

**CENTRO DE INVESTIGACIÓN CIENTÍFICA Y DE EDUCACIÓN
SUPERIOR DE ENSENADA, BAJA CALIFORNIA**



**PROGRAMA DE POSGRADO EN CIENCIAS
EN ECOLOGÍA MARINA**

**Modelación y proyección del reclutamiento del atún aleta
amarilla (*Thunnus albacares*) en el Océano Pacífico Oriental,
con base en las condiciones oceanográficas, usando redes
neuronales artificiales**

Tesis

para cubrir parcialmente los requisitos necesarios para obtener el grado de
Maestro en Ciencias

Presenta:

Laura Karen Torres Faurrieta

Ensenada Baja California México
2015

Tesis defendida por

Laura Karen Torres Faurrieta

y aprobada por el siguiente Comité

Dr. Michel Jules Dreyfus León
Codirector del Comité

Dr. David Alberto Rivas Camargo
Codirector del Comité

Dr. Oscar Sosa Nishizaki
Miembro del Comité

Dr. Enric Pallás Sanz
Miembro del Comité

Dr. David Alberto Rivas Camargo
Coordinador del Posgrado en Ecología
Marina

Dr. Jesús Favela Vara
Director de Estudios de Posgrado

Marzo, 2015

Resumen de la tesis que presenta **Laura Karen Torres Faurrieta** como requisito parcial para la obtención del grado de Maestro en Ciencias en Ecología Marina.

Modelación y proyección del reclutamiento del atún aleta amarilla (*Thunnus albacares*) en el Océano Pacífico Oriental, con base en las condiciones oceanográficas, usando redes neuronales artificiales

Resumen elaborado por:

Laura Karen Torres Faurrieta

El atún aleta amarilla (*Thunnus albacares*) es una especie oceánica epipelágica que se distribuye en mares tropicales y subtropicales, representa la mayor proporción de capturas a través de su distribución y es el principal recurso pesquero para la flota atunera mexicana. Se ha sugerido que las condiciones ambientales tienen fuerte influencia en la variabilidad de los niveles de reclutamiento de esta especie. En el presente estudio, una serie de modelos de redes neuronales artificiales, específicamente redes Autoregresivas No Lineales con Entradas Externas (NARX), fueron utilizadas para modelar y proyectar el reclutamiento del atún aleta amarilla en el Océano Pacífico Oriental (OPO) con base en las condiciones oceanográficas. Para modelar el reclutamiento se analizaron dos periodos de estudio; un periodo denominado “evaluación global” (1975-2012) por tratarse de un modelo en el que se estudió el reclutamiento a través de toda la zona de desove de la especie y otro periodo denominado “evaluación regional” (1980-2012) en el que se utilizaron cinco modelos para estudiar el reclutamiento total del OPO en cinco diferentes regiones dentro de la zona de desove. En la evaluación global el reclutamiento fue modelado a partir del Índice de Oscilación Sureña (SOI), la Oscilación Decadal del Pacífico (PDO) y la biomasa de desovadores. En la evaluación regional el reclutamiento fue modelado a partir de la temperatura, la magnitud del viento, la magnitud de las corrientes y la biomasa de desovadores. Un análisis de sensibilidad, en el cual los valores de las variables fueron incrementados y reducidos en diferentes porcentajes, demostró que el SOI es la variable de mayor importancia para el modelo de la evaluación global, resultando estimaciones de reclutamiento positivas cuando los valores del índice fueron reducidos, lo cual sugiere que las condiciones El Niño son favorables para el reclutamiento de la especie. En los modelos de la evaluación regional la temperatura fue la variable de mayor importancia en la mayoría de las regiones, resultando estimaciones positivas con el incremento en la temperatura. Para hacer proyecciones del reclutamiento se generaron cuatro modelos que estiman el reclutamiento futuro a partir de la temperatura, la magnitud del viento y la magnitud de las corrientes, cuyos valores fueron proyectados por modelos del Laboratorio de Dinámica de Fluidos Geofísicos (GFDL) bajo cuatro diferentes escenarios de emisiones de gases de efecto invernadero.

Palabras clave: Atún Aleta Amarilla, Reclutamiento, Redes Neuronales Artificiales.

Abstract of the thesis presented by **Laura Karen Torres Faurrieta** as a partial requirement to obtain the Master of Science degree in Marine Ecology

Modeling and projection of yellowfin tuna recruitment (*Thunnus abacares*) in the eastern Pacific Ocean, based on oceanographic conditions, using artificial neuronal networks

Abstract by:

Laura Karen Torres Faurrieta

Yellowfin tuna (*Thunnus albacares*) is an epipelagic oceanic species distributed in tropical and subtropical seas. It represents the largest proportion of catches through its distribution and is the main fishery for the Mexican tuna fleet. It has been suggested that environmental conditions have a strong influence on the recruitment variability levels of this species. In the present study, a set of artificial neuronal networks, specifically nonlinear autoregressive networks with exogenous inputs (NARX), was used to model and project the yellowfin tuna recruitment in the eastern Pacific Ocean (OPO), based on oceanographic conditions. Two different periods were analyzed in order to model the recruitment: a global evaluation period (1975-2012) in which the recruitment is studied through the whole species' spawning area, and a regional evaluation period (1980-2012) in which five models are used to study the overall recruitment of the OPO in five different regions within the spawning area. In the global evaluation, the recruitment is modeled with the Southern Oscillation Index (SOI), the Pacific Decadal Oscillation (PDO), and the spawners biomass as inputs. In the regional evaluation, on the other hand, the recruitment is modeled with sea surface temperature, wind magnitude, current-velocity magnitude, and spawners biomass as inputs. A sensitivity analysis, in which the values of each variable are increased and reduced in different percentages, shows that the SOI is the most important variable for the global evaluation model; a positive recruitment estimate is observed when the index values are reduced, suggesting that El Niño conditions are favorable for this species recruitment. In the regional evaluation models, temperature is the most important variable in most regions, showing positive recruitment estimates with increasing temperature. In order to create recruitment projections, four models were generated, which estimate future recruitment based on temperature, wind magnitude, and current-velocity magnitude, whose values were projected by Geophysical Fluid Dynamics Laboratory (GFDL) model version 3.0, under four different scenarios of greenhouse-gas emissions.

Keywords: Yellowfin tuna, Recruitment, Artificial Neuronal Networks

DEDICATORIA

A ellos que representan el centro y equilibrio de mi vida:

A mi padre Santiago, el pilar.

A mi madre Nena, la confianza.

A mi hermano Octavio, el guía.

AGRADECIMIENTOS

Al CICESE, por brindarme la oportunidad de formar parte del posgrado en Ecología Marina y al CONACYT, por el apoyo económico brindado durante estos dos años. A la gente trabajadora de México que a través de sus impuestos hace posible que surjan este tipo de apoyos.

Al Dr. Michel Dreyfus que guio gran parte de esta tesis siempre con paciencia, agradezco a su disposición y a su tiempo para guiarme y atender mis dudas. Le agradezco mucho su interés en mi relación personal con mi trabajo de tesis, porque me mostró que eso era tan importante como cualquier cuestión académica.

Al Dr. David Rivas, porque gran parte de este trabajo de tesis se debe también a su esfuerzo, le agradezco la confianza brindada desde el primer día. Siempre dispuesto a resolver mis dudas de la mejor manera; impulsándome a pensar. No podría medir toda la disposición que vi en él cómo codirector. Agradezco también por su carácter, por el mucho tiempo que me dedicó y por compartirme su conocimiento.

Al Dr. Oscar Sosa por haber aceptado formar parte de mi comité, a pesar de sus muchas actividades. Le agradezco por sus comentarios durante mis avances de tesis y en el desarrollo del escrito, los indudablemente contribuyeron a mejorar este trabajo. Además de que me divierte mucho su forma tan particular de expresar sus opiniones, le admiro esa gran capacidad de análisis.

Al Dr. Enric Pallás por haberse introducido en mi tema de tesis y mostrar interés a pesar de tratarse de un área diferente a la suya. Le agradezco el tiempo dedicado a mis avances, revisiones y todos sus comentarios.

Agradezco a mi mamá lochita (mi abuelita), por siempre desear lo mejor para mí, velar muchas veces por mi salud y bienestar.

A mi tía Vianey que está siempre pendiente de mí y dispuesta ayudarme. Gracias por mostrarme un gran ejemplo de fortaleza.

A mi tía Sughey y mi tío Danny que indistintamente me han mostrado su apoyo durante mi formación profesional, porque me escucharon y aconsejaron, y por todas las palabras de aliento siempre que fueron necesarias.

Agradezco al valioso empuje, al amor, el reconocimiento y los muchos consejos de mi tía Silvia y mi tío Delfino, por creer de esta forma en mí, porque sus palabras pueden llegar en mi conciencia hasta donde llegan las mías.

A mi tía Lety, que es para mí un claro ejemplo de lucha y de esfuerzo, por sus buenos consejos y apoyo incondicional para “la chiquis” (o sea yo).

Agradezco por toda la alegría que me brindan mis otros hermanos, mis primos: Carol, Danna, Laurita, Arely, Orlando, Santi, Mariela, Fer y Mary. Muchas gracias también a Junior porque he recibido de él consejos y apoyo académico. Te admiro y creo que mucho en ti.

A mis grandes amigos a los que guardo con gran cariño, que aun en la distancia siguen siendo como familia: A Susana, Gladys, Ari, David, Abarca, Dosal, Erick, Kike, Tamayo y Gis

A Alfredo por brindarme su valiosa amistad, eres como mi familia en Ensenada, no puedo cuantificar el apoyo que recibí de ti, gracias por toda la felicidad que me brindas en las charlas. Gracia por todos los días que hemos sido pareja del volei, eres el mejor del mundo. A Uriel que se convirtió de pronto en una persona dispuesta a apoyarme, gracias por los muchos apuros de los que me sacaste y por hacerme reír tanto.

A Bety, por el apoyo directo en el desarrollo de la tesis, porque de todo lo que comparto con ella implica siempre un aprendizaje. Aprendí de las muchas veces que compartimos la libertad en un atardecer, en un barco, en algún punto del océano, Aprendí cuando yo me perdía en las estrellas y ella me hablaba de ellas. También de cada metro que nadamos, y por fin me llevo a bucear. Gracias por las agradables tardes en que cantamos con Joaquín sabina, Lila Downs y Chavelita Vargas.

A Hazael, que estuvo para darme soporte en el clímax de mi trabajo, porque me enseñó de humildad, por la seguridad y el descanso que me brinda. Porque su nombre tiene la playa y el volei, eso que tanto me relaja. Gracias por todo lo que aprendimos juntos.

A Hugo, agradezco por hacer a veces el café. Le agradezco por haber escuchado día con día mis problemitas con la tesis y animarme (aún con su particular forma), hasta el punto final de este escrito. Agradezco sobre todo por enseñarme a pensar y por mostrarme el bien de lo radical. Le debo mucho a sus palabras.

A los “Ecólogos marinos buena vibra” por toda la buena onda que traen. En especial a Celia, Pau, Karen y Abi por brindarme amistad en toda la extensión de la palabra.

A mi equipo de futbol “las chonitas” porque jugar con ustedes es la mera felicidad y porque jugando olvidaba el estrés de la tesis.

A César, mi tercera dimensión, porque en esa dimensión representa cuestiones que dan dicha y fuerza, que no se puede explicar.

Tabla de contenido

Resumen en español	ii
Resumen en inglés	iii
Dedicatoria	iv
Agradecimientos	v
Lista de figuras	ix
Lista de tablas	xiv
1. Introducción	1
1.1. Influencia de los factores oceanográficos en el AAA	2
1.2. Redes neuronales artificiales	3
1.2.1. De neurona biológica a neurona artificial	5
1.2.2. Estructura y entrenamiento de las Redes Neuronales Autorregresivas No lineales con entradas Externas (NARX)	8
1.3. Justificación	10
2. Objetivos	11
2.1. General	11
2.2. Específicos	11
3. Hipótesis	12
4. Metodología	13
4.1. Área de estudio	13
4.2. Origen de los datos	14
4.3. Análisis de los datos	15
4.3.1. Configuración de los modelos de redes neuronales	17
4.3.2. Análisis de sensibilidad	18
4.3.4. Proyecciones del reclutamiento	19
4.3.5. Modelo General Lineal	21

Tabla de contenido (continuación)

5. Resultados	23
5.1. Resultados del Modelo General Lineal.....	23
5.2. Estructura y análisis de los modelos NARX	24
5.2.1. Evaluación global.....	24
5.2.2. Evaluación regional	29
5.3. Análisis de sensibilidad y estimación del reclutamiento.....	29
5.3.1. Evaluación global.....	29
5.3.2. Evaluación regional	35
5.4. Proyecciones del reclutamiento	50
6. Discusión	53
6.1. Las ANN's como herramienta de modelación y predicción	53
6.2. Influencia de las variables oceanográficas en el reclutamiento	53
6.3. Proyecciones del reclutamiento del AAA.....	58
7. Conclusiones	61
Lista de referencias	63
Apéndices	67
I. Ventana de la herramienta nstart para generar modelos NARX.....	67
II. Código para la generación de un modelo NARX.....	67
III. Series de tiempo de las variables oceanográficas bajo los diferentes escenarios RCP's.....	69
IV. Serie de tiempo del reclutamiento del AAA para el periodo 1975-2012	71

Lista de figuras

Figura		Página
1	Distribución anual del desove de atún aleta amarilla en el Pacífico Oriental. Se presentan los datos como las proporciones (p) de hembras reproductivamente activas relativas al número total de hembras capturadas en áreas de 1° (Shaefer, 1998).....	2
2	Modelos esquemáticos de neuronas. El panel a) muestra una neurona biológica y el panel b) una neurona artificial.....	6
3	Modelo matemático de una neurona artificial (Beale et al., 2010).....	7
4	Esquema de una red neuronal de tres capas donde las variables representan las señales de entrada, W_{ij} los pesos entre la neurona de entrada i y la neurona oculta j, W_{jk} son los pesos entre la neurona oculta j y la neurona de salida (modificado de Chen y Ware, 1999).....	7
5	Modelo NARX. Los números bajo los recuadros verdes indican el número de variables, los números bajo los recuadros azules, el número de neuronas (Beale et al., 2010).....	9
6	Esquema de las corrientes y las masas de agua superficiales en el OPO: Agua Superficial Subtropical (STSW), Agua Tropical Superficial (TSW), Agua Ecuatorial Superficial (ESW). El sombreado representa el promedio de la temperatura superficial del mar (más oscuro=más frío, tomado de Fiedler y Talley, 2006).....	14
7	Regionalización del área de estudio. El panel (a) muestra las 5 regiones sobre el mapa del promedio de la magnitud del viento en el periodo de la Evaluación regional (1980-2012), los paneles (b) y (c) muestran la regionalización sobre los mapas de la magnitud de las corrientes y la temperatura, respectivamente.....	16
8	Distribución anual de las capturas cerqueras de atún aleta amarilla, por tipo de lance, en el 2012 (CIAT, 2013). El rectángulo azul encierra la región utilizada para el modelo de predicción.....	20
9	Análisis de residuales del modelo de evaluación global. El panel (a) muestra la distribución de varianzas no constantes y el panel (b) muestra distribución normal de los errores.....	24

Lista de figuras (continuación)

10	Reclutamiento esperado contra el calculado por el modelo para la evaluación global.....	25
11	Regresión lineal y coeficiente de correlación entre los datos de reclutamiento esperados y los calculados por el modelo para toda la serie de tiempo (panel (a)). Los paneles (b) (c) y (d) muestran la regresión lineal y el valor del coeficiente de correlación entre los datos de reclutamiento esperados y los calculados para el conjunto de datos de entrenamiento, validación y prueba, respectivamente.....	25
12	Autocorrelación de los errores resultantes en el modelo de evaluación global.....	27
13	Histograma de los errores resultantes del modelo de evaluación global.....	27
14	Respuesta de la salida del modelo del periodo largo a la serie de tiempo. El panel superior muestra la respuesta (línea negra) de la estimación del modelo (asterisco azul) para los datos esperados (punto azul) y los errores obtenidos de la estimación (línea amarilla). El panel inferior muestra la magnitud de dichos errores.....	28
15	Valor de la función de ajuste contra el número de iteraciones. Se Indica que el entrenamiento se detuvo después de 20 iteraciones (epoch). Las curvas representan la forma en que decrece el error durante en el entrenamiento entre los conjunto de datos de entrenamiento (línea azul), validación (línea verde) y prueba (línea roja).....	28
16	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores del SOI modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente.....	31
17	Estimaciones iniciales del modelo de evaluación global (línea roja) y estimaciones con valores del SOI modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente.....	32

Lista de figuras (continuación)

18	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores del PDO modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente.....	32
19	Estimaciones iniciales del modelo de evaluación global (línea roja) y estimaciones con valores del PDO modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente.....	33
20	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de biomasa de los desovadores modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente.....	33
21	Estimaciones iniciales del modelo de evaluación global (línea roja) y estimaciones con valores de la biomasa de los desovadores modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente.....	34
22	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de temperatura modificados, en la región 1. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente.....	42
23	Estimaciones iniciales del modelo de la región 1(línea roja) y estimaciones con valores de la temperatura modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente.....	42
24	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud del viento modificados, en la región 1. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente.....	44

Lista de figuras (continuación)

25	Estimaciones iniciales del modelo de la región 1(línea roja) y estimaciones con valores de magnitud del viento modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente....	44
26	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud del viento modificados en, la región 4. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente.....	45
27	Estimaciones iniciales del modelo de la región 4 (línea roja) y estimaciones con valores de magnitud del viento modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente....	45
28	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud del viento modificados, en la región 5. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente.....	46
29	Estimaciones iniciales del modelo de la región 5 (línea roja) y estimaciones con valores de magnitud del viento modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente....	46
30	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud de las corrientes modificados, en la región 1. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente.....	47
31	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud de las corrientes modificados, en la región 4. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente.....	48

Lista de figuras (continuación)

32	Estimaciones iniciales del modelo de la región 4 (línea roja) y estimaciones con valores de magnitud de las corrientes modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente...	48
33	Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de biomasa de los desovadores modificados, en la región 3. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente.....	49
34	Estimaciones iniciales del modelo de la región 3 (línea roja) y estimaciones con valores de la biomasa de los desovadores. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente....	50
35	Proyecciones del reclutamiento del Atún Aleta Amarilla bajo los diferentes escenarios RCP's	52
	Proyecciones del reclutamiento del Atún Aleta Amarilla bajo los diferentes escenarios RCP's. Se muestran las proyecciones en promedios corridos de 10 años.....	52

Lista de tablas

Tabla		Página
1	Emisiones de CO ₂ planteadas para el 2100 bajo los diferentes escenarios, el valor del forzamiento radiativo y su tendencia.....	21
2	Resumen de los GLM de la evaluación regional.....	23
3	Número de neuronas en la capa oculta para cada región y coeficiente de correlación (Corr) entre los valores estimados y los valores esperados, general y por conjunto de datos.....	29
4	Parámetros del análisis de sensibilidad con las variables modificadas en ambos porcentajes para el modelo de evaluación global.....	30
5	Intervalo de oscilación de las variables oceanográficas en las regiones de la evaluación regional.....	36
6	Parámetros del análisis de sensibilidad en la región 1. Las variables se muestran en orden de importancia para el modelo.....	37
7	Parámetros del análisis de sensibilidad en la región 2. Las variables se muestran en orden de importancia para el modelo.....	38
8	Parámetros del análisis de sensibilidad en la región 3. Las variables se muestran en orden de importancia para el modelo.....	39
9	Parámetros del análisis de sensibilidad en la región 4. Las variables se muestran en orden de importancia para el modelo.....	40
10	Parámetros del análisis de sensibilidad en la región 5. Las variables se muestran en orden de importancia para el modelo.....	41

1. Introducción

El atún aleta amarilla (*Thunnus albacares*, Scombridae) (AAA) es una especie oceánica epipelágica que alcanza tallas superiores a 200 cm de longitud furcal (LF). Se distribuye en todos los mares tropicales y subtropicales, está ausente sólo en el mar Mediterráneo (Collete y Nauen, 1983). Es de las especies más tropicales entre los atunes y es más abundante entre los 30° N y 30° S (Sund et al., 1983). El AAA representa la mayor proporción de las capturas de la flota atunera a través de su distribución (Comisión Interamericana del Atún Tropical, CIAT, 1994), principalmente de las capturas de las capturas que se realizan en la zona oriental y occidental del Océano Pacífico (Minte-Vera, et al., 2014). El atún aleta amarilla es la especie más capturada por la flota atunera mexicana, y es precisamente México el país con mayores capturas de atún aleta amarilla en todo el Océano Pacífico Oriental (OPO). En el año 2012 el 51% del total de las capturas del AAA del OPO provinieron de la flota mexicana (CIAT, 2013).

El desove del AAA dentro del OPO se extiende de los 26°N a los 14°S, de la costa a 140°W (Fig. 1) y ocurre todo el año (Shaefer, 1998). De acuerdo a Shaefer (1998) la talla mínima de madurez sexual de las hembras de AAA en el OPO es de 59 cm de longitud furcal (LF) y casi todas son maduras cuando alcanzan una longitud de ~123 cm LF mientras que en los machos la talla mínima es de ~50 cm LF y la mayoría son maduros con una longitud de ~90 cm LF. Según el estudio anterior, una hembra de esta especie de ~123 cm LF y 3 años de edad, puede desovar durante 222 días, a lo largo de un año, en múltiples ocasiones. No obstante, el reclutamiento de los juveniles a la pesquería es altamente variable, con componentes estacionales (Holey y Maunder, 2007). El AAA es reclutado a la pesquería cuando tiene aproximadamente 30 cm LF y 0.5 años de edad (CIAT, 1994). Holey y Maunder (2007) analizaron el estatus de la población del AAA en el OPO, sugieren que el reclutamiento ha experimentado diferentes cambios de régimen. Ellos encontraron un régimen de reclutamiento bajo de 1975-1984 y un régimen de reclutamiento alto de 1985-2005. La CIAT (2013) estimó posteriormente un cambio de régimen bajo en el periodo 2003-2011. Los cambios de régimen en el reclutamiento han precedido a cambios en abundancia; el alto reclutamiento produciendo altos niveles de biomasa.

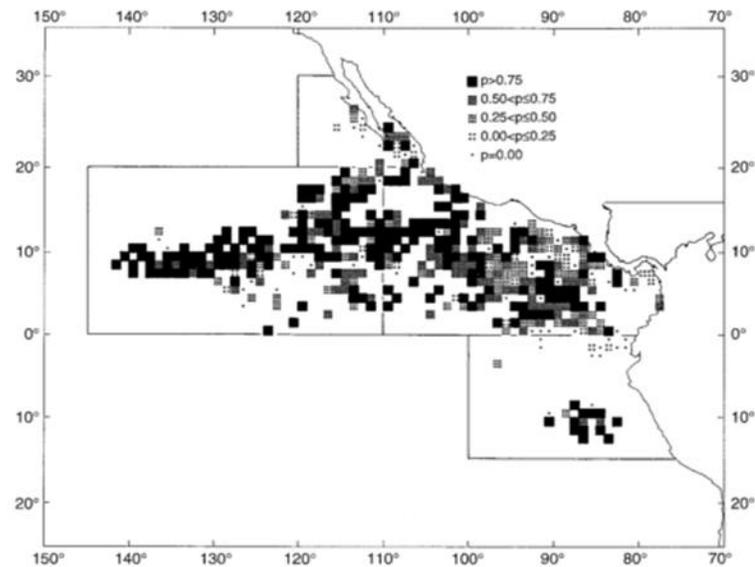


Figura 1. Distribución anual del desove de atún aleta amarilla en el Pacífico Oriental. Se presentan los datos como las proporciones (p) de hembras reproductivamente activas relativas al número total de hembras capturadas en áreas de 1° (Shaefer, 1998)

1.1. Influencia de los factores oceanográficos en el AAA

La distribución del AAA está fuertemente relacionada con la estructura térmica de la columna de agua, especialmente con la temperatura superficial (Suárez-Sánchez et al., 2004), se le encuentra principalmente en áreas en donde la temperatura superficial excede los 26°C (Maury, et al., 2001; Suzuki, et al., 1978). En el OPO el AAA se encuentra en concentraciones favorables para la pesquería comercial en aguas con temperaturas entre los 20 y 28 °C (Castro-Ortíz y Quiñones-Valásquez, 1987) . El desove tiene lugar a temperaturas mayores de 24-26°C (Suzuki, 1994; Wild, 1994). Geográficamente en el OPO el desove ocurre continuamente entre 0°y 20°N, mientras que al norte de 20° y al sur de 0° ocurre sólo cuando la temperatura superficial excede los 24°C (Margulies, 2001). Wexler et al. (2011) encontraron que el intervalo óptimo de temperatura para el crecimiento rápido y alta sobrevivencia de las larvas de atún aleta amarilla es de 26°C a 31°C. Otros factores físicos importantes son las surgencias y la turbulencia. De forma general, se ha establecido que la intensidad de las surgencias inducidas por el viento modula los índices de reclutamiento de los peces pelágicos Cury y Roy (1989). En general, la turbulencia de pequeña escala es un mecanismo potencialmente importante

en la dinámica de alimentación de las larvas de peces (Margulies, 2001). Simulaciones teóricas, como las realizadas por Haury et al. (1990), indicaron que el incremento en la turbulencia podría aumentar la tasa de encuentro entre las larvas de peces y sus presas. La turbulencia parece ser benéfica sólo a niveles intermedios ya que sobre esos niveles se reduce la tasa de captura en las larvas, debido a la disgregación de los parches de sus presas.

En el OPO son escasos los estudios dirigidos a analizar el reclutamiento del AAA y su relación con las condiciones oceanográficas. Lehodey et al. (2003) en el Océano Pacífico Occidental, encontraron una relación entre el reclutamiento del AAA y los índices climáticos PDO y la oscilación sureña de El Niño (ENSO). Dichos autores concluyeron que el reclutamiento depende de la variabilidad en la extensión espacial de la alberca de agua cálida en el Océano Pacífico. Así mismo ellos observaron que los eventos de El Niño parecen ser favorables para el reclutamiento del AAA. De igual forma se ha observado que el reclutamiento del AAA en el OPO, tiende a ser grande después de eventos de El Niño (Joseph y Miller, 1989).

En este mismo sentido, la CIAT (2013) ha reportado un incremento en las capturas del AAA después de un fuerte año El Niño (1982-1983). Por otro lado, Langley et al. (2009) estudiaron la influencia de la variabilidad oceanográfica sobre el reclutamiento del AAA en el Pacífico Occidental y Central, revelando que un alto reclutamiento del AAA está asociado con los fuertes vientos del noroeste.

1.2. Redes neuronales artificiales

Las redes neuronales artificiales (ANNs, por sus siglas en inglés) son algoritmos informáticos que simulan la actividad de neuronas y el procesamiento de información del cerebro humano (Chen y Ware, 1999). El modelado con ANNs es una herramienta poderosa para explorar problemas biológicos complejos, no lineales (Chen y Ware, 1999), como lo es la respuesta del reclutamiento a las condiciones oceanográficas. Basados en la eficiencia de los procesos llevados a cabo por el cerebro, e inspirados en

su funcionamiento, se ha desarrollado la teoría de las ANN's, las cuales se han utilizado para aprender estrategias de solución basadas en ejemplos de comportamiento típico de patrones; estos sistemas no requieren que la tarea a ejecutar se programe, sino que generalizan y aprenden de la experiencia. Las aplicaciones más exitosas de las ANN's son procesamiento de imágenes y de voz, reconocimiento de patrones, planeamiento, Interfaces adaptivas para sistemas hombre/máquina, control y optimización, filtrado de señales y predicción (Tanco, 2003).

Las redes neuronales tienen la capacidad de aprender a realizar tareas basadas en un entrenamiento o experiencia inicial. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje. A partir de esto son capaces de generalizar y responder apropiadamente cuando se les presentan datos o situaciones a los que no habían sido expuestos anteriormente (Zangh et al., 1998; Lek y Guégan, 1999; Tanco, 2003). Por ejemplo, en este estudio se generarán redes a las que se le otorgarán ejemplos (durante un entrenamiento) de la respuesta del reclutamiento a diferentes condiciones de una serie de variables oceanográficas. Estos modelos de redes neuronales, deberán tener la capacidad de aprender las relaciones entre las variables oceanográficas y el reclutamiento y podrán estimar el valor del reclutamiento para condiciones oceanográficas desconocidas por el modelo de red neuronal (siempre y cuando se trate de las mismas variables utilizadas durante el entrenamiento).

Numerosas redes neuronales han sido implementadas para evaluar cuestiones de pesquerías. Gaertner y Dreyfus-León (2004) con base en un modelo de red neuronal artificial, analizaron las relaciones entre la captura por unidad de esfuerzo y la abundancia de peces en la pesquería atunera de cerco. Algunos autores han desarrollado ANNs para predecir el estado del recurso o la pesca, en las que se incluyeron factores oceanográficos como variables explicativas. Algunos ejemplos son la predicción de la biomasa de la anchoveta peruana (*Engraulis rigens*) en el sistema de surgencias de Perú (Jarre-Teichmann et al., 1995), la predicción de la fluctuación en la abundancia de sardina japonesa (*Sardinops melanostictus*) en las costas de Japón (Aoki y Komatsu, 1997), la predicción del reclutamiento del arenque del Pacífico (*Clupea pallasii*) a la biomasa pescable de las costas de Vancouver, Columbia Británica (Chen y Ware, 1999) y la

predicción de los desembarques de la sardina del Pacífico (*Sardinops sagax*) (Gutiérrez Estrada et al., 2009) en el norte de Chile. En los estudios anteriores ha sido posible hacer predicciones de la biomasa, abundancia y reclutamiento de las especies a partir de las condiciones oceanográficas y dichos estudios concuerdan en que las ANNs son una buena herramienta para hacer predicciones.

1.2.1. De neurona biológica a neurona artificial

El cerebro consta de un gran número de elementos de procesamiento altamente interconectados, llamados neurona. Las neuronas del cerebro humano están compuestas de tres partes principales; una célula central o núcleo llamado soma y dos diferentes tipos de ramificaciones, las dendritas y el axón. En una neurona la información es recibida por las dendritas a través de conexiones especiales, la sinapsis. Las dendritas consisten en ramificaciones en forma de árbol que provienen del soma y representan el árbol receptor de la red, son como fibras nerviosas que cargan de señales eléctricas el cuerpo de la célula. El axón es una fibra larga que lleva la señal desde el cuerpo de la célula hacia otras neuronas. Todas las neuronas conducen la información de forma similar, esta viaja a lo largo de axones en breves impulsos eléctricos, denominados potenciales de acción. La sinapsis por medio de neurotransmisores, se encarga de facilitar la generación de impulsos de mayor velocidad hacia la otra neurona, o por el contrario, dificultar la emisión del impulso. La neurona recibe impulsos amplificados o atenuados. La suma de estos impulsos en el cuerpo de la célula determinará si será o no estimulada dependiendo de si el valor de dicha suma es superior al valor del umbral de generación del potencial de acción. (Tanco, 2003; Rico, et al., 2009).

La Fig. 2. muestra los modelos esquemáticos de una neurona biológica y una neurona artificial. En el modelo artificial las entradas x_i representan las señales que provienen de otras neuronas y que son capturadas por las dendritas. Los pesos w_i son la intensidad de la sinapsis que conecta dos neuronas; tanto x_i como w_i son valores reales, θ es la función umbral que la neurona debe sobrepasar para activarse. Las señales de entrada a una neurona artificial son variables continuas en lugar de pulsos discretos, como se

presentan en una neurona biológica. Cada señal de entrada pasa a través de una ganancia o peso, llamado peso sináptico o fuerza de la conexión cuya función es análoga a la de la función sináptica de la neurona biológica. Los pesos pueden ser positivos (excitatorios), o negativos (inhibitorios). Un nodo sumatorio acumula todas las señales de entradas multiplicadas por los pesos o ponderadas y las pasa a la salida a través de una función umbral o función de transferencia para formar una salida final y . Información más detallada del funcionamiento de las redes neuronales biológicas y su analogía con las neuronas artificiales está disponible en (Mehrotra, et al., 1997), Tanco (2003) y (Kriesel, 2007)

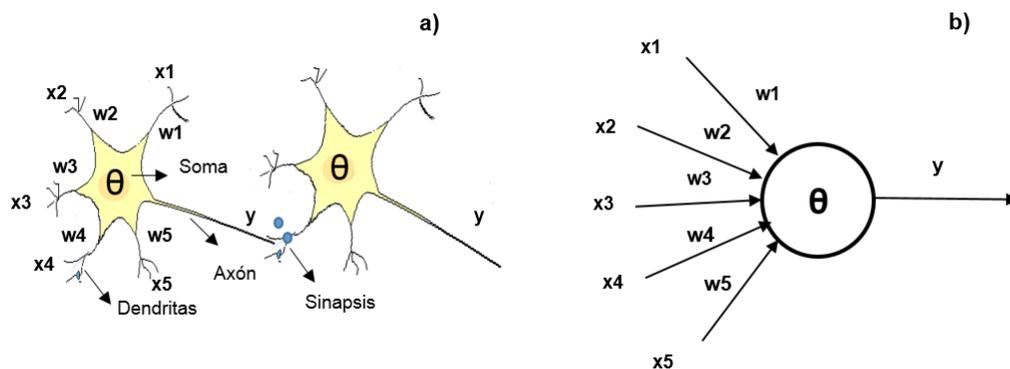


Figura 2. Modelos esquemáticos de neuronas. El panel a) muestra una neurona biológica y el panel b) una neurona artificial.

En el modelo matemático de una neurona artificial Fig. Hay 3 funciones operacionales distintas. Primero, la entrada escalar p es multiplicada por un peso escalar w para formar un producto wp , de nuevo, un escalar. Segundo, la entrada ponderada se añade a un sesgo escalar b para formar la entrada neta n . este sesgo puede ser visto como un ajuste de la función f por una cantidad b . La neuronas sesgo (bias, en inglés) es un truco técnico para considerar el valor del umbral como un peso de conexión cuyo valor siempre es 1, lo cual facilita los cálculos de la red. Finalmente, la entrada neta pasa a través de una función de transferencia f . la cual produce una salida escalar a (Beale et al., 2010).

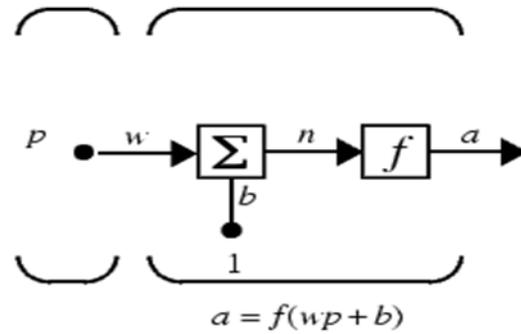


Figura 3. Modelo matemático de una neurona artificial (Beale et al., 2010)

Una red neuronal es una red interconectada de capas con elementos de procesamiento donde la primera capa (capa de entrada) hace cálculos independientes, en donde cada neurona artificial hace su función y pasa los resultados a una capa oculta. Esta capa puede a su vez pasar los resultados a otra capa oculta. Finalmente, la última capa (capa de salida) determina la salida o resultado de la red (Jarre-Teichmann et al., 1995; Chen y Ware, 1999). La Fig. 4 muestra un esquema general de una red neuronal de 3 capas.

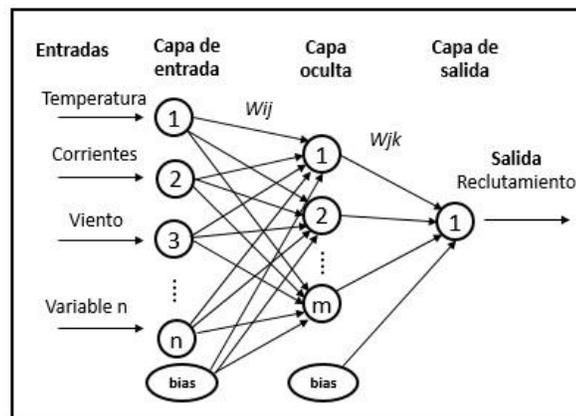


Figura 4. Esquema de una red neuronal de tres capas donde las variables representan las señales de entrada, W_{ij} los pesos entre la neurona de entrada i y la neurona oculta j , W_{jk} son los pesos entre la neurona oculta j y la neurona de salida (modificado de Chen y Ware, 1999)

1.2.2. Estructura y entrenamiento de las Redes Neuronales Autorregresivas No lineales con entradas Externas (NARX)

Existen diferentes tipos de redes neuronales las cuales difieren unas de otras en arquitectura y algoritmos de entrenamiento. Las NARX son redes dinámicas recurrentes con conexiones de retroalimentación. En donde el valor de la salida depende no solo de la señal de entrada actual sino que también depende de entradas y salidas previas. Este tipo de redes cuentan con entradas de desfase que le dan a la red memoria parcial por el hecho de que las capas ocultas y la capa de entrada reciben señales (x) al tiempo t pero también al tiempo $t-n$, donde n es el número de desfases. De la misma forma puede recibir como señales de entrada las salidas (y) calculadas al tiempo $t-n$. El modelo NARX es definido por la siguiente ecuación:

$$y(t) = f(y(t-1), y(t-1) \dots, y(t-n), x(t-1), x(t-2) \dots, x(t-n)) \quad (1)$$

donde el próximo valor de salida, la variable $y(t)$ se calcula a partir de valores previos de la señal de salida y valores previos de la señal de entrada independiente (externos). Este tipo de red cuenta con dos capas de realimentación con una función de transferencia sigmoide en la capa oculta y una función de transferencia lineal en la capa de salida (Beale et al., 2010). Generalmente y en este trabajo en particular, la red neuronal está compuesta por las señales de entrada al inicio de la red, una capa oculta y una capa de salida con una neurona de salida. Sin embargo no existen formas para determinar la arquitectura de la red y en particular el número de neuronas requeridas en la en la capa oculta. La Fig. 5 muestra el modelo de una NARX con tres desfases de las variables dependientes (señalados por 1:3 en la Fig.) lo que indica que las señales de entrada están conformadas por $x(t)$, $x(t-1)$, $x(t-2)$ y $x(t-3)$. Además cuenta con $y(t-1)$, $y(t-2)$ y $y(t-3)$ como variables de entrada.

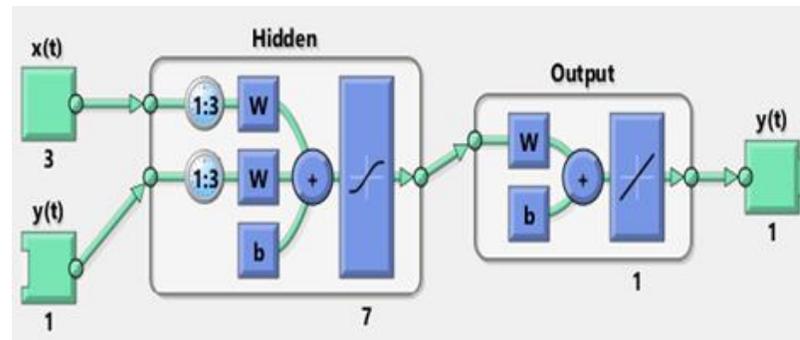


Figura 5. Modelo NARX. Los números bajo los recuadros indican el número de neuronas en las diferentes capas. (Beale et al., 2010)

El entrenamiento de las NARX es de tipo supervisado, este tipo de entrenamiento consiste en otorgar a la red los patrones de entrada así como la salida esperada (resultado correcto). Así para cada conjunto de datos de entrenamiento que es suministrado a la red, la salida puede ser comparada con la solución correcta y los pesos de la red pueden ser cambiados de acuerdo a la diferencia. El objetivo es que la red modifique los pesos con el fin de que ésta pueda no sólo asociar las entradas con las salidas después del entrenamiento sino que pueda también dar resultados plausibles para entradas similares pero desconocidas es decir; que pueda generalizar.

El procedimiento general es la introducción de la información de entrada (donde se activan las neuronas de entrada), después se propaga la información a través de la red y se genera una salida, posteriormente la salida de la red es comparada con la salida deseada y se calcula el error, finalmente se hace correcciones en los pesos que se basan en dicho error hasta que se logra minimizar el error. (Kriesel, 2007). Durante el entrenamiento el conjunto de datos se divide en tres subconjuntos. El primer subconjunto es el conjunto de entrenamiento, con este conjunto de datos se lleva a cabo el aprendizaje de la red por medio del ajuste de los pesos. El segundo subconjunto es el conjunto de validación el cual sirve para monitorear el error durante el proceso de entrenamiento. El error de validación normalmente decrece durante la fase inicial de entrenamiento, igual que el error en el conjunto de entrenamiento. Sin embargo, cuando la red comienza a sobre ajustarse a los datos, el error de validación comienza a elevarse. En ese momento los pesos de la red son guardados en el mínimo error del conjunto de validación. El último subconjunto es el conjunto de prueba, éste no es usado durante el entrenamiento pero

es utilizado posteriormente para evaluar el desempeño de la red. Se trata de un conjunto de datos que son desconocidos para la red, cuando la red calcula la salida para ese conjunto de datos es posible comparar dicha salida con la salida o real o datos esperados y estimar la efectividad del modelo para generalizar (Beale et al., 2010). En el presente estudio modelos NARX son utilizados para modelar y predecir el reclutamiento del atún aleta amarilla con base en las condiciones oceanográficas del OPO ya que estos modelos pueden ser utilizados para representar sistemas dinámicos no lineales y son útiles en la predicción de series de tiempo.

1.3. Justificación

La relevancia de hacer proyecciones de los niveles de reclutamiento de una especie a la pesquería, radica en que estas proyecciones son una herramienta importante dentro de la estructura de manejo de una población de peces que es explotada (Dreyfus-León y Schweigert, 2008). Según la CIAT (2013), a partir del 2010 y con proyecciones hasta el 2023, el cociente de biomasa reproductora del AAA estuvo y estará, por debajo del límite del rendimiento máximo sostenible, debido al incremento en la mortalidad por pesca. Históricamente, situaciones similares dieron lugar a regímenes de baja productividad. Aunque se estima que el esfuerzo de pesca actual está en el nivel que sostiene el rendimiento máximo sostenible, los cambios moderados en el nivel de esfuerzo modificarían considerablemente la biomasa a largo plazo. Dada la susceptibilidad de la pesquería y en el entendido de que el nivel de reclutamiento puede variar tanto a corto como a largo plazo, es muy importante entender cómo esas variaciones responden a las condiciones oceanográficas. Así como se debe hacer un esfuerzo por estimar el reclutamiento futuro considerando también el efecto de dichas condiciones, ya que éstas podrían marcar la pauta en el nivel de reclutas. De esta forma se generará información que puede ser útil para el establecimiento de medidas de manejo subsecuentes.

2. Objetivos

2.1. General

Generar un modelo para proyectar reclutamiento futuro del AAA con base en las condiciones oceanográficas, aplicable en el OPO, con redes neuronales artificiales como herramienta de modelación.

2.2. Específicos

- Generar una base de datos que contenga las variables oceanográficas y biológicas; el Índice de Oscilación Sureña (SOI), el índice de Oscilación Decadal del Pacífico (PDO), la magnitud del viento, la magnitud de las corrientes, la temperatura, la biomasa estimada de desovadores, y el reclutamiento estimado.
- Modelar el reclutamiento del AAA con base en información oceanográfica en diferentes regiones de OPO.
- Identificar las variables con mayor influencia en el reclutamiento del AAA.

3. Hipótesis

- Dado que las temperaturas cálidas son favorables para los juveniles del AAA. se espera que el reclutamiento se vea favorecido bajo condiciones El Niño y en general por las temperaturas más cálidas.
- Debido a que el éxito en la alimentación de las larvas del AAA depende en gran medida de la entrada de nutrientes y de la turbulencia generada por el viento (Haury et al., 1990), habrá una fuerte relación entre la magnitud del viento y los niveles de reclutamiento.
- No habrá una relación entre la biomasa de los adultos y la biomasa de reclutas.

4. Metodología

4.1. Área de estudio

Las principales características oceanográficas del OPO se muestran en la Fig. 6. Esta región está fuertemente influenciada por el sistema de corrientes ecuatoriales; éste consiste en la Corriente Ecuatorial Norte (NEC, por sus siglas en inglés), que fluye hacia el oeste en dirección de los vientos alisios alrededor de 10° y 20°N (Wyrtki, 1964), la Corriente Ecuatorial Sur (SEC), que se extiende desde ~10°S a través del ecuador hasta casi 5°N, y la Contracorriente Ecuatorial del Norte (NECC), la cual fluye hacia el este entre la NEC y la SEC, donde los vientos alisios se relajan en la zona de calmas ecuatoriales asociado a la zona de convergencia intertropical (ICZ). En este sistema se presentan las dos principales zonas de surgencia oceánicas, la surgencia de la NECC en ~10°N y la surgencia ecuatorial en ~0°, además se presenta una convergencia en ~5°N. A lo largo de la frontera oriental del OPO las corrientes de Perú y de California fluyen hacia el ecuador, el anterior sistema costero termina en la NEC y la SEC (Ichii et al., 2002).

Otra de las características importantes en el OPO es la alberca de agua cálida (>27.5°C) que se centra a lo largo de las costas suroeste de México y Guatemala, se origina debido a que la convergencia de los vientos alisios en la ICZ ocurre a una buena distancia del continente americano, por lo que los vientos aquí son comparativamente débiles con menor mezcla (Wang y Enfield, 2001; Fiedler y Talley, 2006). Agua superficial relativamente fría marca una lengüeta de agua fría, centrada directamente en el ecuador al oeste de 120°W y ligeramente al este en el sur del ecuador. La variabilidad temporal en el OPO es dominada por el ENSO, (Fiedler y Talley, 2006). Es bien conocido que el OPO también está influenciado por variaciones interdecadales, representadas por el PDO, aunque el origen de dicha variabilidad es aún un debate (Mestas-Nuñez y Miller, 2006). Los efectos generales se asemejan a un leve y prolongado ENSO, con temperaturas superficiales más altas, termoclina más profunda y menor productividad primaria en la fase cálida (El Niño) que durante la fase fría (La Niña) (Lavín et al., 2006).

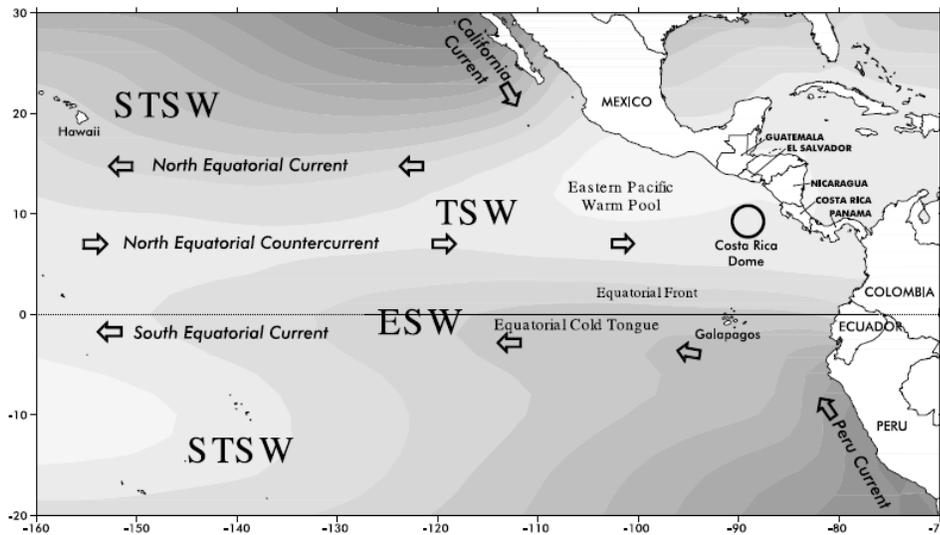


Figura 6. Esquema de las corrientes y las masas de agua superficiales en el OPO: Agua Superficial Subtropical (STSW), Agua Tropical Superficial (TSW), Agua Ecuatorial Superficial (ESW). El sombreado representa el promedio de la temperatura superficial del mar (más oscuro=más frío, tomado de Fiedler y Talley, 2006)

4.2. Origen de los datos

Los datos de las estimaciones del reclutamiento y de la biomasa de los adultos del AAA para el periodo 1975-2012, fueron proporcionados por la CIAT en valores trimestrales para todo el OPO. Dichas estimaciones fueron realizadas con el modelo *Stock Synthesis* versión 3.23b (Methot, 2011), el cual consiste en un modelo estadístico de evaluación de poblaciones integrado con estructura por edad.

Los datos del SOI provienen de Centro Nacional de Investigación Atmosférica (NCAR, por sus siglas en inglés) disponibles en <http://www.cgd.ucar.edu/cas/catalog/climind/soi.html>. El índice del PDO se obtuvo de los datos del Instituto Unido para la Investigación de la Atmósfera y el Océano (JISAO) de la Universidad de Washington, de su sitio de internet <http://jisao.washington.edu/pdo/>. Los datos del viento se obtuvieron de un reanálisis en promedios mensuales, con una resolución de 2.5°, provenientes de la División de Ciencias Físicas (PSD) de la Administración Nacional Oceánica y Atmosférica (NOAA), disponibles en su sitio de internet <http://www.esrl.noaa.gov/psd/>. Se obtuvo además un reanálisis de la velocidad de las corrientes en promedios mensuales con una resolución de 1/3° en latitud y 1° en

longitud, del Sistema Global de Asimilación de Datos Oceánicos (GODAS, provistos por la NOAA, también disponibles en el anterior sitio de internet). Finalmente, para la temperatura se obtuvieron promedios mensuales con una resolución espacial de 2° derivados de un análisis del Set Internacional de Datos Océano-Atmósfera (ICOADS) provistos por la NOAA en su sitio de internet <http://icoads.noaa.gov/products.html>.

4.3. Análisis de los datos

De acuerdo a la disponibilidad de los datos y con la finalidad de estudiar todas las variables de interés en el mayor tiempo posible, se generaron dos periodos de estudio; un periodo denominado “Evaluación global” (1975-2012) y otro periodo denominado “Evaluación regional” (1980-2012). El modelo de la evaluación global está conformado por el SOI, el PDO y la biomasa de los desovadores como variable biológica. Para este periodo se modeló el reclutamiento total que ocurre en el OPO considerando las variables anteriores en la mayor parte de la región del desove de los adultos (de allí el nombre de global) (Fig. 1). Esta región de estudio está comprendida desde la costa oriental del continente americano hasta 130° W y desde 24°N los 14°S.

Los modelos de la evaluación regional también están constituido por la biomasa de los desovadores, además de la temperatura, la magnitud de las corrientes y la magnitud del viento. Con los datos disponibles en este periodo se modeló el reclutamiento total en cinco diferentes regiones (ver Fig. 7), por lo que se obtuvieron datos para cada región y se generó un modelo NARX para cada una de ellas. Cabe mencionar que tanto para el reclutamiento como para la biomasa de los desovadores el modelo *Stock Synthesis* proporciona un solo valor trimestral para todo el OPO por lo que en todos los modelos se usaron los mismos valores de biomasa de desovadores y modelan los mismos valores de reclutamiento. Para la regionalización, la extensión geográfica correspondiente al modelo de evaluación global, fue dividida en cinco regiones, en función de las características oceanográficas, procurando que dichas características fueran diferentes entre las regiones. La Fig. 7 muestra la regionalización sobre los campos promedios de las variables de estudio. La región 1 abarca parte del sistema de la Corriente de California y está delimitada en 7-15°N y 103-117°W. La región 2, dominada por la NEEC está

delimitada en 5-15°N, y 103-130°W. La región 3 dominada por la SEC, está delimitada en 5°N, 2°S y 103-130°W. La región 4, que encierra parte de la NEEC al sur y dominada al norte por la extensión de agua cálida del OPO, se encuentra delimitada 1-18°N y 75-103°W. Finalmente la región 5, que encierra parte de la corriente de Perú delimitada en 1°N, 15°S y 75-95°W. Luego de la obtención de los datos de todas las variables, se realizaron promedios trimestrales de cada variable en cada una de las regiones, lo que permitió que los datos de reclutamiento y el resto de las variables estuvieran en la misma resolución temporal. Dichos datos fueron utilizados para la modelación del reclutamiento con modelos NARX. Finalmente se realizaron modelos lineales generalizados (GML) para cada periodo y sus regiones correspondientes con la finalidad de contrastar los resultados con los obtenidos con los modelos NARX.

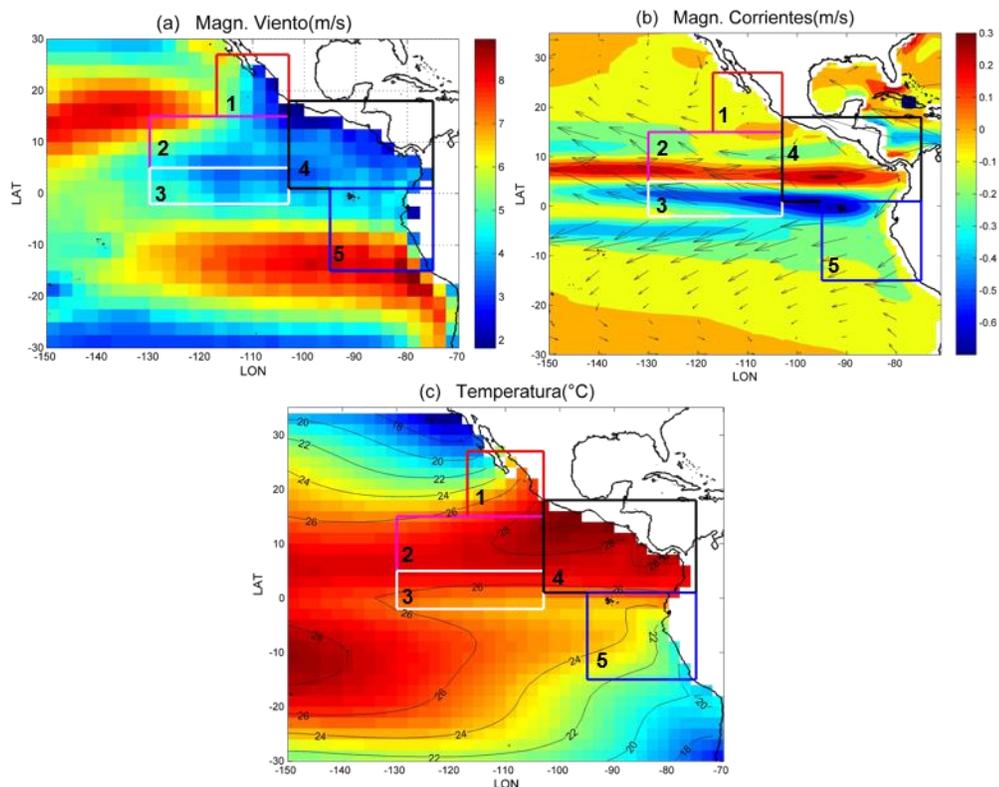


Figura 7. Regionalización del área de estudio. El panel (a) muestra las 5 regiones sobre el mapa del promedio de la magnitud del viento en el periodo de la Evaluación regional (1980-2012), los paneles (b) y (c) muestran la regionalización sobre los mapas de la magnitud de las corrientes y la temperatura, respectivamente

4.3.1. Configuración de los modelos de redes neuronales

Los modelos NARX fueron configurados en la plataforma *Matlab* versión R2012b. Se generó un modelo para el conjunto de datos del modelo de evaluación global y un modelo para cada región de estudio que comprende la evaluación regional. Dichos modelos se generaron con la ayuda de la herramienta **nstart**, la cual consiste una interfaz gráfica (Apéndice I) en la que se integran los datos de entrada (las variables independientes) y los datos de salida esperados (el reclutamiento). También es posible ajustar algunos parámetros por ejemplo, el número de desfases deseados(n), que es simplemente el número de datos de x (variables de entrada) y de y (reclutamiento esperado) al tiempo $t-n$ que son utilizados para estimar el siguiente valor de reclutamiento. La herramienta usa normalmente dos desfases, en los presentes modelos se utilizaron tres desfases (tres datos trimestrales anteriores) con la finalidad de abarcar las condiciones que ocurrieron al tiempo del desove y durante la alimentación de las larvas; aunque el reclutamiento del AAA ocurre a los 6 meses después de nacidos, un desfase más permitió a los modelos obtener mejores ajustes.

Por otro lado, se puede ajustar la proporción de datos que serán utilizados para el entrenamiento, la validación y la prueba, en este caso se usaron las proporciones que la herramienta usa de manera predeterminada, las cuales corresponden al 75%, 15% y 15%, respectivamente. Estas proporciones son recomendadas debido a que es importante que gran parte de los datos se asigne al conjunto de entrenamiento para que los modelos puedan aprender la mayor cantidad de relaciones posibles entre las variables de entrada y las salidas. Además se requiere indicar el número de neuronas que se consideren necesarias en la capa oculta (todos modelos de redes generados consisten en una capa oculta de neuronas y una capa con una neurona de salida). Después de proporcionar los datos y de realizar ajustes, el programa inicia el entrenamiento para encontrar el mejor modelo de red neuronal que haga estimaciones de reclutamiento lo más parecidas a los datos reales. Al finalizar el entrenamiento, se accedió a los códigos de *Matlab* que se generan en la herramienta **nstart** durante la configuración y entrenamiento de los modelos (Apéndice II), con la finalidad de analizar gráficos y corroborar que se hayan generado modelos adecuados. Aunque los modelos de redes neuronales plantean exigencias mínimas sobre los supuestos y la estructura del modelo,

básicamente se evalúa el coeficiente de correlación entre las estimaciones de la red y los datos esperados, así como los errores, los cuales deben ser independientes entre sí y además tener una distribución normal. Cada modelo generado se configuró inicialmente para su entrenamiento con un número de neuronas en la capa oculta igual al número de variables de entrada y con una neurona salida. En caso de no haber obtenido un buen modelo, se modificó el número de neuronas en la capa oculta, las cuales generalmente marcan la diferencia entre tener o no un buen modelo. Esta modificación consistió en incrementar el número de neuronas de uno en uno hasta obtener un buen modelo según los criterios anteriores.

4.3.2. Análisis de sensibilidad

El análisis de sensibilidad se realizó con el fin de determinar la importancia o el impacto que tienen las variables en sus modelos correspondientes. Dicho análisis consistió en incrementar y reducir a cada una de las variables en un cierto porcentaje de su valor original. Los porcentajes de modificación para la evaluación global y la evaluación regional se eligieron procurando que los valores modificados (especialmente los de las variables oceanográficas), entraran en su mayoría en el intervalo de valores que fueron obtenidos inicialmente. Esto para asegurar no exceder el intervalo de valores de aprendizaje del modelo y a la vez otorgar valores que fueran condiciones reales en el océano. Para el modelo de evaluación global, las variables de entrada fueron modificadas (incrementadas o reducidas) en un 10% y 30%, mientras que en los modelos de evaluación regional, el porcentaje de modificación fue de 5% y 10%. Para analizar la importancia de una variable en su modelo correspondiente, por ejemplo el SOI, los argumentos de entrada del modelo fueron sustituidos por los valores de SOI incrementados en 10% en un primer caso y en un segundo caso sustituidos por los valores del SOI reducidos en 10% y lo mismo para el 30%. Mientras la variable en cuestión fue modificada, ya sea incrementada o reducida, el resto de las variables de entrada permanecieron en sus valores originales. El mismo procedimiento se siguió para el análisis de cada una de las variables. Para medir la sensibilidad se calculó la raíz del error cuadrático medio entre las estimaciones iniciales del modelo y las nuevas

estimaciones, resultantes de cada modificación, así como la suma del cuadrado de las diferencias y las correlaciones entre las mismas.

4.3.4. Proyecciones del reclutamiento

Para estructurar el modelo de red neuronal con el cual se hicieran predicciones del reclutamiento en el OPO, se eligió la región 5 partiendo de que aparentemente es la zona donde ocurre el mayor reclutamiento del AAA. Puesto que las mayores capturas de los organismos más pequeños (<100 cm) se obtienen de la pesca asociada a objetos flotantes (Dreyfus-León y Robles-Ruiz, 2008; CIAT,2013) y con base en el mapa de la distribución de capturas por tipo de lance (figura 8), se observa que la región de más capturas con objetos flotantes (la cual sugiere organismos más pequeños y por tanto mayor reclutamiento) es la que concuerda con la región 5.

Las proyecciones de reclutamiento del modelo predictor se realizaron a partir de la temperatura, la magnitud del viento y la velocidad de las corrientes. Dichos datos se obtuvieron en promedios mensuales para periodo 2014-2100, los cuales consisten en proyecciones de las variables bajo cuatro diferentes escenarios climáticos, provenientes del Laboratorio de Dinámica de Fluidos Geofísicos (GFDL, por sus siglas en inglés), versión 3.0, disponibles en <http://data1.gfdl.noaa.gov>. El GFDL ha desarrollado modelos numéricos para pronosticar el comportamiento del clima atmosférico, oceánico, terrestre y de los casquetes polares como parte del Proyecto de Intercomparación de Modelos Acoplados (CMIP) fase 5 (IPCC, 2013). Estos modelos responden a la variación en el tiempo de la concentración de varios constituyentes atmosféricos (por ejemplo, gases de efecto invernadero), de tal forma que hacen proyecciones de simulaciones futuras forzadas por concentraciones específicas de emisiones de gases de efecto invernadero referidas como “vías de concentración representativas” (RCP, por sus siglas en inglés). Los cuatro escenarios utilizados en el estudio, corresponden a RCP’s generados por el GFDL: RCP2.6, RCP4.5, RCP6.0 y RCP8.5 que se generan suponiendo diferentes políticas climáticas. Las etiquetas del RCP proveen una estimación aproximada del forzamiento radiativo que se alcanzará en el año 2100, por ejemplo, RCP8.5 es el escenario de mayores emisiones y mayor forzamiento radiativo, simula el clima futuro con

un escenario de emisiones que alcanza un forzamiento radiativo de aproximadamente 8.5 W m^{-2} en el año 2100 (relativo a las condiciones preindustriales). El RCP4.5 y el RCP6.0 son dos escenarios intermedios que alcanzan un forzamiento radiativo de 4.5 W m^{-2} y 6.0 W m^{-2} , respectivamente. El RCP2.6 es un escenario de bajo forzamiento, también llamado escenario pico y decaimiento, en el cual el forzamiento radiativo alcanza un máximo cerca de la mitad del siglo XXI para luego decrecer a un nivel de 2.6 W m^{-2} en el año 2100 (Taylor et al., 2012). La tabla 1 resume las condiciones de cada escenario. Una vez obtenidos los promedios mensuales de las variables de cada escenario; se obtuvieron promedios trimestrales, los cuales fueron los datos de entrada del modelo. Finalmente a partir del modelo NARX se estimó el reclutamiento a partir de las variables correspondientes a cada escenario.

Cabe mencionar que en sus versiones anteriores el modelo GFDL ha demostrado tener mayor capacidad para reproducir variables como el SOI (Lin, 2007) y el PDO (Overland y Wang, 2007) en comparación con otros modelos de su tipo, de aquí que se decidió usarlo en el presente estudio.

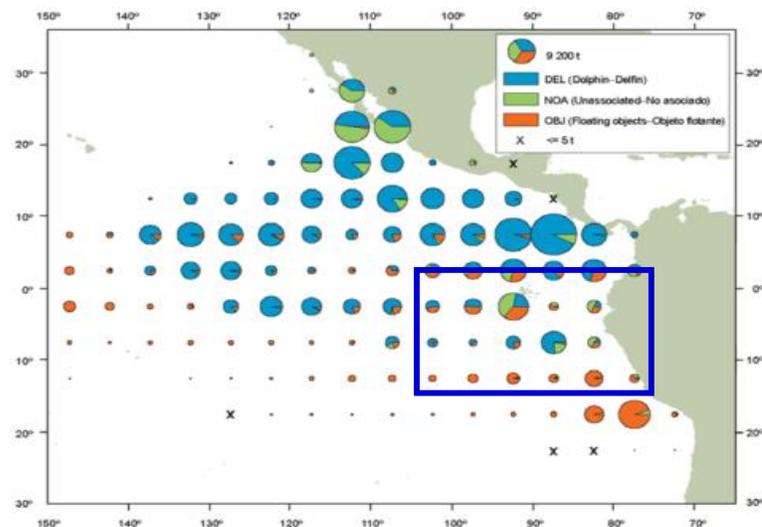


Figura 8. Distribución anual de las capturas cerqueras de atún aleta amarilla, por tipo de lance, en el 2012 (CIAT, 2013). El rectángulo azul encierra la región utilizada para el modelo de predicción

Tabla 1. Emisiones de CO₂ planteadas para el 2100 bajo los diferentes escenarios, el valor del forzamiento radiativo y su tendencia.

Escenario	CO ₂ en 2100	Forzamiento radiativo	Tendencia del forzamiento radiativo
RCP2.6	421 ppm	2.6 w/m ²	Decreciente en 2100
RCP4.5	531 ppm	4.5 w/m ²	Estable en 2100
RCP6	670 ppm	6.0 w/m ²	Creciente en 2100
RCP8.5	936 ppm	8.5 w/m ²	Creciente en 2100

4.3.5. Modelo General Lineal

Con el objetivo de evaluar la relación lineal entre el reclutamiento y las variables de estudio se generaron modelos generales lineales (GLM, por sus siglas en inglés), en la plataforma R versión 3.1.1. Lo mismo que en los modelos NARX, se generó un GLM para los datos de la evaluación global y uno para los datos de cada una de las 5 regiones que conforman la evaluación regional. Los GLM son una extensión de los modelos lineales como la regresión y el ANOVA (McCullagh, 1984; O'Hara, 2009), los cuales se basan en los supuestos de normalidad y varianzas constantes en los errores. Para realizar el modelo, los datos de reclutamiento se desfazaron en el tiempo dos trimestres hacia atrás respecto a las variables independientes, bajo la suposición de que las condiciones que ocurrieron dos trimestres anteriores y en especial las variables oceanográficas, pueden influir más en el reclutamiento que las condiciones que se presentaron en el mismo tiempo en que ocurrió el reclutamiento, dada la edad a la que la especie se recluta a la pesca (6 meses). Primeramente se probó si los datos de reclutamiento están normalmente distribuidos a través de la prueba de Kolmogorov-Smirnov. Dado que estos no presentaron una distribución normal, se utilizó la familia de distribuciones BOX-COX (Box y Cox, 1964), la cual consiste en transformar cualquier variable de distribución desconocida a una distribución normal. Esto se realiza mediante la estimación de un parámetro λ a través de la siguiente función:

$$Y^{(\lambda)} = \begin{cases} \frac{Y^{(\lambda)}-1}{\lambda} & \lambda \neq 0, \\ \text{Log } Y; & \lambda = 0, \end{cases} \quad (2)$$

donde Y es la variable con distribución desconocida (en este caso, el reclutamiento) y λ es el parámetro a estimar. Para la estimación del parámetro λ se aplica el comando *powerTransform* de la paquetería “car “(Companion to Applied Regression) (Fox y Weisberg, 2011). Luego de la transformación, se probó normalidad nuevamente y se analizaron gráficos de residuales. La variabilidad explicada por cada modelo se obtuvo mediante el porcentaje de cambio de la devianza, la cual es equivalente al coeficiente de determinación (r^2) (Stefánsson, 1996).

El modelo de la evaluación global quedó definido como:

$$\text{Recbc} = \beta_0 + \beta_1 \times \text{SOI} + \beta_2 \times \text{PDO} + \beta_3 \times \text{BD} \quad (3)$$

donde Recbc es el reclutamiento transformado con Box-Cox, β_i son los parámetros a estimar, SOI y PDO son los índices y BD, es la biomasa de desovadores

Los 5 modelos de la evaluación regional con sus valores correspondientes quedaron definidos de la siguiente manera:

$$\text{Recbc} = \beta_0 + \beta_1 \times \text{MV} + \beta_2 \times \text{MC} + \beta_3 \times \text{Temp} + \beta_4 \times \text{BD} \quad (4)$$

donde MV es la magnitud del viento, MC es la magnitud de las corrientes y Temp es la temperatura

5. Resultados

5.1. Resultados del Modelo General Lineal

Después de transformar los datos de reclutamiento a una distribución normal, el análisis de residuales indicó distribución normal y varianzas no constantes en los errores, de todos los modelos, lo cual sugiere buenos modelos, tal como se muestra en las gráficas de residuales para el modelo de la evaluación global (Fig. 9). Para el periodo largo la biomasa de los desovadores y el PDO fueron las variables explicativas del reclutamiento con un valor de significancia de $p= 0.00028$ para la biomasa de los desovadores y $p= 0.0052$ para el PDO y la variabilidad explicada por el modelo fue de 0.13 según el cálculo de la devianza. La tabla 2 resume los resultados del GLM para las regiones correspondientes a la evaluación regional. En la región 1, la temperatura (Temp) y la biomasa de los desovadores (BD) fueron las variables explicativas, de la región 2 a la 4 el reclutamiento estuvo explicado por la magnitud del viento (MV) y la biomasa de los desovadores, mientras que en la región 5 estuvo explicado por la magnitud de las corrientes (MC) y la biomasa de los desovares.

Tabla 2. Resumen de los GLM de la evaluación regional.

Regiones	VARIABLES significativas	P valor	Devianza
Región 1	Temp y BD	<0.05	0.28
Región 2	MV y BD	<0.05	0.09
Región 3	MV y BD	<0.05	0.12
Región 4	MV y BD	<0.05	0.14
Región 5	MC yBD	<0.05	0.08

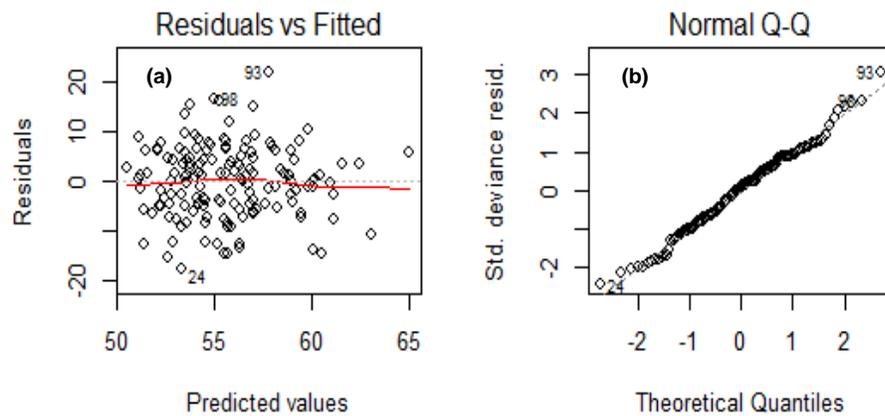


Figura 9. Análisis de residuales del modelo de evaluación global. El panel (a) muestra la distribución de varianzas no constantes y el panel (b) muestra distribución normal de los errores

5.2. Estructura y análisis de los modelos NARX

5.2.1. Evaluación global

El modelo NARX con el que se logró la mejor modelación del reclutamiento del AAA para los datos que comprende el periodo de evaluación regional, está constituido por 4 neuronas en la capa oculta. La figura (10) muestra la serie de tiempo de reclutamiento esperado (obtenidos de la CIAT) junto con la serie de tiempo estimada por dicho modelo. El gráfico de regresión entre estas series muestra que están altamente correlacionadas, con un valor del coeficiente de correlación de $R > 0.85$ (Fig. 11a). Además se obtuvieron altas correlaciones (todas con valores $R > 0.7$) entre los valores esperados y los valores estimados en cada uno de los conjuntos de datos que fueron separados durante el entrenamiento del modelo (conjunto de datos de entrenamiento, validación y prueba). Cabe destacar la alta correlación ($R > 0.83$) que existe entre las estimaciones de reclutamiento generadas por el modelo y los valores de reclutamiento esperados para el conjunto de datos de prueba, ya que dichos datos son completamente desconocidos por el modelo (figura 10d). Esto indica que se alcanzó un buen entrenamiento y que dicho modelo logró generalizar y por lo tanto hacer buenas estimaciones.

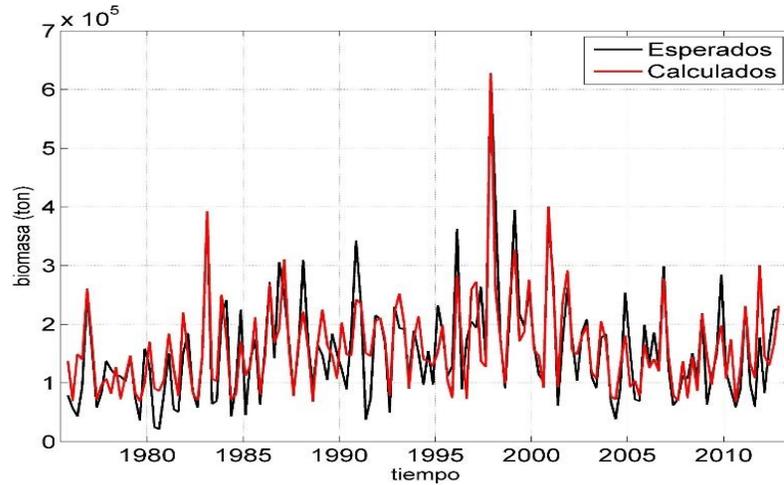


Figura 10. Reclutamiento esperado contra el calculado por el modelo para la evaluación global

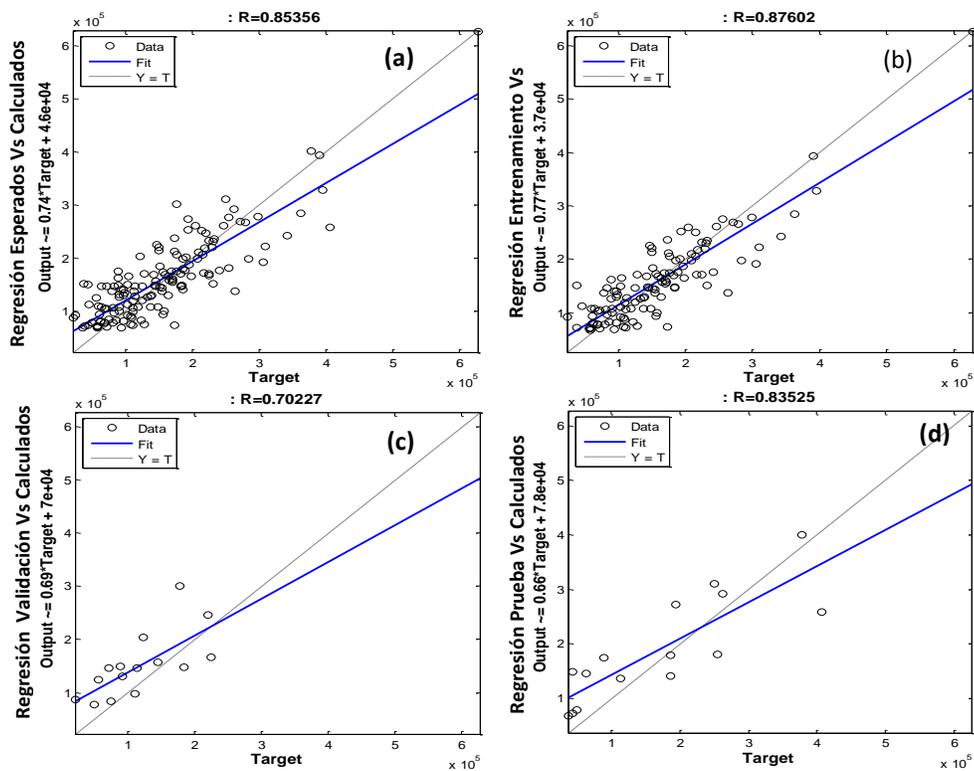


Figura 11. Regresión lineal y coeficiente de correlación entre los datos de reclutamiento esperados y los calculados por el modelo para toda la serie de tiempo (panel (a)). Los paneles (b) (c) y (d) muestran la regresión lineal y el valor del coeficiente de correlación entre los datos de reclutamiento esperados y los calculados para el conjunto de datos de entrenamiento, validación y prueba, respectivamente

En el presente modelo, el gráfico de autocorrelación de los errores muestra un solo valor positivo que ocurre en el desfase cero, el resto de las correlaciones caen en el intervalo de confianza del 95% (Fig. 12). Con base en la guía para el uso de herramientas de redes neuronales artificiales (Beale, 2010), en un buen modelo de predicción NARX los errores no deben estar auto correlacionados en el tiempo. Para que esto se cumpla, el máximo de autocorrelación debe ocurrir a un desfase de cero y la correlación debe ser nula para otros desfases. En el presente modelo, el gráfico de autocorrelación de los errores muestra un solo valor positivo que ocurre en el desfase cero, el resto de las correlaciones caen en el intervalo de confianza del 95% (Fig. 12). Aunado a esto, los errores muestran una distribución aproximadamente normal (Fig. 13). Por otro lado, se observa que los errores entre los valores de reclutamiento estimados por el modelo y los esperados para toda la serie, son generalmente pequeños comparados con las magnitudes de la serie. (Fig. 14).

Una consideración importante después del entrenamiento de un modelo de redes neuronales, es asegurarse de que el modelo no haya sufrido un sobreajuste o sobreentrenamiento. El problema de sobreajuste se da cuando se excede la talla óptima de la red, es decir el número de neuronas, mientras que el sobre-entrenamiento se refiere al tiempo de entrenamiento de la red, lo que finalmente resulta en una mala habilidad predictiva (Tetko et al., 1995). La Fig. 15. muestra cómo cambian los errores entre los conjuntos de datos de entrenamiento (entrenamiento, validación y prueba), durante el proceso de entrenamiento, se observa que los errores entre los conjuntos de datos decrecen hasta que el entrenamiento se detiene a las 20 iteraciones (una iteración donde todos los datos son introducidos a la red, se denomina época), que es el punto en que el error de validación alcanzó un mínimo. Si la curva de prueba tiene un incremento significativo antes de que incremente la curva de validación, entonces es posible que haya sucedido un sobreajuste. No existe sobreajuste si las curvas de prueba y validación son muy parecidas, tal como se muestra en la Fig. 15.

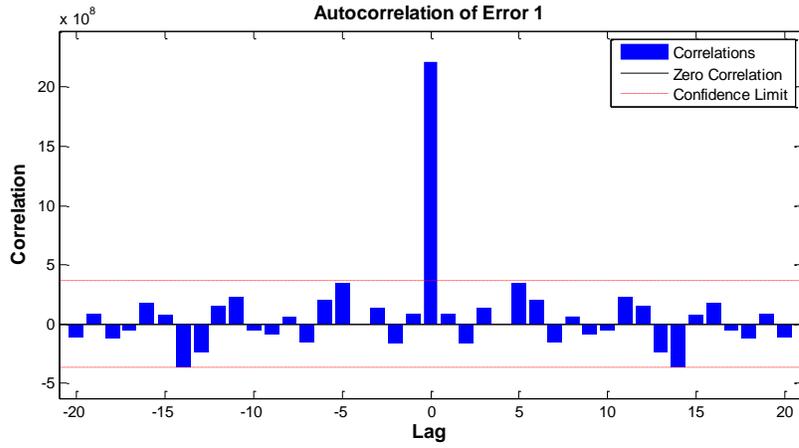


Figura 12. Autocorrelación de los errores resultantes en el modelo de evaluación global

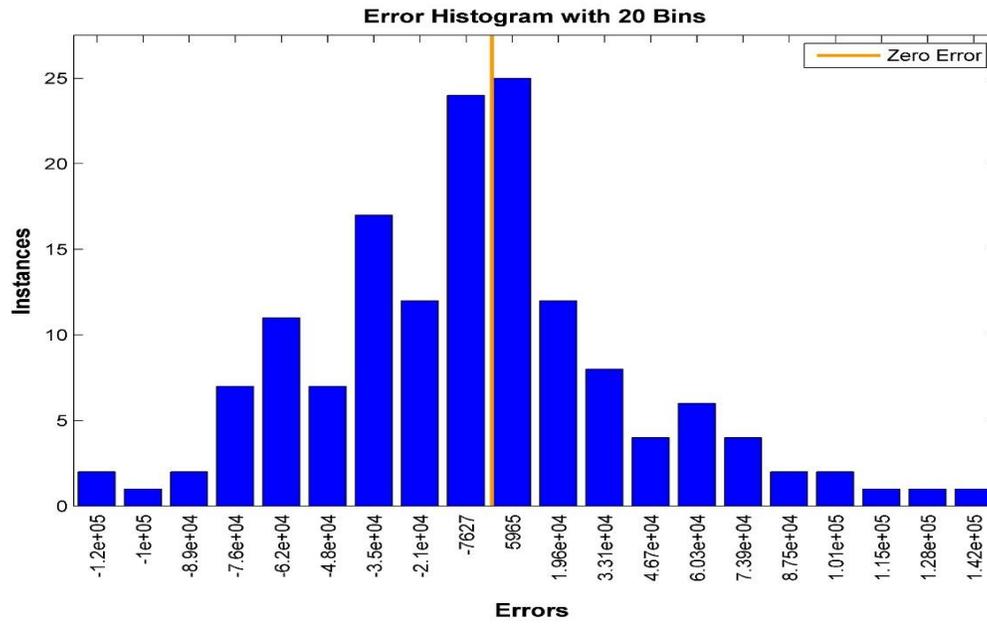


Figura 13. Histograma de los errores resultantes del modelo de evaluación global

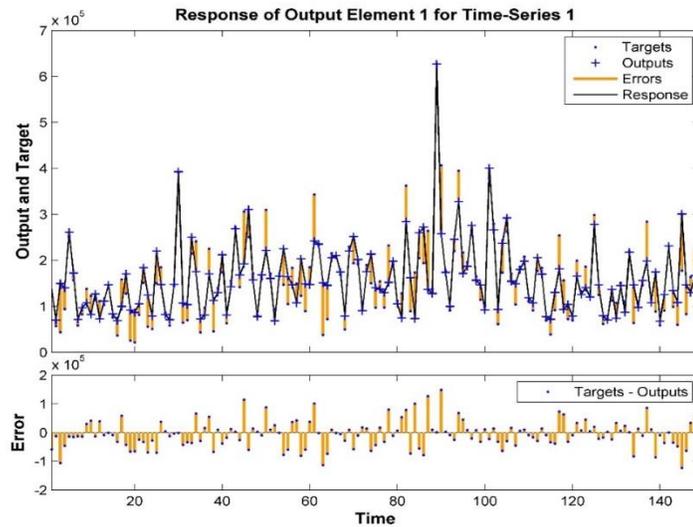


Figura 14. Respuesta de la salida del modelo del periodo largo a la serie de tiempo. El panel superior muestra la respuesta (línea negra) de la estimación del modelo (asterisco azul) para los datos esperados (punto azul) y los errores obtenidos de la estimación (línea amarilla). El panel inferior muestra la magnitud de dichos errores

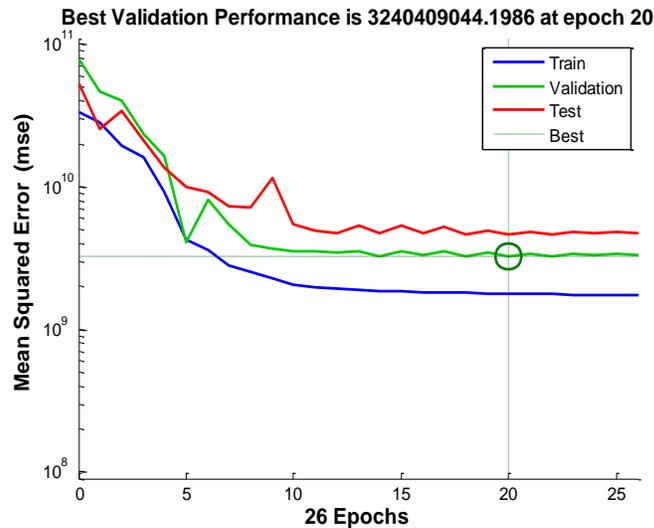


Figura 15. Valor de la función de ajuste contra el número de iteraciones. Se Indica que el entrenamiento se detuvo después de 20 iteraciones (epoch). Las curvas representan la forma en que decrece el error durante en el entrenamiento entre los conjunto de datos de entrenamiento (línea azul), validación (línea verde) y prueba (línea roja)

5.2.2. Evaluación regional

La configuración de los 5 modelos que representan las 5 regiones de la evaluación regional resultó diferente para la mayoría de las regiones. A pesar de todas las regiones cuentan con el mismo número de variables, éstas difieren en el número de neuronas necesarias en la capa oculta para la generación de un buen modelo. La elección de los modelos se hizo con base en el análisis de errores y correlaciones entre los valores estimados y los esperados así como en los gráficos de respuesta y el ajuste de la red, como se mostró en el modelo global. En la Tabla 3 se muestra el número de neuronas que conforman cada modelo, así como las correlaciones obtenidas para cada conjunto de datos.

Tabla 3. Número de neuronas en la capa oculta para cada región y el coeficiente de correlación (Corr) entre los valores estimados y los valores esperados, general y por conjunto de datos.

Región	N° de neuronas	Corr General	Corr Entrenamiento	Corr Validación	Corr Prueba
1	7	0.82	0.83	0.82	0.81
2	4	0.83	0.84	0.85	0.84
3	8	0.90	0.95	0.80	0.82
4	10	0.87	0.93	0.82	0.85
5	4	0.82	0.81	0.90	0.89

5.3. Análisis de sensibilidad y estimación del reclutamiento

5.3.1. Evaluación global

El análisis de sensibilidad utilizado para establecer la importancia de cada una de las variables oceanográficas en el modelo, fue evaluado mediante la suma del cuadrado de las diferencias absolutas (referido en el texto como diferencias), la raíz del error cuadrático medio (referidos como error) y el coeficiente de correlación entre los valores de reclutamiento estimados por el modelo configurado inicialmente y los valores estimados cuando las variables fueron modificadas con algún porcentaje, 10% y 30% en el caso del modelo global. El análisis de sensibilidad en este conjunto, muestra que el

SOI es la variable de mayor importancia para el modelo. En comparación con las otras variables, el SOI presentó los errores y las diferencias más grandes, así como la menor correlación entre las estimaciones iniciales y las estimaciones realizadas cuando la variable fue modificada en 10% y 30% (Tabla 4). Dado que el modelo aprendió a generalizar a partir de los ejemplos otorgados durante el entrenamiento y puesto que ajusta sus parámetros con base en las relaciones encontradas entre las variables de entrada y el reclutamiento; cabe la posibilidad de que el SOI sea no sólo la variable más importante para el modelo sino que también lo sea para el reclutamiento. Por su parte la biomasa de los desovadores presenta menores diferencias y un error más bajo en relación al PDO, lo cual sugiere que es la segunda variable en orden de importancia para el modelo. Sin embargo, el PDO presenta correlaciones menores entre las estimaciones iniciales y las estimaciones con la variable modificada.

Tabla 4. Parámetros del análisis de sensibilidad con las variables modificadas en ambos porcentajes para el modelo de evaluación global.

Variable	Porcentaje de modificación	Suma en Cuadratura de las diferencias (10 ¹⁰ ton)	Raíz del error cuadrático medio (10 ⁴ ton)	Coef. Correlación
SOI	+10%	3.17	1.46	0.98
	-10%	3.36	1.51	0.98
	+30%	26.80	4.24	0.86
	-30%	28.30	4.36	0.90
PDO	+10%	2.23	1.23	0.99
	-10%	2.08	1.18	0.99
	+30%	19.10	3.58	0.93
	-30%	14.80	3.15	0.92
Desovadores	+10%	3.17	1.46	0.99
	-10%	2.60	1.32	0.99
	+30%	31.10	4.57	0.94
	-30%	17.30	3.41	0.95

La gráfica de dispersión de puntos, no muestra una tendencia particular entre las estimaciones iniciales del modelo y las estimaciones con los valores del SOI modificados (Fig.16). No obstante, la gráfica de las series de tiempo de las series de tiempo (Fig. 17),

muestran que al reducir los valores del SOI (el cual con anomalías negativas representa condiciones El Niño), la estimación de reclutamiento presenta picos más altos con respecto a la estimación con valores incrementados. Este patrón se observa especialmente a finales del año 1983 y finales de 1997, aunque en la mayor parte del periodo del 2007 al 2012 con los datos incrementados en ambos porcentajes se estima un mayor reclutamiento, pero estos picos son de menor magnitud que los que se presentan con los valores reducidos. La respuesta del modelo a las modificaciones en el PDO es altamente variable, lo cual se puede observar en la gráfica de dispersión de puntos (Fig. 18). Sin embargo se observan más estimaciones positiva para el reclutamiento en la mayor parte de la serie, cuando dicha variable se incrementó en ambos porcentajes, (lo cual representa temperaturas más cálidas), (Fig. 19). En el caso de las modificaciones en el valor de la biomasa de los desovadores, el modelo estimó un mayor reclutamiento con los valores incrementados y menor con los valores reducidos (Figs. 20 y 21), de tal forma que la respuesta se dio en el mismo sentido.

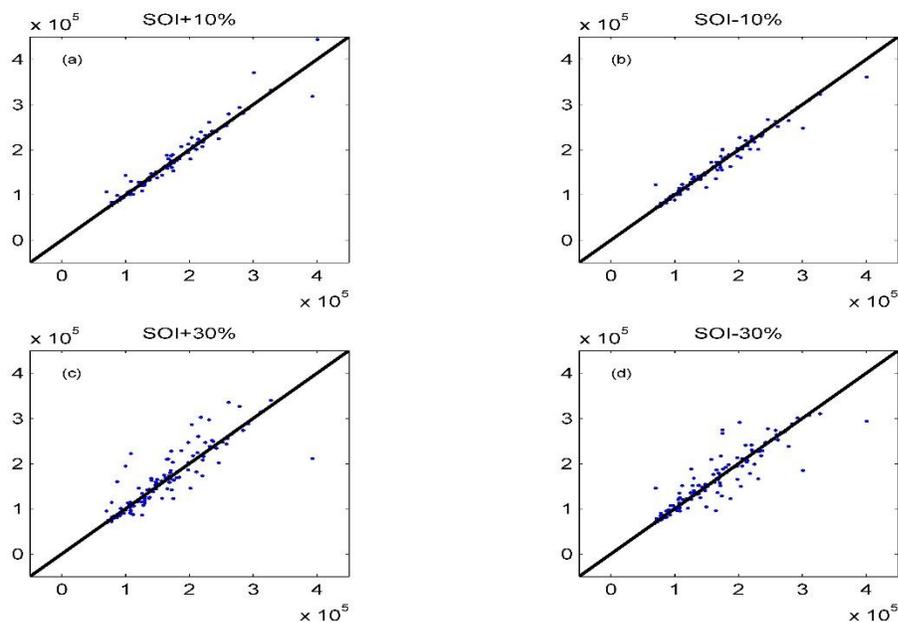


Figura 16. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores del SOI modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente

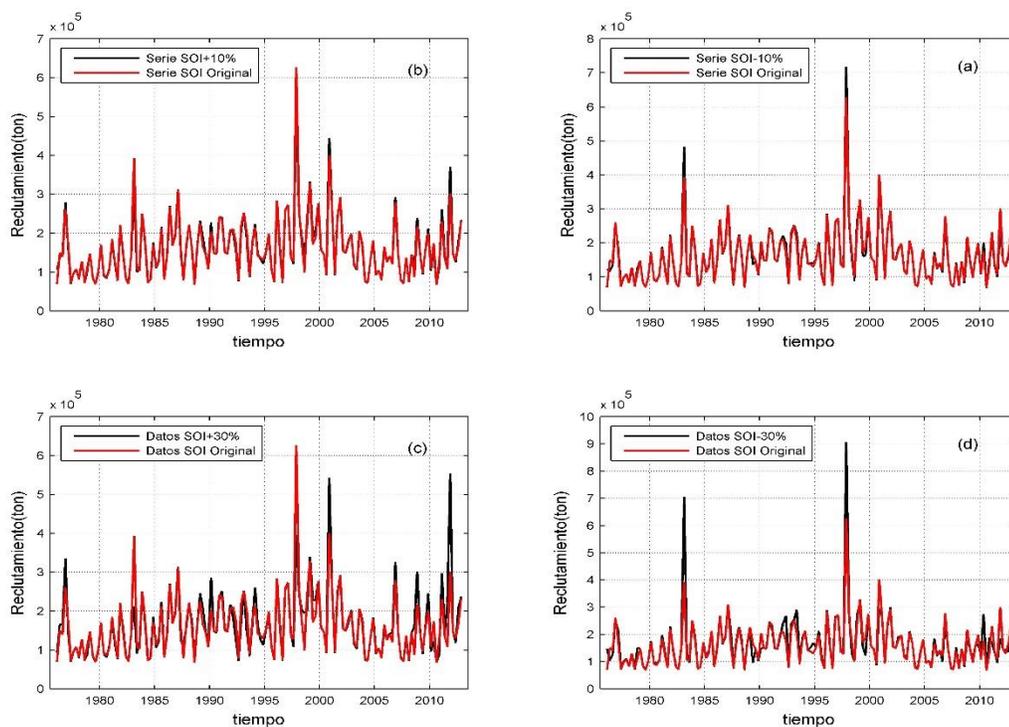


Figura 17. Estimaciones iniciales del modelo de evaluación global (línea roja) y estimaciones con valores del SOI modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente

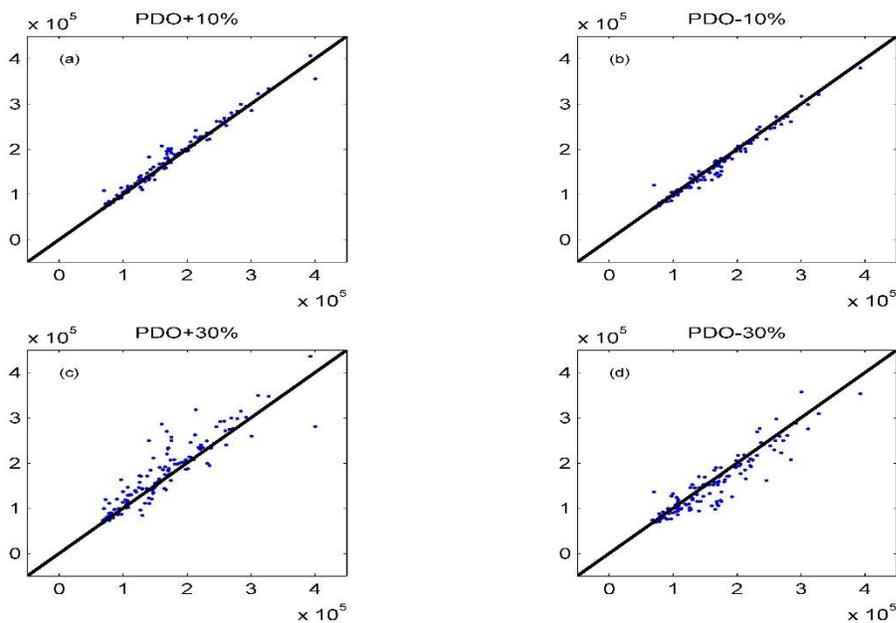


Figura 18. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores del PDO modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente

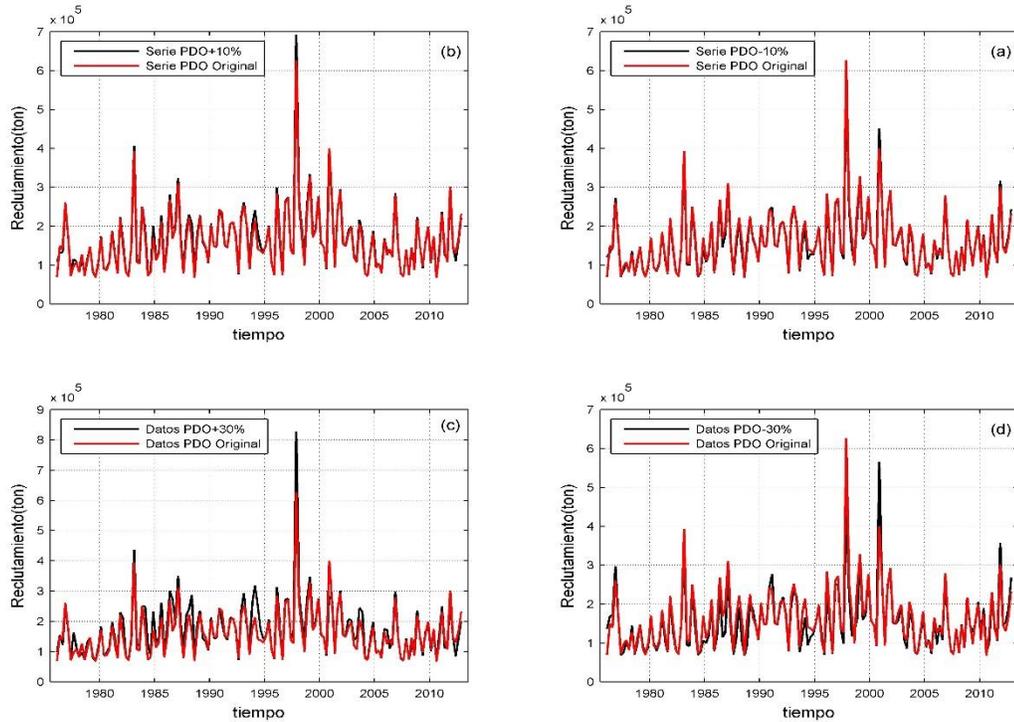


Figura 19. Estimaciones iniciales del modelo de evaluación global (línea roja) y estimaciones con valores del PDO modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente

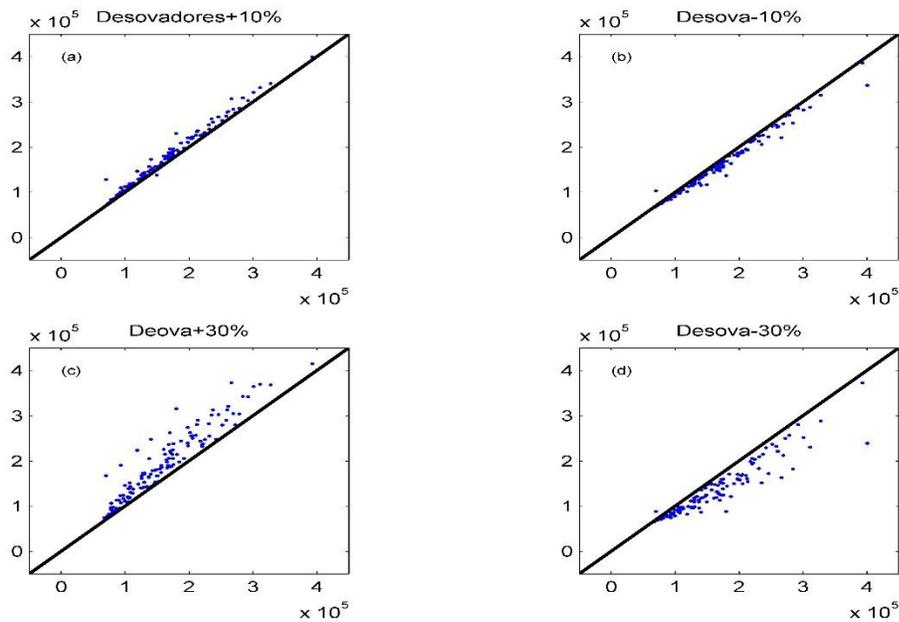


Figura 20. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de biomasa de los desovadores modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente

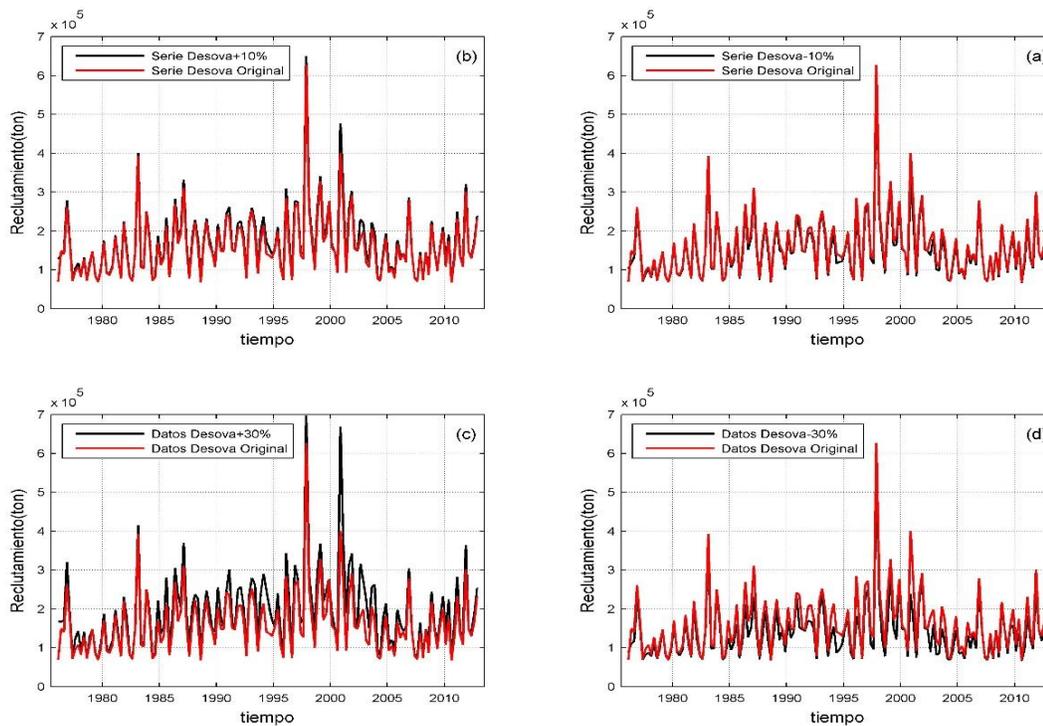


Figura 21. Estimaciones iniciales del modelo de evaluación global (línea roja) y estimaciones con valores de la biomasa de los desovadores modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 10% respectivamente, los paneles (c) y (d) al aumento y la disminución del 30%, respectivamente

5.3.2. Evaluación regional

En la Tabla (5) se presenta el intervalo de oscilación de las variables oceanográficas en cada una de las 5 regiones que conforman los 5 modelos de la evaluación regional. La biomasa de los desovadores durante 1890 y 2012 varió de 1,300 a 9,376 toneladas trimestrales. El análisis de sensibilidad se realizó para cada uno de los modelos y los valores de las variables correspondientes a cada modelo fueron modificados en 5% y 10%.

Los parámetros de evaluación en el análisis de sensibilidad para las regiones 1, 2, 3 y 4 indican que la temperatura es la variable de mayor importancia en sus modelos correspondientes, dado que en comparación con las otras variables, ésta presenta mayor error, mayores diferencias y menor valor del coeficiente de correlación entre los valores estimados inicialmente y las nuevas estimaciones con valores modificados en ambos porcentajes (Tablas 6, 7, 8 y 9). Sin embargo, en la región 2 y en la 4, las cuales presentan un intervalo de oscilación con valores de temperatura más altos, esta variable tiene mayor impacto en sus modelos comparado con el impacto que genera la variable en el resto de las regiones en sus modelos correspondientes. Esto es, que en estas regiones se presentan las diferencias y los errores más grandes entre la estimación inicial y las estimaciones con los valores modificados, en comparación con los valores obtenidos para otras regiones. Además el valor del coeficiente de correlación en estas regiones es muy bajo, cercano 0, especialmente con los valores de temperatura modificados en 10%. Contrario a las regiones anteriores, en la región 3, en la cual se presentan las temperaturas más bajas, el impacto de la variable es menor que en el resto de las regiones, dado que presenta menos error, menos diferencias y un valor del coeficiente de correlación alto, alrededor de 0.9 en ambos porcentajes.

En las regiones 1 y 3 la magnitud del viento figuró como la segunda variable en orden de importancia para sus modelos, continuando con la magnitud de las corrientes. En las regiones 3 y 4 la segunda variable de mayor importancia fue la magnitud de las corrientes y posteriormente la magnitud del viento. Para todas las regiones anteriores (de la 1 a la 4) la biomasa de los desovadores se presentó como la variable con menor importancia en sus modelos, ya que las modificaciones de sus valores no causaron muchas

diferencias con respecto a las estimaciones iniciales, además el error es menor y las correlaciones más altas.

En el modelo de la región 5 la temperatura resultó la variable de mayor importancia con la modificación del 5% en sus valores, sin embargo, con las modificaciones del 10% la magnitud del viento tiene mayor impacto para el modelo de acuerdo a los parámetros de sensibilidad (Tabla 8). Cabe destacar que en esta región, se presentaron los valores más altos en la magnitud del viento y seguido de la región 1 la cual tiene los valores más bajos, las modificaciones en esta variable causaron más impacto en su modelo en comparación con el impacto causado en el resto de las regiones en sus modelos correspondientes. En orden de importancia para este modelo, continúan la biomasa de los desovadores y finalmente la magnitud de las corrientes.

Tabla 5. Intervalo de oscilación de las variables oceanográficas en las regiones de la evaluación regional.

Región	Temperatura (°C)	Magn Viento (m/s)	Magn Corrientes (m/s)
1	22.1 - 28.3	1.8 - 5.7	0.03 - 0.07
2	26.3 - 28.7	2.5 - 7.0	0.08 - 0.24
3	20.8 - 23.0	2.0 - 5.5	0.19 - 1.20
4	26.6 - 29.6	1.7 - 5.7	0.15 - 0.28
5	19.9 - 27.8	4.0 - 7.7	0.13 - 0.32

Tabla 6. Parámetros del análisis de sensibilidad en la región 1. Las variables se muestran en orden de importancia para el modelo.

Variable	Porcentaje de modificación	Suma en Cuadratura de las diferencias (10 ¹⁰ ton)	Raíz del error cuadrático medio (10 ⁴ ton)	Coef. Correlación
Temperatura	+5%	75.0	7.72	0.80
	-5%	76.1	7.77	0.68
	+10%	227.0	13.40	0.59
	-10%	248.0	14	0.15
Magn Viento	+5%	10.5	2.88	0.93
	-5%	11.5	3.02	0.93
	+10%	253.0	14.20	0.15
	-10%	370.0	5.42	0.79
Magn Corrientes	+5	3.1	1.56	0.98
	-5%	3.4	1.64	0.98
	+10%	11.2	2.98	0.93
	-10%	13.7	10.90	0.91
Biomasa Desovadores	+5%	1.1	0.92	0.99
	-5%	1.3	0.99	0.99
	+10%	4.0	1.77	0.98
	-10%	5.2	2.04	0.97

Tabla 7. Parámetros del análisis de sensibilidad en la región 2. Las variables se muestran en orden de importancia para el modelo.

Variable	Porcentaje de modificación	Suma en Cuadratura de las diferencias (10 ¹⁰ ton)	Raíz del error cuadrático medio (10 ⁴ ton)	Coef. Correlación
Temperatura	+5%	656.0	22.8	0.35
	-5%	121.0	9.78	0.18
	+10%	2950.0	48.4	-0.02
	-10%	104	9.09	0.31
Magn Corrientes	+5%	10.9	2.94	0.95
	-5%	11.9	3.07	0.94
	+10%	35.0	5.27	0.88
	-10%	42.4	5.80	0.81
Magn Viento	+5	4.0	1.79	0.98
	-5%	3.5	1.67	0.98
	+10%	15.8	3.54	0.92
	-10%	13.6	3.29	0.95
Biomasa desovadores	+5%	1.6	1.12	0.99
	-5%	1.6	1.14	0.99
	+10%	6.1	2.19	0.97
	-10%	6.1	2.28	0.98

Tabla 8. Parámetros del análisis de sensibilidad en la región 3. Las variables se muestran en orden de importancia para el modelo.

Variable	Porcentaje de modificación	Suma en Cuadratura de las diferencias (10¹⁰ton)	Raíz del error cuadrático medio (10⁴ton)	Coef. Correlación
Temperatura	+5%	10.4	2.88	0.96
	-5%	15.0	3.46	0.95
	+10%	29.8	4.87	0.91
	-10%	44.2	5.92	0.89
Magn Viento	+5%	2.0	1.27	0.99
	-5%	1.9	1.21	0.99
	+10%	8.52	2.60	0.96
	-10%	7.13	2.38	0.96
Magn Corrientes	+5	0.3	0.51	0.99
	-5%	0.3	0.52	0.99
	+10%	1.33	1.03	0.99
	-10%	1.34	1.03	0.99
Biomasa desovadores	+5%	0.4	0.59	0.99
	-5%	0.3	0.55	0.99
	+10%	1.85	1.21	0.99
	-10%	1.43	1.07	0.99

Tabla 9. Parámetros del análisis de sensibilidad en la región 4. Las variables se muestran en orden de importancia para el modelo.

Variable	Porcentaje de modificación	Suma en Cuadratura de las diferencias (10¹⁰ton)	Raíz del error cuadrático medio (10⁴ton)	Coef. Correlación
Temperatura	+5%	398.0	17.80	0.45
	-5%	395.0	17.70	0.30
	+10%	1420.0	33.50	0.24
	-10%	1120.0	29.80	0
Magn Corrientes	+5%	10.7	2.91	0.94
	-5%	8.14	2.54	0.95
	+10%	48.3	6.19	0.81
	-10%	29.2	4.81	0.83
Magn Viento	+5	1.9	1.22	0.99
	-5%	2.2	1.32	0.99
	+10%	7.0	2.36	0.95
	-10%	9.6	2.76	0.96
Biomasa desovadores	+5%	0.4	0.58	0.99
	-5%	0.5	0.59	0.99
	+10%	1.7	1.16	0.99
	-10%	1.9	1.21	0.99

Tabla 10. Parámetros del análisis de sensibilidad en la región 5. Las variables se muestran en orden de importancia para el modelo.

Variable	% de modificación	Suma en Cuadratura de las diferencias (10 ¹⁰ ton)	Raíz del error cuadrático medio (10 ⁴ ton)	Coef. Correlación
Temperatura	+5%	35.7	5.32	0.95
	-5%	37.7	5.47	0.94
	+10%	132.0	10.2	0.82
	-10%	142.0	10.6	0.78
Magn Viento	+5%	12.8	3.18	0.92
	-5%	25.2	4.47	0.89
	+10%	32.8	5.10	0.79
	-10%	109.0	9.31	0.67
Desovadores	+5	0.5	0.65	0.99
	-5%	0.6	0.67	0.99
	+10%	2.10	1.29	0.98
	-10%	2.30	1.35	0.98
Magn Corrientes	+5%	0.3	0.52	0.99
	-5%	0.4	0.54	0.99
	+10%	1.3	10.2	0.99
	-10%	1.6	11.1	0.99

En todas las regiones el reclutamiento estimado con los valores de temperatura modificados, indican que el incremento en la temperatura en ambos porcentajes favoreció las estimaciones de reclutamiento, mientras que con la disminución de los valores se estimó un menor reclutamiento respecto a las estimaciones iniciales. Para ejemplificar, se muestra la gráfica de dispersión de puntos y la serie de tiempo entre las estimaciones iniciales y las estimaciones con valores modificados la región 1 (Figs.22 y 23). Cabe destacar que los modelos llegan a estimar valores de reclutamiento negativos, este hecho se debe a que en los modelos no es posible establecer límites, de tal forma que si las variables de entrada no son favorables para las estimaciones del reclutamiento, según el modelo, éste puede estimar incluso valores negativos. Dado que para una variable como el reclutamiento no es posible expresar valores negativos, dichos valores se consideran como reclutamiento nulo, bajo las condiciones que causaron tales estimaciones.

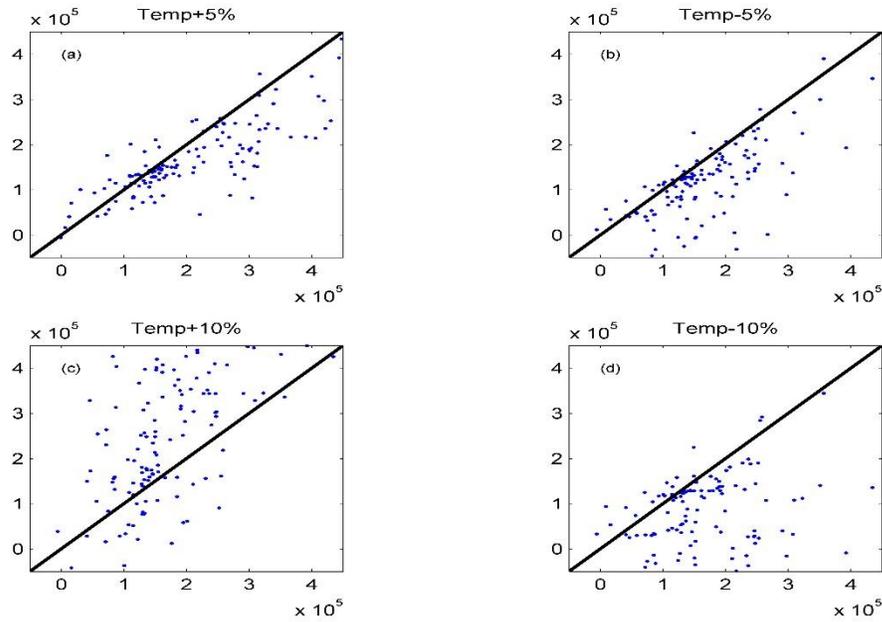


Figura 22. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de temperatura modificados, en la región 1. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente

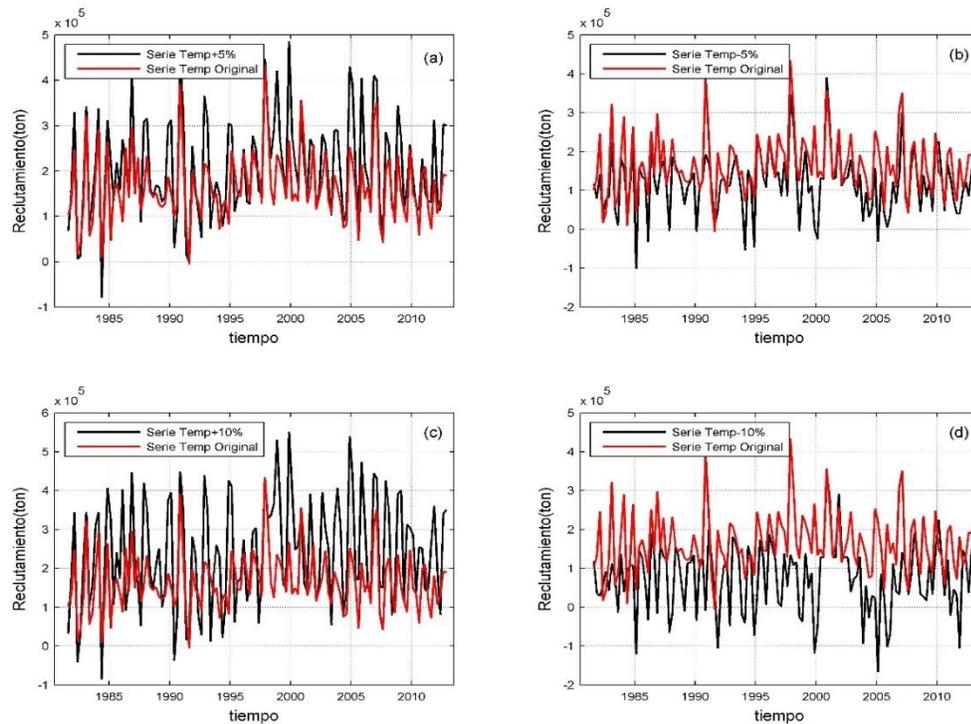


Figura 23. Estimaciones iniciales del modelo de la región 1 (línea roja) y estimaciones con valores de la temperatura modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente

Las modificaciones en la magnitud del viento causaron estimaciones de reclutamiento altamente variables a lo largo del periodo de estudio en la mayoría de las regiones. En la región 1, por ejemplo, se observa que con las modificaciones del 5 % la estimación de reclutamiento varía a través de la serie causando sobreestimación en algunos casos y subestimación en otros, respecto a las estimaciones iniciales. Lo cual se puede observar en la gráfica de dispersión de puntos y en la gráfica de las series de tiempo (Figs. 24a, 24b, 25a y 25b). Sin embargo, de forma general estas variaciones no son tan grandes, lo cual está sustentado por el poco error, la poca diferencia y el alto valor del coeficiente de correlación entre las estimaciones iniciales y las estimaciones con valores modificados en este porcentaje, referidos en el análisis de sensibilidad. Contrario a lo anterior, cuando la variable fue modificada en 10% ésta causó un mayor impacto en su modelo, comparado con el impacto causado en otras regiones. Además se observa que las estimaciones de reclutamiento se ven claramente reducidas con el incremento del 10% en los valores de la variable (Fig. 24c y 25c).

En la región 2 casi toda la variación del modelo se atribuyó a la temperatura, por lo que las modificaciones en la magnitud del viento en ambos porcentajes no causaron mucha diferencia respecto a las iniciales, como se mostró en las variaciones del 5% en la región 1. En la región 3, lo mismo que en la región 2 es poca la variación que causa la modificación de la variable entre las estimaciones iniciales y las estimaciones con valores modificados. En las regiones 4 y 5 los valores de la magnitud del viento disminuidos en ambos porcentajes causaron sobreestimación de reclutamiento; sin embargo tanto la gráfica de dispersión de puntos como la gráfica de las series de tiempo muestran que en la región 4, las nuevas estimaciones son muy parecidas a las iniciales (Figs. 26 y 27). Esto se debe a que también en este modelo casi toda la variación en las estimaciones de reclutamiento fue atribuida a la temperatura. Para la región 5, el análisis de sensibilidad demostró que esta variable ejerce gran impacto en el modelo en comparación con el impacto que produce en otras regiones (excepto en la región 1) por lo que se observa una mayor variación en las nuevas estimaciones respecto a las iniciales (Figs. 28 y 29).

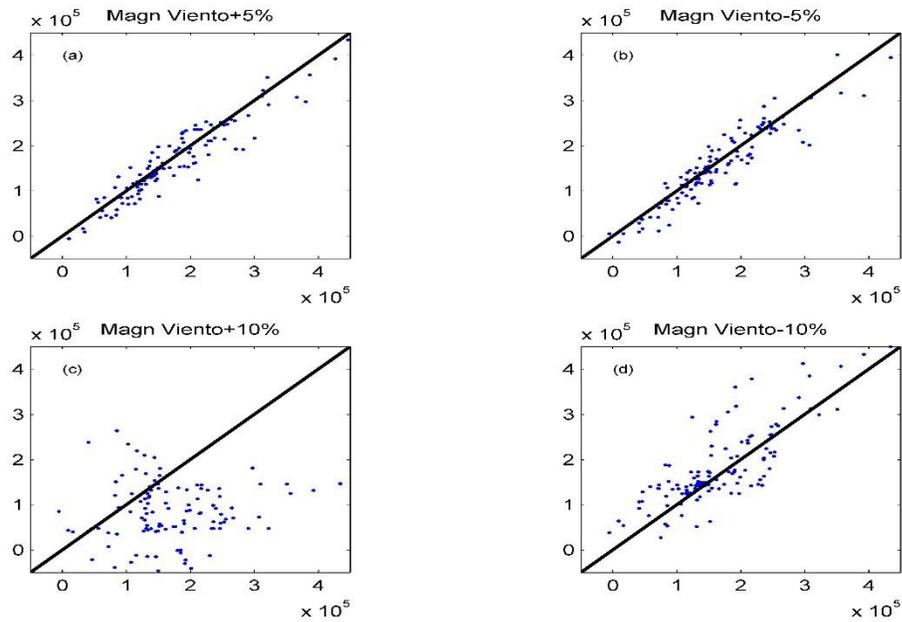


Figura 24. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud del viento modificados, en la región 1. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente

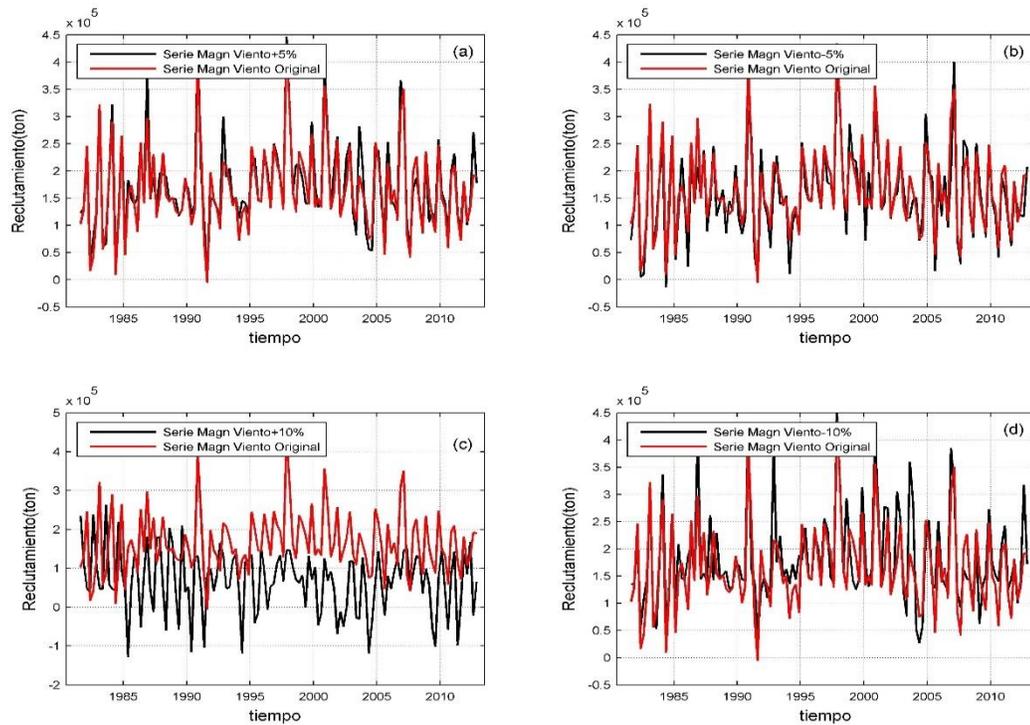


Figura 25. Estimaciones iniciales del modelo de la región 1 (línea roja) y estimaciones con valores de magnitud del viento modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente

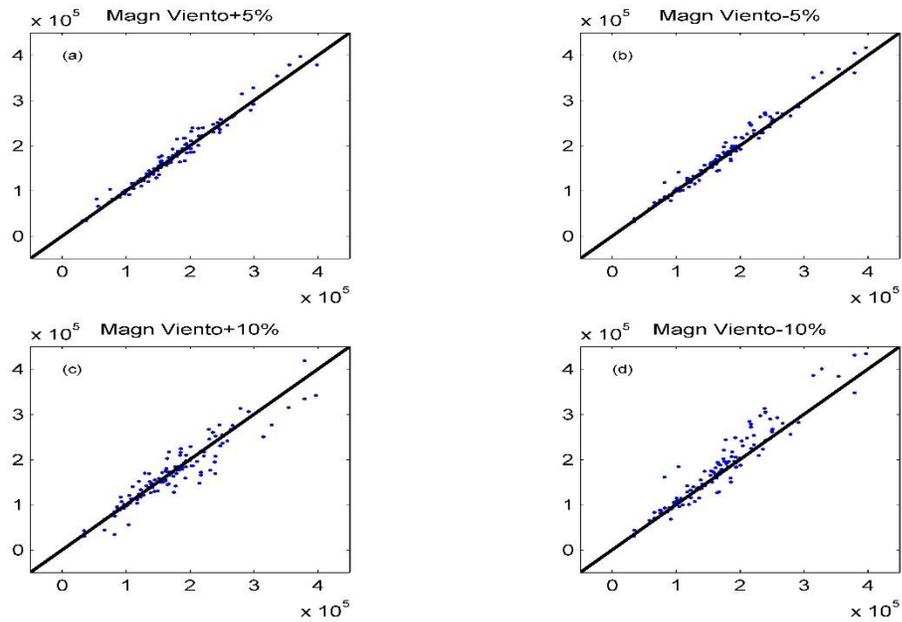


Figura 26. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud del viento modificados en, la región 4. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente

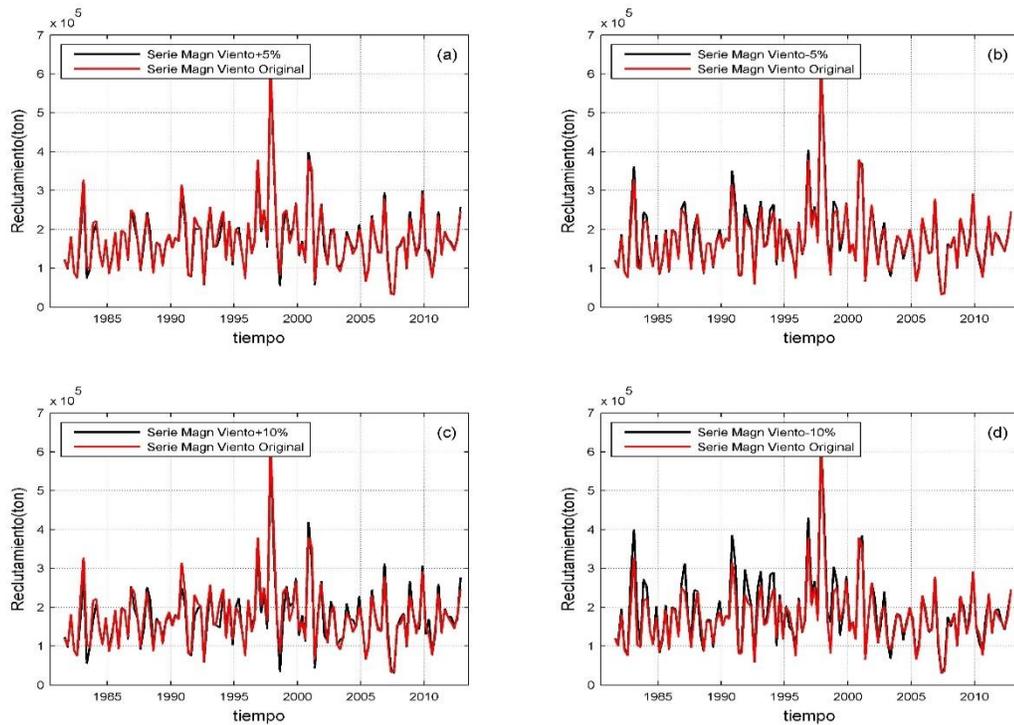


Figura 27. Estimaciones iniciales del modelo de la región 4 (línea roja) y estimaciones con valores de magnitud del viento modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente

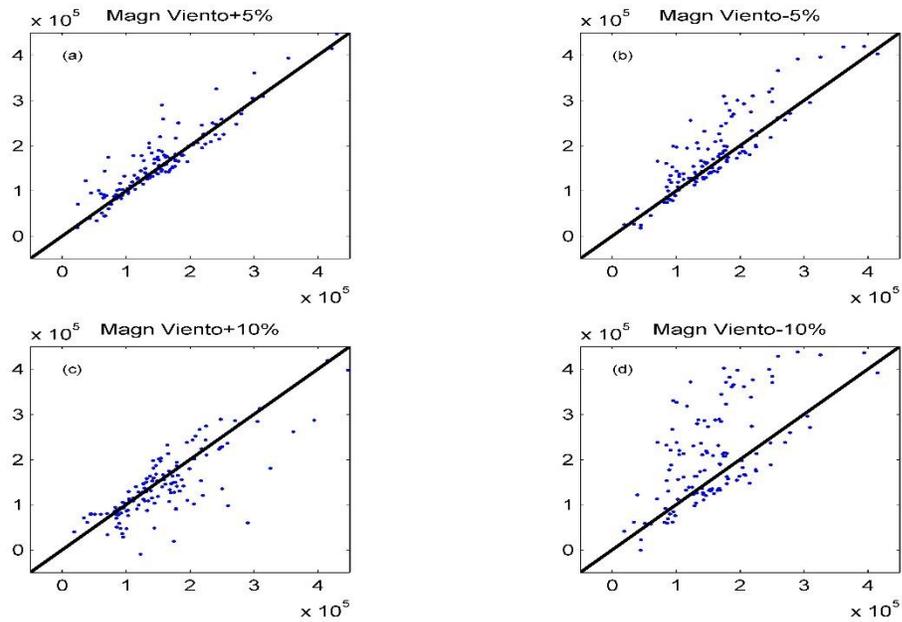


Figura 28. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud del viento modificados, en la región 5. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente.

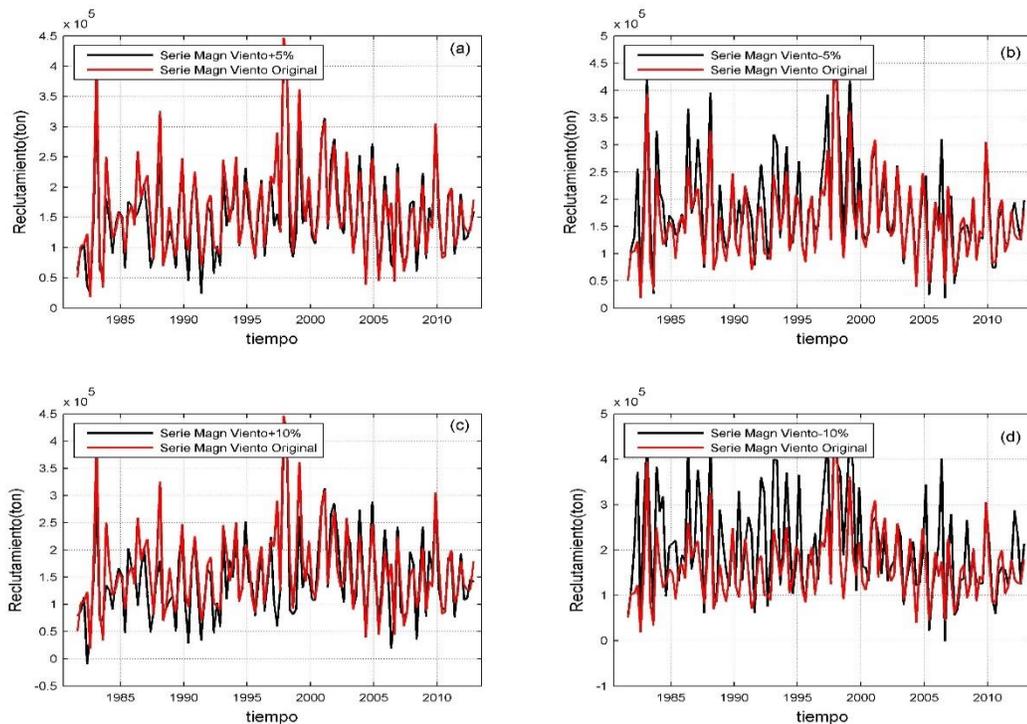


Figura 29. Estimaciones iniciales del modelo de la región 5 (línea roja) y estimaciones con valores de magnitud del viento modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente

Las estimaciones de reclutamiento con la modificación en los valores de la magnitud de las corrientes para la región 1, 2 y 5 también son altamente variables, por lo que no es posible establecer una relación clara entre esta variable y las estimaciones de reclutamiento en estos modelos, como se muestra en el gráfico de dispersión de puntos para la región 1 (Fig. 30.). La gráfica de dispersión de puntos y la gráfica de las series de tiempo en las regiones 3 y 4 muestran que la poca variación que causa la magnitud de las corrientes para sus modelos, produce un valores de reclutamiento ligeramente superiores con los valores incrementados (especialmente con el incremento del 10 %) respecto a los valores disminuidos, como se muestra para la región 4 (Figs. 31 y 32).

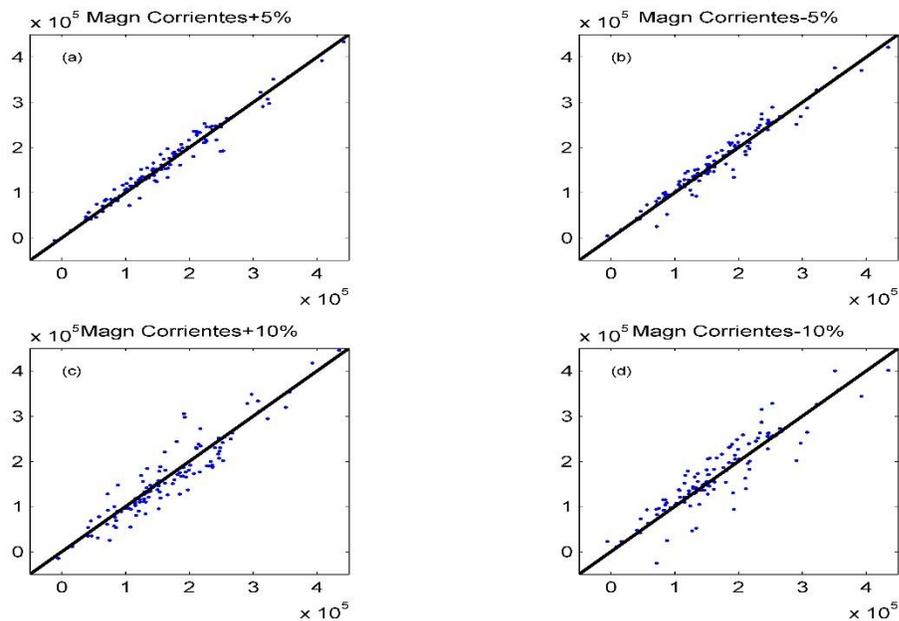


Figura 30. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud de las corrientes modificados, en la región 1. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente.

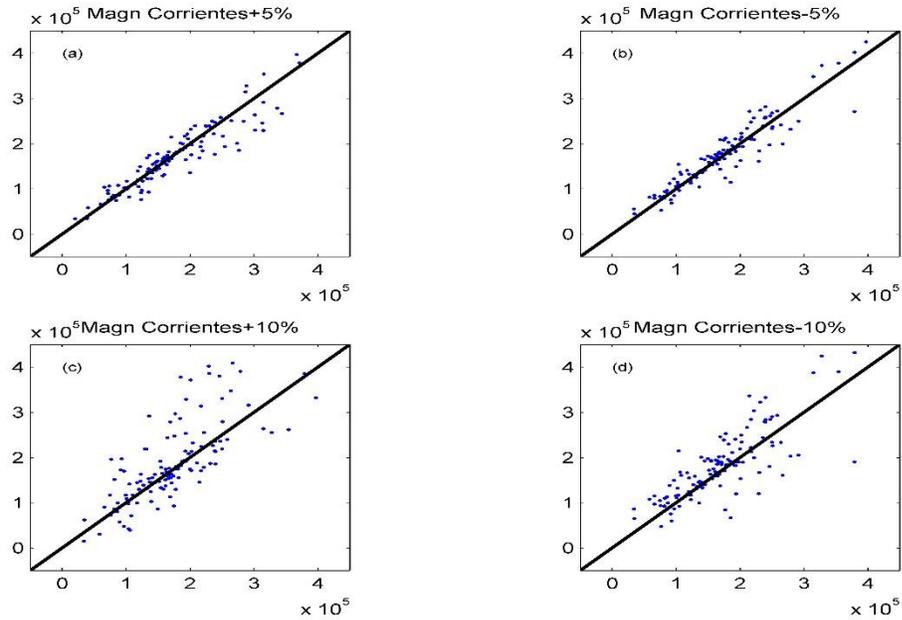


Figura 31. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de magnitud de las corrientes modificados, en la región 4. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente

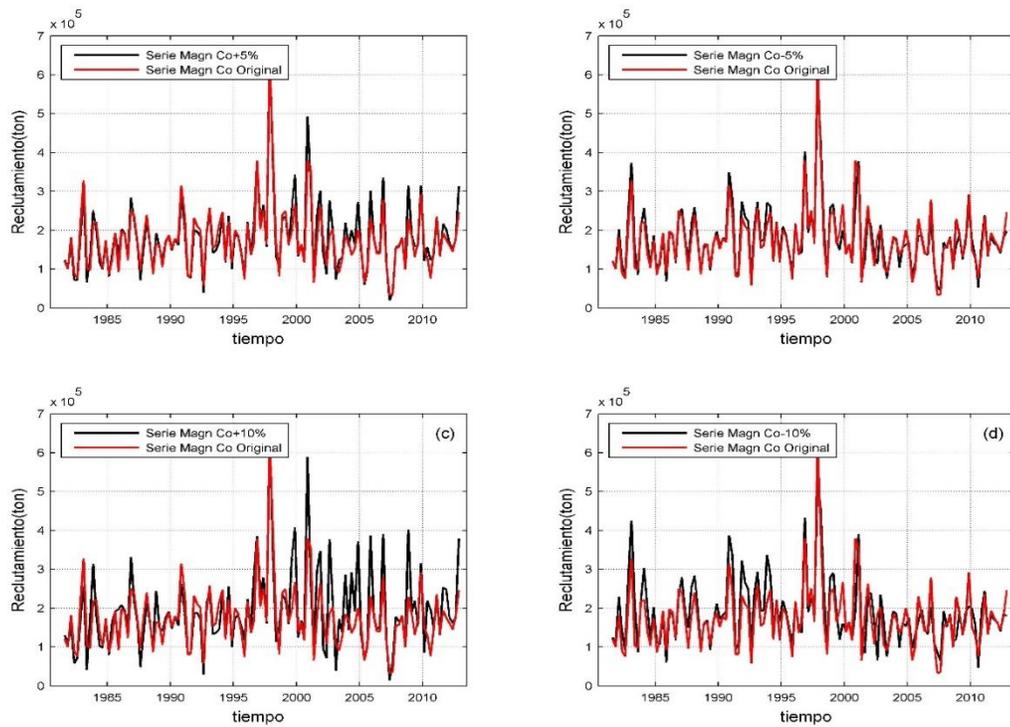


Figura 32. Estimaciones iniciales del modelo de la región 4 (línea roja) y estimaciones con valores de magnitud de las corrientes modificados. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente

La biomasa de los desovadores representó la variable de menor impacto en los modelos de la mayoría de las regiones, excepto en la región 5 en la que representó la penúltima variable en orden de importancia. Estas condiciones dificultan la posibilidad de establecer relaciones entre esta variable y las estimaciones de reclutamiento. Sólo en las regiones 3 y 4, las pocas variaciones en las estimaciones, sugieren que el incremento en la biomasa de los desovadores es favorable para las estimaciones de reclutamiento especialmente con el incremento del 10%. En este último porcentaje se observa que todos los datos están sobreestimados, como se muestra en la gráfica de dispersión de puntos y la gráfica de ambas series de tiempo para la región 3 (Figs. 33 y 34).

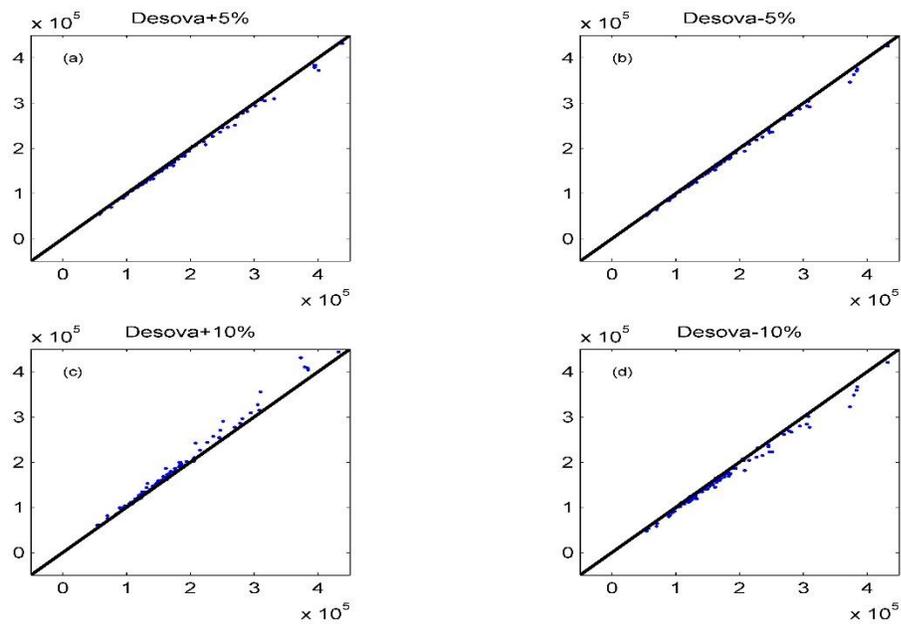


Figura 33. Dispersión de puntos entre las estimaciones iniciales y las estimaciones con los valores de biomasa de los desovadores modificados, en la región 3. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10%, respectivamente

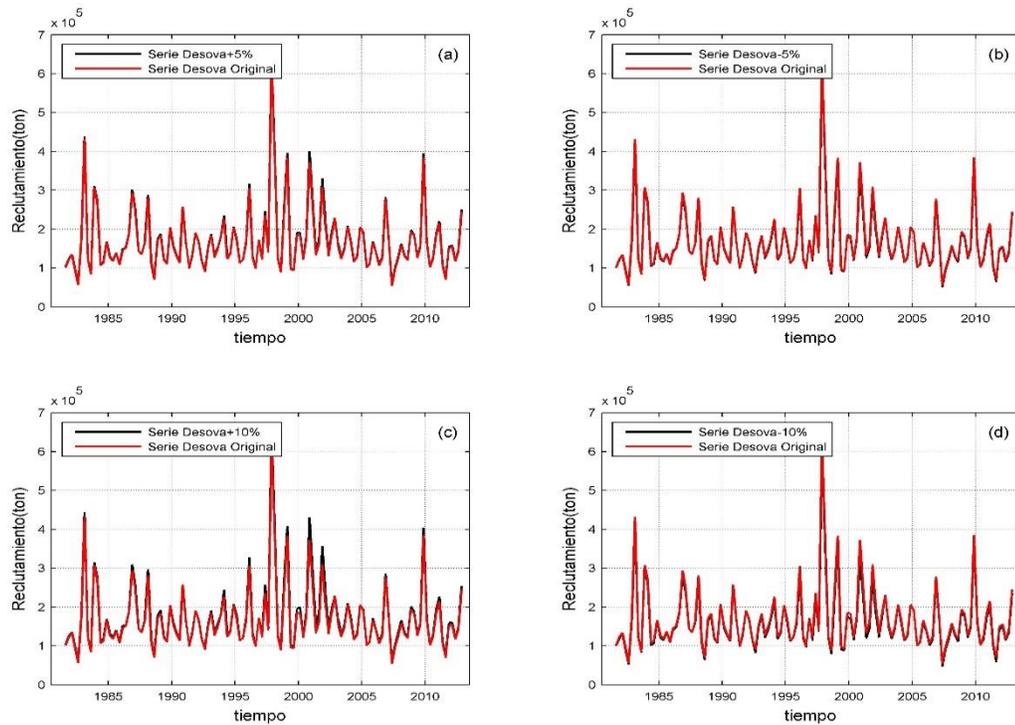


Figura 34. Estimaciones iniciales del modelo de la región 3 (línea roja) y estimaciones con valores de la biomasa de los desovadores. Los paneles (a) y (b) corresponden al aumento y la disminución del 5% respectivamente, los paneles (c) y (d) al aumento y la disminución del 10% respectivamente

5.4. Proyecciones del reclutamiento

Las proyecciones de reclutamiento se hicieron a partir de los 4 escenarios descritos en la sección 4.3.4, los cuales están constituidos por las variables de la evaluación regional; la temperatura, la magnitud del viento y de las corrientes, excepto la biomasa de los desovadores ya que en la actualidad no existen modelos para las proyecciones de esta variable y además el análisis demostró que para esos modelos funciona como la variable de menor impacto. El modelo utilizado para las proyecciones está constituido por 7 neuronas en la capa oculta. Con este modelo se obtuvo un valor del coeficiente de correlación general de $R=0.90$ entre los datos observados y los esperados. Para el conjunto de datos de prueba el coeficiente de correlación fue de $R>0.83$, lo cual sugiere que el modelo es capaz de hacer buenas estimaciones. La Fig. 35, muestra las proyecciones de reclutamiento en promedios anuales para los diferentes escenarios para el periodo 2014-2090, obtenidos con el presente modelo. Con la finalidad de visualizar tendencias, se realizaron promedios corridos en conjuntos de 10 años. Los promedios

corridos se utilizan generalmente en series de tiempo con la finalidad de suavizar las fluctuaciones de corto plazo o alta frecuencia y poder enfatizar las fluctuaciones de largo plazo. La Fig. 36 muestra el promedio corrido de las proyecciones de reclutamiento. De forma general se observa que el RCP 8.5 es el escenario en el que se estima mayor reclutamiento a lo largo del periodo de estudio, mientras que con el RCP2.6 se estiman los más bajos niveles de reclutamiento. Desde el inicio del periodo y hasta aproximadamente el año 2050 las estimaciones de reclutamiento son similares para los todos los escenarios. A partir de ese año y hasta el año 2090 las diferencias en las estimaciones de cada escenario se hacen más grandes. En todos los escenarios el reclutamiento muestra tendencia al incremento, excepto para el RCP2.6, en el que el reclutamiento disminuye por un periodo de 10 años, luego incrementa por un periodo similar, después del cual decae por un corto periodo (aproximadamente 2 años). Finalmente, comienza a recuperarse casi hasta sus valores iniciales para final de la serie.

La estimación de reclutamiento del RCP2.6 para el año 2015 es de 192,773 toneladas de reclutas, las condiciones promedio para ese año en dicho escenario son 0.22 m/s en la velocidad de las corrientes, 6.2 m/s en la magnitud del viento y 23.8 °C en la temperatura. Para el RCP4.5 la estimación 137,252 toneladas considerando que la velocidad de las corrientes es de 0.2 m/s, 6.5 m/s la magnitud del viento y 23.5°C la temperatura. Con el RCP6.0 se estimaron 198,652 toneladas, las condiciones fueron 0.20 m/s, 6.5 m/s y 23.7 °C para la velocidad de las corrientes, la magnitud del viento y la temperatura respectivamente. Finalmente, en el escenario RCP8. 5 se estiman 215,649 toneladas mientras que las condiciones son 0.21 m/s, 6.3 m/s y 23.1°C en la velocidad de las corrientes, la magnitud del viento y la temperatura, respectivamente. Hasta este punto el RCP 8.5 es el escenario que más favorece las estimaciones de reclutamiento, sin embargo, en las estimaciones a corto plazo, por ejemplo en los siguientes 5 años (2015-2020) el RCP2.6 es el escenario más favorable ya que en promedio se estiman 188,465 toneladas de reclutas, mientras que con el RCP 4.5, 6.0 y 8.5 se estiman 174,555, 162,856 y 173,525. Toneladas, respectivamente. En el orden anterior las temperaturas promedio son 23.6°C, 23.4°C, 23.4°C y 23.5°C, mientras que la velocidad de las corrientes es de 0.23 m/s, 0.24 m/s, 0.24 m/s y 0.24 m/s y por último la magnitud del viento es de 6.4 m/s para todos los escenarios.

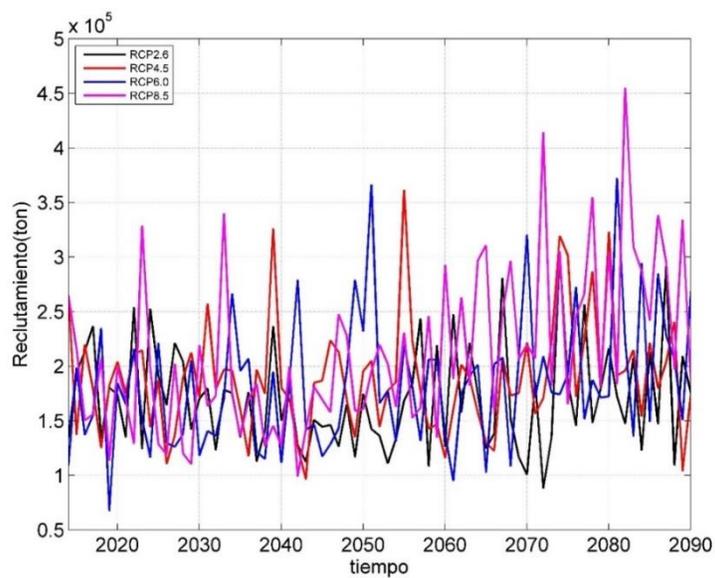


Figura 35. Proyecciones del reclutamiento del Atún Aleta Amarilla bajo los diferentes escenarios RCP's

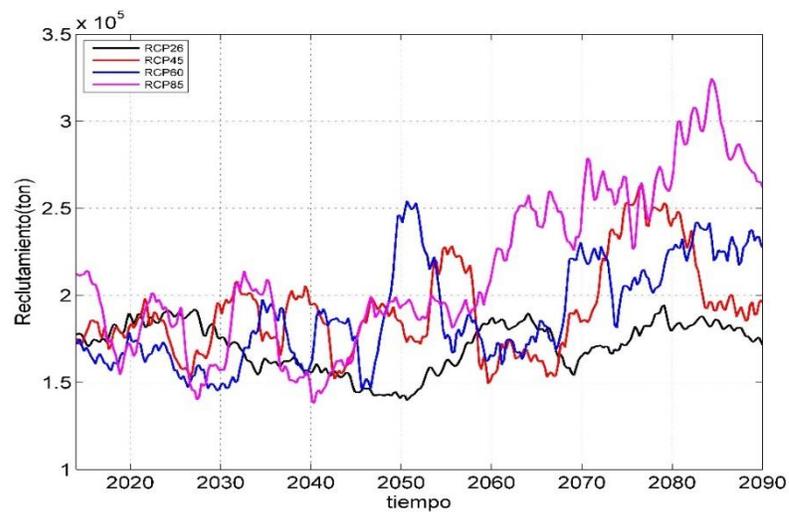


Figura 36. Proyecciones del reclutamiento del Atún Aleta Amarilla bajo los diferentes escenarios RCP's. Se muestran las proyecciones en promedios corridos de 10 años

6. Discusión

6.1. Las ANN's como herramienta de modelación y predicción

La ANN's proveen una forma alternativa de modelar los sistemas dinámicos no lineales como lo es la dinámica del reclutamiento del AAA. El presente estudio indica que el reclutamiento del AAA puede ser modelado a partir de las condiciones oceanográficas y biológicas (como la biomasa de los desovadores). Los resultados obtenidos con las ANN's fueron claramente mejores que los obtenidos con los GLM. Mientras que en los GLM la variabilidad explicada por los modelos para el reclutamiento es alrededor del 10%, con la modelación de las ANN's se encontraron altas correlaciones entre los datos esperados y los calculados, generalmente $R > 0.8$, lo que representa un 64%. Estos resultados apuntan hacia una relación altamente no lineal entre las variables que lo modelan y el reclutamiento. Diversos estudios concuerdan en que las ANN's poseen mayor capacidad predictiva y de modelación que otras técnicas estadísticas tradicionales, por ejemplo los modelos de regresión múltiple (Chen y Ware, 1999; Lek-Ang et al., 1999; Gutiérrez-Estrada et al., 2008; Gutiérrez-Estrada et al., 2009), así como los modelos aditivos generalizados, los cuáles son una herramienta de los GLM para modelar relaciones no lineales (Gutiérrez-Estrada et al., 2009).

6.2. Influencia de las variables oceanográficas en el reclutamiento

El análisis de sensibilidad utilizado para los modelos NARX es una forma general de observar la importancia o el impacto de cada una de las variables dentro de los modelos. Así mismo, puede ser útil para evaluar el impacto de las variables en el reclutamiento, puesto que todos los modelos fueron capaces de aprender y generalizar a partir de las relaciones reales encontradas entre las variables y el reclutamiento. Estos modelos ajustan sus parámetros con base en dichas relaciones, de tal forma que si una variable es de mayor importancia para el modelo, es probable que también lo sea para el reclutamiento. Sin embargo, la información que brinda el análisis de sensibilidad en cuanto a dichas relaciones debe manejarse cuidadosamente.

Es importante mencionar que los modelos fueron configurados para su entrenamiento con 3 desfases en las variables de entrada, es decir; que se consideraron las condiciones oceanográficas que ocurrieron 3 trimestres previos al reclutamiento y 3 valores previos del mismo reclutamiento. Esto debido a que la NARX son útiles para la modelación de series de tiempo y los valores previos le permiten a los modelos encontrar alguna periodicidad (especialmente en la variable dependiente), la cual es útil para estimar el siguiente valor de la variable dependiente. Esto es congruente para la modelación del reclutamiento, considerando que éste muestra cierta periodicidad a lo largo de la serie del periodo de estudio (1975-2012) (Apéndice IV). Puesto que el AAA se recluta a la pesquería a los 6 meses de edad; fue prioritario abarcar por lo menos 2 desfases, con la finalidad de relacionar con el reclutamiento, las condiciones oceanográficas que ocurrieron cuando los organismos estaban en una etapa larvaria. Es importante considerar la etapa larvaria, debido a que en esta se presenta una alta mortalidad en especies de estrategia tipo r como lo es el AAA. Por lo que condiciones oceanográficas en esta etapa tienen un efecto importante en el posterior reclutamiento. Otorgar un desfase más, permitió obtener mejores modelos, posiblemente porque se encuentra más información sobre la periodicidad en el comportamiento del reclutamiento.

Cabe destacar que las relaciones que los modelos encuentran entre las variables oceanográficas y el reclutamiento, especialmente con la magnitud del viento y la velocidad de las corrientes pueden ser más bien relaciones indirectas; por ejemplo, las relaciones con la magnitud del viento no son con la variable en sí sino con sus efectos. El viento es responsable de la generación de surgencias, especialmente en las regiones cercanas a la costa, incrementando la producción primaria así como de la generación de turbulencia, las cuales pueden estar más relacionadas a la alimentación de las larvas, su supervivencia y consecuentemente al reclutamiento. Por otro lado, la velocidad de las corrientes puede tener sus efectos en la dispersión y el transporte de las larvas a zonas de diferentes concentraciones de biomasa de sus presas lo que finalmente influye en la alimentación.

Los modelos NARX atribuyeron casi toda la variación del reclutamiento a las condiciones oceanográficas y sugieren una menor relación entre el reclutamiento y la biomasa de los desovadores. Esto se ve reflejado en el análisis de sensibilidad en donde la biomasa de

los desovadores fue la variable de menor importancia tanto en el modelo de la evaluación global, como en los modelos de la mayoría de las regiones de la evaluación regional. Esto es congruente con la relación población desovadora- reclutamiento (RDR) encontrada en el AAA por Holey y Maunder (2007), quienes observaron que no hay una disminución en el reclutamiento si la biomasa de los desovadores se reduce, a menos que ésta caiga a niveles muy bajos. Así mismo, Langley et al. (2009) reportaron una débil RDR en el AAA en el Océano Pacífico Oriental. Estos autores mencionan que es difícil establecer una RDR para una especie de un tiempo de vida relativamente corto y que además tiene un corto periodo de generación, particularmente cuando el reclutamiento y la biomasa de los desovadores están altamente correlacionadas con las condiciones oceanográficas. Por ejemplo, un periodo de condiciones oceanográficas favorables resultará en un alto reclutamiento (dentro de una cohorte) seguido por el incremento en la biomasa de los desovadores. Por el contrario, un periodo de condiciones menos favorables resultará en un bajo reclutamiento y por lo tanto una baja biomasa de desovadores. Si el periodo de condiciones más o menos favorables persiste por un tiempo mayor al tiempo de generación de las especies podría resultar en una fuerte RDR. De acuerdo al análisis de sensibilidad en la mayoría de los casos los modelos encuentran una relación entre el reclutamiento y la biomasa de los desovadores que va en el mismo sentido, es decir, a mayor biomasa de desovadores mayor reclutamiento aunque esta relación es muy débil. Por el contrario, a nivel lineal si evidente una relación entre el reclutamiento y la biomasa de los desovadores, la cual está sustentada por los GLM.

En el análisis de sensibilidad para la evaluación global, el SOI resultó ser la variable de mayor importancia en los modelos para la estimación del reclutamiento y esta estimación se vio favorecida con la disminución de los valores de la variable (típicamente asociados a los fenómenos de El Niño). Estos resultados son congruentes con algunos estudios que mencionan que los años El Niño son favorables para el reclutamiento del AAA (Joseph and Miller, 1989; Lehodey et al., 2003). Así mismo, se ha reportado un incremento en las capturas de la especie después de un fuerte año EL Niño (1982-1983) (CIAT, 2013). Sin embargo, estos resultados sólo representan la variabilidad relacionada a condiciones de escala global.

Los resultados de la evaluación regional revelan un conjunto de condiciones oceanográficas más complejo que están asociadas con la variación del reclutamiento. En los modelos de evaluación regional, el análisis de sensibilidad sugiere a la temperatura como la variable de mayor importancia en los modelos. Este resultado es razonable dado que se ha demostrado que la especie tiene preferencias térmicas marcadas tanto para su distribución (Collete y Nauen, 1983), como para el desove (Margulies, 2001) y el óptimo crecimiento de las larvas (Wexler et al., 2011). Por ende, la temperatura debe ser importante para el reclutamiento. Según el análisis de sensibilidad, el incremento en la temperatura favoreció las estimaciones de reclutamiento en todas las regiones, lo cual coincide con el resultado que indica que los años El Niño son favorables. Esto se debe a que la especie, al ser tropical, tiene preferencia por aguas cálidas. De acuerdo a Margulies et al. (2007) la temperatura tiene grandes efectos en los estados larvales del AAA, las bajas temperaturas provocan que el tiempo de permanencia en estado de huevo y larva se prolongue. Esto implicaría que con temperaturas altas (dentro de su rango óptimo) el crecimiento de los primeros estadios larvales se vea favorecido. Wexler et al. (2011) encontraron que el intervalo óptimo de temperatura para el crecimiento rápido y alta sobrevivencia de las larvas de atún aleta amarilla es de 26°C a 31°C. La mayoría de los datos en el análisis de sensibilidad caen dentro de este intervalo con el incremento en los valores de la variable. En el mismo sentido, en el modelo del periodo largo, resultó una mayor estimación del reclutamiento con los valores incrementados en el índice del PDO lo cual representa temperaturas más cálidas, que como se ha mencionado son más favorables para la especie.

En la región de mayor reclutamiento del AAA en el OPO, la magnitud del viento resultó de gran importancia para el modelo. Esta sugerencia es bastante aceptable dado que en esta región los fuertes vientos inducen las surgencias costeras, además esta zona forma parte del ecosistema de surgencias de Perú, el área de afloramiento más importante del mundo, con altos niveles de productividad que favorecen el desarrollo de grandes volúmenes de recursos pesqueros (Agüero, 2007; Bakun y Weeks, 2008). En esta región se presentaron los vientos más fuertes de toda el área de estudio alcanzando magnitudes de hasta 7.78 m/s. Langley et al. (2009) también asociaron un alto reclutamiento del AAA a una zona de fuertes vientos. El análisis de sensibilidad indicó que la disminución en los valores de la magnitud del viento favorece las estimaciones de

reclutamiento. Esto sugiere que el modelo de esta región encontró que hay mayor reclutamiento cuando la magnitud del viento no fue tan alta. De acuerdo a Cury y Roy (1989), el índice de reclutamiento anual de peces pelágicos incrementa con la intensificación de las surgencias hasta que el viento alcanza una velocidad de aproximadamente 5-6 m/s. Es probable que los valores reducidos en el análisis de sensibilidad hayan favorecido las estimaciones de reclutamiento puesto que los valores en esta región fueron mayores al intervalo sugerido anteriormente. Por otro lado, el viento también ha sido relacionado al reclutamiento pero con enfoque en la turbulencia que este produce, ya que la mezcla turbulenta es un mecanismo importante en la dinámica de alimentación de los peces larvales (Margulies, 2001). Algunos estudios experimentales de han enfocado a determinar la intensidad de turbulencia que eleva la supervivencia de las larvas (Kimura et al., 2004; Haury et al., 1990) y se ha sugerido que hay un “viento óptimo” que induce surgencias moderadas, que no es tan débil que no promueva la producción primaria y no eleve la tasa de encuentro de las larvas con sus presas a través de la turbulencia ni tan fuerte que pueda dispersar los parches de alimento de las larvas a través de la misma.

La magnitud de las corrientes representó poco impacto en todos los modelos de acuerdo al análisis de sensibilidad y las estimaciones en el análisis no permitieron establecer una relación clara entre esta variable y el reclutamiento. Anteriormente se han establecido relaciones entre el reclutamiento del AAA y las condiciones de flujo en el sistema de corrientes ecuatoriales. De acuerdo a Langley et al. (2009) ocurre un alto reclutamiento en el Océano Pacífico Occidental en periodos de fuerte flujo de la Corriente Ecuatorial del Sur, dominando sobre la Contracorriente Ecuatorial del Norte y una débil Corriente Ecuatorial del Norte. Sin embargo, la dirección del presente estudio no permite hacer comparaciones entre diferentes condiciones de flujo en el sistema de corrientes ecuatoriales y su relación con el reclutamiento, por lo tanto, no es posible obtener conclusiones de ese tipo.

Anteriormente los modelos de ANN's han sido referidos como una caja negra (Zhang et al., 1998; Lek-Ang et al., 1999; Kriesel, 2007), lo que significa que no hay una forma explícita para esclarecer la relación entre las entradas y las salidas en este tipo de modelos, lo cual causa dificultad en la interpretación de los resultados. Sin embargo, el

análisis de sensibilidad propuesto en este estudio es una buena aproximación para evaluar el grado de influencia real de una variable de entrada en la salida calculada, ya que a partir de éste, resultaron como variables de mayor importancia para el reclutamiento del AAA aquellas variables que han sido catalogadas como tal en la literatura, mediante modelación y mediante experimentos físicos.

Por otro lado, los modelos correspondientes a la evaluación regional, demostraron que el reclutamiento total del OPO, puede ser modelado con solo los datos de cada una de las 5 regiones. Dado que cada uno de los 5 modelos logró encontrar una ecuación que permite modelar la totalidad del reclutamiento.

6.3. Proyecciones del reclutamiento del AAA

Los diferentes vías de concentración representativas (RCP's) son escenarios diseñados para simular el cambio climático. Todos los RCP's están sujetos a grandes incertidumbres asociadas a las suposiciones acerca del crecimiento poblacional, hábitos alimenticios, uso de fertilizantes, emisiones y producción de estiércol (Davidson, 2012). Además requieren de proyecciones futuras de emisiones de varios constituyentes atmosféricos, por ejemplo, gases de efecto invernadero y aerosoles (Taylor et al., 2012). A pesar de que se trata de escenarios bajo ciertas suposiciones, éstos han sido la base de diversas investigaciones acerca del cambio climático, como las que realiza el Panel Intergubernamental para el Cambio Climático (IPCC), (IPCC, 2013). Han sido de utilidad para evaluar la respuesta del cambio climático en algunos recursos terrestres como las praderas (Wu et al., 2013). Estos escenarios pueden también ser útiles como base en la evaluación de la respuesta al cambio climático en los recursos marinos.

El modelo diseñado para la proyección del reclutamiento del AAA, tiene la capacidad de dar la respuesta potencial del reclutamiento a los diferentes escenarios y a cualquier conjunto de datos de entrada que contengan las variables usadas durante el entrenamiento. Dada su alta correlación entre los valores de reclutamiento esperados y los calculados por el modelo para el conjunto de datos de prueba ($R > 0.83$). Los resultados de las estimaciones del reclutamiento a largo plazo bajo los diferentes

escenarios mostraron que el reclutamiento se ve más favorecido por las variables asociadas al escenario mayor forzamiento radiativo. Dado que se estimó un mayor reclutamiento en el periodo de estudio bajo condiciones del RCP8.5, mientras que con el RCP2.6 (el de menor forzamiento radiativo) las estimaciones fueron menores. Es muy probable que este resultado se deba a la temperatura asociada a cada escenario, ya que en el análisis de sensibilidad para este modelo se demostró que el incremento en la temperatura favorece al reclutamiento. En cuanto al comportamiento de las variables a través de los escenarios, la magnitud del viento y la velocidad de las corrientes, no presentan alguna tendencia particular a lo largo del periodo de estudio. La temperatura en cambio, muestra tendencia al incremento en todos los escenarios (Apéndice III), lo mismo que el reclutamiento. Bajo el RCP8.5 se obtiene la temperatura más alta, dado un mayor forzamiento radiativo, la cual está alrededor de 27 °C a finales del periodo de estudio mientras que con el RCP2.6 está alrededor de 24 °C, lo cual representa la menor temperatura en todos los escenarios. En el mismo sentido el IPCC reporta que el incremento en la temperatura del océano en las regiones tropicales y subtropicales del Hemisferio Norte es de 2.0 °C bajo el RCP 8.5 a finales del siglo XXI (relativo a las condiciones industriales), mientras que para el RCP 2.6 es de 0.3 °C. Las estimaciones a corto plazo difieren de los resultados anteriores, puesto que para los próximos 5 años se estima mayor reclutamiento bajo condiciones del RCP 2.6. Pero es congruente con la idea de que la temperatura es la variable responsable de tal resultado ya que en éste, es ligeramente mayor para este periodo (2015-2020) que en el resto de los escenarios.

A pesar de que el forzamiento radiativo y las variables asociadas son calculados a partir de supuestos, es muy probable que el comportamiento de las variables oceanográficas, particularmente a corto plazo, se encuentre en el intervalo de valores calculados bajo los diferentes escenarios debido a que éstos tienen como base emisiones históricas y se consideran escenarios propuestos en la literatura (Thompson, et. al., 2011). Puesto que estos valores fueron los utilizados para generar las proyecciones, se tienen las herramientas necesarias para hacer proyecciones del comportamiento futuro del reclutamiento, particularmente a corto plazo.

Un aspecto de gran importancia en las proyecciones de cualquier recurso es evaluar las consecuencias bajo diferentes escenarios climáticos. De acuerdo a informes del IPCC

(IPCC, 2013), el OPO muestra una tendencia al calentamiento, lo cual en apego a la respuesta biológica del AAA y con base en los resultados del presente estudio, estas condiciones favorecerían los índices de reclutamiento. No obstante, para hacer proyecciones de reclutamiento más certeras es fundamental considerar el efecto de dicho calentamiento en las presas y los depredadores de la especie. Así como el estado y el manejo del recurso.

El presente estudio demostró que las NARX son una herramienta viable para la modelación ecológica. El modelo de estimación de reclutamiento futuro es capaz de hacer proyecciones para un largo periodo de tiempo, sin embargo como en todos los modelos, la incertidumbre crece a medida que se avanza en el tiempo, aunada a la incertidumbre de las estimaciones iniciales. Por lo que considerar sólo un periodo corto resultaría en proyecciones de reclutamiento más acertadas. De acuerdo a las proyecciones del modelo con base en los diferentes escenarios de cambio climático, se propone que el reclutamiento estará en un intervalo de 162,856 a 188,465 toneladas en promedio anual para el periodo 2015-2020, el cual en cualquier caso representa un incremento para los siguientes 5 años, relativo al reclutamiento estimado por la CIAT para el periodo 2009-2013 cuyo valor fue de 142,008 toneladas. Los resultados anteriores en su conjunto representan una valiosa información que puede ser de gran utilidad para las estimaciones de reclutamiento futuro y para apoyar el establecimiento de medidas de manejo subsecuentes para el AAA.

7. Conclusiones

- Las redes neuronales artificiales utilizadas en el presente estudio, permitieron obtener buenos modelos del reclutamiento del atún aleta amarilla a partir de las condiciones oceanográficas en el OPO.
- Las redes neuronales artificiales tienen mayor capacidad para modelar el reclutamiento del atún aleta amarilla, respecto a los GLM.
- El reclutamiento total del atún aleta amarilla en el OPO, puede ser modelado a partir de las variables que lo afectan en cualquiera de las regiones de estudio, distribuidas en el área de desove de los adultos.
- El reclutamiento del atún aleta amarilla en la zona de mayor reclutamiento en el OPO está modulado por las variaciones en la temperatura y la magnitud del viento.
- La temperatura es la variable con más influencia en el reclutamiento del atún aleta amarilla. Las condiciones de El Niño, y en general las temperaturas cálidas favorecen el incremento del reclutamiento de esta especie.
- Los modelos de redes neuronales artificiales encontraron poca relación entre el reclutamiento y la biomasa de los desovadores.
- Los GLM demostraron que si existe una relación población-reclutamiento en el atún aleta amarilla.
- La respuesta del reclutamiento a los diferentes escenarios obtenidos a partir del modelo GFDL, está en función de la temperatura principalmente. El escenario RCP2.6 favorecería el reclutamiento del atún aleta amarilla a corto plazo dado que en el periodo para 2015-2020 muestra temperaturas ligeramente superiores al resto de los escenarios. Sin embargo, a largo plazo este escenario es el menos favorable para el reclutamiento puesto que en el

tiempo en el que se brindan los escenarios (hasta el año 2100), se plantea un menor forzamiento radiativo y por ende una menor temperatura. El RCP8.5 es el escenario que de forma general presenta condiciones más favorables para el reclutamiento del atún aleta amarilla.

- Con base en las condiciones de los diferentes escenarios el reclutamiento estará en un intervalo de 162,856 a 188,465 toneladas en promedio anual para el periodo 2015-2020, el cual es superior al reclutamiento reportado por la CIAT para el periodo 2009-2013.

Lista de referencias

- Aoki, I., y Komatsu, T. (1997). Analysis and prediction of the fluctuation of sardine abundance using a neural network. *Oceanologica Acta*, 20(1), 81-88.
- Agüero, M. (2006). Capacidad de pesca y manejo pesquero en América Latina y el Caribe, v. 461. Food and Agriculture Organization.
- Beale, M. H., Hagan, M. T., y Demuth, H. B. (2014). Neural Network Toolbox™ User's Guide R. Recuperado el 2014. Recuperado el 13 de octubre del 2014 de: http://jp.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf
- Bakun, A. y Weeks, S. J. (2008). The marine ecosystem off Peru: What are the secrets of its fishery productivity and what might its future hold?. *Progress in Oceanography*, 79(2), 290-299.
- Castro-Ortiz, J. L., y Quiñones-Valásquez, C. (1987). Distribución y abundancia del atún aleta amarilla (*Thunnus albacares*) en relación con la temperatura superficial en el Pacífico Nororiental (1983-1985). En: M. Ramírez (ed.), *Memorias del Simposio sobre investigación en Biología y Oceanografía Pesquera en México*. CICIMAR, La Paz, Baja California Sur, abril de 1987. 21-23 p.
- Chen, I., y Ware, D. M. (1999). A neural network model for forecasting fish stock recruitment. *Canadian Journal of Fisheries and Aquatic Sciences*, 56(12), 2385-2396.
- CIAT. (1994). Annual report of the Inter-American Tropical Tuna Commission, 1993. La Jolla California. 316 p.
- CIAT. (2013). Atunes y picudos en el Océano Pacífico Oriental en 2012. Informe de la situación pesquera No. 11. Comisión Interamericana del Atún Tropical. La Jolla Cal. 171 p.
- Collette, B., y Nauen, C. (1983). *FAO species catalogue. Vol. 2 Scombrids of the world. An annotated and illustrated catalogue of tunas, mackerels, bonitos and related known to date*. FAO Fisheries Synopsis. 125 p.
- Cury, P., y Roy, C. (1989). Optimal environmental window and pelagic fish recruitment success in upwelling areas. *Canadian Journal of Fisheries and Aquatic Sciences*, 46(4), 670-680.
- Davidson E. A. (2012) Representative concentration pathways and mitigation scenarios for nitrous oxide. *Environmental Research Letters*, 7(2), 024005.
- Dreyfus-León, M., y Robles-Ruiz, H. (2008). Tallas (Longitud furcal) del Atún Aleta Amarilla, *thunnus albacares*, capturado por la flota atunera mexicana durante 2007. *El Vigía. PNAAPD*. Enero-Junio, año 13 num. 33. 5-7 p.
- Dreyfus-León, M. y Schweigert, J. (2008). Recruitment prediction for Pacific herring (*Clupea pallasii*) on the west coast of Vancouver Island, Canada. *Ecological Informatics*, 3(2), 202-206.
- Fiedler, P. C., y Talley, L. D. (2006). Hydrography of the eastern tropical Pacific: A review. *Progress in Oceanography*, 69(2), 143-180.

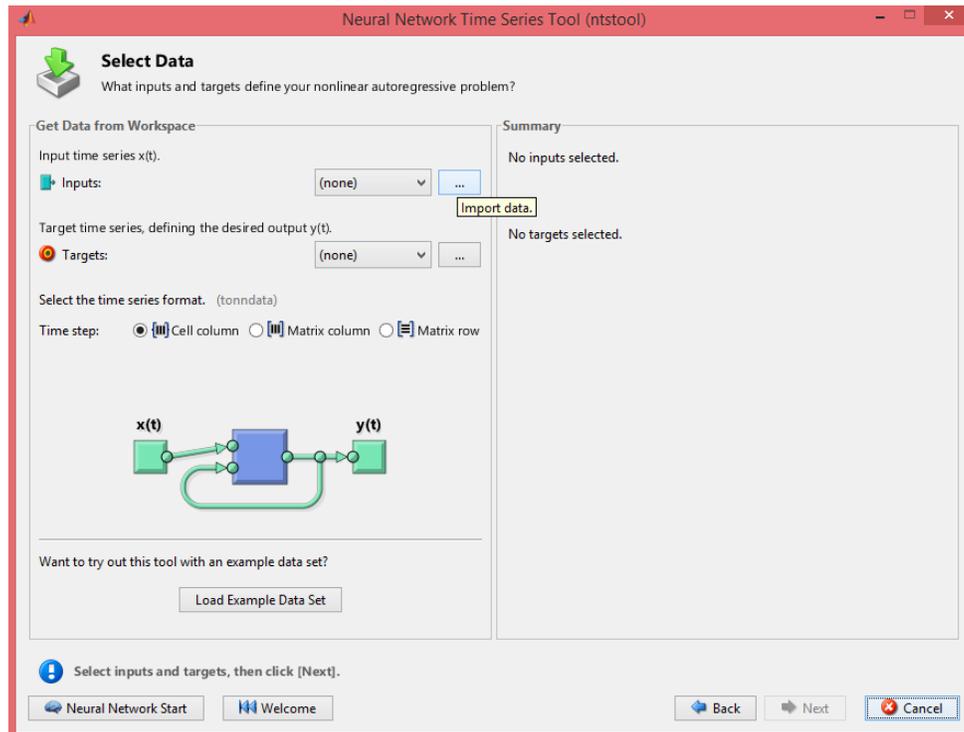
- Fox, J. y Weisberg, S. (2011). *An R Companion to Applied Regression*. Sage, Thousand Oaks CA, second edition.
- Gaertner, D., Dreyfus-León, M. (2004). Analysis of non-linear relationships between catch per unit effort and abundance in a tuna purse-seine fishery simulated with artificial neural networks. *ICES Journal of Marine Science*, 61(15), 812-820.
- Gutiérrez-Estrada, J. C., Vasconcelos, R., y Costa, M. J. (2008). Estimating fish community diversity from environmental features in the Tagus estuary (Portugal): Multiple Linear Regression and Artificial Neural Network approaches. *Journal of Applied Ichthyology*, 24(2), 150-162.
- Gutiérrez-Estrada, J. C., Yáñez, E., Pulido-Calvo, I., Silva, C., Plaza, F., y Bórquez, C. (2009). Pacific sardine (*Sardinops sagax*, Jenyns 1842) landings prediction. A neural network ecosystemic approach. *Fisheries Research*, 100(2), 116-125.
- Haury, L. R., Yamazaki, H., y Itsweire, E. C. (1990). Effects of turbulent shear flow on zooplankton distribution. *Deep Sea Research Part A. Oceanographic Research Papers*, 37(3), 447-461.
- Holey, S. D., y Maunder, M. N. (2007). Status of yellowfin tuna an the Estern Pacific Ocean in 2005 and outlook for 2006. *Inter-American. Tropical Tuna Commission.*, Stock assessment Report, 7, 3-115.
- Ichii, T., Mahapatra, K., Watanabe, T., Yatsu, A., Inagake, D., y Okada, Y. (2002). Occurrence of jumbo flying squid *Dosidicus gigas* aggregations associated with the countercurrent ridge off the Costa Rica Dome during 1997 El Niño and 1999 La Niña. *Marine Ecology. Progress Series*, 231, 151-166.
- IPCC, 2013: *Climate Change 2013. The physical science Basis Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [Stocker, T. F., Qin, D., Plattner, G. K., Tignor M., Allen S. K., Boschung J., Naueles A., Xia Y., Bex V., y Midgley, P. M.(eds.)].Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.135 p
- Jarre-Teichmann, A., Brey, T., y Haltof, H. (1995). exploring the use of neuronal network for forecast in the peruvian upwelling. *NAGA the ICLARM Quarterly*, 18(4), 38-40.
- Josheph, J., y Miller, F. R.(1989). El Niño and the surfce fishery for tunas in the eaastern Pacific. *Japan. Soc. Fish. Ocean., Bulluetin*, 57,77-80.
- Kriesel, D. (2007). A brief introduction to neural networks.Recuperado el 12 de julio del 2014 , de: http://www.dkriesel.com/en/science/neural_networks
- Kimura, S., Nakata, H., Margulies, D., Suter, J. M. y Hunt, S. L. (2004). Effect of oceanic turbulence on the survival of yellowfin tuna larvae. *Nippon Suisan Gakkaishi*, 70(2), 175-178.
- Langley, A., Briand, K., Kirby, D. S., & Murtugudde, R. (2009). Influence of oceanographic variability on recruitment of yellowfin tuna (*Thunnus albacares*) in the western and central Pacific Ocean. *Canadian Journal of Fisheries and Aquatic Sciences*, 66(9),1462-1477.

- Lavín, M. F., Fiedler, P. C., Amador, A. J., Ballance, L. T., Färber-Lorda, J., y Mestas-Nuñez, A., M. (2006). A review of eastern tropical Pacific oceanography: Summary. *Progress in Oceanography*, 69(2), 391-398.
- Lehodey, P., Chai, F., y Hampton, J. (2003). Modelling climate-related variability of tuna populations from a coupled ocean-biogeochemical-populations dynamics model. *Fisheries Oceanography*, 12(4-5), 483-494.
- Lek, S., Deharveng, L., y Lek, S. (1999). Predictive models of collembolan diversity and abundance in a riparian habitat. *Ecological Modelling*, 120(12), 247-260.
- Lek, S., y Guégan, J. F. (1999). Artificial neural networks as a tool in ecological modelling, an introduction. *Ecological modelling*, 120(2), 65-73.
- Lin, J. L. (2007) Interdecadal variability of ENSO in 21 IPCC AR4 coupled GCMs. *Geophysical Research Letters*, 34(12).
- Margulies, D., (2001). Early life history studies of Yellowfin tuna, (*Thunnus albacares*). *Inter-American Tropical Tuna Commission, Bulletin*, 22, 9-20.
- Margulies, D., Sutter, J. M., Hunt, S. L., Olson, R. J., Sholey, V. P., Wexler, J. B., y Nakazawa, A. (2007). Spawning and early development of captive yellowfin tuna, (*Thunnus albacares*). *Inter-American Tropical Tuna Commission, Bulletin*, 105(2), 249-265.
- Maury, O., Gascuel, D., Marsac, F., Fonteneau, A., y Rosa, A. L. D. (2001). Hierarchical interpretation of nonlinear relationships linking yellowfin tuna (*Thunnus albacares*) distribution to the environment in the Atlantic Ocean. *Canadian Journal of Fisheries and Aquatic Sciences*, 58(3), 458-469.
- McCullagh, P. (1984). Generalized linear models. *European Journal of Operational Research*, 16(3), 285-292.
- Mehrotra, K., Mohan, C. K., y Ranka, S. (1997). Elements of Artificial Neural Networks. MIT press.
- Mestas-Nuñez, A. M., y Miller, A. j. (2006). Interdecadal variability and climate change in the Eastern Tropical Pacific: a review. *Progress in Oceanography*, 69(2), 267–284.
- Methot, R.D.(2011). Users manual for Stock Synthesis: model versión 3.23b. November 7, 2011. NOAA Fisheries Service, Seattle Washington.
- Minte-Vera, C. V., Aires-da-Silva, A., Maunder, M. N. (2014). Condición del Atún Aleta Amarilla en el Océano Pacífico Oriental en 2013 y perspectivas para el futuro. Comisión Interamericana del Atún Tropical, Comité científico Asesor, 5ª reunión. La Jolla Cal. 1-15 p.
- O'Hara, R. B. (2009). How to make models add up-a primer on GLMMs, *Annales Zoologici Fennici*, 46(2), 124-137.
- Overland, J. E., y Wang, M. (2007). Future climate of the north Pacific Ocean. *Eos, Transactions American Geophysical Union*, 88(16), 178-182.

- Rico, C., Paredes, M., y Fernández, N. (2009). Modeling of the hierarchical structure of freshwater macroinvertebrates using artificial neural networks. *Acta Biologica Colombiana*, 14(3), 71-96.
- Shaefer, M. K. (1998). Reproductive biology of yellowfin tuna (*Thunnus albacares*) en the eastern Pacific Ocean. *Inter-American Tropical Tuna Commission, Bulletin*, 21(5), 272.
- Stefánsson, G. (1996). Analysis of groundfish survey abundance data : combining the GLM and delta approaches. *ICES Journal of Marine Science*, 53(3), 577-588.
- Suárez-Sánchez, J., Ritter-Ortíz, W., Gay-García, C., y Torres-Jacome, J. (2004). ENSO-tuna relations in the eastern Pacific Ocean and its prediction as a non-linear dynamic system. *Atmósfera*, 17(4), 245-258.
- Sund, P. N., Blackburn, M., y Williams, F. (1981). Tunas and their environment in the Pacific Ocean: a review. *Oceanography and Marine Biology, an Annual Review*, 19, 443-412.
- Suzuki, S. (1994). A review of the biology and fisheries for yellowfin tuna, *Thunnus albacares*, in the Eastern Pacific Ocean *FAO Fisheries Technical Paper*, 336(2), 108-137.
- Suzuki, Z., Tomlinson, P. K., y Honma, M. (1978). Population structure of Pacific yellowfin tuna. *Inter-American Tropical Tuna Commission, Bulletin*, 17(5), 277-362.
- Taylor, K. E., Stouffer, R. J., y Meehl, G. A. (2012). An overview of CMIP5 and the experiment design. *Bulletin of the American Meteorological Society*, 93(4), 485-498.
- Tetko, I. V., Livingstone, D. J., y Luik, A. I. (1995). Neural Network Studies. 1. Comparison of overfitting and overtraining. *Journal of chemical information and computer sciences*, 35(5), 826-833.
- Thomson, A. M., Calvin, K. V., Smith, S. J., Kyle, G. P., Volke, A., Patel, P., y Edmonds, J. A. (2011). RCP4. 5: a pathway for stabilization of radiative forcing by 2100. *Climatic Change*, 109(1-2), 77-94.
- Wang, C., y Enfield, D. B. (2001). The tropical Western Hemisphere warm pool, *Gephysical Research Letters*, 28(8), 1635-1638.
- Wexler, J. B., Margulies, D., y Scholey, V. P. (2011). Temperature and dissolved oxygen requirements for survival of yellowfin tuna, *Thunnus albacares*, larvae. *Journal of Experimental Marine Biology and Ecology*, 404(1), 63-72.
- Wild, A. (1994). A review of the biology and fisheries for yellowfin tuna, *Thunnus albacares*, in the Eastern Pacific Ocean. *FAO Fisheries Technical Paper*, 336(2), 52-107.
- Wyrтки, K. (1964). Upwelling in the costa rica dome. *Fishery Bulletin*. 63(2), 355-372.
- Wu, F., Deng, X., Yin, F., y Yuan, Y. (2013). Projected changes of grassland productivity along the representative concentration pathways during 2010-2050 in China. *Advances in Meteorology*, 2013.
- Zhang, G., Patuwo, B. E., y Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14(1), 35-62.

Apéndices

I. Ventana de la herramienta nstart para generar modelos NARX



II. Código para le generación de un modelo NARX

%Código generado por nstart, 02 Jun 2014

% Esta secuencia de comandos asume que las siguientes variables están definidas:

%

% X – Series de tiempo de entrada

% Y – Serie de tiempo de salida.

%Definiendo:

% Entradas de la red

X= [%serie de datos SOI

 %serie de datos PDO

 %serie de datos Biomasa de desovadores]

%Salida esperada

Y= [%Serie de datos de Reclutamiento]

```
%Convertir los datos a un conjunto de celdas para red neuronal
inputSeries = tonndata(X,true,false);
targetSeries = tonndata(Y,true,false);
```

```
% funciones para generar una NARX, antes se determina el número de desfases tanto en las
entradas como en las salidas y se indica el número de neuronas en la capa oculta.
```

```
inputDelays = 1:3;
feedbackDelays = 1:3;
hiddenLayerSize = 4;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize);
```

```
% Se eligen las las funciones de pre- y post- procesamiento para las entradas y salidas
```

```
%Para conocer la lista y ayuda de todas las funciones de procesamiento ir a "help nnprocess"
```

```
%Adaptar los parámetros de entrada utilizando: "net.inputs{i}.processParam"
```

```
%Adaptar los parámetros de salida utilizando:
```

```
"net.outputs{i}.processParam"
```

```
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
net.inputs{2}.processFcns = {'removeconstantrows','mapminmax'};
```

```
% Preparación los parámetros para el entrenamiento y la simulación de la red
```

```
%La función PREPARETS prepara los datos de las series de tiempo para una red particular.
Permite mantener los datos originales, sin cambios, mientras que facilita la personalización para
redes con diferente número de desfases, con ciclos abiertos o con ciclos cerrados de
retroalimentación
```

```
[inputs,inputStates,layerStates,targets]= preparets(net,inputSeries,{},targetSeries);
```

```
%Configura
```

```
%División del set de datos para el entrenamiento, la validación y la prueba.
```

```
%La función DIVIDERAND aleatoriamente los datos para formar los conjuntos de entrenamiento,
validación y prueba.
```

```
%Para ver una lista de las funciones de división ir a "help nndivide"
```

```
net.divideFcn = 'dividerand';
net.divideMode = 'value';
net.divideParam.trainRatio = 80/100;
net.divideParam.valRatio = 10/100;
net.divideParam.testRatio = 10/100;
```

```
% Elegir la función de entrenamiento
```

```
%Para ver una lista de todas las funciones de entrenamiento ir a "help nntrain"
```

```
net.trainFcn = 'trainlm'; % Levenberg-Marquardt
```

```
% Elegir la función de ajuste para medir el desempeño de la red en este caso, el error cuadrático
medio.
```

```
% Para ver una lista de todas las funciones de ajuste ir a "help nnperformance"
```

```
net.performFcn = 'mse';
```

```

%Elegir las funciones para graficar
%Para una lista de todas las funciones para graficar ir a "helo nnplot"
net.plotFcns = {'plotperform','plottrainstate','plotresponse', ...
    'ploterrcorr', 'plotinerrcorr'};

% Entrenamiento de la red
[net,tr] = train(net,inputs,targets,inputStates,layerStates);

% Prueba de la red
outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)

% Recalcular el entrenamiento, la validación y la prueba
trainTargets = gmultiply(targets,tr.trainMask);
valTargets = gmultiply(targets,tr.valMask);
testTargets = gmultiply(targets,tr.testMask);
trainPerformance = perform(net,trainTargets,outputs)
valPerformance = perform(net,valTargets,outputs)
testPerformance = perform(net,testTargets,outputs)

% Ver la red
view(net)

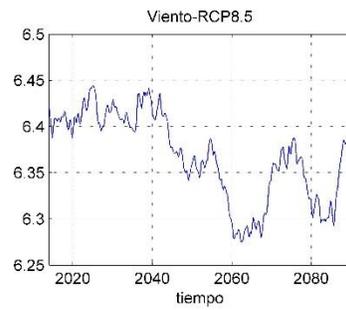
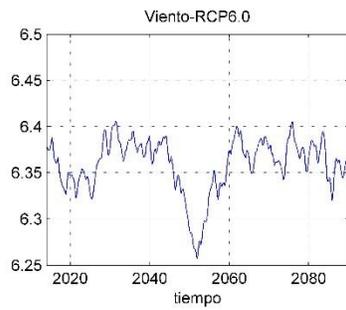
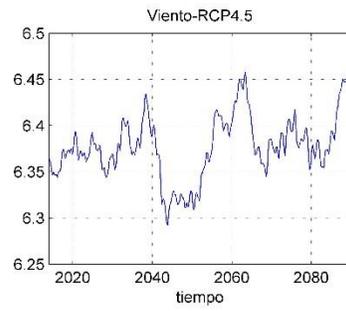
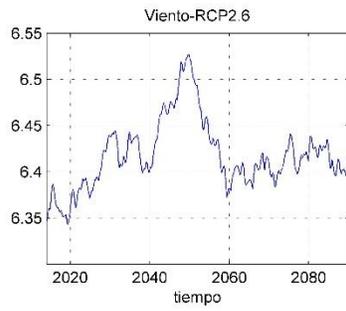
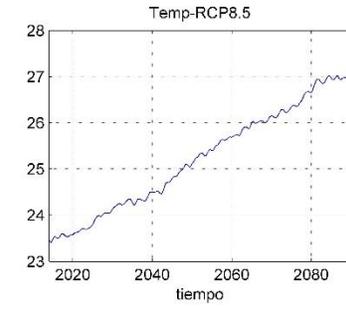
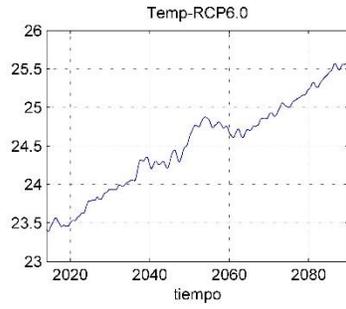
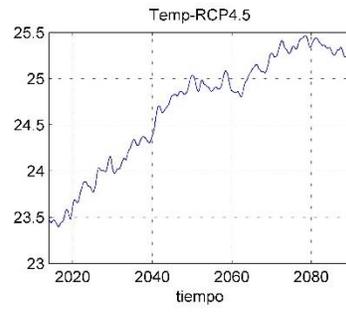
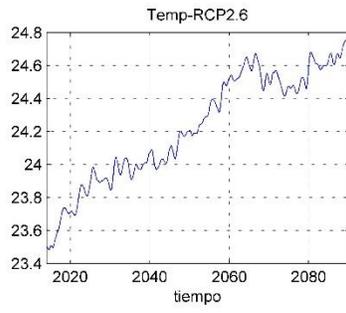
% Graficar resultados
figure, plotperform(tr) % ajuste de la red
figure, plottrainstate(tr) % estado de la red
figure, plotregression(targets,outputs) % correlación entre entradas y salidas
figure, plotresponse(targets,outputs) % Respuesta de la red
figure, ploterrcorr(errors) % correlación en los errores
figure, plotinerrcorr(inputs,errors) % correlación entre entradas y errores
figure, ploterrhist(errors) % histograma de errores

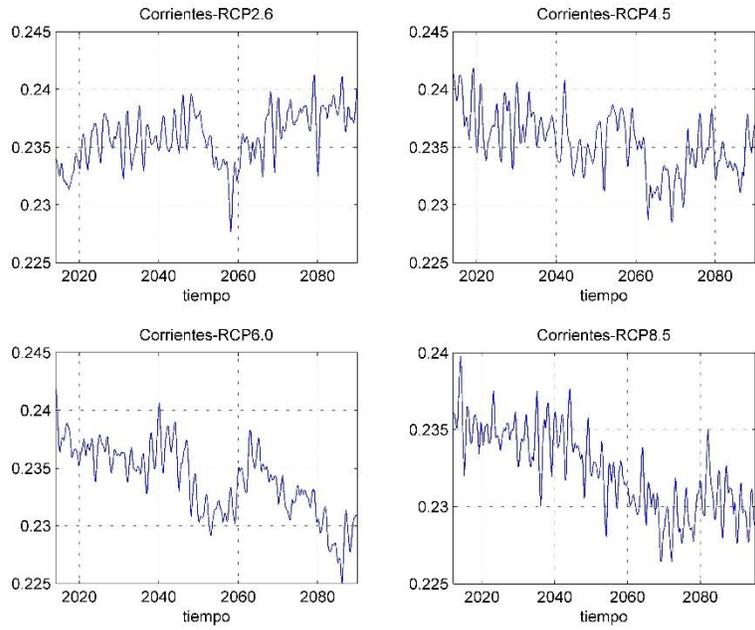
% Si se quiere preparar la red para otras entradas se usa "Closed Loop Network"
netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
view(netc)
[xc,xic,aic,tc] = preparets(netc,inputSeries,{},targetSeries);
yc = netc(xc,xic,aic);
closedLoopPerformance = perform(netc,tc,yc)

% Guardar pesos de conexión
wb = formwb(net,net.b,net.iw,net.lw)
AA=net.iw{1,1}
BB=net.b{1}
plotwb(net)

```

III. Series de tiempo de las variables oceanográficas bajo los diferentes escenarios RCP's





IV. Serie de tiempo del reclutamiento del AAA para el periodo 1975-2012

