dataset; la tasa de aprendizaje de 0,2 fue seleccionada como un balance entre velocidad de convergencia y estabilidad del modelo. No se realizó una búsqueda exhaustiva de hiperparámetros (grid search) por limitaciones computacionales, pero la configuración adoptada permitió alcanzar métricas de validación satisfactorias. En este trabajo no se presentan antecedentes que comparen los experimentos con distintos hiperparámetros para entrenamiento del modelo.


4.7. Evaluación y métricas

El modelo se evaluó sobre el conjunto de validación calculando precisión (precision), exhaustividad (recall) y F1-score por clase. La precisión indica la proporción de predicciones positivas que son correctas para cada clase; el recall indica la proporción de instancias reales de cada clase que el modelo logró detectar; y el F1-score es la media armónica entre ambas métricas, siendo especialmente informativo en datasets con distribución desigual de clases. Las métricas se presentaron en tablas y gráficos de barras codificados por colores para facilitar la interpretación visual.


4.8. Guardado del modelo

El modelo final entrenado se almacenó en formato .pkl utilizando la librería joblib, lo que permite su reutilización para predicciones futuras sin necesidad de volver a entrenar. Este archivo puede ser cargado directamente en cualquier entorno Python con scikit-learn instalado.

5. Resultados




[Fig. 2. Espectrogramas de señales de interés para clasificación con ejemplos de las señales de sonido correspondientes a las clases 0 = otro, 1 = pez y 2 = coro.]



[Fig. 3. Análisis VIP de características extraídas.]

Como se señaló en la metodología, el análisis VIP con umbral de 0,8 se utilizó para seleccionar las características que mejor explican la variabilidad entre clases, reduciendo así el vector de entrada de 40 a 16 coeficientes MFCC más el RMS calibrado. Los coeficientes con mayor importancia corresponden a los MFCC de bajo orden, que capturan la envolvente espectral de la señal, y al RMS

calibrado, que discrimina principalmente los coros —de mayor energía— del resto de las categorías. Los coeficientes de alto orden (MFCC > 20), que codifican variaciones espectrales finas, presentaron importancias bajas y fueron excluidos, lo que es consistente con la naturaleza de las señales analizadas, cuyas diferencias relevantes se expresan principalmente en la energía y la forma general del espectro más que en sus detalles de alta resolución.




[Fig. 4. Análisis PCA de data etiquetada.]

Como complemento exploratorio, se realizó un análisis de componentes principales (PCA) sobre el conjunto completo de 41 características estandarizadas —previo a la selección VIP— con el objetivo de visualizar la estructura de agrupamiento de los datos etiquetados en un espacio de menor dimensionalidad. El modelo PCA fue ajustado sobre el conjunto de entrenamiento y ambos conjuntos (entrenamiento y validación) fueron proyectados sobre las dos primeras componentes principales para su visualización (Fig. 4).

PC1 corresponde a la dirección de máxima varianza en el espacio de 41 dimensiones y resume principalmente las diferencias de energía espectral global entre fragmentos, dado que los coeficientes MFCC de bajo orden —que describen la envolvente espectral de la señal— tienden a concentrar la mayor proporción de varianza entre clases. PC2 captura la máxima varianza residual ortogonal a PC1, representando diferencias más sutiles asociadas a la textura espectral de las señales, posiblemente relacionadas con la distribución de energía en frecuencias medias y la estructura tonal de cada clase.


Mediante este análisis se pudo observar que la clase 2 (coro de peces) presenta una agrupación más diferenciada en el espacio PC1-PC2 respecto a las clases 0 y 1, lo que sugiere que los coros poseen características acústicas más distintivas, probablemente asociadas a su mayor intensidad sonora y al carácter colectivo de la señal. En contraste, las clases 0 (otro) y 1 (pez individual) muestran un mayor solapamiento en el espacio de componentes principales, lo que anticipa la mayor dificultad del modelo para discriminar entre estas dos categorías, resultado que se confirma posteriormente en las métricas de validación (Fig. 5).



[Fig. 5. Métricas de validación por clase, eje X = Clases 0, 1 y 2.]


Analizando las métricas de validación, se observa que el modelo alcanza su mejor desempeño en la detección de coros de peces (Clase 2), con una precisión de 81,7%, un recall de 79,3% y un F1-score de 80,5%. Esto indica que el modelo es capaz de identificar correctamente la mayoría de los eventos de coro presentes en el conjunto de validación, con una tasa relativamente baja de falsos positivos. La clase Otro (Clase 0) presenta métricas intermedias, con valores de F1-score en torno al 75%, lo que refleja cierta confusión con señales individuales de peces. El menor desempeño se observa en la detección de señales individuales de peces (Clase 1), con una precisión de 66,2%, lo que se explica por la similitud espectral de estas señales con la categoría Otro (Clase 0): ambas comparten rangos de energía y perfiles espectrales similares, dificultando la discriminación automática. Esta limitación es coherente con lo observado en el análisis PCA y con las condiciones de etiquetado: las señales individuales de peces son heterogéneas y frecuentemente de baja amplitud, lo que hace que el límite de decisión del modelo sea más difuso para esta clase.

Una vez entrenado y validado, el modelo fue utilizado para analizar dos series temporales de registros acústicos continuos:



[Fig. 6. Lectura de serie de tiempo desde el 13 al 26 de enero de 2025, utilizando el modelo entrenado.]

Al observar esta figura, se aprecia un patrón de ocurrencia de los coros (representados en amarillo) de tipo circadiano, apareciendo todos los días entre las 21:00 y 22:30 h. Este patrón temporal es consistente con comportamientos reproductivos nocturnos reportados para diversas especies de peces en ambientes tropicales y subtropicales (Bolgen et al., 2025). Destaca además la intensidad de presión sonora que pueden alcanzar los coros, superando los 130 dB re 1 μ Pa. Respecto a esta figura, también es relevante plantear nuevas preguntas de investigación: ¿qué factores ambientales inciden en la ocurrencia e intensidad de los coros?, ¿cuántas especies componen estos coros?, ¿existe una relación entre factores antropogénicos y la ocurrencia de los coros?



[Fig. 7. Lectura de serie de tiempo desde el 21 al 25 de abril de 2025, utilizando el modelo entrenado.]

El análisis de esta segunda serie temporal permite observar aspectos complementarios de la actividad acústica de los peces en la zona de estudio. Para el mes de abril, los coros ocurren en un horario diferente al de enero, entre las 18:30 y las 19:30 h, lo que podría reflejar cambios estacionales en el comportamiento reproductivo o en las condiciones de iluminación. Adicionalmente, se observa un incremento de señales individuales de peces (puntos azules, Clase 1) entre las 06:30 y las 07:30 h, posiblemente asociado a actividad crepuscular matutina. El límite inferior de detección de las señales individuales se estima en aproximadamente 94 dB re 1 μ Pa, lo que indica la sensibilidad operativa del sistema en condiciones de ruido de fondo real. Es importante destacar que algunas predicciones

puntuales que el modelo clasifica como coros —particularmente entre los días 21 y 24— corresponden en realidad a episodios de aparente antropofonía (embarcaciones principalmente), evidenciando la necesidad de incorporar contexto adicional o categorías refinadas en futuras versiones del modelo.

6. Necesidades para la implementación de medidas

La implementación efectiva de la propuesta desarrollada en este estudio requiere considerar un conjunto de necesidades técnicas, normativas, operativas e institucionales que resultan indispensables para su aplicación en contextos de diagnóstico y gestión ambiental.

Recursos técnicos y tecnológicos

Uno de los requerimientos fundamentales para la implementación de la propuesta es la disponibilidad de equipamiento adecuado para la adquisición de datos acústicos submarinos. En particular, se requiere el uso de hidrófonos calibrados y de calidad científica, capaces de registrar señales en los rangos de frecuencia relevantes para la bioacústica de peces. La experiencia de este estudio demuestra la importancia de contar con instrumentos que permitan una correcta calibración de los niveles de presión sonora, de modo de asegurar la comparabilidad de los registros y la interpretación adecuada de métricas energéticas como el RMS en decibeles.

Asimismo, es indispensable disponer de infraestructura computacional suficiente para el almacenamiento, procesamiento y análisis de grandes volúmenes de datos acústicos. En el caso de este proyecto, el modelo fue desarrollado inicialmente en un equipo con procesador Intel Core i5-4210U y 12 GB de RAM, y posteriormente se migró a un equipo con procesador Intel Core i7-1185G7 y 32 GB de RAM, lo que agilizó considerablemente el proceso de entrenamiento y ajuste de hiperparámetros. Adicionalmente, se contó con un disco duro de 1 TB para almacenamiento en formato WAV.

La implementación también requiere el uso de software especializado de código abierto, particularmente Python 3.10.0 y librerías asociadas (librosa, scikit-learn, joblib). Si bien estas herramientas no implican costos de licenciamiento, sí demandan conocimientos técnicos específicos para su utilización, mantenimiento y eventual adaptación a nuevos contextos acústicos. Además es importante señalar que para la construcción del código del modelo se utilizó la versión gratuita de Chat gpt (modelo GPT-4o mini) como asistente de codificación, además del uso del modelo Sonnet 4.6 de Claude AI para ajustar la redacción y formato del presente informe.

Recursos humanos y capacidades técnicas

La implementación de la propuesta requiere capital humano con competencias interdisciplinarias en bioacústica marina, procesamiento de señales y análisis de datos, así como conocimientos básicos en ecología de peces y en el contexto ambiental local. Un aspecto crítico identificado es la necesidad de realizar procesos de etiquetado manual de datos acústicos para la construcción de datasets de entrenamiento y validación, tarea que requiere personal con experiencia en interpretación de espectrogramas e identificación de señales biológicas. Además, se requiere personal capaz de interpretar los resultados del modelo en un contexto ambiental, considerando la posibilidad de falsos positivos o confusión con fuentes antropogénicas.

Condiciones de contexto y representatividad de los datos

Dado que los paisajes sonoros marinos presentan alta especificidad espacial y temporal, la implementación del modelo requiere condiciones mínimas de representatividad de los datos: los registros deben abarcar distintos períodos del día, estaciones del año y condiciones ambientales

relevantes. La experiencia de este trabajo muestra que los modelos entrenados con datos locales presentan un mejor desempeño cuando se aplican en el mismo contexto acústico. En consecuencia, para implementar esta propuesta en otros sitios geográficos, resulta necesario generar nuevas líneas de base acústicas y reentrenar o ajustar el modelo con datos representativos del área de estudio.

Validación externa como condición para la implementación

Una necesidad crítica que debe considerarse como el primer paso concreto hacia la implementación operativa del sistema es la validación externa del modelo. En este estudio, el modelo fue entrenado y validado con datos del mismo sitio de estudio (Bahía de Cumberland, Isla Robinson Crusoe), lo que implica que su desempeño en contextos acústicos distintos aún no ha sido evaluado. La validación externa consiste en probar el modelo con registros acústicos obtenidos en sitios diferentes al de entrenamiento —idealmente con condiciones ecológicas y acústicas contrastantes— y evaluar si las métricas de desempeño se mantienen en rangos aceptables. Esta etapa permitiría determinar el alcance real de la generalización del modelo, identificar las condiciones bajo las cuales requiere reentrenamiento y establecer criterios técnicos para su aplicación en procesos de evaluación de impacto ambiental. Sin esta validación, el uso del modelo en otros contextos geográficos o en procedimientos regulatorios sería prematuro.

Marco normativo e institucional

Desde el punto de vista normativo, la implementación se enmarca en la Ley N°19.300 y en los criterios técnicos del SEA. Si bien dichos instrumentos establecen lineamientos generales para la evaluación del ruido, la aplicación de herramientas PAM focalizadas en peces aún no se encuentra plenamente estandarizada. En este contexto, una condición indispensable es el reconocimiento institucional del valor del monitoreo acústico de peces como insumo para el diagnóstico ambiental, lo que implica que las autoridades ambientales y los titulares de proyectos incorporen este tipo de herramientas dentro de las líneas de base o programas de seguimiento exigidos en el SEIA.

Condiciones para la sostenibilidad y escalabilidad de la propuesta

Finalmente, para que la implementación sea sostenible, es necesario considerar condiciones de financiamiento y planificación a mediano y largo plazo. El monitoreo acústico pasivo genera grandes volúmenes de información cuya gestión y análisis continuo requiere recursos permanentes. La integración de estos sistemas en programas institucionales de monitoreo ambiental permitiría distribuir costos, estandarizar metodologías y asegurar la continuidad de los registros.

7. Análisis crítico

El presente estudio se inserta en un campo de investigación emergente dentro de la bioacústica marina: la aplicación del monitoreo acústico pasivo (PAM) y de algoritmos de aprendizaje automático para la detección de peces. Si bien el uso de PAM se ha consolidado como una herramienta robusta para el estudio de mamíferos marinos, su aplicación sistemática en peces aún presenta un desarrollo incipiente, con limitaciones metodológicas, tecnológicas y de estandarización ampliamente reconocidas en la literatura científica (Haver et al., 2018; Bolgan et al., 2025).

Relevancia y aporte del proyecto

Uno de los principales aportes de este trabajo es la incorporación explícita de señales acústicas de peces —tanto individuales como coros— dentro de un marco analítico automatizado. Estudios recientes han destacado que los coros de peces constituyen indicadores ecológicos relevantes, ya que permiten inferir patrones de presencia, actividad reproductiva y uso de hábitat, además de presentar

potencial como bioindicadores sensibles a perturbaciones ambientales (Bolgan et al., 2025). Sin embargo, tal como señalan Popper y Hawkins (2019), la falta de herramientas operativas para detectar estas señales ha limitado su integración efectiva en programas de monitoreo ambiental.

Comparación con enfoques existentes

La literatura muestra que la mayoría de los desarrollos en PAM automatizado se han concentrado en cetáceos, donde las señales acústicas son más estables y existen bibliotecas acústicas extensas que facilitan la detección automática (Frasier et al., 2021; Haver et al., 2018). En contraste, la bioacústica de peces presenta mayores desafíos debido a la diversidad de señales, la variabilidad intra e interespecífica y la fuerte influencia del contexto acústico local (Bolgan et al., 2025).

Trabajos recientes que exploran el uso de aprendizaje automático para identificar sonidos de peces, como el de Barroso et al. (2025), demuestran el potencial de estas técnicas, pero también reconocen limitaciones asociadas a la transferencia de modelos entre sitios y a la necesidad de datasets cuidadosamente etiquetados. En comparación, el presente trabajo se distingue por su énfasis en la validación local del modelo y en la construcción de un dataset representativo del área de estudio.

Por otra parte, investigaciones comparativas entre *machine learning* y *deep learning* han mostrado que, si bien las redes neuronales profundas pueden alcanzar mayores niveles de precisión, su implementación requiere grandes volúmenes de datos etiquetados y mayores recursos computacionales (Mouy et al., 2024). En este contexto, la elección de Gradient Boosting representa una decisión metodológica equilibrada que privilegia la interpretabilidad, la eficiencia computacional y la viabilidad en contextos de gestión ambiental.

Referentes internacionales de implementación de PAM e IA para peces

Más allá de la literatura académica, existen experiencias concretas de implementación de PAM combinado con inteligencia artificial en contextos aplicados que resultan relevantes como referentes para el presente trabajo. En el Reino Unido, el Centro de Ecología y Medio Ambiente Marino (CEFAS) ha desarrollado e implementado protocolos de PAM para el monitoreo de peces en contextos de evaluación de impacto de energía eólica offshore, integrando análisis automatizado de señales acústicas en los procesos de evaluación ambiental requeridos por la legislación británica. En Australia, el sistema IMOS (Integrated Marine Observing System) ha incorporado PAM como componente de redes de monitoreo nacional, con estudios piloto que utilizan *machine learning* para la detección de señales biológicas en arrecifes costeros. En Portugal, el grupo de investigación de bioacústica de peces de la Universidad de Lisboa ha desarrollado detectores automatizados aplicados al monitoreo del *meagre* (*Argyrosomus regius*) en el estuario del Tejo como herramienta de apoyo a la gestión pesquera (Sousa et al., 2024). Estos ejemplos muestran que la integración de PAM e IA para peces es factible y está avanzando en jurisdicciones con marcos regulatorios más desarrollados en esta materia, constituyendo referentes concretos para una eventual implementación en Chile.

Tendencias actuales en monitoreo acústico y aprendizaje automático

Las tendencias actuales en ecología acústica apuntan hacia la integración de inteligencia artificial como herramienta central para el análisis de paisajes sonoros, tanto marinos como terrestres (Pijanowski et al., 2011; Merchant et al., 2022). En ambientes marinos, se observa un creciente interés en utilizar PAM no solo para detectar especies, sino también para evaluar el estado ecológico de los ecosistemas y los efectos del ruido antropogénico (Duarte et al., 2021).

Limitaciones, falencias y brechas

A pesar de sus aportes, este estudio presenta limitaciones que deben ser consideradas críticamente. En primer lugar, el modelo desarrollado está entrenado con datos provenientes de un único sitio geográfico, lo que restringe su capacidad de generalización. Tal como advierten McKenna et al. (2021) y Merchant et al. (2022), los paisajes sonoros marinos son altamente específicos del contexto local, por lo que la transferencia directa de modelos entre regiones puede conducir a interpretaciones erróneas sin una validación adecuada.

Asimismo, el proceso de etiquetado manual, aunque indispensable para el entrenamiento supervisado, constituye una barrera operativa importante. La literatura reconoce que la generación de datasets etiquetados es uno de los principales cuellos de botella en el desarrollo de modelos acústicos para peces (Mouy et al., 2024; Bolgan et al., 2025). Esta limitación abre la necesidad de explorar enfoques complementarios, como el aprendizaje semi-supervisado o la incorporación progresiva de nuevas categorías acústicas.

Otra falencia identificada es la dificultad del modelo para discriminar ciertas señales antropogénicas intensas que pueden confundirse con coros de peces, situación ya reportada en estudios similares (Popper & Hawkins, 2019; Duarte et al., 2021). Este aspecto subraya la importancia de integrar información contextual adicional y refinar las categorías de clasificación en futuros desarrollos.

Síntesis crítica y proyección

En síntesis, este trabajo contribuye a reducir una brecha metodológica relevante en la bioacústica marina aplicada a peces, proponiendo un enfoque automatizado, validado localmente y alineado con las tendencias actuales del campo. Su principal fortaleza radica en demostrar que es posible integrar técnicas de aprendizaje automático en el análisis del paisaje sonoro marino con un enfoque realista y aplicable a contextos de evaluación ambiental. La consolidación de estas herramientas requerirá avanzar en la estandarización de metodologías, en la ampliación de bases de datos acústicas y en la articulación entre ciencia, normativa y toma de decisiones.

8. Conclusiones — Recomendaciones

Los resultados obtenidos demuestran que es posible detectar y clasificar señales acústicas de peces de forma automatizada utilizando características acústicas estándar (MFCC y RMS calibrado) y un modelo de Gradient Boosting, transformando registros continuos en información ecológicamente interpretable.

En relación con los objetivos específicos: (1) se conformó un dataset representativo del paisaje sonoro local con 9.000 fragmentos etiquetados para entrenamiento y 3.600 para validación; (2) las características MFCC y RMS demostraron ser adecuadas para discriminar entre categorías acústicas; (3) el modelo de Gradient Boosting alcanzó un desempeño satisfactorio, con un F1-score superior al 80% para la detección de coros; y (4) las series temporales generadas por el modelo permiten identificar patrones diarios y estacionales de actividad acústica con potencial aplicación en estudios de línea de base ambiental.

Limitaciones del estudio

El modelo fue entrenado y validado con datos de un único sitio geográfico, lo que limita su generalización sin recalibración previa. El etiquetado manual implicó una carga significativa y una dependencia del criterio experto. Algunas señales antropogénicas de alta intensidad presentaron solapamiento espectral con señales biológicas, afectando el desempeño en casos puntuales.

Recomendaciones y proyecciones futuras

1. Validación externa: Como primer paso prioritario, se recomienda evaluar el modelo con registros provenientes de sitios distintos al de entrenamiento, para determinar su capacidad de generalización antes de cualquier implementación operativa.
2. Ampliación del dataset: Incorporar registros acústicos de distintos sitios y estaciones del año para mejorar la robustez y generalización del modelo.
3. Exploración de enfoques avanzados: Evaluar el uso de modelos de aprendizaje profundo o enfoques semi-supervisados en contextos donde se disponga de mayores volúmenes de datos.
4. Integración con variables ambientales: Incorporar información oceanográfica (temperatura, corrientes, ruido antropogénico) para enriquecer la interpretación ecológica de los patrones acústicos detectados.
5. Aplicación en gestión ambiental: Explorar la integración de esta metodología en programas de monitoreo y evaluación de impacto, particularmente como herramienta para la detección temprana de cambios en la actividad biológica.
6. Desarrollo de protocolos estandarizados: Avanzar hacia la estandarización de metodologías de adquisición, procesamiento y análisis de datos acústicos de peces, facilitando la comparación entre estudios y su adopción por instituciones públicas y privadas.

9. Referencias Bibliográficas

- Akarachantachote, N., Chadcham, S., & Saithanu, K. (2014). Cutoff threshold of variable importance in projection for variable selection. *International Journal of Pure and Applied Mathematics*, 94(3), 307–322. <https://doi.org/10.12732/ijpam.v94i3.2>
- Barroso, V. R., Lessa, A. A., Ferreira, C. E. L., & Xavier, F. C. (2025). Optimal feature selection and model explanation for reef fish sound classification. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 380(1928), Article 20240055. <https://doi.org/10.1098/rstb.2024.0055>
- Bolgan, M., Miller, M. E., Stephenson, R., Schiavon, M., Mouchi, V., & Radford, A. N. (2025). Passive acoustic monitoring of fish choruses: A review to inform the development of a monitoring and management tool. *Reviews in Fish Biology and Fisheries*. <https://doi.org/10.1007/s11160-025-09936-9>
- Buchan, S., Harris, C. M., Bedriñana-Romano, L., Dalla Rosa, L., & Huckle-Gaete, R. (2024). Seasonal acoustic presence of sei whales off the Juan Fernandez Archipelago, Chile. *Endangered Species Research*, 55, 43–60. <https://doi.org/10.3354/esr01403>
- Carrasco, S. A., Bravo, M., Avilés, E., Ruíz, P. A., Yori, A., & Hinojosa, I. A. (2021). Exploring overlooked components of remote South-east Pacific oceanic islands: Larval and macrobenthic assemblages in reef habitats with distinct underwater soundscapes. *Aquatic Conservation: Marine and Freshwater Ecosystems*, 31(2), 273–289. <https://doi.org/10.1002/aqc.3359>
- Secretaría del Convenio sobre la Diversidad Biológica [CBD]. (1992). *Convenio sobre la Diversidad Biológica*. Naciones Unidas. <https://www.cbd.int/convention/text/>
- Chérubin, L. M., Nemeth, R. S., & Idrisi, N. (2019). Fish spawning aggregations dynamics as inferred from a novel, persistent presence robotic approach. *Frontiers in Marine Science*, 6, Article 779. <https://doi.org/10.3389/fmars.2019.00779>
- Davis, S., & Mermelstein, P. (1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 28(4), 357–366. <https://doi.org/10.1109/TASSP.1980.1163420>
- Duarte, C. M., Chapuis, L., Collin, S. P., Costa, D. P., Devassy, R. P., Eguiluz, V. M., Erbe, C., Gordon, T. A. C., Halpern, B. S., Harding, H. R., Havlik, M. N., Meekan, M., Merchant, N. D., Miksis-Olds, J. L., Parsons, M., Predragovic, M., Radford, A. N., Radford, C. A., Simpson, S. D., Slabbekoorn, H., ... Juanes, F. (2021). The soundscape of the Anthropocene ocean. *Science*, 371(6529), eaba4658. <https://doi.org/10.1126/science.aba4658>
- Farina, A. (Ed.). (2014). *Soundscape ecology: Principles, patterns, methods and applications*. Springer. <https://doi.org/10.1007/978-94-007-7374-5>
- Farrés, M., Platikanov, S., Tsakovski, S., & Tauler, R. (2015). Comparison of the variable importance in projection (VIP) and of the selectivity ratio (SR) methods for variable selection

and interpretation. *Journal of Chemometrics*, 29(10), 528–536. <https://doi.org/10.1002/cem.2736>

- Fonseca, P. J., Amorim, M. C. P., & Vieira, M. (2022). A review of automated bioacoustics and general acoustics classification research. *Sensors*, 22(21), Article 8361. <https://doi.org/10.3390/s22218361>
- Frasier, K. E., Garrison, L. P., Soldevilla, M. S., Wiggins, S. M., & Hildebrand, J. A. (2021). Cetacean distribution models based on visual and passive acoustic data. *Scientific Reports*, 11, Article 8240. <https://doi.org/10.1038/s41598-021-87577-1>
- Haver, S. M., Gedamke, J., Hatch, L. T., Dziak, R. P., Van Parijs, S., McKenna, M. F., Barlow, J., Berchok, C., DiDonato, E., Hanson, B., Haxel, J., Holt, M., Lipski, D., Matsumoto, H., Meinig, C., Mellinger, D. K., Moore, S. E., Oleson, E. M., Soldevilla, M. S., & Klinck, H. (2018). Monitoring long-term soundscape trends in U.S. waters: The NOAA/NPS Ocean Noise Reference Station Network. *Marine Policy*, 90, 6–13. <https://doi.org/10.1016/j.marpol.2017.12.001>
- Ibrahim, A. K., Zhuang, H., Chérubin, L. M., Schärer-Umpierre, M. T., & Erdol, N. (2018). Automatic classification of grouper species by their sounds using deep neural networks. *The Journal of the Acoustical Society of America*, 144(3), EL196–EL202. <https://doi.org/10.1121/1.5054911>
- Ibrahim, A. K., Zhuang, H., Schärer-Umpierre, M., Woodward, C., Erdol, N., & Chérubin, L. M. (2024). Fish acoustic detection algorithm research: A deep learning app for Caribbean grouper calls detection and call types classification. *Frontiers in Marine Science*, 11, Article 1378159. <https://doi.org/10.3389/fmars.2024.1378159>
- International Maritime Organization [IMO]. (2014). *Guidelines for the reduction of underwater noise from commercial shipping to address adverse impacts on marine life* (MEPC.1/Circ.833). <https://wwwcdn.imo.org/localresources/en/MediaCentre/HotTopics/Documents/833.pdf>
- International Maritime Organization [IMO]. (2023). *2023 guidelines for the reduction of underwater radiated noise from shipping* (MEPC.1/Circ.906). <https://wwwcdn.imo.org/localresources/en/MediaCentre/HotTopics/Documents/MEPC.1-Circ.906.pdf>
- Laplante, J.-F., Akhloufi, M. A., & Gervaise, C. (2022). Deep learning for marine bioacoustics and fish classification using underwater sounds. En *Proceedings of the OCEANS 2022 Hampton Roads Conference*. IEEE. <https://doi.org/10.1109/OCEANS47191.2022.9918242>
- Ministerio Secretaría General de la República. (1994). *Ley N° 19.300: Ley sobre bases generales del medio ambiente*. Biblioteca del Congreso Nacional de Chile. <https://www.bcn.cl/leychile/navegar?idNorma=30667>
- Malfante, M., Dalla Mura, M., Mars, J. I., & Gervaise, C. (2018). Automatic fish sounds classification. *The Journal of the Acoustical Society of America*, 143(5), 2834–2846. <https://doi.org/10.1121/1.5034169>
- McKenna, M. F., Baumann-Pickering, S., Kok, A. C. M., Oestreich, W. K., Adams, J. D., Barkowski, J., Frstrup, K. M., Goldbogen, J. A., Joseph, J., Kim, E. B., Kügler, A., Lammers, M.

- O., Margolina, T., Peavey Reeves, L. E., Rowell, T. J., Stanley, J. A., Stimpert, A. K., Zang, E. J., Southall, B. L., Wall, C. C., ... Hatch, L. T. (2021). Advancing the interpretation of shallow water marine soundscapes. *Frontiers in Marine Science*, 8, Article 719258. <https://doi.org/10.3389/fmars.2021.719258>
- Merchant, N. D., Farina, A., & Mellinger, D. K. (2022). State of play in marine soundscape assessments. *Frontiers in Marine Science*, 9, Article 919418. <https://doi.org/10.3389/fmars.2022.919418>
 - Ministerio del Medio Ambiente [MMA]. (2022). *Ruido submarino*. <https://ruido.mma.gob.cl/ruido-submarino/>
 - Mouy, X., Archer, S. K., Dosso, S., Dudas, S., English, P., Foord, C., Halliday, W., Juanes, F., Lancaster, D., Van Parijs, S., & Haggarty, D. (2024). Automatic detection of unidentified fish sounds: A comparison of traditional machine learning with deep learning. *Frontiers in Remote Sensing*, 5, Article 1439995. <https://doi.org/10.3389/frsen.2024.1439995>
 - Naciones Unidas. (1982). *Convención de las Naciones Unidas sobre el Derecho del Mar (UNCLOS)*. https://www.un.org/depts/los/convention_agreements/texts/unclos/convemar_es.pdf
 - Pijanowski, B. C., Villanueva-Rivera, L. J., Dumyahn, S. L., Farina, A., Krause, B. L., Napoletano, B. M., Gage, S. H., & Pieretti, N. (2011). Soundscape ecology: The science of sound in the landscape. *BioScience*, 61(3), 203–216. <https://doi.org/10.1525/bio.2011.61.3.6>
 - Popper, A. N., & Hawkins, A. D. (2019). An overview of fish bioacoustics and the impacts of anthropogenic sounds on fishes. *Journal of Fish Biology*, 94(5), 692–713. <https://doi.org/10.1111/jfb.13948>
 - Rabiner, L., & Schafer, R. (2007). Introduction to digital speech processing. *Foundations and Trends® in Signal Processing*, 1(1–2), 1–194. <https://doi.org/10.1561/20000000003>
 - Radford, C. A., Stanley, J. A., Tindle, C. T., Montgomery, J. C., & Jeffs, A. G. (2010). Localised coastal habitats have distinct underwater sound signatures. *Marine Ecology Progress Series*, 401, 21–29. <https://doi.org/10.3354/meps08451>
 - Sattar, F., Cullis-Suzuki, S., & Jin, F. (2016). Acoustic analysis of big ocean data to monitor fish sounds. *Ecological Informatics*, 34, 102–107. <https://doi.org/10.1016/j.ecoinf.2016.05.002>
 - Servicio de Evaluación Ambiental [SEA]. (2022). *Criterio de evaluación en el SEIA: Predicción y evaluación de impactos por ruido submarino*. https://www.sea.gob.cl/sites/default/files/imce/archivos/2022/08/31/dt_ruido_submarino.pdf
 - Sousa, C., Fonseca, P. J., Amorim, M. C. P., & Vieira, M. (2024). Long-term passive acoustic monitoring to support adaptive fisheries management: A case study on meagre (*Argyrosomus regius*). *Reviews in Fish Biology and Fisheries*, 34, 115–133. <https://doi.org/10.1007/s11160-023-09825-z>

- Zölzer, U. (2008). *Digital audio signal processing* (2.^a ed.). Wiley.
<https://doi.org/10.1002/9780470680018>