



Universidad de Concepción  
Dirección de Postgrado  
Facultad de Ciencias Naturales y Oceanográficas

Programa de Doctorado en Ciencias con mención en  
Manejo de Recursos Acuáticos Renovables

**PRONÓSTICO DE CORTO PLAZO DE ZONAS DE PESCA DE  
ANCHOVETA (*Engraulis ringens*) EN EL NORTE DE CHILE**

Tesis para optar al grado de Doctor en Ciencias con mención en  
Manejo de Recursos Acuáticos Renovables

ELIER ARMAS LORENZO

CONCEPCIÓN-CHILE

2024

Profesor Guía: Dr. Sergio Neira  
Depto. de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas  
Universidad de Concepción

La presente Tesis fue realizada en el Departamento de Oceanografía de la Facultad de Ciencias Naturales y Oceanográficas de la Universidad de Concepción, y ha sido aprobada por la siguiente Comisión Evaluadora:

Profesor Guía:

---

Dr. Sergio Neira  
Departamento de Oceanografía  
Universidad de Concepción

Comisión evaluadora:

---

Dr. Luis Cubillos  
Departamento de Oceanografía  
Universidad de Concepción

---

Dr. Leonardo Castro  
Departamento de Oceanografía  
Universidad de Concepción

---

Dr. Hugo Arancibia

---

Dr. Francisco Arreguín-Sánchez  
Instituto Politécnico Nacional,  
Centro Interdisciplinario de  
Ciencias Marinas (CICIMAR)

*Dedicada a mi madre*

## AGRADECIMIENTOS

Con profundo respeto y gratitud deseo expresar mi reconocimiento a las instituciones y personas que han sido fundamentales en el desarrollo de esta tesis doctoral.

Mi gratitud más sincera se extiende al programa **Doctorado en Ciencias con Mención en Manejo de Recursos Acuáticos Renovables (MaReA)** y a todo su cuerpo académico por la formación recibida. Su excelencia académica y compromiso con la investigación han sido pilares fundamentales en mi desarrollo como investigador.

Agradezco especialmente al Programa **Pai/Concurso Nacional Tesis de Doctorado en el Sector Productivo**, de la Agencia Nacional de Investigación, por su apoyo financiero, el cual ha sido esencial en la materialización de esta investigación.

A la **Dirección de Postgrado de la Universidad de Concepción**, mi gratitud más sincera por el respaldo financiero otorgado durante mi paso por el programa de doctorado.

Agradezco al **Centro de Investigación Aplicada del Mar y Corpesca S.A.** por facilitarme los datos, las instalaciones y la experiencia científica, elementos esenciales para la realización exitosa de esta investigación.

Al programa **E.U. Copernicus Marine Service Information**, por poner a disposición de la comunidad científica datos oceanográficos validados y de calidad de forma gratuita, sin los cuales no se hubiera podido realizar esta tesis.

Deseo expresar mi gratitud al Centro COPAS Coastal ANID FB210021 por su apoyo económico en la publicación de mi primer manuscrito de tesis.

A mi tutor y amigo, **Dr. Hugo Arancibia**, por la idea original de esta tesis y sus significativos aportes tanto en la tesis como es las publicaciones derivadas de la misma. Por haber confiado en mí y haberme apoyado y

aconsejado tanto académica como personalmente en innumerables oportunidades.

A mi tutor, **Dr. Sergio Neira**, por su orientación experta, apoyo continuo y oportunos consejos a lo largo de este exigente, pero gratificante proceso académico. Por sus significativos aportes en la tesis y las publicaciones derivadas de la misma.

A **María Carla Marín**, compañera de vida y coautora del segundo manuscrito por sus significativos aportes a esta tesis, así como por su apoyo incondicional durante toda mi carrera y por ser mi soporte en los momentos más difíciles.

A la comisión evaluadora de esta tesis, integrada por los doctores Sergio Neira, Hugo Arancibia, Francisco Arreguín-Sánchez, Luis Cubillos y Leonardo Castro.

A mis compañeros de este Programa de Doctorado, representados por Antonio Casuso, Daniela Yepsen, Mónica Barros y Lilian Cisterna, quienes estuvieron siempre dispuestos a ayudarme y brindarme su apoyo y consejos durante esta difícil etapa.

A todos mis compañeros de trabajo del Centro de Investigación Aplicada del Mar de Iquique, a donde me incorporé a laborar un par de años atrás.

A mi familia, mamá, Alberto y tía Elvira, quienes han estado conmigo apoyándome, alentándome y educándome en cada etapa de mi vida.

Este logro trascendental para mí no habría sido posible sin el apoyo generoso de cada una de las instituciones y personas mencionadas. Mi más sincero agradecimiento por su valiosa contribución en esta crucial etapa de mi trayectoria académica.

## TABLA DE CONTENIDOS

INDICE DE FIGURAS.....	vii
INDICE DE TABLAS .....	viii
RESUMEN.....	ix
ABSTRACT.....	xii
1 INTRODUCCIÓN.....	1
1.1 Características de <i>E. ringens</i> en el norte de Chile.....	1
1.2 Relación ambiente–recurso. Variables oceanográficas que determinan en la distribución espacio – temporal de <i>E. ringens</i> .....	2
1.3 Pesquería de <i>E. ringens</i> del norte de Chile.....	2
1.4 Disminución de los desembarques de <i>E. ringens</i> en el norte de Chile durante eventos ENSO .....	4
1.5 Necesidad de pronosticar zonas potenciales de pesca de <i>E. ringens</i> en el norte de Chile.....	5
1.6 Identificación de zonas potenciales de pesca, antecedentes.....	7
1.7 Redes neuronales para la identificación de zonas potenciales de pesca.....	7
1.8 Objetivo de investigación y novedad científica .....	8
1.9 Preguntas de investigación .....	8
2 HIPÓTESIS .....	9
3 OBJETIVOS .....	10
3.1 Objetivo General .....	10
3.2 Objetivos Específicos .....	10
4 Estructura de la Tesis.....	11
5 RESULTADOS .....	12
5.1 Capítulo 1: Análisis de la asociación entre la distribución espacial de <i>E. ringens</i> y variables oceanográficas para el pronóstico de zonas de pesca .....	12
5.1.1 Introducción .....	12
5.1.2 Fuentes de datos pesqueros y variable objetivo .....	14
5.1.3 Fuentes de datos oceanográficos y variables predictoras.....	14
5.1.4 Construcción de la base de datos .....	17
5.1.5 Selección de variables para ser consideradas en la modelación .....	21
5.1.6 El enfoque de redes neuronales.....	22
5.1.7 Conclusión .....	24

5.2	Capítulo 2: Identification and Forecast of Potential Fishing Grounds for Anchovy ( <i>Engraulis ringens</i> ) in Northern Chile Using Neural Networks Modeling ..	25
5.3	Capítulo 3: Neural networks approach for detecting spatial changes in catch probability of <i>Engraulis ringens</i> during ENSO events in Northern Chile .....	36
6	DISCUSIÓN .....	48
7	CONCLUSIONES .....	55
8	REFERENCIAS BIBLIOGRÁFICAS .....	56

## INDICE DE FIGURAS

<b>Figura 1.</b> Stock de anchoveta ( <i>Engraulis ringens</i> ) distribuido desde el sur de Perú al norte de Chile (16°–27° S). El panel de la izquierda indica la distribución de <i>E. ringens</i> en el norte de Chile, siendo ésta el área de estudio cubierta por el modelo de redes neuronales de esta tesis. ....	3
<b>Figura 2.</b> Desembarques (a), captura por viaje (b), captura por lance(c), captura por distancia navegada medida como cantidad de zonas de 3x3 mn <sup>2</sup> recorridas por la flota de Corpesca S.A en el período 2003-2020 (d). Fuente de información: Corpesca S.A. Las etiquetas en los puntos representan la diferencia porcentual con respecto a la media histórica. ....	6
<b>Figura 3:</b> Diferencias en la resolución espacial de los datos satelitales disponibles en la base de datos Corpesca entre los años 2005 y 2020. ....	16
<b>Figura 4:</b> Resolución espacial de los datos de Copernicus (1/12°= 5mn <sup>2</sup> , puntos rojos) y resolución espacial de la data pesquera (3x3 mn <sup>2</sup> , cruces negras).....	18
<b>Figura 5.</b> Matriz de correlación de Spearman entre todas las variables disponibles en la base de datos creada para el entrenamiento del modelo de pronóstico de zonas de pesca de <i>E. ringens</i> . Nomenclatura: lat = latitud, lon = longitud, sst = temperatura superficial del mar, so = salinidad, mlotst = profundidad de la capa de mezcla, zos = altura del mar, uo = componente zonal de la velocidad de las corrientes, vo = componente meridional de la velocidad de las corrientes. ....	22



## INDICE DE TABLAS

<b>Tabla 1.</b> Análisis estadístico descriptivo de la data correspondiente a las trayectorias de las naves industriales de la empresa pesquera Corpesca en el período 2003-2020. ....	19
<b>Tabla 2.</b> Análisis estadístico descriptivo de la data correspondiente a las capturas de <i>E. ringens</i> por las naves industriales de la empresa pesquera Corpesca en el período 2003-2020.....	20
<b>Tabla 3.</b> Comparación entre la cantidad de observaciones disponibles de la data satelital y la data proveniente de Copernicus para toda la zona de estudio (18°21' S–27° S) en el período 2003-2020. ....	21
<b>Tabla 4:</b> Relevancia de cada variable en la predicción de zonas de pesca de <i>Engraulis ringens</i> en la zona norte de Chile con el modelo de redes neuronales.....	23

## RESUMEN

En esta tesis se pronosticó zonas potenciales de pesca de *E. ringens* en el corto plazo en el norte de Chile, utilizando un modelo de redes neuronales. Se determinaron las variables que explicaron mejor la distribución espacial de *E. ringens*, y se las utilizó para entrenar el modelo de redes neuronales. Luego se estudió el impacto de la utilización de los pronósticos de zonas de pesca de *E. ringens* en la eficiencia de la flota cerquera anchovetera industrial del norte de Chile.

*E. ringens* (anchoveta) es una especie de pez pelágico pequeño perteneciente a la familia *Engraulidae*, que habita en la zona nerítico-costera y se distribuye desde el norte de Perú (3°N) hasta la isla de Chiloé en el sur de Chile (43°S). La distribución geográfica y batimétrica de esta especie está condicionada por fluctuaciones en las condiciones oceanográficas a diferentes escalas temporales (diaria, semanal, mensual, anual, supra-anual) y por la pesca. En el norte de Chile, *E. ringens* es un recurso pesquero de gran importancia y es capturado principalmente por el sector industrial, que representa hasta el 80% de los desembarques totales anuales de la flota de cerco. La historia de esta pesquería (1985-2023) muestra una fuerte disminución en los desembarques industriales anuales, especialmente durante eventos extremos del fenómeno El Niño Oscilación del Sur (1997–1998 (muy intenso), 2002–2003 (moderado) y 2015–2016 (muy intenso)). Las mayores caídas en los desembarques en las últimas dos décadas ocurrieron en 2015 (El Niño) y 2020 (La Niña), disminuyendo 65% y 88% en relación a la media histórica, respectivamente.

Dada la disminución de los desembarques de *E. ringens* en el norte de Chile durante eventos ENSO, principalmente durante El Niño 2015 y La Niña 2020, las flotas pesqueras deben destinar mayor esfuerzo pesquero para la localización de los cardúmenes de *E. ringens* que sean accesibles a las artes de pesca. Se ha observado una disminución de la captura con relación al esfuerzo de pesca ejercido en años con condiciones típicas de eventos ENSO. La captura por viaje disminuyó con respecto a la media histórica entre 9% y 33% durante el período 2006-2010, caracterizado por condiciones frías típicas de La Niña; también la captura disminuyó 12% durante el evento El Niño 2015 y 46% durante La Niña 2020. También la captura por lance decreció entre 5% y 13% durante el período 2006-2010 y 40% durante La Niña 2020. La captura con respecto a la distancia recorrida por las naves cerqueras industriales cayó entre 13% y 40% durante el período 2006-2010, 53% durante el Niño 2015 y 78% durante La Niña 2020. Esto conduce a aumentar el esfuerzo (viajes, lances, distancia recorrida) para mantener los niveles promedio de captura.

Actualmente, el principal problema de la flota industrial cerquera del norte de Chile consiste en encontrar la forma de reducir costos en las operaciones de localización y captura de *E. ringens*, y aumentar así la rentabilidad económica. Para esto se requiere optimizar/reducir los viajes de pesca. Una alternativa interesante de explorar es identificar

zonas potenciales de pesca y, junto con ello, conocer cómo cambia la probabilidad de captura de *E. ringens* en función de la variabilidad oceanográfica incluyendo eventos ENSO, y determinar si esta probabilidad tiene alguna relación con los desembarques anuales de *E. ringens* en el área de estudio. Consecuentemente, esta tesis doctoral se enfoca en estudiar el impacto de la utilización de pronósticos de zonas de pesca de *E. ringens* en la eficiencia de la flota anchovetera del norte de Chile. Las hipótesis planteadas en esta tesis sostienen que si la distribución espacial de *E. ringens* en el norte de Chile está determinada principalmente por variables oceanográficas y estas relaciones son capturadas correctamente por un modelo de redes neuronales, entonces el modelo desarrollado pronosticaría adecuadamente las zonas de pesca de *E. ringens* en el norte de Chile en el corto plazo, permitiendo con su aplicación que aumente el rendimiento de la flota industrial cerquera anchovetera. Los resultados obtenidos en esta investigación se presentan en tres capítulos, los que son descritos brevemente a continuación.

En el primer capítulo se analizó la distribución espacial de *E. ringens* en la zona norte de Chile ( $18^{\circ}21''$  S– $27^{\circ}$  S) y su asociación con variables oceanográficas disponibles para esa zona en el período 2003 a 2020. Como información de presencia de *E. ringens* se utilizaron los datos georreferenciados de capturas de esta especie disponibles en la base de datos de la empresa pesquera Corpesca S.A. Se consideró como registros de ausencia de la especie las zonas donde transitó la flota y no se capturó *E. ringens*. Las variables oceanográficas se obtuvieron del modelo Nemo del programa Copernicus, el cual proporciona datos históricos y datos de pronósticos diarios de variables oceanográficas. Se aplicó un modelo de redes neuronales para abordar la relación entre las variables oceanográficas y la distribución de *E. ringens*, determinando las variables que mejor explican la ubicación de las zonas de pesca de esta especie en el período estudiado. En cuanto al porcentaje de la varianza explicada, la longitud geográfica (23%) fue la variable más relevante para identificar posibles zonas de pesca, seguida de la profundidad de la capa de mezcla (18%), la latitud geográfica (15%), la temperatura superficial del mar (12%), el mes (12%), la altura del mar (9%), la salinidad (9%) y las componentes zonales y meridionales de la velocidad de las corrientes (1% cada una).

En el segundo capítulo de esta tesis se implementó un modelo predictivo de zonas de pesca basado en redes neuronales, el que fue entrenado con datos georreferenciados de capturas diarias de naves cerqueras industriales para el período 2003 a 2020 e información de variables oceanográficas (temperatura superficial del mar, salinidad, profundidad de la capa de mezcla, altura del mar y corrientes) obtenidas de Copernicus (<https://marine.copernicus.eu>). El rendimiento del modelo de redes neuronales fue 86% (AUC), clasificando correctamente el 76% de las áreas con pesca. Por lo tanto, se recomienda su uso para predecir zonas de pesca para *E. ringens* en el área de estudio (zona norte de Chile).

En el tercer capítulo se analizó si la disminución actual en los desembarques anuales de *E. ringens* se asocia con cambios oceanográficos en el norte de Chile durante eventos El Niño o La Niña. Se aplicó el modelo de redes neuronales, desarrollado en el segundo

capítulo de esta tesis, para identificar la distribución espacial y temporal de las probabilidades de pesca de *E. ringens*, particularmente para los años El Niño (2015), La Niña (2007, 2013, 2020) y Neutro (2004). Se encontró que la probabilidad de captura de *E. ringens* se extendió más hacia el oeste durante eventos de La Niña (excepto en 2020), ocupando un área más grande, pero se limitó a una franja costera de 10 millas náuticas durante el evento de El Niño 2015. Las mayores probabilidades de captura en la condición Neutra estuvieron cerca de la costa, aunque no tan restringida a la misma como ocurrió durante el evento de El Niño 2015. Las probabilidades de captura más altas en el evento La Niña de 2020 también estuvieron cerca de la costa, en contraste con los eventos anteriores de 2007 y 2013, debido a la restricción del hábitat óptimo de *E. ringens* por cambios en las condiciones oceanográficas. La cantidad anual de zonas potenciales de pesca identificadas por el modelo de redes neuronales es un indicador de qué tan apto es el ambiente para el encuentro de cardúmenes de *E. ringens*. La aplicación de estos resultados permitiría administrar de mejor forma la flota pesquera industrial, reduciendo los costos operacionales.

Los resultados obtenidos en esta tesis sustentan las hipótesis planteadas, pues el modelo de redes neuronales implementado permitió pronosticar correctamente zonas de pesca de *E. ringens* en el corto plazo (hasta 3 días). El modelo de redes neuronales implementado fue capaz de replicar la distribución espacial de *E. ringens* observada durante eventos ENSO. Simulaciones mostraron que el uso de los pronósticos de pesca del modelo de redes neuronales en la operación de la flota habría resultado en disminución del esfuerzo y aumento del rendimiento de la flota. La aplicación de los resultados de este estudio aporta a entender y, probablemente, anticipar las consecuencias que eventos ENSO extremos podrían tener en el rendimiento de las naves cerqueras pertenecientes a la flota anchovetera industrial del norte de Chile. El modelo de redes neuronales utilizado proporciona una herramienta valiosa para la gestión de dicha flota.

## ABSTRACT

This doctoral thesis is focused on short-term forecasting of potential fishing zones for *E. ringens* in northern Chile using a neural network model. The variables most associated with the spatial distribution of *E. ringens* were determined and utilized to train the neural network model. Additionally, the impact of forecasting *E. ringens* fishing zones on the efficiency of the northern Chilean anchovy fleet was studied.

*Engraulis ringens* (anchovy) is a small pelagic fish species belonging to the *Engraulidae* family, inhabiting the neritic-coastal zone and ranging from northern Peru (3°N) to Chiloé Island in southern Chile (43°S). Its geographic and bathymetric distribution is influenced by fluctuations in oceanographic conditions at various temporal scales (daily, weekly, monthly, annual, supra-annual) and by fishing activities. In northern Chile, *E. ringens* is a key industrial fishing resource, representing up to 80% of annual landings by the purse seine fleet. The fishery's history (1985-2023) shows a significant decline in annual industrial landings, especially during extreme El Niño-Southern Oscillation (ENSO) events (1997–1998 (very intense), 2002–2003 (moderate), and 2015–2016 (very intense)). The most substantial declines in landings over the last two decades occurred in 2015 (El Niño) and 2020 (La Niña), decreasing by 65% and 88%, respectively, below the historical average.

Given the decline in *E. ringens* landings in northern Chile during ENSO events, particularly during El Niño 2015 (65% below historical average) and La Niña 2020 (88% below historical average), fishing fleets must allocate more effort to locate *E. ringens* schools accessible to fishing gear. This has resulted in a decrease in catch relative to the fishing effort exerted on *E. ringens* during typical ENSO events. Catch per trip decreased between 9% to 33% during the 2006-2010 period, characterized by La Niña-like cold conditions, 12% during El Niño 2015, and 46% during La Niña 2020. Catch per fishing set also decreased between 5% to 13% during the 2006-2010 period and 40% during La Niña 2020. Catch relative to the distance traveled by industrial vessels declined between 13% to 40% during the 2006-2010 period, 53% during El Niño 2015, and 78% during La Niña 2020. This implies the need to increase effort (trips, sets, distance traveled) to maintain average catch levels.

Currently, the primary challenge for the northern Chilean purse seine fleet is to find ways to reduce costs in locating and catching *E. ringens*, thereby increasing economic profitability. This necessitates optimizing/reducing fishing trips. An interesting alternative to explore is to identify potential fishing zones and to understand how the probability of *E. ringens* catch changes under oceanographic variability and during ENSO events, and to determine whether this probability is related to annual landings of *E. ringens* in the study area. In this context, this doctoral thesis is focused on studying the impact of using *E. ringens* fishing zone forecasts on the efficiency of the industrial fleet in northern Chilean. The hypotheses of this thesis indicates that if the spatial distribution of *E. ringens*

in northern Chile is primarily determined by oceanographic variables, and these relationships are accurately captured by a neural network model, then the developed model will appropriately forecast *E. ringens* fishing zones in the short term, increasing the performance of the purse seine anchovy fleet. The research results are presented in three chapters briefly described below.

In the first chapter, the spatial distribution of *E. ringens* in northern Chile (18°21' S–27° S) is analyzed, along with its association with available oceanographic variables for the study area for the period 2003 to 2020. Georeferenced catch data for this species, obtained from a database built by Corpesca S.A. Fishing Company, were used to approximate *E. ringens* distribution. Areas where the fleet transited without capturing *E. ringens* were considered absence records. Oceanographic variables were obtained from the Copernicus program's Nemo model, providing historical and daily forecast data. A neural network model was applied to address the relationship between oceanographic variables and the distribution of *E. ringens*, determining the variables that best explained the location of fishing zones for this species during the study period. In terms of the explained variance percentage, geographical longitude (23%) was the most relevant variable for identifying potential fishing zones, followed by the depth of the mixing layer (18%), geographical latitude (15%), sea surface temperature (12%), month (12%), sea level (9%), salinity (9%), and zonal and meridional components of current velocity (1% each).

In the second chapter, a predictive model of fishing zones based on neural networks is implemented, trained with georeferenced daily catches from industrial purse seine vessels from 2003 to 2020, along with oceanographic variables (sea surface temperature, salinity, mixing layer depth, sea level, and currents), obtained from Copernicus (<https://marine.copernicus.eu>). The neural network model achieved 86% performance, and correctly classifying the most of areas with and without fishing. Therefore, its use is recommended for predicting fishing zones for *E. ringens* in the study area.

In the third chapter, the thesis analyzes whether the current decline in annual *E. ringens* landings is associated with oceanographic changes in northern Chile during El Niño or La Niña events. The neural network model developed in the second chapter is applied to identify the spatial and temporal distribution of *E. ringens* fishing probabilities, particularly for El Niño (2015), La Niña (2007, 2013, 2020), and Neutral (2004) years. It was found that the probability of *E. ringens* catch extended further west during La Niña events (except in 2020), covering a larger area that is, however, limited to a coastal strip of 10 nautical miles during the El Niño 2015 event. The highest catch probabilities in Neutral conditions are near the coast, although not as restricted as during the El Niño 2015 event. The highest catch probabilities in the La Niña event of 2020 are near the coast, in contrast to the previous events of 2007 and 2013, due to the restriction of the optimal habitat of *E. ringens* by changes in oceanographic conditions. The annual quantity of potential fishing zones identified by the neural network model is an indicator of the environment's suitability for encountering *E. ringens* schools. The application of these

results should enable better management of the industrial fishing fleet, reducing operational costs.

The results of this thesis support the hypotheses, as the implemented neural network model successfully forecasted short-term fishing zones for *E. ringens*. The implemented neural network model was able to replicate the spatial distribution of *E. ringens* observed during ENSO events. Simulations showed that using the fishing forecasts from the neural network model in fleet operations would have resulted in a decrease in effort and an increase in fleet performance. The application of the results of this study will allow understanding, and likely anticipating, the consequences that extreme ENSO events could have on the performance of the northern Chilean anchovy purse seine fleet. The neural network model developed in this study provides a valuable tool for the management of this fleet.

# 1 INTRODUCCIÓN

*Engraulis ringens* (anchoveta) es una especie de pez pelágico de tamaño pequeño de la Familia *Engraulidae*, que habita en el sistema de la Corriente de Humboldt (SCH), donde parece jugar un rol ecológico clave, pues es la principal presa de peces, mamíferos y aves marinas (Medina et al. 2007; Barros et al. 2014). *E. ringens* habita la zona nerítico-costera, principalmente en las primeras millas desde la costa (Silva et al. 2016; Espíndola et al. 2018; Hernández-Santoro et al. 2019) y, debido a su alta productividad y abundancia, *E. ringens* sostiene una importante pesquería en la zona norte de Chile. En este sistema *E. ringens* es capturada tanto por la flota industrial como por la flota artesanal, y la mayor parte de las capturas ocurren dentro de las primeras 10 mn (Silva et al. 2016; Espíndola et al. 2018). En el SCH se identifica tres stocks de *E. ringens*, a saber: la zona norte-centro de Perú (4°-15°S), el stock compartido sur de Perú y el norte de Chile (16°-27°S) y el stock del centro-sur de Chile (34°-40°S). Estos stocks coinciden con los principales subsistemas de surgencia y alta productividad en Chile y Perú (Cubillos et al. 2007; Contreras-Reyes et al. 2016).

## 1.1 Características de *E. ringens* en el norte de Chile

*E. ringens* presenta un ciclo de vida corto con longevidad máxima de cinco años, crecimiento rápido y alta mortalidad natural (Jordán y Chirinos de Vildoso 1965; Aliaga et al. 2001; De La Cruz Barrueto et al. 2021). *E. ringens* se reproduce cíclicamente durante el año, durante el período reproductivo desova permanentemente y las hembras presentan desoves parciales, por lo que resulta difícil determinar los límites del período reproductivo (Oliva y Vilaxa 2016). Sin embargo, se reconoce que en el norte de Chile el desove se extiende desde el invierno hasta el verano (julio-diciembre), con máximos en agosto y en menor intensidad en el resto del año (Castillo et al. 2013; Hernández-Santoro et al. 2013; Contreras et al. 2017). Consecuentemente, el reclutamiento ocurre entre noviembre y febrero, aproximadamente (Castillo et al. 2013).

Entre los principales predadores de *E. ringens* del norte de Chile se encuentran el lobo marino común (*Otaria flavescens*), las aves marinas (Espinoza 2016), el bonito (*Sarda chilensis*), la caballa (*Scomber japonicus*) y el jurel (*Trachurus murphyi*), además de la pesca, la que constituye uno de los factores más importantes de mortalidad (Medina et al. 2007; Barros et al. 2014). En cuanto a hábitos alimentarios, Medina et al. (2015) y Espíndola et al. (2018) encontraron que *E. ringens* se alimenta principalmente de fitoplancton (Leiva et al. 2017), mientras que Medina et al. (2007) y Barros et al. (2014) informan que en la alimentación de *E. ringens* predominan organismos zooplanctónicos como copépodos y eufáusidos.



## **1.2 Relación ambiente–recurso. Variables oceanográficas que determinan en la distribución espacio – temporal de *E. ringens***

La temperatura superficial del mar (TSM) es una de las variables ambientales determinantes para la presencia de *E. ringens* (Silva et al. 2016). El rango de temperatura en el que se distribuye la especie ha sido descrito por diferentes autores. Según Claramunt et al. (2012) y Silva et al. (2012) este rango va desde 12°C hasta 23°C. Aros et al. (2017) encontraron que *E. ringens* se presentó entre 14°C y 18°C con la moda en la isoterma de 16°C. Silva et al. (2016), utilizando una serie de tiempo de 10 años (2001-2010), encontraron que el rango de TSM donde se concentraron las capturas de *E. ringens* fue entre 14,5°C y 23,3°C, destacando que *E. ringens* habita preferentemente en temperaturas bajas, favorecidas por las áreas de surgencia caracterizadas por el afloramiento de aguas frías y ricas en nutrientes (Silva et al. 2016; Espíndola et al. 2018).

La salinidad también parece ser un factor de importancia para *E. ringens*, ya que ésta es una especie estenohalina (susceptible a cambios abruptos de salinidad) (Luján 2016) que soporta valores entre 34,5 y 35,1 unidades prácticas de salinidad (UPS), aproximadamente (Aros et al. 2017; Leiva et al. 2017), constituyendo los valores fuera de estos rangos una limitante en su hábitat (Luján 2016).


Una de las características relevantes frente a las costas de Chile es la presencia de la zona de mínimo oxígeno, ZMO (Paulmier y Ruiz-Pino 2009; Vergara et al. 2016; von Dassow 2017). Las fluctuaciones en la profundidad de esta capa, asociada a la surgencia, pueden restringir el hábitat de diversas especies y, en ocasiones, llegan a atrapar y sofocar poblaciones de peces cerca de la costa debido al déficit de oxígeno (Hernández-Miranda et al. 2010; von Dassow 2017). Aros et al. (2017) informaron que *E. ringens* se presentó entre 3,0 y 8,0 ml L<sup>-1</sup>, con preferencia entre 5,0 y 6,5 ml L<sup>-1</sup>. Leiva et al. (2017) informaron que *E. ringens* registró un rango preferencial de 0,36 a 4,59 ml L<sup>-1</sup>, evidenciando que esta especie pelágica puede sobrevivir a bajas concentraciones de oxígeno disuelto (Jordán y Chirinos de Vildoso 1965; Luján 2016).

## **1.3 Pesquería de *E. ringens* del norte de Chile**

La pesquería industrial de *E. ringens* en el norte de Chile, comprendida entre 18°21' S y 27° S (Figura 1, panel izquierdo), es una de las principales actividades económicas en esa zona del país. Esta especie constituye el 80% de la captura anual de la flota de cerco industrial y es capturada solo con este arte de pesca (Böhm et al. 2017; Armas et al. 2022). Esta pesquería se inicia en 1960 para la producción de harina y aceite de pescado. En 1970 disminuyó la abundancia de *E. ringens*, recuperándose nuevamente en 1985 (Plaza et al. 2017). Los desembarques históricos presentaron tendencia decreciente, desde 2 millones de toneladas, desembarcadas en 1994, hasta 240 mil toneladas desembarcadas en 2016 (Böhm et al. 2017). Esta pesquería es regulada mediante cuotas totales permisibles (TAC) y la regla administrativa es la captura máxima por armador (MCSO) (Ministerio De

Economía 2001, 2002), lo cual estimula a las empresas participantes a regular el esfuerzo pesquero para reducir costos operacionales y obtener mejores rendimientos (Asche et al. 2008). En el año 2022, el estatus de la pesquería de *E. ringens* de la zona norte de Chile fue de sub-explotación y la Cuota Global Anual de Captura (CGAC) para el sector industrial fue establecida en 623.028 toneladas (“Dec. Ex. N° 52-2022” 2022).

La flota industrial de cerco del norte de Chile está conformada por las compañías Corpesca S.A. y Camanchaca, cuyas naves capturan el 85% de la TAC. El 15% restante corresponde a las capturas de la flota artesanal de cerco (“Dec. Ex. N° 22-2022” 2022). La mayor participación en la pesquería de *E. ringens* en el norte de Chile la tiene Corpesca S.A. con el 70% de las naves industriales y el 80% del TAC (“Memoria Camanchaca” 2021, “Memoria Corpesca” 2021, “Dec. Ex. N° 52-2022” 2022; Armas et al. 2022).



**Figura 1.** Stock de anchoveta (*Engraulis ringens*) distribuido desde el sur de Perú al norte de Chile (16°–27° S). El panel de la izquierda indica la distribución de *E. ringens* en el norte de Chile, siendo ésta el área de estudio cubierta por el modelo de redes neuronales de esta tesis.

#### 1.4 Disminución de los desembarques de *E. ringens* en el norte de Chile durante eventos ENSO

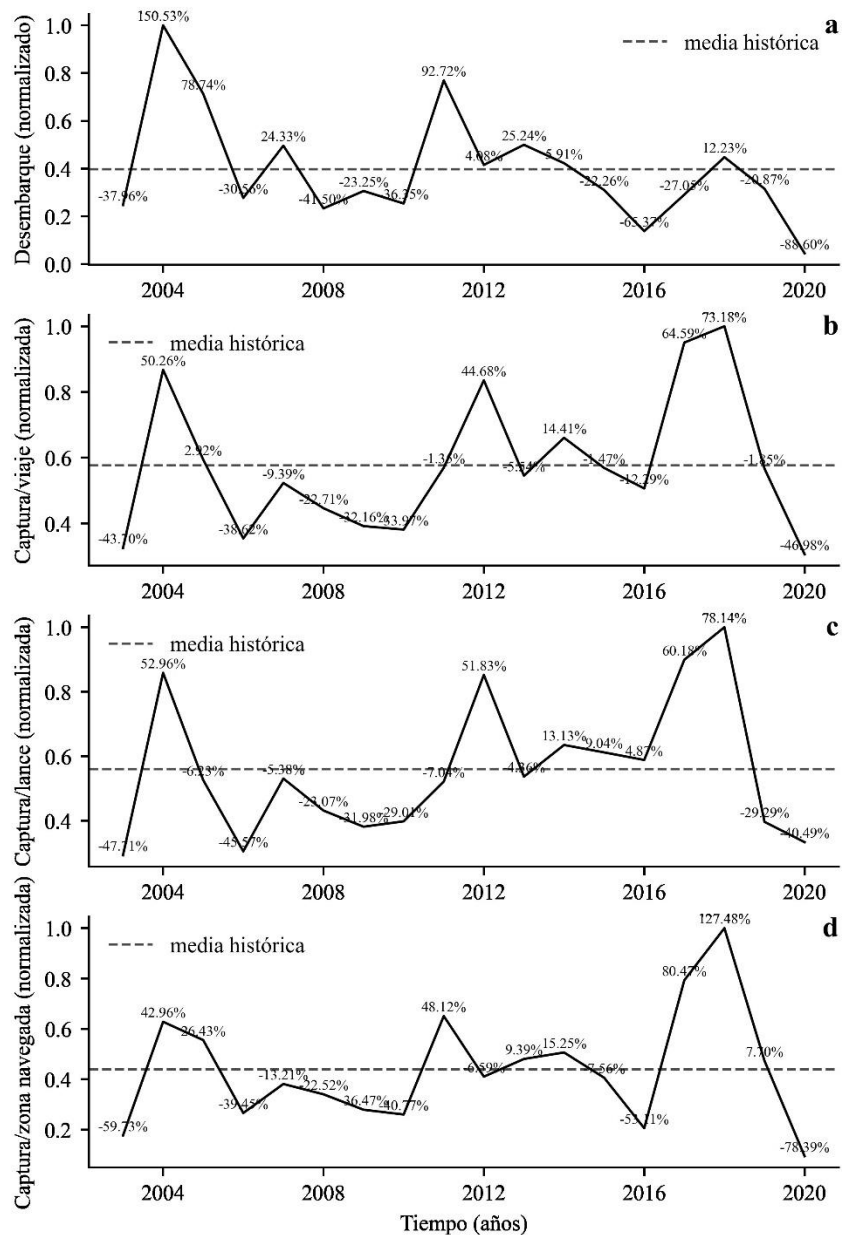
A escala interanual, el forzante oceánico más significativo es El Niño Oscilación del Sur (ENOS) (Espíndola et al. 2018). Este evento se compone de una fase cálida (positiva), la cual se produce por un debilitamiento de los vientos alisios en el Océano Pacífico ecuatorial, provocando el calentamiento anómalo del mar en esta región, y una fase fría (negativa) caracterizada por el aumento de la intensidad de los vientos alisios, lo que trae como consecuencia la disminución de la temperatura superficial del mar (Maturana et al. 2004; Wang et al. 2016; Hernández-Santoro et al. 2019). Los eventos ENSO originan fuertes cambios en las condiciones oceanográficas, llegando a afectar la distribución, biomasa y procesos biológicos de especies de peces pelágicos como *E. ringens* (Ñiquen y Bouchon 2004; Bouchon et al. 2015). Durante la fase positiva del ENSO, las fluctuaciones de los vientos alisios generan ondas Kelvin que se desplazan hacia las costas sudamericanas; una parte de estas ondas se refleja en forma de ondas de Rossby y la otra parte se propaga hacia los polos en forma de ondas atrapadas a la costa, llegando a las costas chilenas y desempeñando un papel clave en la variabilidad de la temperatura superficial del mar (Hormazabal et al. 2002). Estas ondas modifican la profundidad tanto de la termoclina como de la oxiclina y la nutriclina, comprimiendo o expandiendo el hábitat de *E. ringens* y modulando su distribución espacial (Parada et al. 2013). Durante eventos cálidos ENOS la surgencia costera disminuye, profundizándose la capa mínima de oxígeno (Cahuin et al. 2015). Como resultado se incrementa la captura de *E. ringens* debido a la aproximación de cardúmenes de esta especie a las zonas costeras. Sin embargo, luego disminuyen las capturas de *E. ringens* debido a la profundización de sus cardúmenes (Böhm et al. 2017). Durante eventos fríos (La Niña) se intensifican los procesos de surgencia costera, cuyas temperaturas y contenido de nutrientes condicionan favorablemente el ambiente marino fuera de la costa, expandiendo el área de distribución de *E. ringens* al oeste hasta más allá de 180 millas náuticas (Gutiérrez et al. 2007; Bouchon y Peña 2008). Durante estos eventos fríos los cardúmenes de *E. ringens* se encuentran más dispersos, incluso si existiera mayor biomasa (Gutiérrez et al. 2007).

Los desembarques totales anuales de *E. ringens* por la flota de cerco del sur de Perú y norte de Chile disminuyen considerablemente en períodos El Niño, como en 1997–1998 (muy intenso), 2002–2003 (moderado) y 2015–2016 (muy intenso) (Böhm et al. 2017; Armas et al. 2022). En el año 2020 la National Oceanic and Atmospheric Administration (NOAA) declaró un evento La Niña que comenzó a observarse desde el trimestre julio-septiembre con anomalías de  $-0,5^{\circ}\text{C}$  bajo la media histórica (“October 2020 La Niña update | NOAA Climate.gov” 2020, “Climate Prediction Center - ONI” 2022), el que se extendió hasta diciembre del año 2022. Particularmente en el norte de Chile durante el año 2020 los desembarques industriales de *E. ringens* fueron menores a lo esperado, siendo los más bajos desde el año 2003 (Figura 2).

## 1.5 Necesidad de pronosticar zonas potenciales de pesca de *E. ringens* en el norte de Chile

Dada la disminución de los desembarques de *E. ringens* en el norte de Chile durante eventos ENSO, principalmente durante El Niño 2015 (65% por debajo de la media histórica) y La Niña 2020 (88% por debajo de la media histórica) (Figura 2a), las flotas pesqueras deben destinar mayor esfuerzo pesquero para la localización de los cardúmenes de *E. ringens* que sean accesibles a las artes de pesca (Bertrand et al. 2008; Joo et al. 2014). Así se ha observado una disminución de la captura con relación al esfuerzo de pesca ejercido sobre *E. ringens* en años con condiciones típicas de eventos ENSO (Figura 2). La captura por viaje disminuyó con respecto a la media histórica entre 9% y 33% durante el período 2006-2010, caracterizado por condiciones frías típicas de La Niña, y también las capturas disminuyeron a 12% durante el Niño 2015 y 46% durante La Niña 2020 (Figura 2b). También la captura por lance decreció entre 5% y 13% durante el período 2006-2010 y 40% durante La Niña 2020 (Figura 2c). La captura por zona navegada es una aproximación de la captura con respecto a la distancia recorrida por las naves industriales. Esta variable cayó entre 13% y 40% durante el período 2006-2010, 53% durante el Niño 2015 y 78% durante La Niña 2020 (Figura 2d). Esto implica tener que aumentar el esfuerzo (viajes, lances, distancia recorrida) para mantener los niveles promedio de captura (Figura 2). Actualmente, el principal problema de la empresa pesquera Corpesca S.A. consiste en reducir costos operacionales en la localización y captura de *E. ringens* para mejorar la rentabilidad económica (Carlos Merino, Gerente Zonal Iquique de Corpesca, comunicación personal; email: [cmerino@corpesca.cl](mailto:cmerino@corpesca.cl)).

Para disminuir el esfuerzo pesquero y reducir costos operacionales en la localización y captura de *E. ringens* se requiere optimizar/reducir los viajes de pesca. Una alternativa interesante de explorar es identificar zonas potenciales de pesca de *E. ringens*, análogamente a lo reportado por Nammalwar et al. (2013) para las capturas de la sardina *Sardinella gibbosa* y otras especies en North Tamil Nadu, India; y por Wang et al. (2015), donde se utiliza una red neuronal para determinar zonas potenciales de pesca del calamar *Ommastrephes bartramii* frente a las costas de Japón. Además, es interesante reconocer cómo cambia la probabilidad de captura de esta especie en relación a la variabilidad oceanográfica (incluida aquella asociada a eventos ENSO), así como determinar si esta probabilidad tiene alguna relación con los desembarques anuales de *E. ringens*.



**Figura 2.** Desembarques (a), captura por viaje (b), captura por lance(c), captura por distancia navegada medida como cantidad de zonas de 3x3 mn<sup>2</sup> recorridas por la flota de Corpesca S.A en el período 2003-2020 (d). Fuente de información: Corpesca S.A. Las etiquetas en los puntos representan la diferencia porcentual con respecto a la media histórica.

## **1.6 Identificación de zonas potenciales de pesca, antecedentes**

A nivel global varios autores han realizado estudios para determinar zonas potenciales de pesca varios recursos pesqueros marinos. En efecto, Jagannathan et al. (2012), Wang et al. (2015), Fitriyah et al. (2016a, 2016b) y Mane and Mishra (2017) han utilizado como variables predictoras de probabilidad de pesca algunas variables ambientales obtenidas a partir de sensores satelitales como TSM, clorofila-a, altura del nivel del mar, y viento. Los modelos y algoritmos de clasificación de zonas potenciales de pesca han alcanzado niveles de acierto entre 80% a 85% (Solanki et al. 2010; Wang et al. 2015).

Silva et al. (2016) utilizaron variables satelitales y datos de captura para calcular un índice de idoneidad del hábitat de *E. ringens* en el norte de Chile y, mediante sistemas de información geográfica, simularon cambios mensuales de la idoneidad del hábitat para escenarios climáticos decadales futuros. Nieto et al., (2001), Silva et al., (2002), Yáñez et al., (2004) y Silva et al., (2012b) identificaron zonas probables de pesca de *E. ringens* a partir de información satelital de variables oceanográficas tales como temperatura superficial del mar, gradientes térmicos y concentración de clorofila.

Esas investigaciones vincularon variables ambientales con la distribución y abundancia de algunas especies marinas, incluida *E. ringens*, utilizando datos satelitales que proporcionan una instantánea del estado de la atmósfera, pero no predicen el estado futuro. Por ello los pronósticos realizados a partir de ese tipo de datos no son tan precisos, lo que se debe a que la situación atmosférica y oceanográfica puede variar a escala diaria, alterando la dinámica y el comportamiento de las especies marinas en la zona de estudio. En el caso de investigaciones realizadas en Chile sobre el tema, mayormente se ha pronosticado capturas y desembarques mensuales (Yáñez et al. 2010) o realizado estimaciones para escenarios climáticos futuros (Silva et al. 2016).

## **1.7 Redes neuronales para la identificación de zonas potenciales de pesca**

Las redes neuronales artificiales están inspiradas en el funcionamiento del cerebro humano. Estas redes son capaces de aprender la respuesta a un estímulo (datos de entrada) por repetición (esto se denomina entrenamiento) y, posteriormente, predecir la respuesta utilizando solo los datos de entrada (Suryanarayana et al. 2008; Yáñez et al. 2010). Este tipo de modelos tiene la ventaja que pueden implementarse usando pocos supuestos sobre los datos pesqueros y ambientales (Suryanarayana et al. 2008; Wang et al. 2015), mostrando un desempeño superior a los modelos estadísticos convencionales como son los Modelos Lineales Generalizados (GLM) y los Modelos aditivos Generalizados (GAM) (Tan y Beklioglu 2006; Suryanarayana et al. 2008; Mateo et al. 2011; Wang et al. 2015). Tanto GLM como GAM se implementan suponiendo ciertas características de los datos como linealidad, normalidad y homocedasticidad (Yudaputra et al. 2019). Sin embargo, tales supuestos difícilmente se cumplen en situaciones reales debido a falta de información en zonas no exploradas por la flota, la no linealidad de los procesos ecológicos (Tan y

Beklioglu 2006), y las complejas interacciones ambiente-recurso (Wang et al. 2015). Esto hace a las redes neuronales una alternativa más adecuada para la modelación de procesos complejos y no lineales, tal como la relación ambiente recurso y el pronóstico de zonas potenciales de pesca (Wang et al. 2015).

## **1.8 Objetivo de investigación y novedad científica**

En Chile no se dispone de pronósticos de zonas de pesca probables de *E. ringens* o de otro recurso pesquero marino con los que se pueda gestionar (administrar) de mejor forma a la flota, siendo el propósito reducir el esfuerzo de pesca, por un lado, y mejorar el rendimiento de la flota, por el otro lado. El objetivo general de esta tesis doctoral es estudiar el impacto de la utilización de pronósticos de zonas potenciales de pesca de *E. ringens* en la eficiencia de la flota anchovetera del norte de Chile. Para esto se implementó un modelo de redes neuronales con el que se pronosticó zonas potenciales de pesca de esta especie en el corto plazo (días). La solución que se presenta en esta tesis es innovadora, contribuyendo a resolver un problema de interés de la industria pesquera del norte de Chile, lo que podría permitir la reducción de costos en las operaciones de búsqueda y captura de *E. ringens*.

## **1.9 Preguntas de investigación**

Considerando los antecedentes mencionados, en esta tesis se abordaron las siguientes preguntas de investigación:

- ¿Cuál es el efecto de la variabilidad ambiental en la distribución y eficiencia de la pesquería de *E. ringens* en el norte de Chile?
- ¿Este conocimiento puede ser utilizado para incrementar la eficiencia de la flota cerquera anchovetera del norte de Chile?

## **2 HIPÓTESIS**

Si la distribución espacial de la anchoveta (*Engraulis ringens*) en el norte de Chile está determinada principalmente por variables oceanográficas entonces:

### **Hipótesis 1**

El uso de variables oceanográficas permite predecir zonas probables de pesca de *E. ringens* en el norte de Chile en el corto plazo.

### **Hipótesis 2**

Los pronósticos de zonas probables de pesca basados en variables oceanográficas mejoran el rendimiento de la flota industrial cerquera anchovetera del norte de Chile.



## **3 OBJETIVOS**

### **3.1 Objetivo General**

Demostrar que el conocimiento y pronóstico del efecto de la variabilidad ambiental sobre la distribución espacial de la anchoveta (*Engraulis ringens*) es útil para incrementar significativamente la eficiencia de la flota anchovetera del norte de Chile.

### **3.2 Objetivos Específicos**

1. Analizar la asociación entre la distribución espacial de *E. ringens* (presencia-ausencia) y variables oceanográficas disponibles como la temperatura superficial del mar, salinidad, y altura del nivel del mar, para determinar cuáles de estas variables serán utilizadas en el pronóstico de zonas de pesca.
2. Implementar para el norte de Chile, un modelo de pronóstico en el corto plazo de zonas de pesca de *E. ringens* basado en variables oceanográficas.
3. Evaluar el impacto de los pronósticos del modelo en la eficiencia de la flota industrial cerquera anchovetera del norte de Chile.

## 4 Estructura de la Tesis

Los resultados principales de esta tesis son presentados en tres capítulos, correspondiendo cada uno de ellos a un objetivo específico.

Capítulo 1: Corresponde al primer objetivo específico. Se detalla las fuentes de datos, así como su obtención y procesamiento. Se presenta la estructura de la base de datos final con la que se trabajó y la selección de las variables asociadas a la distribución espacial de *E. ringens*, las cuales fueron utilizadas como entrada al modelo de pronóstico de zonas de pesca de esta especie.

Capítulo 2: Corresponde al segundo objetivo específico. Se detalla la implementación y evaluación de un modelo de pronóstico en el corto plazo de zonas de pesca de *E. ringens* basado en variables oceanográficas y redes neuronales. Estos resultados fueron publicados en la revista “Fishes” con el título “Identification and Forecast of Potential Fishing Grounds for Anchovy (*Engraulis ringens*) in Northern Chile Using Neural Networks Modeling” (<https://doi.org/10.3390/fishes7040204>).

Capítulo 3: Corresponde al tercer objetivo específico. Se evalúa el impacto de los pronósticos del modelo de redes neuronales en la eficiencia de la flota industrial cerquera anchovetera del norte de Chile desde 2003 a 2020 y con mayor énfasis bajo diferentes fases del evento ENSO (El Niño, La Niña, Neutral). Estos resultados forman parte de un manuscrito científico publicado en la revista “Fisheries Oceanography”, el que se titula “Neural networks approach for detecting spatial changes in catch probability of *Engraulis ringens* during ENSO events in Northern Chile”.

## 5 RESULTADOS

### 5.1 Capítulo 1: Análisis de la asociación entre la distribución espacial de *E. ringens* y variables oceanográficas para el pronóstico de zonas de pesca

#### 5.1.1 Introducción

En el norte de Chile *E. ringens* se distribuye mayormente dentro de las primeras 20 mn desde la costa (Silva et al. 2016; Espíndola et al. 2018; Hernández-Santoro et al. 2019). Variables oceanográficas como temperatura superficial del mar (Claramunt et al. 2012; Silva et al. 2012a, 2016; Aros et al. 2017; Espíndola et al. 2018), salinidad (Luján 2016; Aros et al. 2017; Leiva et al. 2017) y oxígeno disuelto (Jordán y Chirinos de Vildoso 1965; Paulmier y Ruiz-Pino 2009; Vergara et al. 2016; Aros et al. 2017; Leiva et al. 2017; von Dassow 2017) pueden condicionar su distribución espacio temporal. Por tanto, es posible utilizar estas variables como predictoras de la distribución potencial de *E. ringens* y con ello identificar y pronosticar zonas potenciales de pesca, tal como ha sido reportado por Nammalwar et al. (2013) para sardina *Sardinella gibbosa* y otras especies en North Tamil Nadu, India; y por Wang et al. (2015), para el calamar *Ommastrephes bartramii* frente a las costas de Japón.

La información oceanográfica puede obtenerse de diferentes formas tal como observaciones directas (*in situ*), observaciones remotas (información satelital) o información modelada (Dickey et al. 2006). En el caso de las observaciones *in situ* y satelitales, aunque son más precisas que las modeladas, presentan un problema común consistente en que no pueden ser proyectadas hacia el futuro, además que no son constantes ni en cuanto al área cubierta ni en frecuencia de las mediciones (Dickey et al. 2006; Morrow y Traon 2012).

Para abordar el pronóstico de zonas potenciales de pesca se requiere una fuente de datos oceanográfica de actualización diaria, que tenga alta cobertura espacial y que pueda proporcionar información futura. Con esas características se puede contar con la información de modelos numéricos de pronóstico de condiciones oceanográficas. Una de las fuentes más reconocidas y completas de información de modelos oceanográficos es el programa Copernicus (“Home | CMEMS” 2022), el que cuenta con productos que proveen información de variables oceanográficas desde 1993 hasta la actualidad (“Global Ocean Physics Reanalysis | Copernicus Marine MyOcean Viewer” 2023) y pronósticos hasta 10 días (“Global Ocean Physics Analysis and Forecast | Copernicus Marine MyOcean Viewer” 2023). El acceso a la información es gratuito y se puede acceder desde Python, lo que permite implementar códigos para la descarga y procesamiento de la información. Esta fuente de datos se considera como la fuente de datos oceanográficos más adecuada para el propósito de esta tesis.

La variable a predecir en esta investigación es “presencia de pesca” de *E. ringens*. Esta variable se definió como 1 si se capturó en la zona y 0 si no se capturó, lo cual convierte el caso de estudio en un problema de aprendizaje supervisado, particularmente clasificación binaria (Fitriah 2015). Las redes neuronales son uno de los algoritmos más utilizados en problemas de clasificación y predicción (Suryanarayana et al. 2008). Estas son modelos de inteligencia artificial que se inspiran en el funcionamiento del cerebro humano, siendo capaces de aprender a partir de datos de entrada mediante un proceso de entrenamiento y, una vez entrenadas, pueden predecir respuestas o realizar clasificaciones basadas únicamente en los datos de entrada (Suryanarayana et al. 2008; Yáñez et al. 2010). Este enfoque de aprendizaje se diferencia de los modelos convencionales, ya que no requiere supuestos rígidos de la estructura de los datos, lo que las hace especialmente adecuadas para tareas como la identificación de zonas potenciales de pesca (Wang et al. 2015).

Uno de los principales problemas para implementar cualquier modelo predictivo es identificar qué combinación de variables es más adecuada para ser utilizadas como predictoras (Fitriah 2015). Para que el modelo implementado sea lo más óptimo y estable posible, se requiere que exista alta correlación entre cada una de las variables predictoras con la variable a predecir (presencia de pesca) y baja correlación entre las variables independientes entre sí (García et al. 2006). Entonces, uno de los primeros pasos que se puede hacer para seleccionar variables es eliminar aquellas variables redundantes (Gardner y Dorling 1998; Ren-Yan et al. 2014), lo que se puede hacer mediante correlación cruzada entre todas las variables. Dicha correlación puede identificarse mediante el coeficiente de correlación de Pearson (Schober et al. 2018; Fabri-Ruiz et al. 2019), para variables que se distribuyen normal, o mediante el test no paramétrico de Spearman, para variables que no cumplen con esta distribución (Schober et al. 2018).

Otra forma de discriminar variables relevantes en un modelo es a través del propio modelo, construyendo varios modelos con diferentes combinaciones de variables y, mediante algún criterio de selección, se escoge el mejor (Fitriah 2015). Para determinar la relevancia de cada variable en un modelo de redes neuronales, uno de los algoritmos más efectivos se basa en el cálculo de la varianza de los pesos de las neuronas durante el entrenamiento de la red neuronal, donde mayor varianza en los pesos de las neuronas, para una variable en particular, implica mayor influencia de dicha variable en la predicción del modelo (de Sá 2019). Finalmente, el entrenamiento de la red neuronal permite construir un ranking de variables según su relevancia relativa en el modelo.

En este capítulo se detalla las fuentes de datos utilizadas, los procedimientos de construcción de la base de datos y, mediante el propio modelo de redes neuronales, se determina las variables a utilizar para pronosticar zonas de pesca de *E. ringens*.

### 5.1.2 Fuentes de datos pesqueros y variable objetivo

Para desarrollar un modelo predictivo de zonas de pesca se requiere, en primer lugar, disponer de la información de dónde y cuándo se encontró o no se encontró cardúmenes de la especie objetivo (presencia o ausencia), ya que ésta es la variable a predecir. Para esto se utilizó como base la trayectoria diaria de cada nave pesquera industrial de Corpesca S.A., obtenida de los sistemas de posicionamiento global (GPS) a bordo. Dicha información se encuentra disponible en una base de datos de esta empresa que se encuentra alojada en la nube de Amazon Web Services (AWS). El tipo de base de datos es Amazon Redshift (<https://aws.amazon.com/es/redshift/>), a la cual se accede mediante comandos en el lenguaje SQL. Este motor de bases de datos, diseñado por los desarrolladores de AWS, permite el almacenamiento de grandes volúmenes de datos, así como realizar consultas complejas, procesamiento y cálculos en la nube a grandes velocidades (<https://aws.amazon.com/es/redshift/>). Gran parte del pre-procesamiento de los datos para esta investigación se realizó en AWS Redshift.

Con las trayectorias de las naves industriales como base, se clasificó cada zona de tránsito como zonas de presencia o ausencia. Se utilizó las capturas estimadas por nave por día, disponibles también en la base de datos de Corpesca. La resolución de los datos de captura georreferenciados es de  $3 \times 3 \text{ mn}^2$ , por lo que, a cada zona de estas dimensiones por donde transitó al menos una nave de la flota, se le asignó el valor 0 si no hubo capturas ó 1 si hubo capturas de *E. ringens*. Así quedó construida la base de datos diaria de presencia-ausencia de *E. ringens* desde el año 2003 hasta el año 2020, la que cuenta con la fecha, latitud y longitud de cada zona de  $3 \times 3 \text{ mn}^2$ , capturas (toneladas) y la variable ausencia/presencia de pesca (0, 1).

Para clasificar cada zona como presencia o ausencia, se asumió que durante todo momento la flota estaba buscando cardúmenes de *E. ringens*, lo cual no sucede necesariamente así en la realidad, pues en muchas oportunidades las naves se dirigen a una zona recomendada por otro capitán o por el jefe de flota, no realizando búsqueda propiamente tal. Sin embargo, es una aproximación necesaria, ya que no se dispone de una forma de discriminar la búsqueda de cardúmenes. La calidad y precisión de las zonas de captura queda sujeta a la precisión en el dato de desembarque de Corpesca S.A. y a la metodología utilizada por dicha empresa para asignar las capturas a cada zona específica, ya que hasta el año 2020 no se disponía de las Bitácoras Electrónicas de Pesca, actualmente operativas.

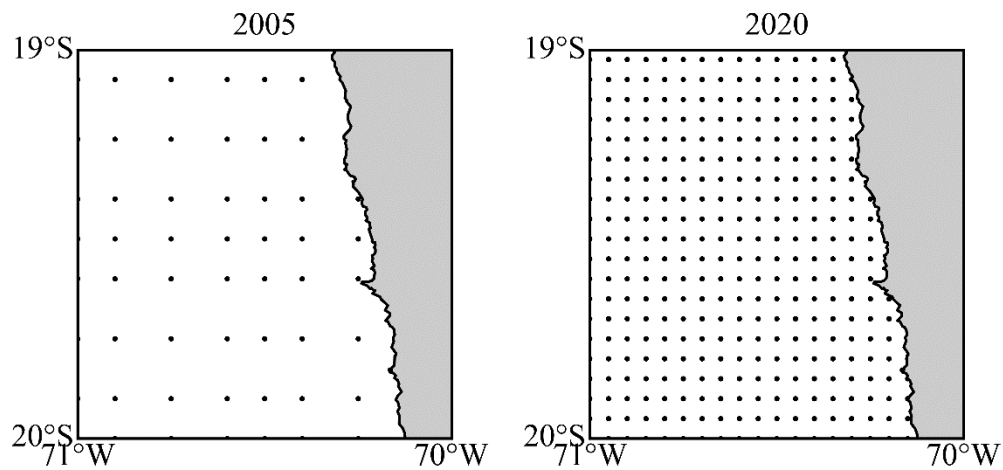
### 5.1.3 Fuentes de datos oceanográficos y variables predictoras

Luego de obtenida la variable a predecir (presencia-ausencia de pesca) es necesario determinar qué variables se utilizarán como predictoras, pues éste es el objetivo principal del primer capítulo. Es conocida la relación entre variables físicas oceanográficas como la temperatura superficial del mar (Claramunt et al. 2012; Silva et al. 2012a, 2016; Aros et al. 2017; Espíndola et al. 2018), salinidad (Luján 2016; Aros et al. 2017; Leiva et al.

2017) y oxígeno disuelto (Jordán y Chirinos de Vildoso 1965; Paulmier y Ruiz-Pino 2009; Vergara et al. 2016; Aros et al. 2017; Leiva et al. 2017; von Dassow 2017) con la distribución espacial de *E. ringens*. Dada esta relación entre *E. ringens* y variables oceanográficas se planteó utilizar dichas variables como predictoras de la distribución espacial de *E. ringens* y, por tanto, como variables de entrada al modelo de pronóstico de zonas de pesca.

Los datos oceanográficos pueden obtenerse de diversas formas y fuentes, a saber: datos *in situ*, datos satelitales, y datos modelados. En el caso de los datos *in situ*, éstos pueden ser tomados en cruceros oceanográficos, por boyas o estaciones automáticas en tiempo y espacio definidos. Por esta razón, estos datos no pueden proyectarse hacia el futuro y no son adecuados para pronosticar futuras zonas de pesca. La información satelital, aunque más extendida espacialmente, pudiendo cubrir regiones completas, presenta múltiples dificultades. Una de ellas es la nubosidad, que en la región de estudio (norte de Chile) es bastante frecuente y provoca extensas áreas donde los sensores satelitales no pueden obtener información de la superficie oceánica (Yáñez et al. 1995, 1997; Rojas y Eche 2006). Además, la información satelital es una captura instantánea del estado del océano por lo que solo permitiría evaluar las condiciones favorables a la presencia de *E. ringens* de forma instantánea y no pronosticar condiciones futuras.

Como primera opción, en esta investigación se evaluó la utilización de información satelital disponible en la base de datos de Corpesca S.A., dada su disponibilidad inmediata, y que ya se encontraba con la misma resolución de los datos de pesca (3x3 mn<sup>2</sup>). Sin embargo, se encontró diferencias en la resolución espacial de los datos entre algunos años de la base de datos (Figura 3), además de ausencia de datos a causa de la nubosidad en zonas donde hubo pesca. Esto dificulta obtener zonas donde se tenga datos de trayectorias, capturas y variables oceanográficas, lo cual es requerido como datos de entrada para el modelo de pronóstico de zonas de pesca. Además, esta data era actualizada semanalmente en la base de datos, lo cual dificultaba la implementación de un modelo que diera pronósticos a escala diaria.



**Figura 3:** Diferencias en la resolución espacial de los datos satelitales disponibles en la base de datos Corpesca entre los años 2005 y 2020.

Para pronosticar zonas de pesca de *E. ringens* en el corto plazo (días) es necesario tener una fuente de datos oceanográfica que pueda actualizarse diariamente como mínimo, con alta resolución espacial y sin faltantes de datos a causa de la nubosidad. De esta forma se podría unir esta data con la de trayectorias y capturas sin perder información valiosa. Con estas características, la fuente de datos más completa que se encontró pertenece al programa Copernicus (“Home | CMEMS” 2022) y consta de dos productos que proveen información oceanográfica de alta resolución espacial y con escala temporal diaria. El primer producto es un reanálisis oceanográfico, el que se encuentra disponible desde 1993 hasta 2020 (“Global Ocean Physics Reanalysis | Copernicus Marine MyOcean Viewer” 2023).

La principal característica del reanálisis es que utiliza toda la información disponible, tanto de boyas oceanográficas, información satelital, barcos para inicializar un modelo numérico que replica las condiciones oceanográficas pasadas lo más cercano posible a la realidad. El segundo es un producto de pronóstico oceanográfico y se encuentra disponible desde el año 2020 hasta la actualidad (“Global Ocean Physics Analysis and Forecast | Copernicus Marine MyOcean Viewer” 2023), y provee pronósticos oceanográficos desde un día hasta 10 días. Ambos productos se basan en el mismo modelo hidrodinámico (Nemo) (Madec et al. 2017) y tienen como salida las mismas variables físicas oceanográficas (temperatura superficial del mar, salinidad, profundidad de la capa de mezcla, altura del mar, y corrientes marinas). Los anteriores productos, combinados con la información pesquera, proporcionan la base para el entrenamiento del modelo de pronóstico de zonas de pesca de *E. ringens*.

#### 5.1.4 Construcción de la base de datos

La construcción de la base de datos necesaria para este estudio implicó un proceso exhaustivo de extracción, transformación y carga de datos, lo que permitió organizar y combinar los datos de las diferentes fuentes, creando un conjunto de datos coherente para entrenar el modelo de pronóstico de zonas de pesca. Para realizar este proceso se utilizó el lenguaje de programación Python (“Python.org” 2023), permitiendo asegurar la integridad y la calidad de los datos.

##### Descarga y procesamiento de datos de reanálisis

Los datos de las variables oceanográficas fueron descargados desde el producto de reanálisis de Copernicus. Estos datos tienen resolución espacial de 1/12 grados y frecuencia temporal diaria, en ficheros codificados en formato NetCDF (“Unidata | NetCDF” 2023). Cada fichero fue filtrado para el área de estudio (Figura 1) y se implementó un proceso recursivo en Python que recorría cada fecha desde 2003 a 2019, y agregaba cada fecha con las variables correspondientes a la base de datos.

##### Descarga de datos de Pronóstico


Los datos de análisis-pronóstico tienen la misma resolución espacial y temporal de los datos de reanálisis, además de contar con las mismas variables producto de la simulación con el mismo modelo hidrodinámico (Madec et al. 2017). Estos datos se descargaron diariamente para el año 2020. Cabe destacar que, aunque sean productos diferentes, los datos presentan la misma base matemática por lo que son consistentes y pueden utilizarse como una misma base de datos para entrenamiento y prueba del modelo. El producto de reanálisis permite tener la data histórica para el entrenamiento del modelo, mientras que el producto de pronóstico permite seguir almacenando y completando esta data histórica. Además, permite tener pronósticos hasta 10 días, lo cual posibilita que el modelo final pueda ser utilizado para realizar pronósticos de zonas de pesca de *E. ringens*.

##### Resolución espacial y base de datos final

Los datos de variables oceanográficas de Copernicus se encuentran en una resolución espacial diferente a los datos de pesca y trayectorias almacenados en la base de datos de Corpesca (Figura 4). Para llevar estos datos a una resolución espacial común fue necesario aplicar un método de interpolación. Entonces, se llevó la data oceanográfica a la resolución de la data pesquera ( $3 \times 3 \text{ mn}^2$ ), dado que los datos de captura y trayectorias de cada nave son más escasos y con una mayor variabilidad espacial. De esta forma no se afectaba la posición geográfica de las capturas. Dicha interpolación se realizó en el lenguaje Python, utilizando la biblioteca griddata (“Griddata” 2023) mediante el método “vecino más cercano”. Esta interpolación se realizó para cada día desde 2003 a 2020.



Finalmente se unieron las bases de datos pesquera y oceanográfica, utilizando como índices la latitud, la longitud, y la fecha.



**Figura 4:** Resolución espacial de los datos de Copernicus ( $1/12^\circ = 5\text{mn}^2$ , puntos rojos) y resolución espacial de la data pesquera ( $3 \times 3\text{ mn}^2$ , cruces negras)

Se obtuvo una base de datos final consistente y completa, la que cumplió con los criterios necesarios para el análisis y modelado subsiguientes. En las Tablas 1 y 2 se muestra el resumen estadístico de todas las zonas donde navegó la flota (Tabla 1) y de las zonas donde se hubo capturas (Tabla 2).

**Tabla 1.** Análisis estadístico descriptivo de la data correspondiente a las trayectorias de las naves industriales de la empresa pesquera Corpesca en el período 2003-2020.

	<b>Cantidad</b>	<b>media</b>	<b>std</b>	<b>mínimo</b>	<b>25%</b>	<b>50%</b>	<b>75%</b>	<b>máximo</b>	<b>cv</b>
<b>Temperatura superficial del mar (°C)</b>	1.503.756	18,54	2,36	12,12	16,75	18,3	20,13	26,85	12,73
<b>Salinidad</b>	1.503.756	34,83	0,18	33,25	34,71	34,81	34,93	35,61	0,53
<b>Profundidad de la capa de mezcla (m)</b>	1.503.756	13,03	5,93	6,71	10,53	10,53	12,36	74,47	45,54
<b>Altura del mar (m)</b>	1.503.756	0,06	0,04	-0,11	0,03	0,06	0,09	0,26	69,77
<b>Componente zonal de la velocidad de la corriente (m/s)</b>	1.503.756	-0,04	0,08	-0,57	-0,09	-0,03	0,01	0,63	-203,84
<b>Componente meridional de la velocidad de la corriente (m/s)</b>	1.503.756	0,13	0,15	-0,49	0,03	0,12	0,22	0,89	113,6
<b>Toneladas capturadas</b>	68.229	87,83	153,0 7	0	13,78	36,41	95,13	3229,51	174,28

**Tabla 2.** Análisis estadístico descriptivo de la data correspondiente a las capturas de *E. ringens* por las naves industriales de la empresa pesquera Corpesca en el período 2003-2020.

	<b>cantidad</b>	<b>media</b>	<b>std</b>	<b>mínimo</b>	<b>25%</b>	<b>50%</b>	<b>75%</b>	<b>máximo</b>	<b>cv</b>
<b>Temperatura superficial del mar (°C)</b>	68.229	18,26	2,11	12,67	16,67	18,02	19,68	25,69	11,57
<b>Salinidad</b>	68.229	34,82	0,18	33,3	34,71	34,8	34,91	35,55	0,51
<b>Profundidad de la capa de mezcla (m)</b>	68.229	12,67	5,6	7,02	10,53	10,53	11,6	60,43	44,22
<b>Altura del mar (m)</b>	68.229	0,06	0,04	-0,1	0,03	0,06	0,09	0,26	70,59
<b>Componente zonal de la velocidad de la corriente (m/s)</b>	68.229	-0,05	0,08	-0,53	-0,09	-0,04	0	0,34	-177,75
<b>Componente meridional de la velocidad de la corriente (m/s)</b>	68.229	0,13	0,14	-0,42	0,04	0,13	0,22	0,81	105,86
<b>Toneladas capturadas</b>	68.229	87,83	153,07	0	13,78	36,41	95,13	3229,51	174,28

En cuanto a las condiciones oceanográficas donde ocurrieron capturas de *E. ringens*, se observó que la temperatura superficial del mar presenta una media de 18.26°C con desviación estándar de 2.11°C. La salinidad muestra un valor medio de 34.82 con desviación estándar de 0.18. Una variable de especial interés es la captura, que presenta una media de 87.83 toneladas y desviación estándar de 153,07. Según el coeficiente de variación (cv) (Tablas 1 y 2), las variables oceanográficas que presentaron mayor variación en el período de estudio (2003-2020) fueron las componentes de la velocidad de las corrientes, seguida por la altura del mar, la profundidad de la capa de mezcla y la temperatura. La salinidad fue la variable que menos varió en el período de estudio.


La base de datos final, utilizando Copernicus, contiene una cantidad de registros considerablemente mayor que la satelital (Tabla 3). También es mayor la cantidad de zonas con trayectorias y donde se ocurrieron capturas, lo que determina que la base de datos final para el entrenamiento del modelo sea mayor utilizando los datos de Copernicus.

**Tabla 3.** Comparación entre la cantidad de observaciones disponibles de la data satelital y la data proveniente de Copernicus para toda la zona de estudio (18°21” S–27° S) en el período 2003-2020.

<b>Fuente de datos</b>	<b>Total de Datos disponibles</b>	<b>Total de datos donde hay trayectorias</b>	<b>Total de datos sin pesca</b>	<b>Total de datos con pesca</b>
<b>Satelital</b>	47.000.948	560.022	536.078	23.944
<b>Copernicus</b>	100.493.664	1.503.756	1.435.527	68.229

#### 5.1.5 Selección de variables para ser consideradas en la modelación

Para la correcta implementación de cualquier modelo predictivo es necesario encontrar alta correlación entre cada una de las variables independientes (variables oceanográficas) con la variable dependiente (presencia de pesca), pero baja correlación entre las variables independientes entre sí, ya que, si se utiliza variables muy correlacionadas, entonces se podría afectar el rendimiento del modelo, provocando su inestabilidad (García et al. 2006). Para evitar este tipo de error se aplicó correlación cruzada entre cada par de variables para cada zona para comprobar independencia. Primero se realizó el test de Shapiro-Wilk (Mohd Razali y Bee Wah 2011) para verificar si las variables predictoras se distribuyen normal, determinándose que ninguna de las variables cumplía esta condición. Por lo tanto, fue necesario utilizar el coeficiente no paramétrico de Spearman para calcular la correlación cruzada entre todas las variables. Se consideró como alta correlación un índice de Spearman  $> 0,8$  (Akoglu 2018) con el propósito de eliminar variables y lograr baja correlación entre las variables predictoras a utilizar. Sin embargo, se encontró que las variables independientes no se correlacionaron significativamente entre sí y tampoco con la variable presencia de pesca (Figura 5).



**Figura 5.** Matriz de correlación de Spearman entre todas las variables disponibles en la base de datos creada para el entrenamiento del modelo de pronóstico de zonas de pesca de *E. ringens*. Nomenclatura: lat = latitud, lon = longitud, sst = temperatura superficial del mar, so = salinidad, mlotst = profundidad de la capa de mezcla, zos = altura del mar, uo = componente zonal de la velocidad de las corrientes, vo = componente meridional de la velocidad de las corrientes.

Esta falta de correlación entre las variables oceanográficas y la pesca dificultó la aplicación de modelos estadísticos tradicionales como Generalized Additive Models (GAM) y Generalized Linear Models (GLM), los que son utilizados comúnmente en este tipo de estudios (Yáñez et al. 2010; Naranjo et al. 2015). Además, como ninguna variable predictora se correlacionó fuertemente con otra, entonces hasta esta parte de la investigación no se eliminó ninguna de aquellas variables en la modelación.

#### 5.1.6 El enfoque de redes neuronales

Dada la falta de correlación lineal entre las variables y la pesca, se plantea la hipótesis que la relación puede ser no lineal y compleja. Las redes neuronales pueden capturar

relaciones no lineales y patrones complejos en los datos, lo que las convierte en una herramienta con alto potencial para el pronóstico de zonas de pesca (Suryanarayana et al. 2008; Wang et al. 2015). Las redes neuronales están inspiradas en el funcionamiento del cerebro humano, son capaces de aprender la respuesta a un estímulo por repetición (esto se denomina entrenamiento), y posteriormente predecir la respuesta utilizando solo los datos de entrada (Suryanarayana et al. 2008; Yáñez et al. 2010). Este tipo de modelos puede ser implementado con pocos supuestos sobre los datos de entrada, lo cual difiere de los modelos convencionales y los hace más adecuados para la identificación de zonas potenciales de pesca (Suryanarayana et al. 2008).

Las redes neuronales son un enfoque más adecuado para determinar y seleccionar las variables más relevantes en la predicción de zonas de pesca. Para el análisis de importancia de las variables se aplicó la metodología propuesta por de Sá (2019), asumiéndose que las variables donde los pesos de las neuronas presentan mayor varianza durante el entrenamiento son las más relevantes en la predicción. El resultado de aplicar este método es el porcentaje de aporte de cada variable en la predicción de zonas de pesca (Tabla 4).

**Tabla 4:** Relevancia de cada variable en la predicción de zonas de pesca de *Engraulis ringens* en la zona norte de Chile con el modelo de redes neuronales.

Variables	Importancia relativa %
Longitud	23
Profundidad de la capa de mezcla	18
Latitud	15
Temperatura superficial del mar	12
Mes	12
Altura del mar	9
Salinidad	9
Componente zonal de la velocidad de la corriente marina	1
Componente meridional de la velocidad de la corriente marina	1

De forma similar a lo observado en la investigación de Wang et al. (2015), en el presente trabajo las variables geográficas latitud y longitud se encuentran entre las tres primeras del ranking, sumando entre ambas 38% en la predicción. La variable oceanográfica con mayor relevancia fue la profundidad de la capa de mezcla (18% de la varianza total explicada por el modelo de redes neuronales). Esta variable está directamente relacionada con el hábitat vertical de *E. ringens*, que en casos extremos, tal como en eventos El Niño

fuertes, se expande a más de 50 m de profundidad, generando la profundización de los cardúmenes y dificultando su accesibilidad a las artes de pesca (Böhm et al. 2017).

#### 5.1.7 Conclusión

Se concluye que las variables independientes que explican mejor las capturas por zonas de pesca de *E. Ringens* en la zona norte de Chile son: longitud geográfica (23%), profundidad de la capa de mezcla (18%), latitud geográfica (15%), temperatura superficial del mar (12%), mes (12%), altura del mar (9%) y salinidad (9%).

## 5.2 Capítulo 2: Identification and Forecast of Potential Fishing Grounds for Anchovy (*Engraulis ringens*) in Northern Chile Using Neural Networks Modeling

### Abstract

*Engraulis ringens* (*E. ringens*) is a small pelagic fish of which the geographic and bathymetric distribution is conditioned by fluctuations in oceanographic conditions at different time scales (daily, weekly, monthly, annually, supra-annually, and longer) and by fishing. Understanding the organism–environment interactions and predicting the spatial distribution of its schools can improve conservation actions and fishery management, along with the operation of the fleets targeting *E. ringens*. There is an important fishery of *E. ringens* in Northern Chile ( $18^{\circ} 21' S$ - $26^{\circ} 00' S$ ), which provides about 80% of the purse seine catch. To identify and predict potential fishing grounds for *E. ringens* in this system, we implemented a predictive model of fishing grounds based on neural networks, which was trained with the georeferenced data of daily catches by industrial purse sein ships from 2003 to 2020 and information on oceanographic variables (sea surface temperature, salinity, depth of the mixed layer, sea height, and currents) obtained from the Copernicus Marine Environment Monitoring Service (CMEMS program; <https://marine.copernicus.eu/> (accessed on 30 January 2021)). The neural network model had a very good performance (86%). Longitude (23%) was the most relevant variable for identifying potential fishing grounds, followed by the mixed layer depth (18%), latitude (15%), sea surface temperature (12%), month (12%), sea height (9%), salinity (9%), and the zonal and meridional components of the current velocity (2%). The neural network model classified correctly the majority of the areas with and without fishing potential; thus, its use is recommended to predict fishing grounds for *E. ringens* in the study area. Its application could increase by 88% of the probability of capture anchovy by the purse seine fleet of Northern Chile.



Article

# Identification and Forecast of Potential Fishing Grounds for Anchovy (*Engraulis ringens*) in Northern Chile Using Neural Networks Modeling

Elier Armas<sup>1,2</sup>, Hugo Arancibia<sup>1</sup> and Sergio Neira<sup>1,3,4,\*</sup>

<sup>1</sup> Doctorado en Ciencias con Mención Manejo de Recursos Acuáticos Renovables (MaReA), Departamento de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, P.O. Box 160-C, Concepción 4030000, Chile

<sup>2</sup> Centro de Investigación Aplicada del Mar (CIAM), Av. Arturo Prat #33, Iquique 1100000, Chile

<sup>3</sup> Departamento de Oceanografía, Universidad de Concepción, Víctor Lamas St. 1290, Concepción 4030000, Chile

<sup>4</sup> Programa COPAS COASTAL ANID FB210021, Departamento de Oceanografía, Universidad de Concepción, Víctor Lamas St. 1290, Concepción 4030000, Chile

\* Correspondence: seneira@udec.cl

**Abstract:** *Engraulis ringens* (*E. ringens*) is a small pelagic fish of which the geographic and bathymetric distribution is conditioned by fluctuations in oceanographic conditions at different time scales (daily, weekly, monthly, annually, supra-annually, and longer) and by fishing. Understanding the organism–environment interactions and predicting the spatial distribution of its schools can improve conservation actions and fishery management, along with the operation of the fleets targeting *E. ringens*. There is an important fishery of *E. ringens* in Northern Chile (18°21' S–26°00' S), which provides about 80% of the purse seine catch. To identify and predict potential fishing grounds for *E. ringens* in this system, we implemented a predictive model of fishing grounds based on neural networks, which was trained with the georeferenced data of daily catches by industrial purse sein ships from 2003 to 2020 and information on oceanographic variables (sea surface temperature, salinity, depth of the mixed layer, sea height, and currents) obtained from the Copernicus Marine Environment Monitoring Service (CMEMS program). The neural network model had a very good performance (86%). Longitude (23%) was the most relevant variable for identifying potential fishing grounds, followed by the mixed layer depth (18%), latitude (15%), sea surface temperature (12%), month (12%), sea height (9%), salinity (9%), and the zonal and meridional components of the current velocity (2%). The neural network model classified correctly the majority of the areas with and without fishing potential; thus, its use is recommended to predict fishing grounds for *E. ringens* in the study area. Its application could increase by 88% of the probability of capture anchovy by the purse seine fleet of Northern Chile.

**Keywords:** neural network model; catch probability; potential fishing grounds; *Engraulis ringens*; anchovy; Northern Chile



Citation: Armas, E.; Arancibia, H.; Neira, S. Identification and Forecast of Potential Fishing Grounds for Anchovy (*Engraulis ringens*) in Northern Chile Using Neural Networks Modeling. *Fishes* **2022**, *7*, 204. <https://doi.org/10.3390/fishes7040204>

Academic Editor: Yang Liu

Received: 10 June 2022

Accepted: 9 July 2022

Published: 15 August 2022

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.




**Copyright:** © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

## 1. Introduction


*Engraulis ringens* (anchovy) is a small pelagic fish of the Family Engraulidae. This species plays a key role in the Humboldt Current System (HCS), since it is the main prey of fish, mammals, and sea birds [1,2]. *E. ringens* inhabits the neritic-coastal zone, mostly in the first few miles from the coast; the majority of the catch is conducted within the first 10 nm [3,4]. This species provides 75–80% of the annual catch of the purse seine fleet of Northern Chile (18°21' S–27° S) (Figure 1) [5]. In this system, *E. ringens* is targeted only by this fleet and gear, and it is managed using the total allowable catch (TAC) system. The artisanal fleet captures 15% of the TAC, while the industrial fleet, represented by the fishing

companies Corpesca S.A. and Camanchaca, captures 85% of the TAC [6]. Corpesca S.A. concentrates 70% of the industrial vessels and 80% of the industrial TAC [7,8].



**Figure 1.** Stock of anchovy (*Engraulis ringens* (*E. ringens*)) distributed from Southern Peru to Northern Chile (16°–27° S). The right panel indicates the distribution of *E. ringens* in Northern Chile that is the study area covered by a neural network model applied to predict *E. ringens* fishing grounds.

The annual landings of the anchovy industrial purse seine fleet of Southern Peru and Northern Chile declined considerably (Figure 2) in the 1997–1998, 2002–2003, and 2015–2016 periods [5], coinciding with moderate to very strong El Niño Southern Oscillation (ENSO) events [9]. Since 2003, with the application of the Chilean administrative rule of Maximal Annual Catch per Ship Owner (MCSO) [10,11], the purse seine fleet of Northern Chile changed from an operation with high fishing effort to one in which fishing effort is regulated, due to the reduction in the capture quotas assigned to each ship owner [5].



**Figure 2.** Annual landings of the industrial fleet that operates over the anchovy stock shared by Southern Peru and Northern Chile. Data were obtained from [3].

Decreasing fishing effort and reducing operational costs of locating and capture of *E. ringens* requires optimizing/reducing fishing trips. An interesting alternative is to explore and identify potential fishing grounds (PFGs) of *E. ringens*, analogous to the study by Nammalwar et al. (2013) [12] for captures of *Sardinella gibbosa* and other species in North Tamil Nadu, India, and by [13] who used a neural network to determine PFGs of the squid *Ommastrephes bartramii* off the coast of Japan.

Artificial neural networks are inspired in the functioning of the human brain; they are capable of learning the response to a stimulus (entry data) by repetition (called training) and then predicting the answer using only entry data [14,15]. This kind of model may be implemented with few assumptions on the entry data, differing from conventional models, which makes them more adequate for identification of PFGs [14].

There have not yet been predictions of probable fishing grounds for *E. ringens*, or other marine species, in Northern Chile that allow better management of the fleet to reduce fishing effort and improve the yield. The objective of this study is to predict fishing grounds of *E. ringens* by implementing a neural network model (using information fishing days per industrial purse seine vessel in Northern Chile), which could help to reduce the operational costs of the fleet.

## 2. Materials and Methods

### 2.1. Fishery and Environmental Data

The georeferenced catch data of *E. ringens* per vessel and the daily trajectories of each ship were obtained from the database of the fishing company Corpesca S.A., which owns a fleet of 23 out of 33 vessels that comprise the industrial fleet in Northern Chile [7,8]. This database contains 1.5 million records for the 2003–2020 period, with a spatial resolution of  $3 \times 3 \text{ nm}^2$ . For the period 2003–2020, there was not differences in terms of the resolution and quality of the data in the database. The data included date (day, month, and year), geographic position where the vessel operated (latitude and longitude), georeferenced capture, and vessel identification. Each  $3 \times 3 \text{ nm}^2$  cell was associated with a dichotomous variable to differentiate whether or not *E. ringens* was captured (0 = no catch; 1 = catch), independently of the catch volume. The absence data were determined from the full trajectory of the fishing vessels, under the assumption that vessels were searching for schools throughout the entire fishing trip. Each cell was also associated with the following daily oceanographic variables: sea surface temperature, salinity, depth of the mixed layer, currents, and sea height, which were obtained from the Copernicus Marine Environment Monitoring Service [16] and especially the product of the Global Analysis Forecast Phy 001 024 [17]. This source includes good-quality time series [18] produced using the NEMO physical model [19]. The study area ranged from  $18^\circ \text{ S}$  to  $26^\circ \text{ S}$  and from the coast to  $73^\circ \text{ W}$ .

### 2.2. A forecasting Model Based on Artificial Neural Network

Data processing was performed in the Python programming language, using TensorFlow version 2.8 [20] and the Keras library [21] to implement the neural network. We used the daily trajectories of each ship, catches of *E. ringens* (with or without catch), and oceanographic variables to train a multi-layer perceptron, which is one of the neural network architectures most used for practical applications [14,22]. Eighty percent of the 1.5 million records were randomly assigned to training the model; the other 20% were used to validate it. Input data were standardized using the StandardScaler of Sklearn [23]. The neural network architecture was found using Auto-Keras [24]. The best architecture found consists of an input layer of nine neurons corresponding to the dimension of the input data (nine predictor variables). Two hidden (intermediate) layers were used with 1024 and 512 neurons, respectively, both with ReLU activation function [25]. The output layer of the model has a neuron with Sigmoid activation function [25], and the output is a value ranging from 0 to 1 for each  $3 \times 3 \text{ nm}^2$  cell, which represents the catch probability in this cell. Since the case study corresponds to a binary classification, the loss function used was the BinaryCrossentropy [21]. We used Adam [26] as a neural network optimizer, with an

initial learning rate of 0.001 that was configured to decrease throughout the training using the ReduceLROnPlateau keras function [27]. To avoid overfitting the model, a stopping criterion was implemented using the EarlyStopping function of Keras [28]. To analyze the importance of the variables, we applied the method proposed by [29], which assumes that the variables in which the weights of the neurons have greater variance in the training are the most relevant for prediction. The result of applying this method is the percentage support for each variable in predicting fishing grounds.

### 2.3. Model Validation

According to [30,31], the metrics used to evaluate neural network are the area under the receiving curve (AUC), precision (probability of catch in areas predicted by the model as PFGs), specificity (proportion of areas where there was no catch that the model detected correctly), recall (proportion of the catch areas detected by the model), and the false omission rate (FOR; the probability of catch in areas the model predicted as not apt for fishing). The AUC measures the relation between the true positive rate (TPR) and the false positive rate (FPR) [32]; it is 0 if the prediction is always wrong and is 1 when predictions are perfect [33–35]. The cross-validation of the model was performed to check if the results were the same independently of the data selected for training and validation. We used 10 random partitions of the database, varying the training and validation data.

### 2.4. Model Application

For each year of the 2003–2020 period, we simulated the catch probability of the fleet in the potential and non-PFGs, training a model for each year with the catch data and oceanographic variables for all the other years. A  $3 \times 3 \text{ nm}^2$  cell was considered to be a PFG, if the probability determined by the model was greater than 0.5. The probability of the annual catch was calculated as:

$$YCP = TC / TV, \quad (1)$$

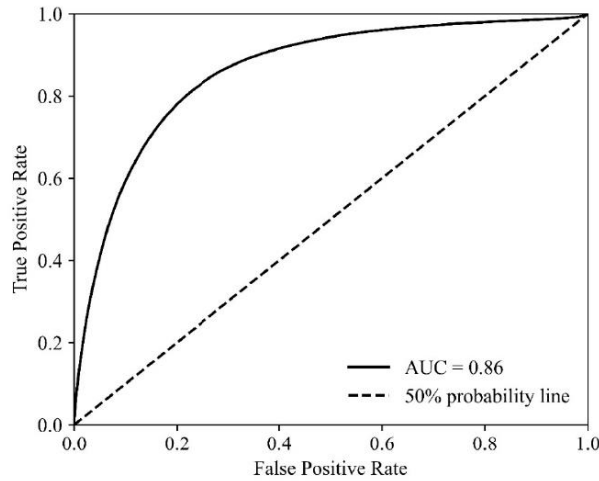
where  $YCP$  is the catch probability for a year,  $TC$  is the number of  $3 \times 3 \text{ nm}^2$  cells where *E. ringens* was caught, and  $TV$  is the total areas visited by the fleet.

To validate the neural network model as a daily predictive tool, we chose the 36 days (10% of the total days in a year) with greatest total captures in the study period (authors' criterion). These 36 days were chosen only for graphic representation and to show examples of forecast maps of daily probabilities. This was used to generate a new model without using the information of the days selected for training, which was used to predict the probability of daily catch for each cell. Then, we mapped the probability of catch against the actual catches of the fleet.

## 3. Results

### 3.1. Performance of the Artificial Neural Network Forecasting Model

The AUCs were 0.848 for the model trained with 80% of the database and 0.86 for the test data (Figure 3). The test data included 302,182  $3 \times 3 \text{ nm}^2$  cells visited by the fleet (Table 1); *E. ringens* was captured in 13,459 of them (4.45%), and thus, the catch probability was 0.0445. The model correctly identified 10,606 cells (78.8% of the cells where *E. ringens* was captured). Of the 85,341 cells predicted to have fish, catches were recorded in 10,606 (12%). Of the 216,841 cells predicted not to have fish, *E. ringens* was caught in 2853 (1.3%). The fishing effort (the number of cells fished by the fleet) in areas predicted not to have fish was 2.54 times that of the effort in areas predicted to have fish. The cross-validation of the model behaved similarly in all data partitions; the mean AUC was 0.84 (similar to that of the initial model test) and the recall was 0.79, both with a standard deviation of 0.01.



**Figure 3.** Receiver operating characteristic curve of the evaluation of the neural network model on the test data for the fishery of anchovy (*E. ringens*) in Northern Chile.

**Table 1.** Results of applying the neural network model on the test data (not used for training) from the fishery of anchovy (*E. ringens*) and the oceanographic characteristics of the study area (Northern Chile). Tabulated values correspond to the numbers of cells.


	Non-Potential Fishing Grounds	Potential Fishing Grounds	Total
Areas visited	216,841	85,341	302,182
Capture areas	2853	10,606	13,459
Probability	0.013	0.124	0.045

The most relevant variables for predicting PFGs were longitude (23%), depth of the mixing layer (18%), and latitude (15%), followed by sea surface temperature (12%), month (12%), sea height (9%), and salinity (9%). The least relevant variables were the zonal and meridional components of the marine currents (2% each); thus, these variables were excluded from the final model.

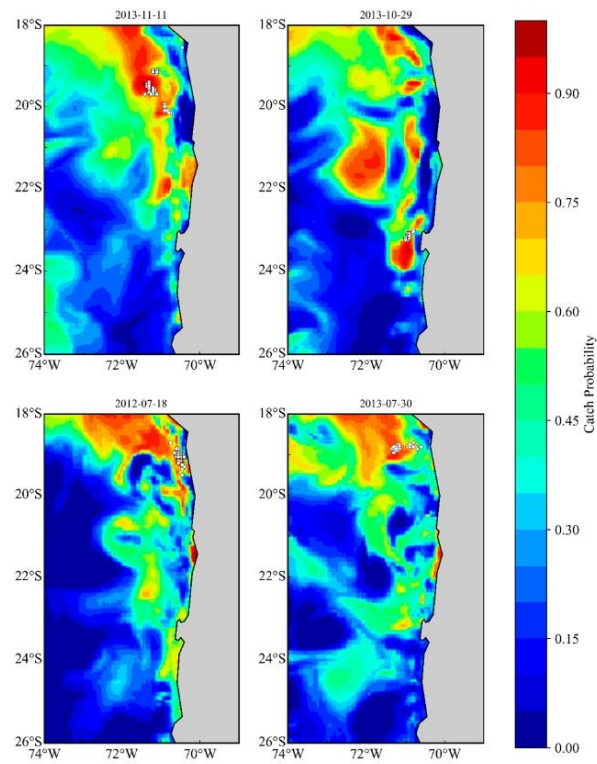
### 3.2. Model Application

Figure 4 shows the yield of the industrial purse seine fleet, expressed as YCP (Equation (1)) for all years studied. The mean catch probability in the PFGs was 88% greater than in the non-PFGs. The minimum difference was 19% (2010), and the maximum was 322% (2003).

Due to space limitations, Figure 5 shows the results of applying the model to the four days with the greatest catch of *E. ringens* in the entire time series. Table 2 shows a statistical summary of the behavior of the model for the 36 days of the greatest catch in the entire series. A larger number of areas with catches were within the areas of highest probability provided by the model. Seventy-five percent of the days had a precision greater than 0.12; this metric is equivalent to the catch probability in the areas predicted as PFGs by the model. The FOR, equivalent to the catch probability in areas predicted not to be PFGs, was below 0.05 in 75% of the cases. The recall is the fraction of fishing areas correctly detected by the model, and it was above 0.7 in 75% of the cases.



**Figure 4.** Annual catch probabilities of the fleet in the potential (dark bars) and non-potential (clear bars) fishing areas from the neural network model applied for the fishery of anchovy (*E. ringens*) in Northern Chile.



**Figure 5.** Maps of catch probabilities predicted by the neural network model applied to the fishery of anchovy (*E. ringens*) in Northern Chile, for the four days with the greatest catch in the 2003–2020 period (the 36 days with the greatest catch were ranked, and the first four were displayed). White circles indicate where *E. ringens* was captured.

**Table 2.** Summary of statistics describing the performance of the neural network model applied to the fishery of anchovy (*E. ringens*) in Northern Chile, considering the 36 days of the greatest catch in the entire series chosen as a study case.

	n	Mean	Standard Deviation	Minimum Value	25%	50%	75%	Maximum Value
Precision	36	0.208	0.136	0.063	0.121	0.174	0.242	0.654
False omission rate (FOR)	36	0.036	0.028	0.004	0.012	0.026	0.054	0.11
Recall	36	0.764	0.211	0.125	0.705	0.844	0.911	0.971

#### 4. Discussion

The use of a neural network model to predict PFGs of *E. ringens* in Northern Chile proved to be an interesting method with practical applications. Predicting fishing grounds has been a great challenge for Chile and Latin America, due to which many efforts have made [36–40]. Although Chilean efforts have shown satisfactory results [37,39,40], they used oceanographic satellite information, which are instantaneous moments of the ocean state that do not allow temporal projection of these conditions in the short term. It is also unknown if these studies would have practical applications for the administration of the fleet.

Nieto et al. (2001) identified PFGs for *E. ringens* in 1999; 67% of the actual catch areas were among those the model identified (this metric is equivalent to recall, which is used in this study). Silva et al. (2002) [38], Yáñez et al. (2004) [39], and Silva et al. (2012) [40] used a similar methodology to identify PFGs of *E. ringens*, obtaining a 74% recall, which is comparable to the 79% recall obtained by us in the cross-validation and mean of 76% for the 36 days, of which 50% had a recall greater than 84% (Table 2). Our study identified and predicted 78.8% of the fishing grounds using a neural network (recall = 0.788) (Table 1 in Section 3.1). The AUC value of 0.84 indicates that the classification was very good according to the criteria of [41,42]. This result was compared favorably with the results of [43], who used a neural network model to predict the distribution of 14 species of freshwater fish and crustaceans in New Zealand; they reported AUC values of 0.63–0.88.

The neural network model applied in this study has the advantage that it may be implemented with few assumptions on the fishing and environmental data [13,14], showing better performance than conventional statistical models such as generalized linear models (GLMs) and generalized additive models (GAMs) [13,14,34,44]. The latter models require certain characteristics of the data, including linearity, normality, and heteroscedasticity [45]. However, these assumptions are unlikely to be fulfilled in real fishing situations, due to the lack of information in areas not explored by the fleet, the difficulty associated with the non-linearity of ecological processes (Tan and Beklioglu 2006), and the complex species-environment interactions (Wang et al. 2015). We found that the neural model also has limitations and disadvantages that need to be considered. For example, neural network models are considered as black boxes for which the prediction mechanism is not a transparent process or defined by an equation. Despite this, there are methods such as the one used in this study [29] to determine the importance of the variables in the predictions. The neural network requires data on presence and absence. The absence data were determined from the trajectory of the fishing vessels. As stated earlier, the assumption was that the vessels searched for schools during the full fishing trip, which is not necessarily correct. This assumption may have resulted in excessive absence zones and fewer presence zones. Therefore, the classes to be predicted are unbalanced, and the fishing probabilities are low. These could be improved in future studies by using fishing logbooks.

The neural network model applied in this study identified areas with oceanographic conditions favorable to the presence of *E. ringens*. However, this does not necessarily imply that schools will be present in those areas due to the existence of interactions with other species such as predation and competition [46]. This could explain why the model identified more PFGs than those where *E. ringens* was really caught (Table 1). However,

the catch probability in the potential areas was greater than in the non-potential areas and greater than the fishing probability of the fleet if it visited all the areas (Table 1).

Similar to the report of Wang et al. (2015), in this study, the variables latitude and longitude were among the most important for identifying PFGs; In the case of *E. ringens*, their combined importance was 38%. The most relevant oceanographic variable was the depth of the mixing layer (18% of the variance). This variable is directly related to the vertical habitat of *E. ringens*, which in extreme events such as El Niño can expand to more than a 50 m depth; in this case, anchovy schools go deeper, making them less available for the purse seiners [5]. The annual simulation with the neural network model to recommend fishing grounds (Figure 4) showed that the probability in PFGs was greater than in the non-PFGs in all years. If the fleet had searched for schools of *E. ringens* in the areas recommended by the model, on average it would have had an 88% better probability of finding fish than in the non-recommended areas.

It must be emphasized that this study had millions of catch data provided by the fishing company Corpesca S.A., together with oceanographic predictions obtained from the Copernicus program. Corpesca S.A. is currently using this tool in Northern Chile to predict anchovy catch areas, which allows the fleet to self-regulate fishing effort better.

We concluded that the neural network model implemented in this study had 84% success in predicting PFGs for *E. ringens*. The real fishing areas were consistent with model predictions (Figure 5), which suggests that the model may be used to predict fishing grounds for *E. ringens* in Northern Chile. In addition, the model can help in reducing the fleet's search effort for the target species and improving the fishing yield.

**Author Contributions:** Conceptualization, E.A., H.A. and S.N.; methodology, E.A. and H.A.; software, E.A.; validation, E.A.; formal analysis, E.A.; investigation, E.A. and H.A.; resources, E.A.; data curation, E.A.; writing—original draft preparation, E.A.; writing—review and editing, E.A., H.A. and S.N.; visualization, E.A. and H.A.; supervision, H.A. and S.N.; project administration, E.A.; funding acquisition, E.A. All authors have read and agreed to the published version of the manuscript.

**Funding:** This research was funded by Conicyt + Pai/Concurso Nacional Tesis de Doctorado en el Sector Productivo, Convocatoria 2019 + Folio (T7819110004) and partially funded by Centro COPAS Coastal ANID FB210021.

**Data Availability Statement:** The data that support the findings of this study are available from the corresponding author upon reasonable request.

**Acknowledgments:** This study was conducted using E.U. Copernicus Marine Service Information (<https://doi.org/10.48670/moi-00016> (accessed on 24 June 2022)). E.A. thanks the “Doctorado en Ciencias con Mención en Manejo de Recursos Acuáticos Renovables (MaReA)” and Dirección de Postgrado from Universidad de Concepción (Chile) for the financial support provided through student scholarships. E.A. and H.A. thank the “Centro de Investigación Aplicada del Mar” (<https://www.ciamchile.cl/> (accessed on 15 March 2021)) and Corpesca S.A. (<https://www.corpesca.cl/> (accessed on 15 March 2021)) for providing the data, offices, and staff support to carry out this research. S.N. acknowledges partial funding from Centro COPAS Coastal ANID FB210021.

**Conflicts of Interest:** The authors declare no conflict of interest.

## References

1. Barros, M.E.; Neira, S.; Arancibia, H. Trophic interactions in northern Chile upwelling ecosystem, Year 1997. *Lat. Am. J. Aquat. Res.* **2014**, *42*, 1109–1125. [[CrossRef](#)]
2. Medina, M.; Arancibia, H.; Neira, S. Un modelo trófico preliminar del ecosistema pelágico del norte de Chile (18°20' S–24°00' S). *Invest. Mar.* **2007**, *35*, 25–38. [[CrossRef](#)]
3. Espíndola, F.; Quiroz, J.C.; Böhm, G.; Leiva, F.; Aros, J.A. INFORME 2 ESTATUS. Convenio de Desempeño 2017. Estatus y posibilidades de explotación biológicamente sustentables de los principales recursos pesqueros nacionales Año 2018: Anchoveta XV-II Regiones. *Inst. Fom. Pesque* **2018**. [[CrossRef](#)]
4. Silva, C.; Andrade, L.; Yáñez, E.; Hormazabal, S.; Barbieri, M.A.; Aranis, A.; Böhm, G. Predicting habitat suitability and geographic distribution of anchovy (*Engraulis ringens*) due to climate change in the coastal areas off Chile. *Prog. Oceanogr.* **2016**, *146*, 159–174. [[CrossRef](#)]



5. Böhm, M.G.; Hernández, C.; Díaz, E.; Pérez, G.; Ojeda, R.; Cerna, F.; Valero, C.; Gómez, M.; Machuca, C.; Muñoz, L. INFORME FINAL. Convenio de Desempeño, 2016. Programa de seguimiento de las principales pesquerías pelágicas de la zona norte de Chile, XV–IV Regiones, Año 2016. *Inst. Fom. Pesq.* **2017**.
6. Dec. Ex. N° 22-2022 Modifica Dec. Ex. Folio 202100228 Establece Cuota de Captura de Unidades de Pesquería de Anchoqueta y Sardina Española Zona Norte Sometidas a Licencias Transables de Pesca, Año 2022. (Publicado En Página Web 23-05-2022) (F.D.O. 25-05-2022)–SUBPESCA Normativa. Available online: <https://www.subpesca.cl/portal/615/w3-article-114576.html> (accessed on 27 June 2022).
7. Memoria Corpesca. 2021. Available online: <https://www.corpesca.cl/wp-content/uploads/2022/04/Memoria-Anual-Corpesca-2021.pdf> (accessed on 27 June 2022).
8. Memoria Camanchaca. 2021. Available online: <https://www.camanchaca.cl/wp-content/uploads/2022/04/Camanchaca-Memoria-2021-web.pdf> (accessed on 27 June 2022).
9. NOAA Climate Prediction Center. Available online: [https://origin.cpc.ncep.noaa.gov/products/analysis\\_monitoring/ensostuff/ONI\\_v5.php](https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php) (accessed on 29 October 2020).
10. Ley N° 19.713 Establece Como Medida de Administración el Límite Máximo de Captura por Armador a las Principales Pesquerías Industriales Nacionales y la Regularización del Registro Pesquero Artesanal; Subsecretaría de Pesca; Ministerio de Economía, Fomento y Reconstrucción: Santiago, Chile, 2001.
11. Ley N° 19.822 Modifica la ley N° 19.713, Incorporando las Unidades de Pesquería que Indica en las Zonas que Señala la Medida de Administración Límite Máximo de Captura por Armador; Subsecretaría de Pesca; Ministerio de Economía, Fomento y Reconstrucción: Santiago, Chile, 2002.
12. Nammalwar, P.; Satheesh, S.; Ramesh, R. Applications of remote sensing in the validations of potential fishing zones (PFZ) along the Coast of North Tamil Nadu, India. *Indian J. Mar. Sci.* **2013**, *42*, 283–292.
13. Wang, J.; Yu, W.; Chen, X.; Lei, L.; Chen, Y. Detection of potential fishing zones for neon flying squid based on remote-sensing data in the northwest Pacific Ocean using an artificial neural network. *Int. J. Remote Sens.* **2015**, *36*, 3317–3330. [[CrossRef](#)]
14. Suryanarayana, I.; Braibanti, A.; Sambasiva Rao, R.; Ramam, V.A.; Sudarsan, D.; Nageswara Rao, G. Neural networks in fisheries research. *Fish. Res.* **2008**, *92*, 115–139. [[CrossRef](#)]
15. Yáñez, E.; Plaza, F.; Gutiérrez-Estrada, J.C.; Rodríguez, N.; Barbieri, M.A.; Pulido-Calvo, I.; Bórquez, C. Anchovy (*Engraulis ringens*) and sardine (*Sardinops sagax*) abundance forecast off northern Chile: A multivariate ecosystemic neural network approach. *Prog. Oceanogr.* **2010**, *87*, 242–250. [[CrossRef](#)]
16. Home | CMEMS. Available online: <https://marine.copernicus.eu/> (accessed on 22 March 2022).
17. Data | Copernicus Marine. Available online: [https://resources.marine.copernicus.eu/product-detail/GLOBAL\\_ANALYSIS\\_FORECAST\\_PHY\\_001\\_024/INFORMATION](https://resources.marine.copernicus.eu/product-detail/GLOBAL_ANALYSIS_FORECAST_PHY_001_024/INFORMATION) (accessed on 22 March 2022).
18. Legaloudec, O.; Desportes, C.; Levier, B. Quality information document for global sea physical analysis and forecasting product. *Mercator Ocean. Q. Newsl.* **2019**, 1–100.
19. Madec, G.; Bourdallé-Badie, R.; Bouttier, P.-A.; Bricaud, C.; Bruciaferri, D.; Calvert, D.; Chanut, J.; Clementi, E.; Coward, A.; Delrosso, D.; et al. NEMO Ocean Engine. 2017. Available online: <https://zenodo.org/record/3248739#.Ys-BY4RBxPY> (accessed on 27 June 2022).
20. TensorFlow. Available online: <https://www.tensorflow.org/> (accessed on 27 June 2022).
21. Moolayil, J.; Moolayil, J.; John, S. *Learn Keras for Deep Neural Networks*; Springer: Berlin/Heidelberg, Germany, 2019.
22. Bertrand, S.; Diaz, E.; Lengaigne, M. Patterns in the spatial distribution of peruvian anchovy (*Engraulis ringens*) revealed by spatially explicit fishing data. *Prog. Oceanogr.* **2008**, *79*, 379–389. [[CrossRef](#)]
23. Sklearn.Preprocessing.StandardScaler–Scikit-Learn 1.1.1 Documentation. Available online: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html> (accessed on 27 June 2022).
24. Jin, H.; Song, Q.; Hu, X. Auto-Keras: An Efficient Neural Architecture Search System. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*; Association for Computing Machinery: New York, NY, USA, 2019; pp. 1946–1956.
25. Sharma, S.; Sharma, S.; Athaiya, A. Activation Functions in Neural Networks. *Int. J. Eng. Appl. Sci. Technol.* **2020**, *4*, 310–316. [[CrossRef](#)]
26. Kingma, D.P.; Ba, J.L. Adam: A method for stochastic optimization. In *Proceedings of the 3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, 7–9 May 2015*; pp. 1–15.
27. ReduceLRonPlateau. Available online: [https://keras.io/api/callbacks/reduce\\_lr\\_on\\_plateau/](https://keras.io/api/callbacks/reduce_lr_on_plateau/) (accessed on 27 June 2022).
28. EarlyStopping. Available online: [https://keras.io/api/callbacks/early\\_stopping/](https://keras.io/api/callbacks/early_stopping/) (accessed on 27 June 2022).
29. de Sá, C.R. Variance-based feature importance in neural networks. *Lect. Notes Comput. Sci.* **2019**, *11828*, 306–315. [[CrossRef](#)]
30. Verma, S.; Rubin, J. Fairness Definitions Explained. *Proc.-Int. Conf. Softw. Eng.* **2018**, *24*, 1–7. [[CrossRef](#)]
31. Wardhani, N.W.S.; Rochayani, M.Y.; Iriany, A.; Sulistyono, A.D.; Lestantyo, P. Cross-validation metrics for evaluating classification performance on imbalanced data. In *Proceedings of the 2019 International Conference on Computer, Control, Informatics and Its Applications, Tangerang, Indonesia, 23–24 October 2019*; pp. 14–18. [[CrossRef](#)]
32. Hoo, Z.H.; Candlish, J.; Teare, D. What is an ROC curve? *Emerg. Med. J.* **2017**, *34*, 357–359. [[CrossRef](#)] [[PubMed](#)]
33. Maina, I.; Kavadas, S.; Katsanevakis, S.; Somarakis, S.; Tserpes, G.; Georgakarakos, S. A methodological approach to identify fishing grounds: A case study on greek trawlers. *Fish. Res.* **2016**, *183*, 326–339. [[CrossRef](#)]

34. Mateo, R.G.; Felicísimo, Á.M.; Muñoz, J. Modelos de distribución de especies: Una revisión sintética. *Rev. Chil. Hist. Nat.* **2011**, *84*, 217–240. [[CrossRef](#)]
35. Zhang, X.; Saitoh, S.I.; Hirawake, T. Predicting potential fishing zones of japanese common squid (*Todarodes pacificus*) using remotely sensed images in coastal waters of South-Western Hokkaido, Japan. *Int. J. Remote Sens.* **2017**, *38*, 6129–6146. [[CrossRef](#)]
36. Barbieri, M.A.B.; Yáñez, E.R.; Farias, M.S.; Aguilera, R.H. Determination of probable fishing areas for the albacore (*Thunnus Alalunga*) in Chile's central zone. *Dig. Int. Geosci. Remote Sens. Symp.* **1989**, *4*, 2447–2450. [[CrossRef](#)]
37. Nieto, K.; Yáñez, E.; Silva, C.; Barbieri, M.A. Probable fishing grounds for anchovy in northern Chile using an expert system. *Int. Geosci. Remote Sens. Symp.* **2001**, *7*, 2985–2987. [[CrossRef](#)]
38. Silva, C.; Nieto, K.; Barbieri, M.A.; Yáñez, E. Expert systems for fishing ground prediction models: A management tool in the Humboldt ecosystem affected by ENSO. *Investig. Mar.* **2002**, *30*, 201–204. [[CrossRef](#)]
39. Yáñez, E.; Silva, C.; Nieto, K.; Barbieri, M.A.; Martínez, G. Using satellite technology improve chilean purseine fishing fleet. *Gayana* **2004**, *68*, 578–585. [[CrossRef](#)]
40. Silva, C.; Barbieri, M.A.; Yáñez, E.; Gutiérrez-Estrada, J.C.; Delvalls, Á. Using indicators and models for an ecosystem approach to fisheries and aquaculture management: The anchovy fishery and pacific oyster culture in Chile: Case studies. *J. Aquat. Res* **2012**, *40*, 955–969. [[CrossRef](#)]
41. Ren-Yan, D.; Xiao-Quan, K.; Min-Yi, H.; Wei-Yi, F.; Zhi-Gao, W. The predictive performance and stability of six species distribution models. *PLoS ONE* **2014**, *9*, e112764. [[CrossRef](#)]
42. Yusop, S.M.; Mustapha, M.A. Influence of oceanographic parameters on the seasonal potential fishing grounds of *Rastrelliger kanaqurta* using maximum entropy models and remotely sensed data. *Sains Malays.* **2019**, *48*, 259–269. [[CrossRef](#)]
43. Joy, M.K.; Death, R.G. Predictive modelling and spatial mapping of freshwater fish and decapod assemblages using GIS and neural networks. *Freshw. Biol.* **2004**, *49*, 1036–1052. [[CrossRef](#)]
44. Tan, C.O.; Beklioglu, M. Modeling complex nonlinear responses of shallow lakes to fish and hydrology using artificial neural networks. *Ecol. Modell.* **2006**, *196*, 183–194. [[CrossRef](#)]
45. Yúdaputra, A.; Robiansyah, I.; Rinandio, D.S. The Implementation of Artificial Neural Network and Random Forest in Ecological Research: Species Distribution Modelling with Presence and Absence Dataset. In Proceedings of the 3rd SATREPS Conference, 2019. Available online: <https://publikasikr.lipi.go.id/index.php/satreps/article/view/216> (accessed on 27 June 2022).
46. Melo-Merino, S.M.; Reyes-Bonilla, H.; Lira-Noriega, A. Ecological niche models and species distribution models in marine environments: A literature review and spatial analysis of evidence. *Ecol. Modell.* **2020**, *415*, 108837. [[CrossRef](#)]

### 5.3 Capítulo 3: Neural networks approach for detecting spatial changes in catch probability of *Engraulis ringens* during ENSO events in Northern Chile

#### Abstract

*Engraulis ringens* (anchovy) is a small pelagic fish of the Family Engraulidae that inhabits the neritic-coastal zone from northern Peru to south-central Chile. It is the main resource species of industrial fishing of northern Chile, representing 80% of the annual landings of the purse seine fleet. The history of this fishery (1985-2023) shows a strong decrease in annual industrial landings, especially during extreme El Niño Southern Oscillation (ENSO) events. The greatest decrease in landings in two decades occurred in 2020, coinciding with a cold La Niña event, which had not been observed in previous La Niña events. We evaluated whether the current decrease in annual landings of *E. ringens* is associated with oceanographic changes in northern Chile during El Niño or La Niña events. We applied a neuronal network model to identify the spatial and temporal distribution of *E. ringens* using the catch probability of each boat of the industrial purse seine fleet. The selected oceanographic variables (sea surface temperature, salinity, depth of the mixed layer, sea height and currents) for the 2003-2020 period were obtained from the Copernicus Marine Environment Monitoring Service (CMEMS program) and used as predictor variables of the monthly landings of *E. ringens*. The neural network model explained 97% of the monthly variability of catch probability of *E. ringens* by the industrial purse seine fleet. The spatial distribution of catch probability of *E. ringens* was analyzed independently for El Niño (2015), La Niña (2007, 2013, 2020) and Neutral (2004) years. We found that catch probability extended further west during La Niña events (except for 2020), occupying a greater area, but were limited to a 10 nautical mile coastal strip during the El Niño event. The spatial distribution of catch probability in the Neutral condition was near the coast, although not as restricted as during the 2015 El Niño event. The higher catch probabilities in the La Niña event of 2020 were near the coast, in contrast to the previous events of 2007 and 2013, due to the restriction of the optimal habitat of *E. ringens* because of changes in oceanographic conditions. The application of the results of this study will allow understanding, and probably anticipating the consequences that extreme ENSO events could have on the yield of the industrial anchovy purse seine fleet in northern Chile.

# Neural network approach for detecting spatial changes in catch probability of *Engraulis ringens* during El Niño-Southern Oscillation events in northern Chile

Elier Armas<sup>1,2</sup>  | Hugo Arancibia<sup>1</sup> | Sergio Neira<sup>2,3,4</sup> | María Carla Marín<sup>1,5</sup>

<sup>1</sup>Centro de Investigación Aplicada del Mar (CIAM), Iquique, Chile

<sup>2</sup>Programa de Doctorado en Ciencias con mención Manejo de Recursos Acuáticos Renovables (MaReA), Departamento de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, Concepción, Chile

<sup>3</sup>Departamento de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, Concepción, Chile

<sup>4</sup>Programa COPAS COASTAL ANID FB210021, Departamento de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, Concepción, Chile

<sup>5</sup>Programa de Doctorado en Oceanografía, Departamento de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, Concepción, Chile

## Correspondence

Elier Armas, Centro de Investigación Aplicada del Mar (CIAM), Av. Arturo Prat #33, Iquique, Chile.  
Email: elorenz1991@gmail.com

## Funding information

This research was funded by Conicyt + Pai/Concurso Nacional Tesis de Doctorado en el Sector Productivo, Convocatoria 2019 + Folio (T7819110004).

## Abstract

*Engraulis ringens* (anchovy) is a small pelagic fish of the Family Engraulidae that inhabits the neretic-coastal zone from northern Peru to south-central Chile. It is the main resource species of industrial fishing of northern Chile, representing 80% of the annual landings of the purse seine fleet. The history of this fishery (1985–2023) shows a strong decrease in annual industrial landings, especially during extreme El Niño–Southern Oscillation (ENSO) events. The greatest decrease in landings in two decades occurred in 2020, coinciding with a cold La Niña event, which had not been observed in previous La Niña events. We evaluated whether the current decrease in annual landings of *E. ringens* is associated with oceanographic changes in northern Chile during El Niño or La Niña events. We applied a neuronal network model to identify the spatial and temporal distribution of *E. ringens* using the catch probability of each boat of the industrial purse seine fleet. The selected oceanographic variables (sea surface temperature, salinity, depth of the mixed layer, sea height and currents) for the 2003–2020 period were obtained from the Copernicus Marine Environment Monitoring Service (CMEMS program) and used as predictor variables of the monthly landings of *E. ringens*. The neural network model explained 97% of the monthly variability of catch probability of *E. ringens* by the industrial purse seine fleet. The spatial distribution of catch probability of *E. ringens* was analyzed independently for El Niño (2015), La Niña (2007, 2013, and 2020), and Neutral (2004) years. We found that catch probability extended further west during La Niña events (except for 2020), occupying a greater area, but were limited to a 10 nautical mile coastal strip during the El Niño event. The spatial distribution of catch probability in the Neutral condition was near the coast, although not as restricted as during the El Niño event. The higher catch probabilities in the La Niña event of 2020 were near the coast, in contrast to the previous La Niña events of 2007 and 2013, due to the restriction of the optimal habitat of *E. ringens* in response to changes in oceanographic conditions. The application of the results of this study will allow understanding and probably anticipating the consequences that extreme ENSO events could have on the catch probability of the industrial anchovy purse seine fleet in northern Chile.

## KEYWORDS


anchovy; catch probability; *Engraulis ringens*; ENSO, El Niño, La Niña; neural network model; northern Chile; potential fishing grounds

## 1 | INTRODUCTION

*Engraulis ringens* (anchovy) is a small pelagic fish of the Family Engraulidae that inhabits the neritic-coastal zone from northern Peru to south-central Chile (Cubillos et al., 2007), mainly in the first few miles off the coast; the highest landings are in the first 10 nm (Espíndola et al., 2018; Silva et al., 2016). *E. ringens* represents 80% of the annual landings of the purse seine fleet in northern Chile (18°–21° S to 27° S, Figure 1); it is only captured in this way. Anchovy fishing is regulated by the Total Allowable Catch (TAC); the administrative norm is the Maximum Annual Catch per Ship Owner (Ministerio De Economía, 2002, 2001), which stimulates the participating companies to regulate the fishing effort to reduce operational costs and obtain better yields. The purse seine fleet of northern Chile is composed of two large fishing companies, whose ships together catch 85% of the TAC; the rest is captured by the artisanal purse seine fleet ("Dec. Ex. N° 22-2022", 2022).

The El Niño–Southern Oscillation (ENSO) is the most important ocean forcing in the study area (Espíndola et al., 2018). ENSO events produce strong changes in oceanographic conditions, affecting the behavior, biomass and biological processes of pelagic fish such as

*E. ringens* (Bouchon et al., 2015; Niquen & Bouchon, 2004). Trade wind fluctuations during the positive ENSO phase generate Kelvin waves that move towards the coast of South America; some of them are reflected in Rossby waves and others are propagated as waves trapped near the coast, reaching the coast of Chile and having a key role in the variability of the sea surface temperature (SST) (Hormazabal et al., 2002). These waves modify the depth of the thermocline, oxycline, and nutricline, compressing or expanding the habitat of *E. ringens* and modulating its spatial distribution (Parada et al., 2013). Coastal upwelling decreases during El Niño events, deepening the minimum oxygen level (Cahuin et al., 2015). The first consequence is an increase in the landings of *E. ringens* since the schools approach the coast. However, catch soon decreases, since the schools go deeper in the water column (Böhm et al., 2017). During the cold La Niña events coastal upwelling increases, increasing both the temperature and nutrient content of the masses of water that emerge, producing a favorable offshore environment, and expanding the distribution area of *E. ringens* up to 180 nm to the west (Bouchon & Peña, 2008; Gutiérrez et al., 2007). During these events, the schools of *E. ringens* are more disperse, even if there is greater biomass (Gutiérrez et al., 2007).



**FIGURE 1** Stock of anchovy (*Engraulis ringens*) distributed from southern Peru to northern Chile (16–27° S). The left panel indicates the distribution of *E. ringens* in northern Chile, which is the study area covered by a neural network model applied to estimate *E. ringens* catch probability.

The total annual landings of *E. ringens* by the purse seine fleets of southern Peru and northern Chile decreased during the very intense El Niño of 1997–1998, the moderate event of 2002–2003 and the very intense event of 2015–2016 (Armas et al., 2022; Böhm et al., 2017). The National Oceanic and Atmospheric Administration (NOAA) declared that a La Niña event began to be observed in June–September 2020, with an anomaly of  $-0.5^{\circ}\text{C}$  below the historical mean (“Climate Prediction Center - ONI”, 2022, “October 2020 La Niña update|NOAA Climate.gov”, 2020); it lasted until December 2022. Landings were lower in 2020 (Figure 2).

Due to the decrease in landings of *E. ringens* by the purse seine fleet of northern Chile (Corpesca S.A) during the El Niño event of 2015–2016 and especially during La Niña 2020, we proposed to identify how the spatial distribution of the harvest of the industrial fleet changes using the catch probability (CP) with respect to the oceanographic variability during these events (El Niño, La Niña, Neutral). Previously, Nieto et al. (2001), Silva et al. (2002), Yáñez et al. (2004), and Silva et al. (2012) identified probable fishing grounds of *E. ringens* using satellite information of the oceanographic variables SST, thermal gradients (TGR), and chlorophyll concentration (Chl); they identified 74% of the real fishing zones within the probable fishing grounds for specific years (1999–2000). We are not aware that these studies had practical application in the administration of the fleet.

Recently, Armas et al. (2022) demonstrated the efficacy of neural network models to identify areas with high CP of *E. ringens* by the industrial seine fleet in northern Chile in the short term (1–3 days). The good performance of this model (86%) allowed its application to longer time scales (monthly, quarterly, annual) to analyze how the distribution of *E. ringens* catches vary during ENSO events. In this study, it is proposed to take a step further by demonstrating that the model can capture interannual variability in the distribution of fishing probabilities and how these variations impact the performance of the purse seine fleet in northern Chile. Although there are studies relating El Niño events to the spatial distribution and landings of *E. ringens* (Bouchon & Peña, 2008; Gutiérrez et al., 2007; Ortiz, 2021;


Xu et al., 2013), this relation has been little studied during La Niña events (Bouchon & Peña, 2008). There are no time series studies that cover multiple ENSO phases and their relationship with the spatio-temporal distribution of *E. ringens* in northern Chile. In addition, there is no study that explain the strong decrease in the annual industrial landings of *E. ringens* in northern Chile during the extensive La Niña event of 2020–2022. Thus, the objectives of this study are (i) to analyze the changes in CP of *E. ringens* in response to the oceanographic variability during El Niño (2015), La Niña (2007, 2013, and 2020), and Neutral (2004) periods using neural networks and (ii) to explore the existence of a relationship between the CP estimated by the neural network model and the annual industrial landings in northern Chile.

## 2 | MATERIALS AND METHODS

### 2.1 | Fishery and environmental data

To estimate the CP of *E. ringens* using neural networks, we used monthly fishing and oceanographic information from January 2003 to December 2020, from latitudes between  $18^{\circ}\text{S}$  and  $26^{\circ}\text{S}$  and from the coast to  $73^{\circ}\text{W}$  (Figure 1). The monthly georeferenced catch data per boat and the trajectories of the boats in the fishing trips were obtained from the database of Corpesca S.A., since this is the only georeferenced information available and its boats compose 70% of the total industrial purse seine fleet of northern Chile (“Memoria Camanchaca”, 2021, “Memoria Corpesca”, 2021).

These data have a spatial resolution of  $3 \times 3$  nm, which we call quadrants, and include the month, year, geographic location of each quadrant through which a ship passed (latitude, longitude), and the monthly landing per boat (tons). Each quadrant was associated with the oceanographic variables sea surface temperature, salinity, depth of the mixing layer, currents, and sea height, which were obtained from the Global Analysis Forecast Phy 001024 (“Data|Copernicus Marine”, 2022) of the Copernicus Marine Environment Monitoring Service program (“Home|CMEMS”, 2022). The physical model that supports this product is NEMO (Madec et al., 2017), which has valid and good-quality time series (Lellouche et al., 2019). To make the temporal oceanographic data coincide with the fishing data, for each quadrant, we calculated the monthly mean per year of each oceanographic variable. The combination of these data sources provided a base with 3.6 million records. Within the time series 2003–2020 (which is the only one available with catch data), we selected data of years with conditions associated with El Niño (2015), Neutral (2004), and La Niña (2007, 2013, and 2020) to determine the influence of ENSO events on the spatial distribution and CP of *E. ringens*. We used the Índice Costero de El Niño (ICEN, Índice Costero El Niño (ICEN) (imarpe.gob.pe)) as a reference, since it is a relevant indicator of the oceanographic conditions of the South American coast (Adams & Flores, 2016; Farias & Montero, 2019; Ramírez & Briones, 2017; Takahashi et al., 2014).



**FIGURE 2** Landings (Y axis, left) and fishing effort (Y axis, right), measured as the number of  $3 \times 3$  nm areas fished by the purse seine fleet of Corpesca S.A. in 2003–2020. Source: Corpesca S.A.

## 2.2 | Fishing effort and CP of *E. ringens* and yield of the fleet

We used the number of quadrants visited monthly by ships of the industrial fleet as a measure of fishing effort. The trajectories of each boat were obtained from GPS data available in the Corpesca S.A. database. We considered a quadrant visited if it was crossed by at least one industrial boat in 1 month. This assumption was the best possible considering the lack of data to differentiate whether boats were actively searching (with acoustic equipment turned on) when passing through a specific area. The CP of the fleet was calculated as the proportion of quadrants with catch divided by the quadrants visited by the entire fleet, that is,

$$CP = \frac{TC}{TV} \quad (1)$$

CP is the CP; TC is the number of quadrants in which the fleet captured *E. ringens*, and TV is the total number of quadrants visited by the fleet (fishing effort).

The yield of the industrial fleet was calculated as the ratio of landings (tons) to the number of quadrants visited by the whole fleet:

$$FY = \frac{C}{TV} \quad (2)$$

where FY is fishing yield, C is the catch of *E. ringens* in tons, and TV is the total quadrants visited by the fleet (fishing effort). CP and FY were calculated for each selected year and for each interval of 5 nm (width of each band for which CP and FY were calculated annually) from the coastline to 70 nm to the west (distance commonly frequented by the fleet). Equations (1) and (2) were developed by us based on the available data.

## 2.3 | Model application and validation

We used a model of neural networks previously trained and validated by Armas et al. (2022) to estimate the monthly probability of encountering schools of *E. ringens*. This model was implemented in the Python language, using Tensorflow version 2.8 ("TensorFlow", 2022) and the Keras library (Moolayil et al., 2019). The architecture of the neural network that composes the model is a multilayer perceptron with nine neurons in each entry layer, two intermediate layers of 1024 and 512 neurons, with a ReLU activation function (Sharma et al., 2020) and an exit layer of a neuron with a sigmoid activation function (Sharma et al., 2020) (see detailed architecture in Armas et al., 2022). Since in this study we used the trained model built by Armas et al. (2022), we considered the same predictor variables selected these authors: monthly means of sea surface temperature, salinity (surface), depth of the mixing layer, currents (surface), and sea height as predictor variables of the CP of *E. ringens* (Armas

et al., 2022). To train the neural network model described in Armas et al. (2022), a cross-correlation test was conducted for each of the oceanographic variables. No significant correlations were found among variables, so they were considered as independent. The impact of oceanographic factors on the distribution of *E. ringens* was calculated using the neural network model itself. For more details see Armas et al. (2022). We applied the model to the entire series (2003–2020), obtaining a value between 0 and 1 for each quadrant, which is the monthly CP of *E. ringens* estimated by the model.

The performance of the model was evaluated by comparing the CP of *E. ringens* by the fleet to that estimated by the model. The database was divided into intervals of 0.01 according to the probabilities resulting from applying the model. For each interval, we calculated the fleet CP (Equation 1); the curve was fit to determine the degree of association of CP with the probability estimated by the model.

## 2.4 | Detecting spatial changes in CP of *E. ringens* during ENSO events using a model based on an artificial neural network

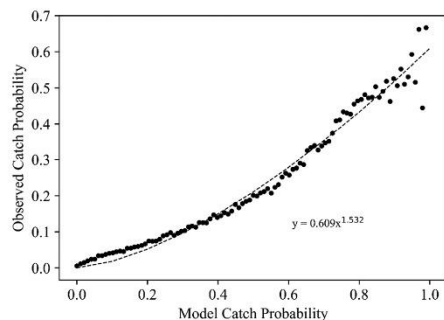
To determine the behavior of the CP of during different phases of ENSO we compared the selected years, by range of distance to the coast (5 nm), between the school encounters of *E. ringens* estimated by the model and the observed catch probabilities (CP) and the fleet yield (FY). The probabilities estimated by the model were averaged in intervals of 5 nm so they would correspond to the CP and FY for the same intervals.

The catch probabilities estimated by the model for each quadrant were averaged, to map and compare the catch probabilities for the selected periods. We chose quarterly as the temporal scale, assuming that this is the time scale in which the catches have the smallest variance (Pennington, 1996), and that this will also allow capturing the seasonal variability in the distribution of *E. ringens* in different seasons (Castillo et al., 2016; Yáñez et al., 2008). To test for a relation between the number of annual areas with high CP (potential fishing ground, PFG), which the model estimates and the annual landings of *E. ringens*, for each year of the 2003–2020 series we used the number of PFG as the number of quadrants with CP greater than 0.5, from the coast out to 100 nm. We fit a linear model to estimate the percentage of the variability in landings explained by the number of PFG available each year.

## 3 | RESULTS

### 3.1 | Performance of the artificial neural network forecasting model

The observed CP of the purse seine fleet and the CP estimated by the neural network model showed a potential type relationship (Figure 3) by the following expression:



**FIGURE 3** Relationship between predicted (X axis) and observed (Y axis) catch probability of *Engraulis ringens* by the purse seine fleet of northern Chile. Period: 2003–2020.

$$y = 0.609x^{1.532} \quad (3)$$

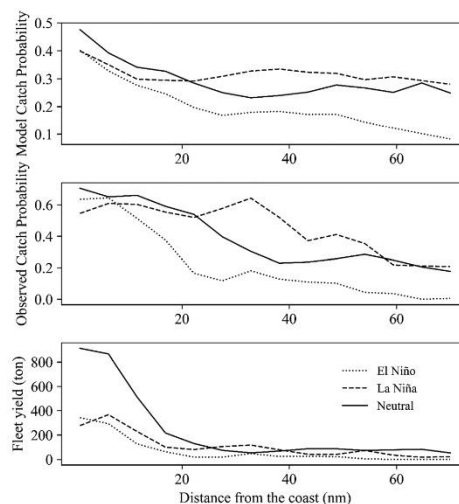
where  $y = CP$  (catch probability) and  $x$  is the probability given by the neural network model.

The potential model had an excellent fit ( $r^2 = 0.978$ , slope and intercept both significant, with probabilities near 0), indicating that the neural network used can estimate the fishing probability of the purse seine fleet of northern Chile. This potential type of relationship was also found in the El Niño, Neutral, and La Niña years (data not shown).

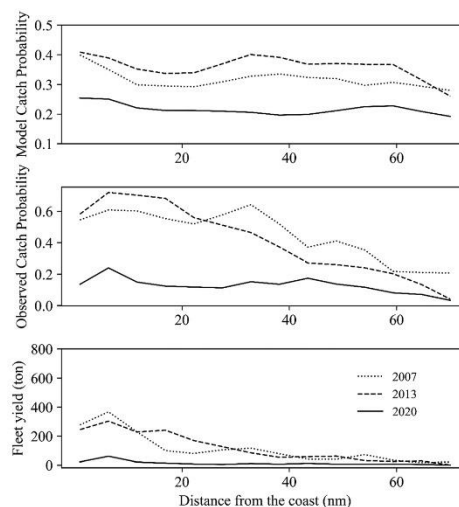
### 3.2 | Detecting spatial changes in CP of *E. ringens* during ENSO events using a model based on an artificial neural network

In Figure 4, we show the CP of *E. ringens* estimated by the neural network model (upper panel), the CP of the purse seine fleet (center panel), and the yield of the fleet (lower panel). The highest values of these three variables were in the coastal zone (<20 nm), especially in neutral conditions. The greatest differences among the three were found beyond 20 nm from the coast (Figure 4). The highest catch probabilities occurred in La Niña years, both estimated and observed. The fishing yield was greater closer to the coast, and there were no large differences in yield between La Niña years and the Neutral year beyond 20 nm from the coast. The three probabilities decreased farther from the coast during El Niño (2015), below the levels of *E. ringens* during La Niña years and the Neutral year.

In Figure 5, we compared the catch probabilities of schools and yield of the fleet in 3 years with La Niña (2007, 2013, and 2020). Both the catch probabilities estimated by the model and the yield of the fleet were greater in 2007 and 2013 compared with 2020. Fishing yield in 2007 and 2013 less than 20 nm from the coast was only about a quarter of that in the Neutral year (2004, Figure 4).



**FIGURE 4** Comparison between years with El Niño (2015) (dotted line), La Niña (2007) (dashed line), and Neutral (2004) (solid line) estimated by the model (upper panel), landings of the Corpesca S.A. fleet (middle panel), and yield (catch/quadrants searched by the fleet).



**FIGURE 5** Comparison between La Niña periods of 2007 (dotted line), 2013 (dashed line), and 2020 (solid line) of distance to the coast with respect to (a) mean of encounter probability of *Engraulis ringens* estimated by the model (upper panel), (b) fishing probability of the purse seine fleet of Corpesca S. A (middle panel), and (c) fishing yield (FY) (landings/quadrants fished by the fleet).



The fishing probabilities generated by the model (Figure 4, upper panel) are lower in the La Niña of 2020 compared with La Niña 2007 and 2013 in the first 70 nm from the coast. This was confirmed by the observed fishing probabilities (Figure 4, middle panel). The fleet yield was also lower in 2020 than in other La Niña years, especially in the coastal sector (Figure 4, lower panel).

In Figure 6, we show the mean fishing probabilities per trimester provided by the model for the years 2015, 2007, and 2004 (El Niño, La Niña, and Neutral, respectively). Black dots indicate where *E. ringens* were captured; note that these are mostly in the areas with highest catch probabilities. The highest fishing probabilities in the 2015 El Niño were near the coast, in contrast to the 2007 La Niña and the 2014 Neutral conditions. The greatest differences in the spatial distribution of fishing probability occurred in the June–September quarter in all three conditions. Catches occurred far from the coast in 2004 and 2007, in areas where the neural network model predicted the highest fishing probabilities. However, the highest landings and yield occurred within the first 20 nm (Figures 4 and 6).

In Figure 7, we show three periods with environmental conditions characteristic of La Niña (2007, 2013, and 2020). In the July–September quarter, there was more expansion to the west to areas with high fishing probability according to the model (>0.5). In the 2007 and 2013 La Niña years, there were larger areas with high fishing probability in all quarters compared with 2020. Greater catch of *E. ringens* was observed in 2007 and 2013 (Figure 2). The areas with high CP in 2020 were reduced and very near the coast, in contrast with previous La Niña periods.

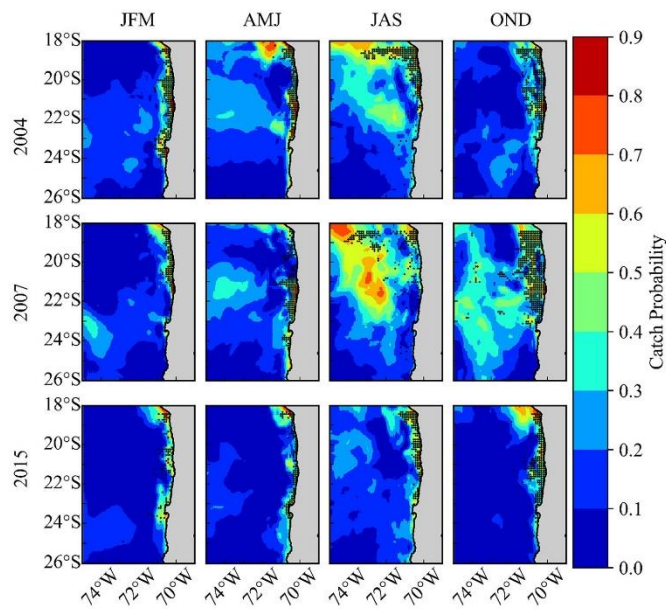
Landings of *E. ringens* were significantly correlated with the annual number of favorable quadrants for encountering this species or PFG (Pearson correlation 0.86,  $p$ -value =  $1.1 \times 10^{-5}$ ). Both variables showed a tendency to decrease in the last 10 years (Figure 8), and are linearly related (Figure 9) by the following expression:

$$y = 0.086x - 0.283 \quad (3)$$

where  $y$  is the total annual landing of *E. ringens* (tons) and  $x$  is the number of favorable quadrants for finding schools detected annually by the model (quadrants with probability >0.5). Both the slope and fit were significant, with  $p$ -values of 0 and 0.01, respectively. The relationship between annual landings of *E. ringens* and the number of PFGs was linear and significant ( $r^2 = 0.74$ ;  $p$ -value = 0.01).



#### 4 | DISCUSSION

This study aimed to understand the spatial changes of *E. ringens* during El Niño, La Niña, and Neutral event; these have direct influence in the probable fishing areas and the landings of the industrial fleet, which has been decreasing in recent years (Figure 2). We used a neural network model which has proven its efficacy in representing non-linear processes (Armas et al., 2022; Tan & Beklioglu, 2006) such as those of the relation between oceanographic variables and the distribution of species in the ocean (Wang et al., 2015).



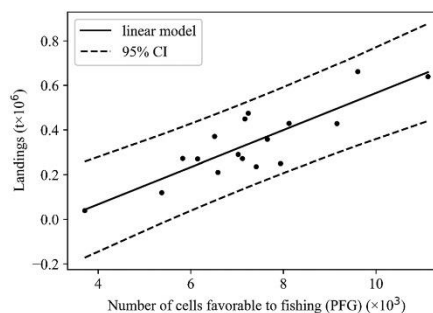
**FIGURE 6** Maps of catch probabilities estimated quarterly by the neural network model applied to the fishery of *Engraulis ringens* in northern Chile for the 3 years chosen: El Niño (2015), La Niña (2007), neutral (2004). Black dots indicate where *E. ringens* was captured.

**FIGURE 7** Maps of catch probabilities estimated quarterly by the neural network model applied to the fishery of *Engraulis ringens* in northern Chile for the three La Niña periods chosen (2007, 2013, and 2020). Black dots indicate where *E. ringens* was captured.



**FIGURE 8** Number of potential fishing grounds of *Engraulis ringens* estimated annually by the neural network model applied to the 2003–2020 period in northern Chile (solid line) and annual landings of the fleet of Corpesca S. A (dashed line).

This approach, requiring few assumptions about fishery and environmental data, outperforms conventional statistical models such as generalized linear models (GLM) and generalized additive models (GAM) (Mateo et al., 2011; Suryanarayana et al., 2008; Tan & Beklioglu, 2006; Wang et al., 2015). GLM and GAM rely on assumptions such as linearity, normality, and homoscedasticity, which are often challenging to meet due to nonlinearity in ecological processes (Tan & Beklioglu, 2006) and complex environment–resource interactions (Wang et al., 2015). Since the model was trained using only



**FIGURE 9** Linear fit of landings of the fleet Corpesca S. A and the number of quadrants estimated by the model as potential fishing grounds of *Engraulis ringens* in northern Chile in 2003–2020. The fit of the model was ( $r^2 = 0.74$ ,  $p$ -value = 0.01,  $p$ -value of the intercept = 0).

oceanographic variables, any variation in fishing probabilities estimated by the model would be a consequence of oceanographic changes. Relationships, such as predation and food competition, may be important in the system, but they are not considered in this study due to lack of time series of abundance and distribution of groups that are predators, prey, and competitors for *E. ringens*.

Monthly application of the model (Figure 3) proved to be effective, since the observed catch probabilities of the fleet potentially

increased with the increase in the predicted number of catch probabilities (Figure 3). The catch quadrants of the fleet were strongly correlated with the quadrants with highest quarterly catch probabilities (Figures 6 and 7). Thus, the temporal scale of the neural network model was able to identify potential fishing grounds of *E. ringens*; capturing the spatial variability of the catch probabilities of this species during ENSO events in the years 2007, 2013, 2015, and 2020 (Figures 6 and 7). In these 4 years, the highest catch probabilities estimated by the model occurred in the coastal area (<20 nm) (Figures 4 and 5), coinciding with the observed CP and fishing yield of the fleet. This agrees with previous studies, in which the greatest catches and acoustic density of anchovies were found in the first 2 nm from the coast (Espindola et al., 2018; Hernández-Santoro et al., 2019; Silva et al., 2016). The fishing yield of the fleet decreased to less than half beyond 20 nm from the coast in La Niña, El Niño and Neutral years.

The catch probabilities estimated for *E. ringens* in 2015 (El Niño) by the model had the same tendencies as the observed CP (Figure 4), lower than the catch probabilities in 2004 (Neutral) and 2007 (La Niña). The catch probabilities and yields were greater near the coast; both variables decreased rapidly as distance from the coast increased. It is well-known that during warm El Niño events, coastal upwelling decreases and the minimum oxygen level is deeper (Cahuin et al., 2015). The schools approach the coast, then go deeper in the water column becoming less accessible to purse seine nets, producing a decrease in catch and fishing yield (Böhm et al., 2017; Yáñez et al., 2008), which agrees with the results of this study for the 2015 El Niño year.

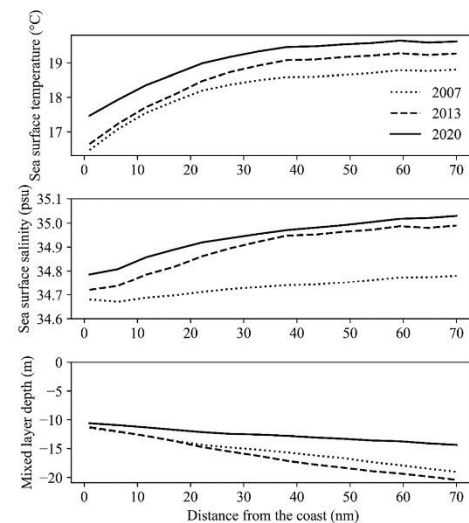
There was less difference in the fishing probability of *E. ringens* in the La Niña years (2007, 2013, and 2020) between the coastal sector (<20 nm) and the oceanic sector (>20 nm) (Figures 4 and 5), indicating that favorable oceanic conditions for the presence of this species were more homogenous. This led to an increase in the probability of encounter of schools of *E. ringens* farther from the coast (Bouchon & Peña, 2008; Gutiérrez et al., 2007; Segura & Vásquez, 2002). During La Niña events, the thermocline, oxycline, and nutricline are all shallower (Parada et al., 2013), reducing the vertical habitat of *E. ringens* and causing the schools to be closer to the surface (Bouchon & Peña, 2008) and more expanded horizontally (Bouchon & Peña, 2008; Gutiérrez et al., 2007; Segura & Vásquez, 2002). Schools of *E. ringens* have been detected up to 200 nm from the coast during these cold periods (Bouchon & Peña, 2008; Segura & Vásquez, 2002), with wider dispersion of the schools (Bouchon & Peña, 2008; Gutiérrez et al., 2007; Yáñez et al., 2008); this dispersion makes fishing more difficult (Yáñez et al., 2008).

The year 2004 (neutral year) stands out in the studied period, since it had the greatest catch probabilities of *E. ringens* (Figure 4) and had the highest landings (Figure 2). This result is consistent with previous reports (Bertrand et al., 2008; Gutiérrez et al., 2007; Yáñez et al., 2008), since *E. ringens* moves near the coast with shallow schools in neutral oceanographic periods (Yáñez et al., 2008). Thus, schools are more compact and accessible in neutral periods, which make them more vulnerable to capture than in cold periods like La Niña, when they are more disperse and farther from the coast

(Gutiérrez et al., 2007; Yáñez et al., 2008). The consequence is that the fleet uses less searching effort and obtains better yield in neutral periods (Bertrand et al., 2008).

The last 3 years (2020–2022) had La Niña conditions, with lower landings of *E. ringens*, different than in the La Niña events of 2007 and 2013 when catch increased (Figure 2). This difference in landings may be produced by oceanographic and biological conditions, and by the operation of the fleet. This study used the variation in CP estimated by a neural network model as an approximation to the change in oceanographic conditions favorable to *E. ringens*. The catch probabilities in 2020 were more costal and reduced, in contrast to earlier La Niña events (Figure 7) and with previous knowledge on the spatial distribution of *E. ringens* during La Niña events (Bouchon & Peña, 2008; Gutiérrez et al., 2007; Segura & Vásquez, 2002). This implies that oceanographic conditions were different than in previous events of this kind.

The surface temperature of the ocean in 2020 was almost 1°C higher than the temperature observed in other La Niña events (Figure 10, upper panel). Salinity is an important factor in the distribution of *E. ringens*, since it is a stenohaline species (Luján, 2016); salinity was 0.1 greater in 2020 than in 2007 and 2013 (Figure 10, central panel). The mixing layer was shallower (between one and 2.5 m in the first 20 nm) in 2020 with respect to 2007 and 2013 (Figure 10, lower panel). The 15°C isotherm and the depth of the oxygen minimum zone (OMZ) were less than 15 m (PROGRAMA BIO-OCEANOGRÁFICO-PESQUERO DE LA ZONA NORTE DE CHILE [18°S-23°S] UNAP-



**FIGURE 10** Oceanographic variables studied during La Niña events of 2007 (dotted line), 2013 (dashed line), and 2020 (solid line). X axis: distance to the coast; Y axis: sea surface temperature; salinity (center panel); depth of the mixing layer (lower panel).

CIAM in the winter and spring of 2020 and summer, 2021; <https://www.ciamchile.cl/documentos/>). These two variables and the depth of the mixing layer restricted the vertical habitat of *E. ringens*, producing greater dispersion of its schools. The consequence was that in 2020 the usual spatial distribution of *E. ringens* was modified in northern Chile (in the first 20 nm west of the coast), making it hard for the industrial purse seine fleet to find its schools in more oceanic waters. Thus, the highest catch probabilities by the fleet were restricted to very coastal sectors (first 5 nm from the coast), with colder temperatures (Figure 10, upper panel).

The areas with highest CP (more accessible to the fleet) in 2020 were reduced to a small strip of 10 nm along the coast (Figure 7). The consequence was the area available to search for schools of *E. ringens* was reduced even more; most of the schools were out of reach of the industrial fleet (the first 5 nm are reserved for artisanal fishing). Due to this, the fleet obviously reduced the number of fishing trips significantly (Figure 2). The combination of a reduced fishing area and lower fishing effort led to a strong reduction in landings in 2020, lower than it had ever been in 2003–2019.

The annual number of potential catch quadrants identified by the neural network model is an indicator of how apt the environment is for finding schools of *E. ringens*, since the more quadrants that are favorable for finding schools, the greater is the probability that they will be visited by the fleet and caught. This variable was highly correlated with landings (Figures 8 and 9), explaining 74% of the variability. The lowest numbers of potential fishing zones were found in 2015, 2016, and 2020, coinciding with the greatest decreases in the landings of *E. ringens* (Figure 9).

The neural network model we implemented has some disadvantages and limitations related to the neural network itself and others with the entry data. The neural network model is a black box model, given the difficulty in interpreting the internal mechanism by which it makes its predictions (Olden et al., 2004). A previous study (Armas et al., 2022) analyzed the importance of each variable. However, this study focused on determining changes in the oceanographic condition using the fishing probability estimated by the neural network model. Despite that in this study we had only one El Niño year and one Neutral year in the time series, results obtained for these years regarding the distribution of catch probabilities of *E. ringens* agreed with the existing knowledge and studies conducted by other authors, validating the outcomes.

One of the assumptions of this research was that the boats are constantly searching for the *E. ringens* resource and that if they find a favorable fishing zone, they will stop to fish. This would be extremely challenging without a comprehensive historical record of such decisions. Ideally, detailed information from the swept area would be needed, something achievable only through short-duration seasonal acoustic surveys, and even the recently incorporated electronic logs do not capture this type of information. Although this assumption overlooks schools of little interest to the fleet, such as those very deep or scattered, potentially leading to an underestimation of *E. ringens* distribution, the model has demonstrated acceptable results. The neural network's learning capability, by assigning more weight to

crucial observations, generated consistent outcomes despite this assumption.

Although our objective was to provide a comprehensive representation of the effects of the ENSO phenomenon on the distribution of *E. ringens*, it is well-known that each occurrence of El Niño exhibits distinct characteristics in terms of its spatial and temporal attributes, evolutionary patterns, and associated effects. Therefore, our conclusions are confined to the observed events. We encourage that future studies expand the duration of the study period as time series become available. This will allow discerning overarching trends by through the analysis of multiple cases for El Niño, Neutral, and La Niña years.

This study goes a step further than Armas et al. (2022), adopting a longer-term temporal perspective at a monthly and quarterly scale, exploring changes in the spatio-temporal distribution of *E. ringens* in response to extreme El Niño and La Niña events. This approach provides a robust foundation for medium-term analysis and decision-making in fisheries management, expanding the utility of the model beyond short-term predictions. We demonstrated that neural networks are a valid approach to identify changes in fishing probability of *E. ringens* during the different phases of the ENSO cycle in northern Chile. The relation found between the number of potential fishing grounds and the annual industrial landings of *E. ringens* shows the importance that oceanographic changes have in the distribution and availability of the species for fishing, and thus in the yield of the fleet and the level of annual landings. The application of our results will improve both our understanding and the capacity to predict the consequences of ENSO events on the probability that the fleet will find schools of *E. ringens*. Its application will allow better administration of the fleet, reducing operational costs.

#### AUTHOR CONTRIBUTIONS

Conceptualization: E.A., H.A., S.N., and M.M. Methodology: E.A., H.A., and M.M. Software: E.A. and M.M. Validation: E.A. and M.M. Formal analysis: E.A. Investigation: E.A. and H.A. Resources: E.A. Data curation: E.A. and M.M. Writing—original draft preparation: E.A.: writing—review and editing: E.A., H.A., S.N., and M.M. Visualization: E.A., H.A., and M.M. Supervision: H.A. and S.N. Project administration: E.A. Funding acquisition: E.A. All authors have read and agreed to the published version of the manuscript.

#### ACKNOWLEDGMENTS

This study was conducted using E.U. Copernicus Marine Service Information (<https://doi.org/10.48670/moi-00016>). E.A. thanks the “Doctorado en Ciencias con mención en Manejo de Recursos Acuáticos Renovables (MaReA)” and Dirección de Postgrado of the Universidad de Concepción (Chile) for the financial support provided through student scholarships. E.A., H. A. S. N, and M.M. thank the “Centro de Investigación Aplicada del Mar” (<https://www.ciamchile.cl/> [accessed on 15 March 2021]) and Corpesca S. A (<https://www.corpesca.cl/> [accessed on 15 March 2021]) for providing the data, offices, and staff support to carry out this research. E.A. thanks the financial support of Conicyt + Pai/Concurso Nacional Tesis de Doctorado en el Sector Productivo, Convocatoria 2019 + Folio (T7819110004). We are

grateful to two anonymous reviewers whose comments and suggestions greatly improved an earlier version of this paper.

#### CONFLICT OF INTEREST STATEMENT

The authors declare no conflicts of interest.

#### DATA AVAILABILITY STATEMENT

The data that support the findings of this study are available from the corresponding author upon reasonable request.

#### ORCID

Elier Armas  <https://orcid.org/0000-0002-0759-904X>

#### REFERENCES

- Adams, G. D., & Flores, D. (2016). El Niño Southern Oscillation driven fluctuations in the availability and abundance of artisanal fishery resources in Ica, Peru. *Revista de Biología Marina Y Oceanografía*, 51, 265–272. <https://doi.org/10.4067/s0718-19572016000200005>
- Armas, E., Arancibia, H., & Neira, S. (2022). Identification and forecast of potential fishing grounds for anchovy (*Engraulis ringens*) in northern Chile using neural networks modeling. *Fishes*, 7, 204. <https://doi.org/10.3390/fishes7040204>
- Bertrand, S., Dewitte, B., Tam, J., Diaz, E., & Bertrand, A. (2008). Impacts of Kelvin wave forcing in the Peru Humboldt current system: Scenarios of spatial reorganizations from physics to fishers. *Progress in Oceanography*, 79, 278–289. <https://doi.org/10.1016/j.pocean.2008.10.017>
- Böhm, M. G., Hernández, C., Díaz, E., Pérez, G., Ojeda, R., Cerna, F., Valero, C., Gómez, M., Machuca, C., & Muñoz, L. (2017). INFORME FINAL. Convenio de desempeño, 2016. Programa de Seguimiento de las Principales Pesquerías Pelágicas de la Zona Norte de Chile, XV – IV Regiones, año 2016. *Inst. Fom. Pesq.*
- Bouchon, M., & Peña, C. (2008). Impactos de los eventos la niña en la pesquería peruana. *Inf. del Inst. del Mar del Perú*, 35, 193–198.
- Bouchon, M., Peña, C., & Salcedo, J. (2015). El Evento El Niño y su impacto en la pesquería de Anchoveta en el mar peruano. *Boletín Trimest. Ocean.*, 1, 17–19.
- Cahuin, S., Cubillos, L. A., & Escribano, R. (2015). Synchronous patterns of fluctuations in two stocks of anchovy *Engraulis ringens* Jenyns, 1842 in the Humboldt current system. *Journal of Applied Ichthyology*, 31, 45–50. <https://doi.org/10.1111/jai.12646>
- Castillo, P. R., Madureira, L., Marangoni, J., Gerlotto, F., & Guevara-Carrasco, R. (2016). Variability in distribution and aggregation behavior of the Peruvian anchovy (*Engraulis ringens*) analyzed using a fifteen year long series of acoustic surveys (2000–2014). 2015 IEEE/OES Acoust. Underw. Geosci. Symp. RIO Acoust. 2015. <https://doi.org/10.1109/RIOAcoustics.2015.7473636>
- Climate Prediction Center - ONI [WWW Document], 2022. URL [https://origin.cpc.ncep.noaa.gov/products/analysis\\_monitoring/ensostuff/ONI\\_v5.php](https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php) (accedido 12.3.22).
- Cubillos, L. A., Serra, R., & Fréon, P. (2007). Synchronous pattern of fluctuation in three anchovy fisheries in the Humboldt current system. *Aquatic Living Resources*, 20, 69–75. <https://doi.org/10.1051/alr:2007017>
- Data[Copernicus Marine [WWW Document], 2022. URL [https://data.marine.copernicus.eu/product/GLOBAL\\_ANALYSISFORECAST\\_PHY\\_001\\_024/description](https://data.marine.copernicus.eu/product/GLOBAL_ANALYSISFORECAST_PHY_001_024/description) (accedido 3.22.22).
- Dec. Ex. N° 22-2022 [WWW Document], (2022). *Modif. Dec. Ex. Folio 202100228 Establ. Cuota Captura Unidades Pesca. Anchoveta y Sardina Española Zo. Norte Sometidas a Licencias Transables Pesca. Año 2022.* (Publicado en Página Web 23-05-2022) (F.D.O. 25-05-2022). SUB-PESCA Norma. URL <https://www.subpesca.cl/portal/615/w3-article-114576.html> (accedido 6.27.22)
- Espíndola, F., Quiroz, J. C., Böhm, G., Leiva, F., & Aros, J. A. (2018). INFORME 2 ESTATUS. Convenio de Desempeño 2017. Estatus y posibilidades de explotación biológicamente sustentables de los principales recursos pesqueros nacionales año 2018. *Anchoveta XV-II Regiones. Inst. Fom. Pesq.* <https://doi.org/10.13140/RG.2.2.20521.29285>
- Fariás, M., & Montero, K. (2019). Analysis of oceanic-atmospheric parameters and identification of occurrences of global El Niño and coastal El Niño between 1950 and 2018. 38th IAHR World Congr. - "Water Connect. World", 38, 4357–4365. <https://doi.org/10.3850/38wc092019-0721>
- Gutiérrez, M., Swartzman, G., Bertrand, A., & Bertrand, S. (2007). Anchovy (*Engraulis ringens*) and sardine (*Sardinops sagax*) spatial dynamics and aggregation patterns in the Humboldt current ecosystem, Peru, from 1983–2003. *Fisheries Oceanography*, 16, 155–168. <https://doi.org/10.1111/j.1365-2419.2006.00422.x>
- Hernández-Santoro, C., Landaeta, M. F., & Castillo Pizarro, J. (2019). Effect of ENSO on the distribution and concentration of catches and reproductive activity of anchovy *Engraulis ringens* in northern Chile. *Fisheries Oceanography*, 28, 241–255. <https://doi.org/10.1111/fog.12405>
- Home/CMEMS [WWW Document], 2022. URL <https://marine.copernicus.eu/> (accedido 3.22.22).
- Hormazabal, S., Shaffer, G., & Pizarro, O. (2002). Tropical Pacific control of intraseasonal oscillations off Chile by way of oceanic and atmospheric pathways. 29, 1–4. <https://doi.org/10.1029/2001GL013481>
- Lellouche, J.-M., Legaloudec, O., Desportes, C., & Levier, B. (2019). Quality information document for Global Sea physical analysis and forecasting product. *Mercat. Ocean. Q. News*, 1–100.
- Luján, D. (2016). *Factores Determinantes De La Variabilidad Espacial De Anchoveta Peruana (Engraulis ringens) En El Pacífico Sudoriental.* Tesis para optar al grado de Maestro en Ciencias del Mar. Universidad Peruana Cayetano Heredia.
- Madec, G., Bourdallé-Badie, R., Bouttier, P.-A., Bricaud, C., Bruciaferri, D., Calvert, D., Chanut, J., Clementi, E., Coward, A., Delrosso, D., Ethé, C., Flavoni, S., Graham, T., Harle, J., Iovino, D., Lea, D., Lévy, C., Lovato, T., Martin, N., Masson, S., Mocavero, S., Paul, J., Rousset, C., Storkey, D., Storto, A., Vancoppenolle, M., 2017. NEMO Ocean engine. <https://doi.org/10.5281/ZENODO.3248739>
- Mateo, R. G., Felicísimo, Á. M., & Muñoz, J. (2011). Modelos de distribución de especies: Una revisión sintética. *Revista Chilena de Historia Natural*, 84, 217–240. <https://doi.org/10.4067/S0716-078X2011000200008>
- Memoria Camanchaca [WWW Document], 2021. URL <https://www.camanchaca.cl/wp-content/uploads/2022/04/Camanchaca-Memoria-2021-web.pdf> (accedido 6.27.22).
- Memoria Corpesca [WWW Document], 2021. URL <https://www.corpesca.cl/wp-content/uploads/2022/04/Memoria-Anual-Corpesca-2021.pdf> (accedido 6.27.22).
- Ministerio De Economía, 2001. *Ley 19713 Establece Limite Máximo de Captura por Armador (LMCA).*
- Ministerio De Economía, 2002. *Ley 19.822 Extiende LMCA a pesquerías de sardina española; anchoveta y jurel en las regiones I y II.*
- Moolayil, J., Moolayil, J., & John, S. (2019). *Learn Keras for deep neural networks.* Springer. <https://doi.org/10.1007/978-1-4842-4240-7>
- Nieto, K., Yáñez, E., Silva, C., & Barbieri, M. A. (2001). Probable fishing grounds for anchovy in northern Chile using an expert system. *Int. Geosci. Remote Sens. Symp.*, 7, 2985–2987. <https://doi.org/10.1109/igars.2001.978230>
- Niquen, M., & Bouchon, M. (2004). Impact of El Niño events on pelagic fisheries in Peruvian waters. *Deep. Res. Part II Top. Stud. Oceanogr.*, 51, 563–574. <https://doi.org/10.1016/j.dsr2.2004.03.001>
- October 2020 La Niña update|NOAA Climate.gov [WWW Document], 2020. URL <https://www.climate.gov/news-features/blogs/enso/october-2020-la-ni%C3%B1a-update> (accedido 12.3.22).
- Olden, J. D., Joy, M. K., & Death, R. G. (2004). An accurate comparison of methods for quantifying variable importance in artificial neural

- networks using simulated data. *Ecological Modelling*, 178, 389–397. <https://doi.org/10.1016/j.ecolmodel.2004.03.013>
- Ortiz, M. (2021). Marine coastal ecosystems modelling and conservation. *Mar. Coast. Ecosyst. Model. Conserv.* <https://doi.org/10.1007/978-3-030-58211-1>
- Parada, C., Yanicelli, B., Hormazabal, S., Vásquez, S., Porobic, J., Ernst, B., Gatica, C., Arteaga, M., Montecinos, A., Nuñez, S., & Gretchina, A. (2013). Variabilidad ambiental y recursos pesqueros en el Pacífico sur-oriental: Estado de la investigación y desafíos para el manejo pesquero. *Latin American Journal of Aquatic Research*, 41, 1–28. <https://doi.org/10.3856/vol41-issue1-fulltext-1>
- Pennington, M. (1996). Estimating the mean and variance from highly skewed marine data. *Fishery Bulletin*, 94, 498–505.
- Ramírez, I. J., & Briones, F. (2017). Understanding the El Niño Costero of 2017: The definition problem and challenges of climate forecasting and disaster responses. *International Journal of Disaster Risk Science*, 8, 489–492. <https://doi.org/10.1007/s13753-017-0151-8>
- Segura, M., Vásquez, L., 2002. *Influence of the oceanographic conditions in the distribution and behavior of the anchovy (1–11)*.
- Sharma, S., Sharma, S., & Athaiya, A. (2020). Activation functions in neural networks. *Int. J. Eng. Appl. Sci. Technol.*, 4, 310–316. <https://doi.org/10.33564/IJEAST.2020.v04i12.054>
- Silva, C., Andrade, I., Yáñez, E., Hormazabal, S., Barbieri, M. A., Aranis, A., & Böhm, G. (2016). Predicting habitat suitability and geographic distribution of anchovy (*Engraulis ringens*) due to climate change in the coastal areas off Chile. *Progress in Oceanography*, 146, 159–174. <https://doi.org/10.1016/j.pocean.2016.06.006>
- Silva, C., Barbieri, M. A., Yáñez, E., Gutiérrez-Estrada, J. C., & Del Valls, T. Á. (2012). Using indicators and models for an ecosystem approach to fisheries and aquaculture management: The anchovy fishery and Pacific oyster culture in Chile: Case studies. *Latin American Journal of Aquatic Research*, 40, 955–969. <https://doi.org/10.3856/vol40-issue4-fulltext-12>
- Silva, C., Nieto, K., Barbieri, M. A., & Yáñez, E. (2002). Expert Systems for Fishing Ground Prediction Models: A management tool in the Humboldt ecosystem affected by ENSO. *Investigaciones Marinas*, 30, 201–204. <https://doi.org/10.4067/S0717-1782002030100088>
- Suryanarayana, I., Braibanti, A., Sambasiva Rao, R., Ramam, V. A., Sudarsan, D., & Nageswara Rao, G. (2008). Neural networks in fisheries research. *Fisheries Research*, 92, 115–139. <https://doi.org/10.1016/j.fishres.2008.01.012>
- Takahashi, K., Mosquera Vásquez, K.A., Reupo, J., 2014. *El Índice Costero El Niño (ICEN): Historia y actualización*.
- Tan, C. O., & Bekkioglu, M. (2006). Modeling complex nonlinear responses of shallow lakes to fish and hydrology using artificial neural networks. *Ecological Modelling*, 196, 183–194. <https://doi.org/10.1016/j.ecolmodel.2006.02.003>
- TensorFlow [WWW Document], 2022. URL <https://www.tensorflow.org/> (accedido 6.27.22).
- Wang, J., Yu, W., Chen, X., Lei, L., & Chen, Y. (2015). Detection of potential fishing zones for neon flying squid based on remote-sensing data in the Northwest Pacific Ocean using an artificial neural network. *International Journal of Remote Sensing*, 36, 3317–3330. <https://doi.org/10.1080/01431161.2015.1042121>
- Xu, Y., Chai, F., Rose, K. A., Niquen, C. M., & Chavez, F. P. (2013). Environmental influences on the interannual variation and spatial distribution of Peruvian anchovy (*Engraulis ringens*) population dynamics from 1991 to 2007: A three-dimensional modeling study. *Ecological Modelling*, 264, 64–82. <https://doi.org/10.1016/j.ecolmodel.2013.01.009>
- Yáñez, E., Hormazabal, S., Silva, C., Montecinos, A., Barbieri, M. A., Valdenegro, A., Órdenes, A., & Gómez, F. (2008). Coupling between the environment and the pelagic resources exploited off northern Chile: Ecosystem indicators and a conceptual model. 36, 159–181. <https://doi.org/10.3856/vol36-issue>
- Yáñez, E., Silva, C., Nieto, K., Barbieri, M. A., & Martínez, G. (2004). Using satellite technology improve Chilean Purseine fishing Fleet. *Gayana (Concepción)*, 68, 578–585. <https://doi.org/10.4067/S0717-65382004000300048>

**How to cite this article:** Armas, E., Arancibia, H., Neira, S., & Marín, M. C. (2024). Neural network approach for detecting spatial changes in catch probability of *Engraulis ringens* during El Niño-Southern Oscillation events in northern Chile. *Fisheries Oceanography*, e12672. <https://doi.org/10.1111/fog.12672>

## 6 DISCUSIÓN

La disminución de los desembarques de *E. ringens* en el norte de Chile durante eventos ENSO (2015, 2020) ha aumentado el esfuerzo realizado por la flota industrial para capturar este recurso hasta en 78% (2020) y, por consiguiente, han aumentado proporcionalmente los costos operativos (Figura 2 d). En esta tesis se sugiere la siguiente solución innovadora para reducir costos de la flota: identificar zonas potenciales de pesca utilizando redes neuronales. Este enfoque permite optimizar el proceso de búsqueda de los cardúmenes de *E. ringens*, reduciendo tanto la cantidad de viajes de cada nave como la cantidad de lances, distancias recorridas por cada nave y, consecuentemente, mejorar el rendimiento de pesca de cada nave y del conjunto de la flota. Además, se busca entender cómo la variabilidad oceanográfica relacionada con eventos ENSO impacta en la probabilidad de captura de *E. ringens*.

El objetivo general de esta tesis doctoral es evaluar el impacto de la utilización de pronósticos de zonas potenciales de pesca de *E. ringens* en la eficiencia de la flota anchovetera del norte de Chile. Se analizó la asociación entre la distribución espacial de *E. ringens* (presencia-ausencia) y variables oceanográficas disponibles (temperatura superficial del mar, altura del mar, salinidad, profundidad de la capa de mezcla), determinándose las variables a utilizar para el desarrollo de un modelo de pronóstico de zonas de pesca (**Capítulo 1**). Se implementó un modelo de redes neuronales basado en variables oceanográficas, el que fue capaz de pronosticar adecuadamente zonas de pesca de *E. ringens* en el corto plazo (**Capítulo 2**), y se evaluó el impacto de la utilización de dichos pronósticos en la eficiencia de la flota industrial cerquera anchovetera del norte de Chile (**Capítulo 2 y Capítulo 3**).

Las hipótesis planteadas en este estudio sostienen que si la distribución espacial de la anchoveta (*Engraulis ringens*) en el norte de Chile está determinada principalmente por variables oceanográficas entonces, el uso de estas variables permite predecir zonas probables de pesca de *E. ringens* en el norte de Chile en el corto plazo con la consecuencia que dicha predicción aumentaría el rendimiento de la flota industrial cerquera anchovetera. Los resultados de esta tesis respaldan las hipótesis planteadas, aunque fue necesario utilizar, además de variables oceanográficas (temperatura superficial del mar, salinidad, altura del mar, profundidad de la capa de mezcla), las coordenadas geográficas (latitud y longitud) y la variable temporal “mes” para capturar la estacionalidad en la distribución de *E. ringens* (**Capítulo 1**). De forma similar a lo observado en la investigación de Wang et al. (2015), las coordenadas geográficas latitud y longitud se encuentran entre las tres primeras del ranking, sumando 38% su importancia en la predicción. La variable oceanográfica con mayor relevancia en la predicción de zonas de pesca fue la profundidad de la capa de mezcla (18% de la varianza total explicada por el modelo de redes neuronales). Esta variable está directamente relacionada con el hábitat vertical de *E. ringens*, que en casos extremos, como eventos El Niño, se expande a

profundidades mayores a 50 m, generando la profundización de los cardúmenes y dificultando su accesibilidad a las artes de pesca (Böhm et al. 2017).

El modelo de redes neuronales demostró ser efectivo para pronosticar zonas de pesca de *E. ringens* en la zona norte de Chile en el corto plazo, alcanzando 86% (AUC=0,86) de éxito (Capítulo 2, Fig. 3), lo que significa que la clasificación fue muy buena, atendiendo los criterios de Ren-Yan et al. (2014) y Yusop and Mustapha (2019). El valor de AUC es consistente con los obtenidos por Joy and Death (2004), quienes aplicaron redes neuronales para predecir la distribución de catorce especies de peces y crustáceos dulceacuícolas en Nueva Zelanda, obteniendo valores de AUC entre 0,63 y 0,88. El modelo de redes neuronales construido en esta tesis fue capaz de identificar correctamente el 79% de las zonas de pesca reales. En comparación, Nieto et al. (2001) identificaron 67% de las zonas potenciales de pesca de *E. ringens* para el año 1999. Silva et al. (2002), Yáñez et al. (2004) y Silva et al. (2012) identificaron el 74% las zonas reales de pesca.

Además, en el presente trabajo la red neuronal fue capaz de identificar correctamente zonas de pesca de *E. ringens* a diferentes escalas temporales. En efecto, en la escala diaria las zonas de pesca reales son consistentes con las predichas por el modelo (Capítulo 2, Fig. 5) y, al aplicar el modelo mensual, las probabilidades de pesca observadas de la flota aumentan potencialmente con el aumento de las probabilidades de pesca mensuales predichas, observándose alta correlación entre ambas variables (Capítulo 3, Figura 3). También se aplicó el modelo de redes neuronales a escala trimestral, particularmente en años con condiciones El Niño, La Niña y Neutras, logrando captar la variabilidad en las probabilidades de pesca de *E. ringens* durante estos eventos en el norte de Chile. Esto coincidió también con las zonas de pesca observadas (Capítulo 3, Figura 6 y 7) y con el conocimiento existente sobre la distribución espacial de *E. ringens* durante estos eventos (Gutiérrez et al. 2007; Bouchon y Peña 2008; Yáñez et al. 2008; Cahuin et al. 2015).

Tanto para las simulaciones en los años 2004 (Neutral) y 2015 (El Niño) como para los años 2007, 2013 y 2020 (La Niña), las mayores probabilidades de pesca estimadas por el modelo de redes neuronales se encuentran en la zona costera (< 20 mn) (Capítulo 3, Figuras 4 y 5). Esto es consecuente con resultados de investigaciones previas donde las mayores capturas y biomasa acústica detectadas de *E. ringens* se encontraron dentro de las primeras 20 millas de la costa (Silva et al. 2016; Espíndola et al. 2018; Hernández-Santoro et al. 2019). Los mayores valores de probabilidad de pesca de *E. ringens* se observaron en el año 2004 (Capítulo 3, Figura 4), el cual presentó condiciones oceanográficas cercanas a la neutralidad. Esto se correspondió con las mayores capturas en la serie de tiempo (Capítulo 3, Figura 2) y resulta consistente con el conocimiento existente, ya que en períodos neutrales *E. ringens* se distribuye cercana a la costa, como es habitual, pero no se profundiza tanto como en años El Niño (Yáñez et al. 2008). En este sentido, *E. ringens* queda más accesible a las artes de pesca en períodos neutros comparado con períodos cálidos. Además, los cardúmenes de *E. ringens* están más



compactos y cercanos a la costa, haciéndolos más vulnerables a las artes de pesca, comparado con períodos fríos (Gutiérrez et al. 2007; Yáñez et al. 2008).

En el año con características típicas de El Niño (2015), las probabilidades de pesca de *E. ringens* estimadas por el modelo de redes neuronales presentaron igual tendencia que la probabilidad de pesca observada (Capítulo 3, Figura 4), manteniéndose inferiores a las probabilidades de pesca en el año 2004 (Neutral) y 2007 (La Niña). Las probabilidades de pesca son mayores en la costa, aunque disminuyen rápidamente con el incremento de la distancia a la costa. Es conocido que durante eventos cálidos (El Niño) disminuye la surgencia costera, profundizándose la capa de mínima de oxígeno (Cahuin et al. 2015). Los cardúmenes de *E. ringens* se aproximan a zonas muy costeras, profundizándose luego y quedando menos accesibles a las artes de pesca, provocando la disminución de las capturas (Yáñez et al. 2008; Böhm et al. 2017), lo que concuerda con los resultados de esta investigación para el año con condiciones El Niño (2015).

Durante los períodos La Niña (2007, 2013), se observó menores diferencias de probabilidad de pesca de *E. ringens* entre la zona costera (< 20 mn) y la zona oceánica (> 20 mn) (Capítulo 3, Figuras 4 y 5), lo que indica que las condiciones oceanográficas favorables a la presencia de esta especie se encuentran más homogéneas, conduciendo al aumento de las probabilidades de encuentro de cardúmenes de *E. ringens* en zonas más alejadas de la costa (Segura y Vásquez 2002; Gutiérrez et al. 2007; Bouchon y Peña 2008). Los eventos La Niña se caracterizan por la somerización de la termoclina, así como de la oxiclina y la nutriclina (Parada et al. 2013), reduciéndose el hábitat vertical de *E. ringens*, causando que los cardúmenes se encuentren más cercanos a la superficie (Bouchon y Peña 2008) y más expandidos horizontalmente (Segura y Vásquez 2002; Gutiérrez et al. 2007; Bouchon y Peña 2008). Durante estos períodos fríos se ha detectado presencia de cardúmenes de *E. ringens* hasta 200 mn de la costa (Segura y Vásquez 2002; Bouchon y Peña 2008). A mayor distancia a la costa se ha observado también mayor dispersión de cardúmenes de *E. ringens* durante períodos fríos como La Niña (1998-2000) (Gutiérrez et al. 2007; Bouchon y Peña 2008; Yáñez et al. 2008), lo que dificulta su búsqueda y captura debido a su dispersión, haciéndolo menos accesibles a las artes de pesca (Yáñez et al. 2008).

Sin embargo, en el año 2020, a diferencia de la distribución más dispersa y alejada de la costa de las probabilidades de pesca de *E. ringens* entregadas por el modelo de redes neuronales para los períodos La Niña 2007 y 2013, la zona de mayores probabilidades más accesible a la flota se reduce a una pequeña y angosta franja costera (Capítulo 3, Figura 7). Dadas las regulaciones aplicadas desde ese año, cuando se prohibió a la flota industrial perforar las 5 mn reservadas para la pesca artesanal, se reduce aún más el área disponible para la búsqueda del recurso anchoveta por la flota industrial de cerco, dejando fuera del alcance de dicha flota las zonas con mayores probabilidades de encuentro de cardúmenes. Esto, unido a la reducción del esfuerzo pesquero (Capítulo 3, Figura 2), pudo haber condicionado la caída de los desembarques en el año 2020, alcanzándose valores mínimos nunca registrados en la serie 2003-2020, incluso menores que durante el evento

El Niño 2015-2016 (Capítulo 3, Figura 2). Esto implica que las condiciones oceanográficas han sido diferentes a anteriores eventos La Niña y que el modelo de redes neuronales es capaz de reflejar este cambio a través de las probabilidades de zonas de pesca de *E. ringens*.

De acuerdo con lo expuesto precedentemente, se da cumplimiento al segundo objetivo específico de esta tesis, obteniendo como resultado un modelo de redes neuronales entrenado para pronosticar zonas de pesca de *E. ringens* en el norte de Chile en el corto plazo (días). Los resultados apoyan la primera hipótesis, ya que el modelo mostró buen desempeño para dicha tarea, coincidiendo los resultados con el conocimiento generado en investigaciones previas en cuanto a la distribución espacial de esta especie. Además, el modelo de redes neuronales implementado fue capaz de detectar los cambios mensuales y trimestrales en las probabilidades de pesca de la flota observadas durante eventos ENSO.

Como consecuencia del buen desempeño del modelo de redes neuronales y su capacidad para identificar zonas de pesca de *E. ringens*, su aplicación en la operación de la flota aumentaría el rendimiento de pesca. Para probar esta hipótesis fue necesario simular el rendimiento de pesca de la flota en las zonas pronosticadas y no pronosticadas por el modelo como zonas potenciales de pesca. Se utilizó varias aproximaciones para calcular el rendimiento de la flota; una de ellas fue considerar la cantidad de zonas por nave donde se capturó *E. ringens* dividida por la cantidad de zonas visitadas por barco, siendo ésta la probabilidad de pesca de la flota en un período de tiempo dado, correspondiendo a una aproximación del rendimiento de la misma (más capturas a menor esfuerzo implica mayor rendimiento) (Capítulo 2). También se utilizó las capturas (toneladas) divididas por la cantidad de zonas visitadas (Capítulo 3).

El modelo de redes neuronales identificó zonas con condiciones oceanográficas favorables a la presencia de *E. ringens* (zonas potenciales de pesca), aunque esto no implica que necesariamente la especie estará presente. Esto ocurre debido a la existencia de interacciones con otras especies, tal como predación o competencia (Melo-Merino et al. 2020). Esta es la razón por la que el modelo identifica más zonas potenciales de pesca en relación a aquellas en las que se capturó realmente *E. ringens* (Tabla 1). Sin embargo, la probabilidad de pesca (rendimiento) en las zonas potenciales fue mayor que en las zonas no potenciales, y mayor que la probabilidad de pesca de la flota visitando todas las zonas (Tabla 1). Por lo tanto, el rendimiento de la flota sería mayor si visitara sólo las zonas potenciales de pesca identificadas por el modelo de redes neuronales. Se aclara que esto se refiere al rendimiento como probabilidad de pesca, no como volumen de captura (toneladas).

En el Capítulo 2 de esta tesis se simuló cómo hubiera sido el rendimiento anual de la flota, siguiendo las zonas recomendadas por el modelo de redes neuronales (zonas potenciales de pesca). En esta simulación (Figura 4, Capítulo 2) se observó que la probabilidad en las zonas potenciales de pesca fue mayor que en las zonas no potenciales en todos los años. Los resultados indicaron que si la flota hubiese realizado la búsqueda de cardúmenes de

*E. ringens* en las zonas recomendadas por el modelo, entonces se habría obtenido, en promedio, 88% más de probabilidad de encontrar pesca que en las zonas no recomendadas por el modelo. A escala mensual, el modelo de redes neuronales resultó ser efectivo en la predicción de las probabilidades de pesca de *E. ringens*, dado que las probabilidades de pesca observadas de la flota aumentan potencialmente con el aumento de las probabilidades de pesca mensuales predichas (Capítulo 3, Figura 3), observándose alta correlación entre ambas variables. De lo anterior es posible deducir que, operando en las zonas de mayor probabilidad entregadas por el modelo, se podría mejorar la probabilidad de pesca de la flota y, por tanto, su rendimiento. En las simulaciones realizadas para el año con condiciones características de El Niño (2015), La Niña (2007, 2013, 2020) y Neutrales (2004) se observó que los mayores rendimientos de la flota (toneladas captura por zona navegada) ocurrieron dentro de las primeras 20 mn desde la costa, coincidiendo con las mayores probabilidades entregadas por el modelo. El año con mayor rendimiento de pesca de los analizados fue el 2004, cuando las condiciones oceánicas eran neutrales. En ese mismo año también se presentaron las mayores probabilidades de pesca predichas por el modelo (Capítulo 3, Figura 4).

La cantidad anual de zonas potenciales de pesca de *E. ringens*, identificada por el modelo de redes neuronales, presentó correlación positiva con los desembarques (Capítulo 3, Figuras 8 y 9). Esta variable es un indicador de qué tan apto está el ambiente para el encuentro de cardúmenes de esta especie. Las menores cantidades de zonas potenciales de pesca ocurrieron en los períodos 2015-2016 y 2020-2021, coincidiendo con las mayores caídas de los desembarques de Corpesca (Capítulo 3, Figura 9), excepto en los años 2005 y 2007, cuando se observó un ligero desfase de estas series. En el resto de los años se presenta la misma tendencia, destacando la marcada tendencia a la baja de ambas series en el período 2012 a 2016, que culminó con un evento El Niño (el segundo año de menores capturas de la serie). También con este indicador se estimó correctamente el incremento en los desembarques de los años 2011 y 2018. A mayor cantidad de zonas favorables al encuentro de cardúmenes de *E. ringens* determinadas por el modelo, mayor es la probabilidad de que sean visitadas por la flota y se capture al recurso pesquero objetivo *E. ringens*. Además, si se prioriza la búsqueda en dichas zonas, entonces es posible obtener mejores rendimientos que buscando aleatoriamente en toda el área de operación de la flota, apoyando con este resultado la segunda hipótesis de esta tesis.

La predicción de zonas de pesca ha sido un fuerte desafío en Chile y Latinoamérica, habiéndose realizado varios esfuerzos en este tema (Barbieri et al. 1989; Nieto et al. 2001; Silva et al. 2002, 2012a; Yáñez et al. 2004). En efecto, Nieto et al., (2001), Yáñez et al., (2004) y Silva et al., (2012a), aunque muestran resultados satisfactorios, utilizan información oceanográfica de productos satelitales, la cual es una instantánea del estado del océano, pero no permite proyectar temporalmente estas condiciones en el corto plazo. Además, se desconoce si dichos estudios tuvieron alguna aplicación práctica para la administración de la flota.

Para la predicción de zonas potenciales de pesca de *E. ringens* en el norte de Chile, la aplicación de redes neuronales se revela como una alternativa interesante con aplicación práctica. El modelo de redes neuronales aplicado tiene la ventaja que se puede implementar con pocos supuestos sobre los datos pesqueros y ambientales (Suryanarayana et al. 2008; Wang et al. 2015). Este tipo de modelos ha mostrado desempeño superior a los modelos estadísticos convencionales como son los GLM (Generalized Linear Models) y GAM (Generalized Additive Models) (Tan y Beklioglu 2006; Suryanarayana et al. 2008; Mateo et al. 2011; Wang et al. 2015). Estos últimos son implementados suponiendo ciertas características de los datos, tales como linealidad, normalidad y homocedasticidad (Yudaputra et al. 2019). Sin embargo, tales supuestos difícilmente se cumplen en situaciones reales debido a falta de información en zonas no exploradas por la flota, a la dificultad asociada a la no linealidad de los procesos ecológicos (Tan y Beklioglu 2006), y a las complejas interacciones ambiente-recurso (Wang et al. 2015).

En esta tesis se analizó fundamentalmente cambios en la distribución, capturas y desembarques de *E. ringens* forzados por las condiciones oceanográficas. Las relaciones entre variables oceanográficas y la distribución especies en el océano no son lineales (Wang et al. 2015); por esta razón se recurrió a las redes neuronales, ya que se ha demostrado su eficacia en la representación de procesos no lineales (Tan y Beklioglu 2006; Armas et al. 2022). Se utilizó la probabilidad estimada por el modelo de redes neuronales como *proxy* de la variación de las condiciones oceanográficas, ya que dicho modelo fue entrenado solamente con tales condiciones; por tanto, cualquier variación de las probabilidades de pesca de *E. ringens* estimadas por el modelo se produce a consecuencia de un cambio a nivel oceanográfico.

El modelo de redes neuronales desarrollado como parte de esta tesis presenta algunas limitaciones relacionadas con la propia red neuronal, y otras con los datos de entrada. Las redes neuronales son consideradas modelos de caja negra, dada la dificultad en interpretar el mecanismo interno por el cual estas hacen sus predicciones (Olden et al. 2004). En el Capítulo 1 se indagó en la importancia de cada variable en el modelo. Sin embargo, el presente trabajo se centró más en determinar los cambios de las condiciones oceanográficas a través de la probabilidad de pesca estimada por el modelo de redes neuronales. No se profundizó en el análisis de las variables oceanográficas que en particular produjeron los cambios oceanográficos que condujeron a la disminución de los desembarques de *E. ringens*, sino que se trataron todas las variables en conjunto a través de la probabilidad de pesca. Los datos de entrada al modelo están desbalanceados, existiendo muchos más registros de zonas sin pesca que con pesca, lo cual añade la dificultad que el modelo tiende a pronosticar mayormente que no habrá pesca y a entregar bajas probabilidades de pesca. La georreferenciación de las capturas existentes en la base de datos de Corpesca se asigna mediante un algoritmo automático que, según las trayectorias de las naves, estima la zona probable de captura, esta estimación está sujeta a errores. Sin embargo, se considera que los resultados del presente estudio, aún con las limitaciones antes mencionadas, fueron satisfactorios.

Se recomienda la mejora continua de este modelo, ya que las redes neuronales son modelos complejos que se componen de una serie de parámetros (tasas de aprendizaje, criterios de detención del entrenamiento, función de optimización objetivo; **ver Capítulo 2**), los cuales pueden seguir siendo optimizados para mejorar las predicciones. Además, la mejora y aumento de los datos de entrada al modelo pueden contribuir a la mejora en la precisión del modelo. Se recomienda trabajar en la eliminación del sesgo geográfico (latitud y longitud), ya que de esta forma se podría encontrar nuevas zonas de pesca nunca visitadas por la flota. En esta investigación se utilizó un perceptrón multicapa que es la red neuronal más sencilla, aunque en futuras investigaciones se podría probar diferentes arquitecturas de redes neuronales buscando mejorar los pronósticos.

En relación con la presente investigación debe destacarse la disponibilidad de millones de datos de presencia-ausencia de *E. ringens* pesca (2003-2020), aportados por la empresa pesquera Corpesca S.A., y pronósticos oceanográficos obtenidos del programa Copernicus, lo cual permitió proyectar las condiciones oceanográficas hacia adelante en el tiempo y, por tanto, proyectar las probabilidades de pesca de *E. ringens*. De hecho, la empresa pesquera Corpesca S.A. está usando esta herramienta en el norte de Chile como apoyo a las prospecciones pesqueras, para recomendar zonas de pesca de *E. ringens*, lo que permite administrar mejor a la flota en términos de auto-regulación del esfuerzo de pesca.

En este estudio se probó que el uso de redes neuronales es un enfoque válido para identificar cambios en las probabilidades de pesca de *E. ringens* durante eventos ENSO por parte de la flota cerquera anchovetera del norte de Chile. La relación encontrada entre la cantidad de zonas potenciales de pesca y los desembarques industriales anuales de *E. ringens* (Capítulo 3, Figura 8, 9), en el norte de Chile, muestra el peso que tienen los cambios oceanográficos en la distribución, accesibilidad y vulnerabilidad de esta especie a la pesca y, por tanto, en el rendimiento de la flota y en el nivel de capturas anuales. Los mapas de distribución de probabilidades de zonas de pesca de *E. ringens* (Capítulo 2 y Capítulo 3) pueden permitir entender y anticipar las consecuencias que eventos ENSO extremos pudieran tener sobre la probabilidad de la flota de encontrar cardúmenes de *E. ringens* accesibles a la pesca, y, por tanto, en los desembarques y rendimiento de la flota industrial. Esto podría tener un impacto positivo en la toma de decisiones en la operación de la flota tanto a corto como a mediano plazo.

Con el seguimiento de la cantidad de zonas potenciales de pesca disponibles identificadas por el modelo es posible monitorear remotamente cuán apto está el ambiente para la presencia de *E. ringens*. El modelo de redes neuronales y la metodología desarrollados en este estudio (Capítulo 2, Sección Materiales y Métodos) podrían aplicarse a otros stocks de *E. ringens* y a otras especies de las que se disponga de datos de presencia-ausencia de pesca. Las salidas de este tipo de modelos (mapas de distribución de probabilidades de pesca) pueden ser utilizados como input de modelos de optimización de operación de la flota, con lo que se podría mejorar la eficiencia de las operaciones pesqueras, optimizando rutas y tiempos de pesca.

## 7 CONCLUSIONES

1. Los resultados obtenidos dan sustento a las hipótesis planteadas, ya que se demuestra que la variabilidad ambiental, representada por las variables seleccionadas logran explicar la eficiencia de pesca de corto plazo de *E. ringens* en el norte de Chile.
2. Las variables independientes que explican mejor las capturas por zonas de pesca de *E. Ringens* en la zona norte de Chile son: longitud geográfica (23%), profundidad de la capa de mezcla (18%), latitud geográfica (15%), temperatura superficial del mar (12%), mes (12%), altura del mar (9%) y salinidad (9%).
3. El modelo de redes neuronales que considera las variables oceanográficas seleccionadas fue capaz de pronosticar efectivamente zonas de pesca de *E. ringens* en el corto plazo y la distribución espacial de esta especie durante eventos ENSO en la zona norte de Chile.
4. El uso de los pronósticos de pesca del modelo de redes neuronales podría resultar en una mejor operación de la flota al disminuir el esfuerzo y aumentar el rendimiento.
5. La aplicación de resultados obtenidos en la presente tesis puede contribuir a entender y anticipar las consecuencias que eventos ENSO extremos pudieran tener sobre la probabilidad de la flota de encontrar cardúmenes de *E. ringens* accesibles a la pesca y, por tanto, en el rendimiento de la flota industrial.

## 8 REFERENCIAS BIBLIOGRÁFICAS

- Akoglu, H. 2018. User's guide to correlation coefficients. *Turkish Journal of Emergency Medicine* 18(3):91–93.
- Aliaga, B., D. Gómez, y S. Neira. 2001. Análisis bioeconómico de la pesquería de sardina (*Sardinops sagax*) y anchoveta (*Engraulis ringens*) de la zona norte de Chile. *Investigaciones marinas* 29(2):15–23.
- Armas, E., H. Arancibia, y S. Neira. 2022. Identification and Forecast of Potential Fishing Grounds for Anchovy (*Engraulis ringens*) in Northern Chile Using Neural Networks Modeling. *Fishes* 7(4):204. MDPI.
- Aros, J., M. Pizarro, C. Grendi, Ú. Cifuentes, A. Bustamantes, H. Reyes, y A. Varas. 2017. INFORME FINAL. Convenio Desempeño 2016. Monitoreo de las condiciones bio-oceanográficas y evaluación del stock desovante de anchoveta entre la XV y II Regiones, año 2016. Instituto de Fomento Pesquero:299 + anexos.
- Asche, F., H. Eggert, E. Gudmundsson, A. Hoff, y S. Pascoe. 2008. Fisher's behaviour with individual vessel quotas-Over-capacity and potential rent. Five case studies. *Marine Policy* 32(6):920–927.
- Barbieri, M. A. B., E. R. Yanez, M. S. Farias, y R. H. Aguilera. 1989. Determination of probable fishing areas for the albacore (*Thunnus alalunga*) in Chile's central zone. *Digest - International Geoscience and Remote Sensing Symposium (IGARSS)* 4:2447–2450.
- Barros, M. E., S. Neira, y H. Arancibia. 2014. Trophic interactions in northern Chile upwelling ecosystem, year 1997. *Latin American Journal of Aquatic Research* 42(5):1109–1125.
- Bertrand, S., B. Dewitte, J. Tam, E. Díaz, y A. Bertrand. 2008. Impacts of Kelvin wave forcing in the Peru Humboldt Current system: Scenarios of spatial reorganizations from physics to fishers. *Progress in Oceanography* 79(2–4):278–289. Elsevier Ltd.
- Böhm, M. G., C. Hernández, E. Días, G. Pérez, R. Ojeda, F. Cerna, C. Valero, M. Gómez, C. Machuca, y L. Muñoz. 2017. INFORME FINAL. Convenio de desempeño, 2016. Programa de Seguimiento de las Principales Pesquerías Pelágicas de la Zona Norte de Chile, XV – IV Regiones, año 2016. Instituto de Fomento Pesquero.
- Bouchon, M., y C. Peña. 2008. Impactos de los eventos la niña en la pesquería peruana. *Informe del Instituto del Mar del Perú* 35(3):193–198.
- Bouchon, M., C. Peña, y J. Salcedo. 2015. El Evento El Niño y su impacto en la pesquería de Anchoveta en el mar peruano. *Boletín Trimestral Oceanográfico* 1(1–4):17–19.
- Cahuin, S., L. A. Cubillos, y R. Escribano. 2015. Synchronous patterns of fluctuations in two stocks of anchovy *Engraulis ringens* Jenyns, 1842 in the Humboldt Current System. *Journal of Applied Ichthyology* 31(1):45–50.
- Castillo, J., E. M. Pizarro, B. Leiva, F. Cerna, V. Catasti, L. Herrera, y V. Valenzuela. 2013. INFORME FINAL Evaluación del stock desovante de anchoveta en la XV, I y II Regiones, año 2013.

- Claramunt, G., L. R. Castro, L. A. Cubillos, H.-J. Hirche, G. Perez, y M. Braun. 2012. Inter-annual reproductive trait variation and spawning habitat preferences of *Engraulis ringens* off northern Chile. *Revista de biología marina y oceanografía* 47(2):227–243.
- Climate Prediction Center - ONI. 2022. . [https://origin.cpc.ncep.noaa.gov/products/analysis\\_monitoring/ensostuff/ONI\\_v5.php](https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php).
- Contreras-Reyes, J. E., T. M. Canales, y P. M. Rojas. 2016. Influence of climate variability on anchovy reproductive timing off northern Chile. *Journal of Marine Systems* 164:67–75. Elsevier B.V.
- Contreras, J. E., C. Rodríguez-Valentino, M. F. Landaeta, G. Plaza, M. I. Castillo, y M. Alvarado-Niño. 2017. Growth and mortality of larval anchoveta *Engraulis ringens*, in northern Chile during winter and their relationship with coastal hydrographic conditions. *Fisheries Oceanography* 26(6):603–614.
- Cubillos, L. A., R. Serra, y P. Fréon. 2007. Synchronous pattern of fluctuation in three anchovy fisheries in the Humboldt Current System. *Aquatic Living Resources* 20(1):69–75.
- von Dassow, P. 2017. Informe de antecedentes científicos relevantes a propuestas de geo-ingeniería marina en Chile: experimentos de fertilización con hierro en aguas costeras y de transición costera frente a Chile.
- Dec. Ex. N° 22-2022. 2022. . <https://www.subpesca.cl/portal/615/w3-article-114576.html>.
- Dec. Ex. N° 52-2022. 2022. . <https://www.diariooficial.interior.gob.cl/publicaciones/2022/12/05/43418/01/2228185.pdf>.
- Dickey, T., M. Lewis, y G. Chang. 2006. Optical oceanography: Recent advances and future directions using global remote sensing and in situ observations. *Reviews of Geophysics* 44(1):1–39.
- Espíndola, F., J. C. Quiroz, G. Böhm, F. Leiva, y J. A. Aros. 2018. INFORME 2 ESTATUS. Convenio de Desempeño 2017. Estatus y posibilidades de explotación biológicamente sustentables de los principales recursos pesqueros nacionales año 2018: Anchoveta XV-II Regiones. Instituto de Fomento Pesquero.
- Espinoza, R. A. 2016. Análisis de la distribución espacial de las aves guaneras en relación con la anchoveta en el mar peruano. Universidad Peruana Cayetano Heredia.
- Fabri-Ruiz, S., B. Danis, B. David, y T. Saucède. 2019. Can we generate robust species distribution models at the scale of the Southern Ocean? *Diversity and Distributions* 25(1):21–37.
- Fitrianah, D. 2015. Feature Exploration for Prediction of Potential Tuna Fishing Zones. *International Journal of Information and Electronics Engineering* 5(4):270–274.
- Fitrianah, D., H. Fahmi, A. N. Hidayanto, y A. M. Arymurthy. 2016a. A Data Mining Based Approach for Determining the Potential Fishing Zones. *International Journal of Information and Education Technology* 6(3):187–191.
- Fitrianah, D., A. N. Hidayanto, J. L. Gaol, H. Fahmi, y A. M. Arymurthy. 2016b. A



- Spatio-Temporal Data-Mining Approach for Identification of Potential Fishing Zones Based on Oceanographic Characteristics in the Eastern Indian Ocean. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9(8):3720–3728.
- García, J. L., H. Chagolla, y S. Noriega. 2006. Efectos de la colinealidad en el modelado de regresión y su solución. *Culcyt/Modelos* (16):23–34.
- Gardner, M. W., y S. R. Dorling. 1998. Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences. *Atmospheric Environment* 32(14–15):2627–2636.
- Global Ocean Physics Analysis and Forecast | Copernicus Marine MyOcean Viewer. 2023. .  
[https://data.marine.copernicus.eu/product/GLOBAL\\_ANALYSISFORECAST\\_PHY\\_001\\_024/description](https://data.marine.copernicus.eu/product/GLOBAL_ANALYSISFORECAST_PHY_001_024/description).
- Global Ocean Physics Reanalysis | Copernicus Marine MyOcean Viewer. 2023. .  
[https://data.marine.copernicus.eu/product/GLOBAL\\_MULTIYEAR\\_PHY\\_001\\_030/description](https://data.marine.copernicus.eu/product/GLOBAL_MULTIYEAR_PHY_001_030/description).
- Griddata. 2023. .  
<https://docs.scipy.org/doc/scipy/reference/generated/scipy.interpolate.griddata.html>.
- Gutiérrez, M., G. Swartzman, A. Bertrand, y S. Bertrand. 2007. Anchovy (*Engraulis ringens*) and sardine (*Sardinops sagax*) spatial dynamics and aggregation patterns in the Humboldt Current ecosystem, Peru, from 1983-2003. *Fisheries Oceanography* 16(2):155–168.
- Hernández-Miranda, E., R. A. Quiñones, G. Aedo, A. Valenzuela, N. Mermoud, C. Román, y F. Yañez. 2010. A major fish stranding caused by a natural hypoxic event in a shallow bay of the eastern South Pacific Ocean. *Journal of Fish Biology*:1543–1564.
- Hernández-Santoro, C., M. F. Landaeta, y J. Castillo Pizarro. 2019. Effect of ENSO on the distribution and concentration of catches and reproductive activity of anchovy *Engraulis ringens* in northern Chile. *Fisheries Oceanography* 28(3):241–255.
- Hernández-Santoro, C., G. Pérez-Mora, E. Díaz-Ramos, y G. Böhm-Stoffel. 2013. Análisis de indicadores macro y microscópicos para establecer el periodo de máxima intensidad de desove de la anchoveta *Engraulis ringens* en la zona norte de Chile. *Revista de Biología Marina y Oceanografía* 48(3):451–457.
- Home | CMEMS. 2022. . <https://marine.copernicus.eu/>.
- Hormazabal, S., G. Shaffer, y O. Pizarro. 2002. Tropical Pacific control of intraseasonal oscillations off Chile by way of oceanic and atmospheric pathways 29(6):1–4.
- Jagannathan, S., A. Samraj, y M. Rajavel. 2012. Potential fishing zone estimation by rough cluster predictions. *Proceedings of International Conference on Computational Intelligence, Modelling and Simulation*:82–87.
- Joo, R., A. Bertrand, M. Bouchon, A. Chaigneau, H. Demarcq, J. Tam, M. Simier, D. Gutiérrez, M. Gutiérrez, M. Segura, R. Fablet, y S. Bertrand. 2014. Ecosystem scenarios shape fishermen spatial behavior. The case of the Peruvian anchovy fishery in the Northern Humboldt Current System. *Progress in Oceanography* 128:60–73. Elsevier Ltd.

- Jordán, R., y A. Chirinos de Vildoso. 1965. La Anchoveta (*Engraulis ringens* J.) Conocimiento actual sobre su biología, ecología y pesquería.
- Joy, M. K., y R. G. Death. 2004. Predictive modelling and spatial mapping of freshwater fish and decapod assemblages using GIS and neural networks. *Freshwater Biology* 49(8):1036–1052.
- De La Cruz Barrueto, K. N., A. E. Delgado Domínguez, J. F. Baca Izquierdo, D. S. Hualcas Chinchayhuara, J. M. Costa Herrera, C. A. González Campos, y Z. G. Culquichicón Malpica. 2021. BIOLOGICAL SYNOPSIS OF *Engraulis ringens*(Jenyns, 1842)Anchovy. *REBIOL* 40(2):298–317. Universidad Nacional de Trujillo.
- Leiva, F., R. Vargas, C. Grendi, M. Pizarro, Ú. Cifuentes, A. Bustamantes, B. Leiva, F. Cerna, y A. López. 2017. INFORME FINAL. Convenio de Desempeño 2016. Evaluación hidroacústica del reclutamiento de anchoveta en la XV, I y II Regiones, año 2016. Instituto de Fomento Pesquero:130 + anexos.
- Luján, D. 2016. Factores Determinantes De La Variabilidad Espacial De Anchoveta Peruana (*Engraulis ringens*) En El Pacífico Sudoriental. Tesis para optar al grado de Maestro en Ciencias del Mar, Universidad Peruana Cayetano Heredia.
- Madec, G., R. Bourdallé-Badie, P.-A. Bouttier, C. Bricaud, D. Bruciaferri, D. Calvert, J. Chanut, E. Clementi, A. Coward, D. Delrosso, y others. 2017. NEMO ocean engine. In Notes du Pôle de modélisation de l'Institut Pierre-Simon Laplace (IPSL) (v3.6-patch, Number 27). Zenodo. Note du Pôle de modélisation de l'Institut Pierre-Simon Laplace.
- Mane, S. U., y A. D. Mishra. 2017. Application of Remote Sensing with R Tool in Validation of Potential Fishing Zone along the Coast of Ratnagiri . *International Research Journal of Engineering and Technology(IRJET)* 4(5):1182–1187.
- Mateo, R. G., Á. M. Felicísimo, y J. Muñoz. 2011. Modelos de distribución de especies: Una revisión sintética. *Revista Chilena de Historia Natural* 84(2):217–240.
- Maturana, J., M. Bello, y M. Manley. 2004. Antecedentes históricos y descripción del fenómeno El Niño, Oscilación del Sur. *El Niño y la Niña 1997 - 2000. Sus efectos en Chile*:13–27.
- Medina, M., H. Arancibia, y S. Neira. 2007. Un modelo trófico preliminar del ecosistema pelágico del norte de Chile (18° 20' S - 24° 00' S). *Invest. Mar.* 35(1):25–38.
- Medina, M., L. Herrera, J. Castillo, J. Jaque, y N. Pizarro. 2015. Alimentación de la anchoveta (*Engraulis ringens*) en el norte de Chile (1825, 2540S) en diciembre de 2010. *Latin American Journal of Aquatic Research* 43(1):46–58.
- Melo-Merino, S. M., H. Reyes-Bonilla, y A. Lira-Noriega. 2020. Ecological niche models and species distribution models in marine environments: A literature review and spatial analysis of evidence. *Ecological Modelling* 415(October 2019):108837. Elsevier.
- Memoria Camanchaca. 2021. . <https://www.camanchaca.cl/wp-content/uploads/2022/04/Camanchaca-Memoria-2021-web.pdf>.
- Memoria Corpesca. 2021. . <https://www.corpesca.cl/wp-content/uploads/2022/04/Memoria-Anual-Corpesca-2021.pdf>.

- Ministerio De Economía. 2001. Ley 19713 Establece Límite Máximo de Captura por Armador (LMCA).
- Ministerio De Economía. 2002. Ley 19.822 Extiende LMCA a pesquerías de sardina española; anchoveta y jurel en las regiones I y II.
- Mohd Razali, N., y Y. Bee Wah. 2011. Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. *Journal of Statistical Modeling and Analytics* 2(1):13–14.
- Morrow, R., y P. Le Traon. 2012. *Archimer* 50(8):1062–1076.
- Nammalwar, P., S. Satheesh, y R. Ramesh. 2013. Applications of remote sensing in the validations of Potential Fishing Zones (PFZ) along the coast of North Tamil Nadu, India. *Indian Journal of Marine Sciences* 42(3):283–292.
- Naranjo, L., F. Plaza, E. Yáñez, M. Á. Barbieri, y F. Sánchez. 2015. Forecasting of jack mackerel landings (*Trachurus murphyi*) in central-southern Chile through neural networks. *Fisheries Oceanography* 24(3):219–228.
- Nieto, K., E. Yáñez, C. Silva, y M. A. Barbieri. 2001. Probable fishing grounds for anchovy in northern Chile using an expert system. *International Geoscience and Remote Sensing Symposium (IGARSS)* 7(C):2985–2987.
- Ñiquen, M., y M. Bouchon. 2004. Impact of El Niño events on pelagic fisheries in Peruvian waters. *Deep-Sea Research Part II: Topical Studies in Oceanography* 51(6–9):563–574.
- October 2020 La Niña update | NOAA Climate.gov. 2020. .  
<https://www.climate.gov/news-features/blogs/enso/october-2020-la-niña-update>.
- Olden, J. D., M. K. Joy, y R. G. Death. 2004. An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. *Ecological Modelling* 178(3–4):389–397.
- Oliva, J., y A. Vilaxa. 2016. EVALUACIÓN REPRODUCTIVA DE LA ANCHOVETA (*Engraulis ringens*) EN LA XV, I Y II REGIÓN DE CHILE.
- Parada, C., B. Yanicelli, S. Hormazabal, S. Vásquez, J. Porobic, B. Ernst, C. Gatica, M. Arteaga, A. Montecinos, S. Nuñez, y A. Gretchina. 2013. Variabilidad ambiental y recursos pesqueros en el Pacífico suroriental: estado de la investigación y desafíos para el manejo pesquero. *Lat. Am. J. Aquat. Res.* 41(1):1–28.
- Paulmier, A., y D. Ruiz-Pino. 2009. Oxygen minimum zones (OMZs) in the modern ocean. *Progress in Oceanography* 80(3–4):113–128. Elsevier Ltd.
- Plaza, G., M. Landaeta, A. Hernández, J. Contreras, C. Rodríguez, J. Merino, y D. Queirolo. 2017. Revisión Experta De La Estimación Y Asignación De Edad De La Anchoveta XV-II Región. Informe Final, Proyecto Fip N° 2014-31:114 + anexos.
- Python.org. 2023. . <https://www.python.org/>.
- Ren-Yan, D., K. Xiao-Quan, H. Min-Yi, F. Wei-Yi, y W. Zhi-Gao. 2014. The predictive performance and stability of six species distribution models. *PLoS ONE* 9(11).
- Rojas, J., y C. Eche. 2006. La Temperatura De La Superficie Del Mar Peruano a Partir De Las Imágenes Avhrr / Noaa ( 2000 - 2003 ) 9:24–30.
- de Sá, C. R. 2019. Variance-Based Feature Importance in Neural Networks. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 11828 LNAI(November):306–

315.

- Schober, P., C. Boer, y L. A. Schwarte. 2018. Correlation Coefficients. *Anesthesia & Analgesia* 126(5):1.
- Segura, M., y L. Vásquez. 2002. Influence of the oceanographic conditions in the distribution and behavior of the anchovy (:1–11.
- Silva, C., I. Andrade, E. Yáñez, S. Hormazabal, M. A. Barbieri, A. Aranís, y G. Böhm. 2016. Predicting habitat suitability and geographic distribution of anchovy (*Engraulis ringens*) due to climate change in the coastal areas off Chile. *Progress in Oceanography* 146:159–174. Elsevier Ltd.
- Silva, C., M. A. Barbieri, E. Yáñez, J. C. Gutiérrez-Estrada, & Tomás, y Á. Delvalls. 2012a. Using indicators and models for an ecosystem approach to fisheries and aquaculture management: the anchovy fishery and Pacific oyster culture in Chile: case studies. *J. Aquat. Res* 40(4):955–969.
- Silva, C., M. A. Barbieri, E. Yáñez, J. C. Gutiérrez-Estrada, y T. Á. Del Valls. 2012b. Using indicators and models for an ecosystem approach to fisheries and aquaculture management: The anchovy fishery and Pacific oyster culture in Chile: Case studies. *Latin American Journal of Aquatic Research* 40(4):955–969.
- Silva, C., K. Nieto, M. A. Barbieri, y E. Yáñez. 2002. Expert Systems for Fishing Ground Prediction Models: A Management Tool in the Humboldt Ecosystem Affected by ENSO. *Investigaciones marinas* 30(1):201–204. Escuela de Ciencias del Mar. Pontificia Universidad Católica de Valparaíso.
- Solanki, H. U., P. Prakash, R. M. Dwivedi, S. Nayak, A. Kulkarni, y V. S. Somvamshi. 2010. Synergistic application of oceanographic variables from multi-satellite sensors for forecasting potential fishing zones: Methodology and validation results. *International Journal of Remote Sensing* 31(3):775–789.
- Suryanarayana, I., A. Braibanti, R. Sambasiva Rao, V. A. Ramam, D. Sudarsan, y G. Nageswara Rao. 2008. Neural networks in fisheries research. *Fisheries Research* 92(2–3):115–139.
- Tan, C. O., y M. Beklioglu. 2006. Modeling complex nonlinear responses of shallow lakes to fish and hydrology using artificial neural networks. *Ecological Modelling* 196(1–2):183–194.
- Unidata | NetCDF. 2023. . <https://www.unidata.ucar.edu/software/netcdf/>.
- Vergara, O., B. Dewitte, I. Montes, V. Garçon, M. Ramos, y O. Pizarro. 2016. Seasonal variability of the oxygen minimum zone off Peru in a high-resolution regional coupled model. *Biogeosciences* 13(15):4389–4410.
- Wang, J., W. Yu, X. Chen, L. Lei, y Y. Chen. 2015. Detection of potential fishing zones for neon flying squid based on remote-sensing data in the Northwest Pacific Ocean using an artificial neural network. *International Journal of Remote Sensing* 36(13):3317–3330.
- Wang, Y., A. Gozolchiani, Y. Ashkenazy, y S. Havlin. 2016. Oceanic El-Niño wave dynamics and climate networks. *New Journal of Physics* 18(3). IOP Publishing.
- Yáñez, E., V. Catasti, M. Á. Barbieri, y G. Böhm. 1997. Relaciones entre la distribución de recursos pelágicos pequeños y la temperatura superficial del mar registrada con satélites NOAA en la zona central de Chile \* Relationships between the small

- pelagic resources distribution and the sea surface temperature. *Investigaciones Marinas* 24(March):107–122.
- Yáñez, E., A. González C, y M. A. Barbieri B. 1995. Estructura térmica superficial del mar asociada a la distribución espacio-temporal de sardina y anchoveta en la zona norte de Chile entre 1987 y 1992. *Investigaciones marinas* 23:123–147.
- Yáñez, E., S. Hormazábal, C. Silva, A. Montecinos, M. A. Barbieri, A. Valdenegro, A. Órdenes, y F. & Gómez. 2008. Coupling between the environment and the pelagic resources exploited off northern Chile: ecosystem indicators and a conceptual model 36(2):159–181.
- Yáñez, E., F. Plaza, J. C. Gutiérrez-Estrada, N. Rodríguez, M. A. Barbieri, I. Pulido-Calvo, y C. Bórquez. 2010. Anchovy (*Engraulis ringens*) and sardine (*Sardinops sagax*) abundance forecast off northern Chile: A multivariate ecosystemic neural network approach. *Progress in Oceanography* 87(1–4):242–250. Elsevier Ltd.
- Yáñez, E., C. Silva, K. Nieto, M. A. Barbieri, y G. Martínez. 2004. Using Satellite Technology Improve Chilean Purseine Fishing Fleet. *Gayana (Concepción)* 68(2):578–585. Universidad de Concepción. Facultad de Ciencias Naturales y Oceanográficas.
- Yudaputra, A., I. Robiansyah, y D. S. R. 2019. The Implementation of Artificial Neural Network and Random Forest in Ecological Research : Species Distribution Modelling with Presence and Absence Dataset.
- Yusop, S. M., y M. A. Mustapha. 2019. Influence of Oceanographic Parameters on the Seasonal Potential Fishing Grounds of *Rastrelliger kanagurta* using Maximum Entropy Models and Remotely Sensed Data. *Sains Malaysiana* 48(2):259–269.