

REDES DE NEURONAS ARTIFICIALES PARA EL PRONÓSTICO DE BIOMASA DE SARDINA DEL PACÍFICO Y DE SU MEDIO AMBIENTE

ARTIFICIAL NEURAL NETWORKS TO FORECAST BIOMASS OF PACIFIC SARDINE AND ITS ENVIRONMENT

Miguel A. Cisneros-Mata^{1,2,*}

Thomas Brey¹

Astrid Jarre-Teichmann³

Walterio García-Franco⁴

Gabriela Montemayor-López²

¹Alfred Wegener Institute for Polar and Marine Research
Columbusstrasse, D-27515 Bremerhaven, Germany

² Instituto Nacional de la Pesca
Centro Regional de Investigaciones Pesqueras de Guaymas
Calle 20 No. 605-Sur, Guaymas, Sonora 85400, México

³ Danish Institute for Fisheries Research, North Sea Centre
P.O. Box 101, 9850 Hirtshals, Denmark

⁴ Instituto Nacional de la Pesca
Centro Regional de Investigaciones Pesqueras de Ensenada
Apartado postal 1306, Ensenada, Baja California, México

Recibido en abril de 1996; aceptado en agosto de 1996

RESUMEN

Se investigó el funcionamiento de redes de neuronas artificiales (RNAs) utilizando diversas series de tiempo de datos ambientales y biológicos del ecosistema nerítico de la Corriente de California (CC). Mediante el uso de RNAs fue posible hacer buenas predicciones hasta con nueve años de anticipación de temperatura mensual a 10 m de profundidad de la CC, con base en registros de temperatura del muelle del Instituto de Oceanografía Scripps. También se pudieron hacer buenos pronósticos en general de la biomasa desovante anual de la sardina del Pacífico (*Sardinops sagax caeruleus*) con un año de anticipación, usando como predictores la temperatura del agua, velocidad del viento al cubo, abundancia de huevos y larvas, captura comercial, y biomasa desovante de sardina del Pacífico y de anchoveta norteña (*Engraulis mordax*). Se discuten los resultados, enfatizando sobre la filosofía y posibles problemas enfrentados durante la construcción y uso de RNAs.

Palabras clave: sardina, redes neuronales, pronósticos, biomasa.

ABSTRACT

We tested the forecasting performance of artificial neural networks (ANNs) using several time series of environmental and biotic data pertaining to the California Current (CC) neritic ecosystem.

* Enviar correspondencia a este autor a (*corresponding author*): Instituto Nacional de la Pesca, Centro Regional de Investigaciones Pesqueras de Guaymas, Calle 20 No. 605-Sur, Guaymas, Sonora 85400, México.

ANNs performed well predicting CC monthly 10-m depth temperature up to nine years in advance, using temperature recorded at Scripps Institution of Oceanography pier. Annual spawning biomass of Pacific sardine (*Sardinops sagax caeruleus*) was forecasted reasonably well one year in advance using time series of water temperature, wind speed cubed, egg and larval abundance, commercial catch, and spawning biomass of northern anchovy (*Engraulis mordax*) and Pacific sardine as predictors. We discuss our results and focus on the philosophy and potential problems faced during ANN modelling.

Key words: sardine, neural networks, biomass forecasts.

INTRODUCCIÓN

Una buena parte (más del 25% en 1992) de la captura mundial de peces marinos se compone de pelágicos menores como anchovetas, sardinas, arenques y macarelas, entre otros. Ciertos conjuntos típicos de peces de estas especies son fundamentales en la ecología de los sistemas de afloramiento importantes y en la economía de países desarrollados y en vías de desarrollo (Hunter y Alheit, 1995). Dos de los grupos más importantes de pelágicos menores, las sardinas (*Sardinops* spp.) y anchovetas (*Engraulis* spp.), se alimentan de fitopláncton y de zooplancton. Sin embargo, debido a que son consumidores primarios y habitan en zonas neríticas muy dinámicas, estos recursos se caracterizan por ser muy variables (Beverton, 1983; Lluch-Belda *et al.*, 1989).

La investigación sobre ecología de los pelágicos menores ha significado un gran esfuerzo e inclusive se han establecido programas regionales e internacionales con tal fin. A lo largo de algunas décadas se ha acumulado gran cantidad de información, en particular de las zonas de afloramiento de California, Humboldt y Benguela. A pesar de la abundancia de datos e investigaciones sobre la variabilidad experimentada por los pelágicos menores, aún se desconocen aspectos ecológicos básicos. Esto limita nuestra capacidad de predicción y, como consecuencia, la administración de estos recursos sigue siendo difícil en particular. Las relaciones no lineales entre estas especies y su medio ambiente, además de nuestros alcances actuales en la modelación dificultan la elaboración de pronósticos precisos de reclutamiento mediante métodos estadísticos y modelos mecanísticos tradicionales. Una alternativa potencial es el uso de técnicas de computación intensiva

INTRODUCTION

Small pelagic species such as anchovies, sardines, herrings and mackerels, among others, comprise a substantial amount (over 25% in 1992) of the annual world yield of marine fishes. Guilds of these species play key roles in the ecology of all major upwelling systems and in the economy of developed and developing countries (Hunter and Alheit, 1995). Two of the most important groups of small pelagic fishes, sardines (*Sardinops* spp.) and anchovies (*Engraulis* spp.), feed on both zooplankton and phytoplankton and are able to reach very high levels of abundance. However, because of being low in the food chain in the variable neritic environment, it has been recognized that populations of small pelagic fishes are highly variable (Beverton, 1983; Lluch-Belda *et al.*, 1989).

A great deal of effort has been directed towards understanding the ecology of small pelagic fishes. Regional and international programs were developed for that purpose, and massive amounts of information have been collected over the past several decades, particularly in upwelling systems such as the California, Humboldt and Benguela currents. Despite the accumulation of data and vast work on small pelagic fish variability, our understanding of basic ecological aspects is far from complete and this hampers our predictive capability. Consequently, management of small pelagic stocks continues to be particularly difficult. Given our present modelling capabilities, nonlinearities in relationships between these species and their environment complicate the accurate forecasting of recruitment by traditional mechanistic and statistical techniques. In this respect, the use of computer-intensive

para encontrar posibles relaciones entre series de datos de pelágicos menores y su medio ambiente.

En el presente trabajo se evaluó el funcionamiento de redes de neuronas artificiales para la investigación del ecosistema nerítico de la Corriente de California. El trabajo inicia con una descripción de las redes de neuronas artificiales; luego se explora su potencial utilizando datos biológicos, pesqueros y oceanográficos relacionados con los pelágicos menores de la Corriente de California. Se concluye con una discusión de nuestros resultados, enfatizando sobre la filosofía y problemas encontrados en la modelación usando redes de neuronas.

Redes de neuronas artificiales

Esta sección no tiene como objetivo describir en forma exhaustiva las redes de neuronas artificiales (RNAs). Existen varios textos en donde se hacen explicaciones detalladas, por ejemplo Trippi y Turban (1993), Azoff (1994) y Saila (en prensa). Dos ejemplos de aplicaciones recientes en ecología son los trabajos de Komatsu *et al.* (1994), sobre la predicción de la captura comercial de larvas de sardina japonesa, y de Tan y Smeins (1996), sobre la predicción de cambios en la estructura de comunidades terrestres.

Hasta cierto punto, las RNAs funcionan en forma semejante a la optimización mediante la computación intensiva usando, por ejemplo, Simplex, para buscar soluciones a funciones multidimensionales complejas. Las RNAs son también análogas a técnicas no paramétricas, pues no se requiere asumir que los datos se distribuyen estadísticamente de manera específica. Las RNAs se basan en un procedimiento empírico y su filosofía es diferente a la de otras técnicas actuales.

Las RNAs son sistemas "expertos", programas de computación que realizan funciones complejas emulando la estructura y funcionamiento de neuronas biológicas en el cerebro. Por medio de cálculos masivos en paralelo (simultáneos), las RNAs detectan tendencias dentro y entre series de tiempo de datos (Azoff, 1994), que se pudieran interpretar como

techniques in the search for patterns and relationships between data sets pertaining to small pelagic fish and their environment is a promising alternative.

In the present work we assess the performance of artificial neural networks to investigate the neritic community of the California Current. We begin with a description of artificial neural networks, then explore their potential using biological, fisheries and oceanographic time series relevant to the small pelagic fish community of the California Current. We end with a discussion of our results, which focuses on the philosophy and common problems encountered during artificial neural network modelling.

Artificial neural networks

A complete description of artificial neural networks (ANNs) is beyond the goals of this report. Thorough explanations of ANNs can be found in Trippi and Turban (1993), Azoff (1994) and Saila (in press). Examples of recent applications of ANNs in ecology are works by Komatsu *et al.* (1994) on the prediction of commercial catch of Japanese sardine larvae, and by Tan and Smeins (1996) on the prediction of structural changes in a grassland community.

In a sense, ANN modelling is similar to optimization through computer-intensive techniques using, for example, Simplex, in search of solutions to n-dimensional complex functions. ANNs are also analogous to nonparametric techniques, as one does not require the assumption of a specific statistical distribution of data. ANN modelling is based on a completely empirical approach with a different philosophy than other research techniques.

ANNs are "expert" systems, which are computer programs that use a body of knowledge to perform relatively difficult tasks emulating the structure and function of biological neurons in the brain. By means of massive parallel (simultaneous) computations, neural networks can identify patterns within and between series of data (Azoff, 1994), which one would interpret as functional relationships. ANNs are collections of relatively simple,

relaciones funcionales. Estos programas son grupos de elementos de proceso relativamente simples pero con una gran cantidad de interconexiones que "aprenden" de acuerdo a ciertos conjuntos de datos de entrada (Saila, en prensa).

Las unidades básicas de una RNA son los elementos procesadores, denominados neuronas, dispuestos en capas y conectados a una o más neuronas en otras capas. La arquitectura de una red típica consiste en una capa de entrada, por lo menos una intermedia y una de salida. Cada elemento recibe y procesa señales de entrada provenientes de neuronas en otras capas y produce un valor de salida ponderado, denominado valor activado. Este valor es transformado usando alguna función (v.g., sigmoida) y transferido a otros elementos interconectados. El nivel de actividad o suma ponderada de los valores activados de las neuronas en la capa de salida determina la solución de la red a un problema específico.

La modelación con RNAs tiene dos etapas: entrenamiento y prueba. Se debe entrenar a las redes con datos que sirven como ejemplos y que representan variables independientes y dependientes, en nuestro caso series de tiempo. Durante esta fase el programa analiza los datos, generaliza y aprende su estructura mediante una función objetivo que minimiza las desviaciones entre valores reales y calculados por la red. Una diferencia fundamental entre las RNAs y técnicas de optimización comunes es que las RNAs incluyen un algoritmo (por lo general retropropagación; v.g., Dayhoff, 1990) que incrementa la eficiencia de la red. En cada ciclo o iteración el algoritmo genera cambios en el peso específico de la función de transferencia, lo cual afecta su valor de salida, y reparte el error entre todas las conexiones.

Una vez que la red ha sido entrenada se prueba su capacidad de predicción con datos homólogos que no le han sido presentados. Si la red realmente aprendió bien podrá predecir adecuadamente los valores observados a partir de variables independientes. Si la red sólo memorizó los patrones detectados durante la fase de entrenamiento, las predicciones pudieran ser muy deficientes.

highly connected processing elements that "learn" according to given sets of inputs (Saila, in press).

The basic unit of an ANN is the processing element, or simulated neuron, arranged in layers and connected to one or several neurons in other layers. The architecture of a typical network consists of an input layer, at least one intermediate, and an output layer. Each neuron receives and processes signal inputs from neurons in other layers to produce a weighted output, which is then called an activated value. This value is transferred, prior transformation using different functions (e.g., sigmoid), to other interconnected processing elements arranged in layers. The activity level or weighted sum of neurons in the output layer determines the network's solution to a given problem.

ANN modelling consists of two phases: training and testing. Networks are trained from sets of data that serve as examples representing independent and dependent variables, in our case time series. During this phase, the program analyzes the data, generalizes and learns its structure, while a target function minimizes deviations between actual values and those predicted by the net. A key difference between common optimization techniques and ANNs is an algorithm (commonly backpropagation; e.g., Dayhoff, 1990) in ANNs which improves performance of the network. During each cycle or iteration, the algorithm changes the transfer function output by decreasing (increasing) its weight, and prorates the error among all connections.

After training, a homologous data set of variables not previously presented to the network is used to test its predictive performance. If the network really learned it will be able to predict adequately the observed values from independent variables. If, however, the network only memorized patterns detected during training, its predictive performance might be quite poor.

MATERIALS AND METHODS

We tested performance of ANNs as diagnostic and predictive tools of both abiotic and

MATERIALES Y MÉTODOS

Se probó el funcionamiento de las RNAs para la diagnosis y predicción de factores ambientales y biológicos a diferentes escalas de tiempo y alcance en el futuro. En el primer ejemplo se usó la temperatura mensual de la costa del sur de California y norte de Baja California (en lo sucesivo llamada TE), como indicador ambiental de las condiciones de la Corriente de California. En el último ejemplo se investiga el funcionamiento de las RNAs en la predicción de la biomasa desovante anual de sardina del Pacífico, *Sardinops sagax caeruleus* Girard 1854, usando series de datos biológicos, ambientales y pesqueros.

Pronóstico de temperatura

Se construyeron RNAs para buscar una posible relación entre la temperatura promedio mensual a 10 m de profundidad, registrada en cruceros en las áreas 7 y 11 de la región CalCOFI (California Cooperative Oceanic Fisheries Investigations), y la temperatura superficial, registrada en el muelle del Instituto de Oceanografía Scripps (TIOS), al norte de San Diego, California (fig. 1). La serie de muestras de CalCOFI inicia en enero de 1951, pero faltan datos en algunos meses debido a indisponibilidad de tiempo de barco (Smith, 1995). La serie de TIOS inicia en 1916 y ha sido usada extensamente en investigación oceanográfico-pesquera (v.g., Lluch-Belda *et al.*, 1992; Hammann *et al.*, 1995; Smith, 1995).

Se construyeron tres redes para diagnosticar y predecir la temperatura en las áreas 7 y 11 (TE) usando 12 medias mensuales de TIOS: (a) TIOS de febrero a enero para predecir TE en enero, (b) TIOS de enero a diciembre para pronosticar la TE en el mes de enero siguiente, y (c) TIOS de enero a diciembre para pronosticar la TE del mes de febrero siguiente. Debido a que el modelo (a) incluye la TIOS de enero para "predecir" la TE del mismo mes de enero, se le considera un modelo de diagnóstico o correlación. Para los modelos (b) y (c) se utilizó TIOS de meses anteriores para pronosticar TE uno y dos meses en el futuro, respectivamente.

biotic components of the California Current neritic community for different time scales and lag into the future of predictions. In our first example we used monthly temperature data for the Southern California Bight and northern Baja California, a key indicator of conditions in the California Current. In our final example we used biotic, environmental and fishing data to determine how ANNs perform to predict annual spawning biomass of Pacific sardine, *Sardinops sagax caeruleus* Girard 1854.

Forecasting of temperature

We used ANNs to relate mean monthly 10-m-depth survey temperature in areas 7 and 11 of the CalCOFI (California Cooperative Oceanic Fisheries Investigations) sampling region and sea surface temperature measured at Scripps Institution of Oceanography pier (SIOT), north of San Diego, California (fig. 1). The CalCOFI survey series starts in January 1951 and has some gaps due mainly to non-availability of ship time (Smith, 1995). The SIOT series, which starts in 1916, has been widely used in fisheries oceanographic research (e.g., Lluch-Belda *et al.*, 1992; Hammann *et al.*, 1995; Smith, 1995).

We constructed three networks to diagnose and forecast temperature (BT) in CalCOFI areas 7 and 11, using 12 mean monthly SIOT: (a) February-January SIOT to predict January BT, (b) January-December SIOT to forecast the following January BT, and (c) January-December SIOT to forecast the following February BT. Because model (a) includes January SIOT to "predict" BT in the same January, we call this a diagnostic or correlation model. Models (b) and (c), however, used past SIOT to forecast BT one and two months ahead, respectively. We then conducted a sensitivity analysis to investigate how far into the future the ANNs could forecast BT based on SIOT. We did so by increasing the lag up to nine years, then proceeded as was done with models (b) and (c), comparing real values versus those forecasted by the networks.

In our analyses we used the geometric mean (GM) computed from monthly data in regions

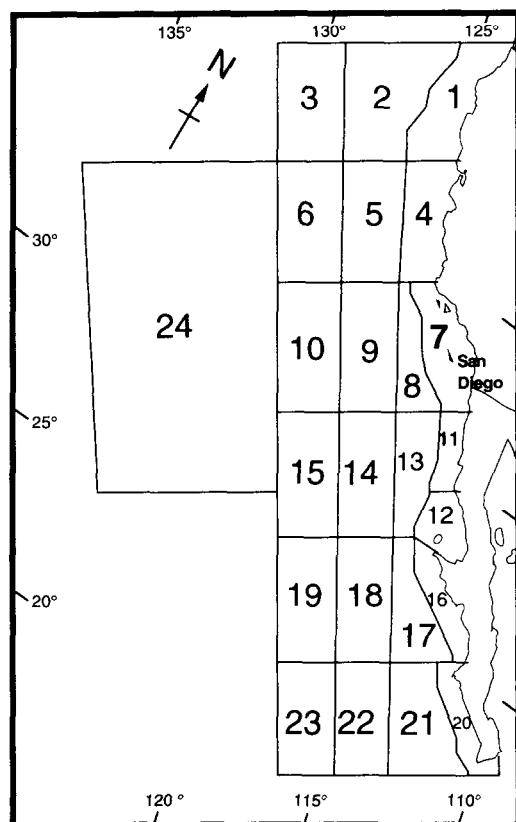


Figura 1. Regiones de muestreo del programa California Cooperative Oceanic Fisheries Investigations.

Figure 1. California Cooperative Oceanic Fisheries Investigations survey regions.

Posteriormente, se realizó un análisis de sensibilidad para investigar con qué anticipación se puede pronosticar la TE con base en TIOS usando RNAs. Para esto se incrementó sucesivamente el desfasamiento mensual hasta llegar a nueve años y luego se compararon los pronósticos con los datos reales, tal como en el caso de los modelos (b) y (c).

La serie de TE usada en los análisis se obtuvo calculando la media geométrica (MG) de datos mensuales de las regiones 7 y 11 de CalCOFI, importante zona de reproducción de la sardina del Pacífico (Moser *et al.*, 1993). El número de datos usados fue determinado por el número de meses en que se dispuso de TE.

7 and 11 of the CalCOFI data base, the main spawning habitat for Pacific sardine in the California Current (Moser *et al.*, 1993). The number of data points for our analyses were determined by the number of months when BT was available. From January 1951 to December 1984 there were a total of 182 data points, i.e., monthly GMs of temperature from CalCOFI regions 7 and 11.

To feed the networks we arranged a matrix of 13 columns and 181 rows for model (a) and 182 rows for models (b) and (c). The first 12 columns contained serially ordered SIOT and the 13th column contained BT as the dependent variable. These matrices were then randomly

De enero de 1951 a diciembre de 1984 se contó con 184 meses con MG de temperatura en las regiones 7 y 11 de CalCOFI.

Los datos de ejemplo consistieron en matrices de 13 columnas y 181 renglones para el modelo (a) y 182 renglones para los modelos (b) y (c). Las primeras 12 columnas contenían TIOS en orden cronológico y la treceava TE como variable dependiente. Los renglones de cada matriz fueron luego reordenados al azar y separados en dos conjuntos, el de entrenamiento y el de prueba; los conjuntos de entrenamiento contenían 150 vectores renglón. El resto de las matrices se usaron en la etapa de prueba, llamada de pronóstico, pues estos datos no se habían presentado antes a las redes. En el análisis de sensibilidad se usaron 26 vectores renglón para probar los pronósticos, de manera que el número de vectores de entrenamiento disminuyó a medida que el desfasamiento aumentaba.

Pronóstico de la biomasa desovante anual de sardina

Para investigar el funcionamiento de las RNAs para el pronóstico a escala anual se utilizaron las siguientes bases de datos: (a) descarga comercial anual (en toneladas métricas, TM) en California de sardina del Pacífico (DS) y de anchoveta norteña, *Engraulis mordax* Girard 1856 (DA); (b) índice mensual promedio de ictiopláncton en las áreas 7 y 11 de CalCOFI (nos./10 m²): huevos (HS) y larvas (LS) de sardina del Pacífico; (c) biomasa desovante anual (TM) de sardina del Pacífico (BS) y de anchoveta norteña (BA); (d) series ambientales: velocidad del viento al cubo (en (m/s)³) mensual en las áreas 7 y 11 (V³), y TIOS mensual (en °C).

Los datos de captura comercial se obtuvieron de los informes anuales de las pesquerías de California publicados en *CalCOFI Reports* (v.g., Anónimo, 1995). Las series de ictiopláncton nos fueron proporcionadas por P. Smith (National Marine Fisheries Service, Southwest Fisheries Science Center, La Jolla, California, EUA) y constan del número promedio de huevos y larvas de todos los estadios por cada 10 m². Los métodos empleados en el programa CalCOFI para el muestreo de ictiopláncton están descritos en Kramer *et al.* (1972).

sorted by rows and partitioned into two sets, the training set and the test set. Training sets always consisted of 150 row vectors. The remaining matrices in each case were used to test predictions of the ANNs, in what we call forecast because they contained data the net had not previously been presented with. In the sensitivity analysis, 26 row vectors were always left to test the forecasts, hence the number of row vectors for training decreased as the lag increased.

Forecasting of annual spawning biomass of sardine

To ascertain the performance of ANNs to forecast at annual scales we used the following data: (a) annual commercial catch (in metric tonnes, MT) in California of Pacific sardine (SY) and northern anchovy, *Engraulis mordax* Girard 1856 (AY); (b) monthly ichthyoplankton index (nos./10 m²): average Pacific sardine eggs (SE) and larvae (SL) in CalCOFI areas 7 and 11; (c) annual spawning biomass (MT) of Pacific sardine (SB) and northern anchovy (AB); (d) environmental series: monthly wind speed cube (in (m/s)³) for areas 7 and 11 (W³), and monthly SIOT (in °C).

Commercial catch data were obtained from the annual reviews of the California fisheries published in *CalCOFI Reports* (e.g., Anonymous, 1995). The ichthyoplankton data bases we used were provided by P. Smith (National Marine Fisheries Service, Southwest Fisheries Science Center, La Jolla, California, USA) and contain mean numbers of eggs and larvae of all stages per 10 m². Methods employed in sampling ichthyoplankton by the CalCOFI program are described in Kramer *et al.* (1972).

Sardine spawning biomass data were taken from MacCall (1979) and Jacobson and MacCall (1995). Data up to 1965 were estimated using virtual population analysis (Murphy, 1966), while the more recent estimates were done using CANSAR (catch-at-age analysis for sardine), a model similar to CAGEAN (catch-at-age analysis) which was developed for halibut (Deriso *et al.*, 1985). Anchovy biomass data up to 1966 were obtained from Methot (1989) and were estimated by the stock-synthesis method. Recent data

Los datos de biomasa de sardina fueron tomados de MacCall (1979) y de Jacobson y MacCall (1995). Hasta 1965 la biomasa se estimó por el método de análisis de población virtual (Murphy, 1966) y después usando el programa CANSAR (análisis de captura por edad para la sardina), el cual se basa en el modelo CAGEAN (análisis de captura por edad), desarrollado para las platijas (Deriso *et al.*, 1985). Los datos de biomasa de anchoveta hasta 1966 se tomaron de Methot (1989) y fueron estimados usando el modelo de síntesis poblacional. Los datos más recientes se tomaron de Jacobson *et al.* (1994) y fueron estimados mediante SMPAR, un modelo que combina modelos de producción con modelos de estructura de edad.

La serie mensual de TIOS, basada en mediciones diarias, nos fue facilitada por M.G. Hammann (Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California, México). La serie de V^3 se obtuvo del archivo en CD-ROM, volumen 5: Pacífico Oriental, de COADS (*Comprehensive Ocean-Atmosphere Data Set*), desarrollado por l'Institut Français de Recherche Scientifique pour Développement en Coopération y el National Oceanic and Atmospheric Administration de Estados Unidos.

Para representar las condiciones durante la primavera, el periodo de reproducción de la sardina (Moser *et al.*, 1993), se obtuvieron promedios de HS, LS, V^3 y TIOS durante los meses de marzo a julio. Se usó la serie de TIOS en lugar de la de BT debido a que aquélla tiene varios huecos y porque encontramos que la TIOS es un buen indicador de la temperatura superficial en las áreas 7 y 11 (ver Resultados). En algunos años en que se carecía de datos de ictioplankton y biomasa de adultos, se obtuvieron por interpolación de valores contiguos. La serie anual resultante abarcó de 1952 a 1990. Utilizando esta serie se construyó una red de neuronas siguiendo el modelo general:

$$\begin{aligned} BS_t &= f(TIOS_{t-2,t-1}; V^3_{t-2,t-1}; HS_{t-1}; LS_{t-1}; \\ &DS_{t-3,t-2,t-1}; DA_{t-3,t-2,t-1}; BA_{t-1}; BS_{t-2}) \end{aligned}$$

en donde los subíndices indican el desfasamiento (en años) de cada variable incluida. La

were taken from Jacobson *et al.* (1994) and were obtained using SMPAR, a model which combines surplus production and age-structured models.

The monthly SIOT series, computed from daily measurements, was made available to us by M.G. Hammann (Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California, Mexico). The W^3 time series was retrieved from COADS (*Comprehensive Ocean-Atmosphere Data Set*) CD-ROM, volume 5: Eastern Pacific, developed by l'Institut Français de Recherche Scientifique pour le Développement en Coopération, and the US National Oceanic and Atmospheric Administration.

To represent conditions during spring, the sardine spawning period (Moser *et al.*, 1993), annual indices of spring egg and larval abundance (SE and SL), wind speed cube (W^3) and temperature at Scripps pier (SIOT) were computed as the March-July average of monthly values. We used SIOT instead of survey temperature data because the latter series has several gaps and because we found that SIOT is a good indicator of mean surface temperature of areas 7 and 11 (see Results). In some years lacking ichthyoplankton and sardine biomass, data were interpolated from adjacent values. The resulting annual time series spanned from 1952 to 1990. Using these data series we constructed a network following the general model:

$$\begin{aligned} SB_t &= f(SIOT_{t-2,t-1}; W^3_{t-2,t-1}; SE_{t-1}; SL_{t-1}; \\ &SY_{t-3,t-2,t-1}; AY_{t-3,t-2,t-1}; AB_{t-1}; SB_{t-2}) \end{aligned}$$

where sub-indices indicate time lag (in years) of each variable used. The resulting matrix for this particular model consisted of 14 columns (C) and 39 rows (R). This matrix was randomly ordered by rows and then split into training (14 C, 30 R) and test (14 C, 9 R) matrices. In recent works it has been customary to leave between 10 and 30% of the data to test the trained networks (Jarre-Teichmann *et al.*, 1995; Brey *et al.*, in press).

The networks were constructed using the Professional Works II+ software by NeuralWare, Inc., and the backpropagation algorithm

matriz de datos para este modelo constó de 14 columnas (C) y 39 renglones (R). Los renglones de esta matriz fueron ordenados al azar y separados en dos matrices, de entrenamiento (14 C, 30 R) y de prueba (14 C, 9 R). En trabajos recientes se dejan entre 10 y 30% de los datos para probar las redes entrenadas (Jarre-Teichmann *et al.*, 1995; Brey *et al.*, en prensa).

Las redes se construyeron con el programa Profesional Works II+ de NeuralWare, Inc., usando el algoritmo de retropropagación. Las redes para pronóstico de temperatura se entrenaron durante 10,000 ciclos y tenían 12 capas de entrada, 3 intermedias y 1 de salida; las de pronóstico de biomasa se entrenaron durante 15,000 ciclos y tenían 14 capas de entrada, 3 intermedias y 1 de salida. Los resultados fueron analizados estadísticamente calculando el error medio (RMC = raíz cuadrada de la media de las desviaciones al cuadrado de valores pronosticados), coeficientes de determinación (r^2), pruebas *t* de Student para datos por parejas y pruebas χ^2 (Sokal y Rohlf, 1995).

RESULTADOS

Las RNAs funcionaron satisfactoriamente en las dos diferentes escalas de tiempo probadas. En lo sucesivo nos referiremos a los datos usados en los modelos como valores reales, mientras que a los valores calculados por las redes después del entrenamiento les llamamos predicciones y a los calculados durante la fase de prueba, pronósticos.

Modelos para temperatura

Los resultados del modelo (a), para diagnóstico, se muestran en la fig. 2. La red funcionó mejor en el entrenamiento ($r^2 = 0.89$, RMC = 0.54, $N = 150$) que durante la prueba ($r^2 = 0.85$, RMC = 0.77, $N = 32$), aunque los r^2 no difirieron significativamente ($1.0 < P < 0.5$, prueba χ^2). Posteriormente, se utilizó la red entrenada para pronosticar los datos faltantes en la serie de TB. La bondad de los datos pronosticados se puede apreciar observando cómo en la fig. 2 los puntos siguen de cerca la tendencia indicada por la línea continua que conecta los valores reales.

was used in all instances. Networks for the forecasting of temperature were trained during 10,000 cycles and had 12 input and 3 intermediate layers and 1 output layer; those for biomass were trained during 15,000 cycles, and the number of input, intermediate and output layers were 14, 3 and 1, respectively. Resulting data were analyzed statistically to determine goodness of fit for predictions by means of root mean square (RMS = square root of average deviations of predicted values), coefficients of determination (r^2), paired *t*-tests and χ^2 tests (Sokal and Rohlf, 1995).

RESULTS

The networks constructed showed good forecasting performance for the two time scales tested. We henceforth refer to real data used in the models as actual values, whereas those that were returned by the networks after training are called predicted values. Values computed by networks during testing are called forecasted values.

Models for temperature

Results of model (a), the diagnostic model, are shown in fig. 2. The network performed better during training ($r^2 = 0.89$, RMS = 0.54, $N = 150$) than during testing ($r^2 = 0.85$, RMS = 0.77, $N = 32$), although the corresponding coefficients of determination were not significantly different ($1.0 < P < 0.5$, χ^2 test). After the training and testing we used the network to fill in gaps of the whole series of BT. Goodness of fit for the forecasted values can be observed in fig. 2, where the dots follow closely the trend indicated by the solid line connecting the actual values.

The forecasting performance of the networks deteriorated as the lag into the future increased when testing models (b) and (c) (table 1). The RMS values increased and r^2 decreased when the lag increased from zero, to one and two months into the future, although paired *t*-tests comparing actual and forecasted values did not indicate significant differences in any case (table 1). During the sensitivity analysis, the ANNs yielded reasonably good

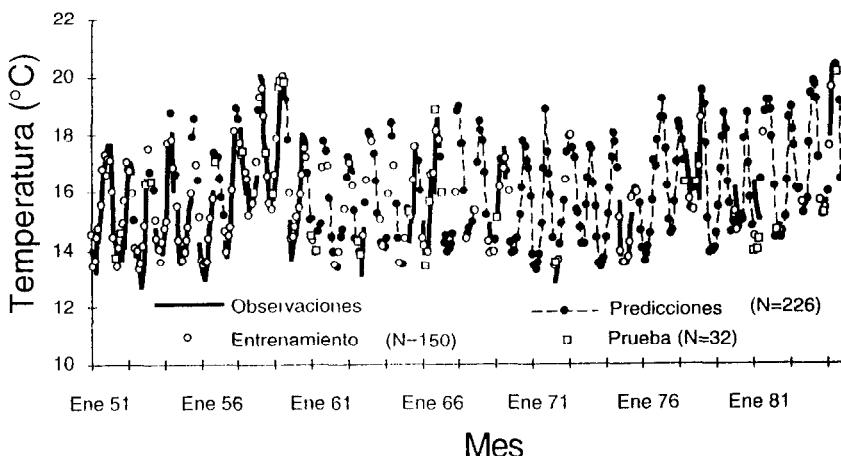


Figura 2. Resultados del modelo de neuronas artificiales para la predicción de la temperatura promedio mensual a 10 m de profundidad en las áreas 7 y 11 de la red de muestreo CalCOFI (TB), con base en el registro de la temperatura del muelle de Scripps (TIOS). La línea continua indica los meses en que existen datos; los círculos indican el ajuste de la red después de la fase de entrenamiento; los cuadros indican los valores pronosticados, esto es, los valores calculados por la red con base en una serie de la variable independiente que no le había sido presentada. Los puntos indican predicciones de TB, con base en la TIOS, durante los meses en que no hubo crucero de muestreo.

Figure 2. Results of artificial neural network modelling using Scripps pier time series of mean monthly sea temperature (SIOT) to predict 10-m sea temperature in CalCOFI areas 7 and 11 (BT) based on surveys. The continuous line indicates months when actual data were available; open circles indicate fit of the network after training; open squares indicate forecasted values, i.e., values computed by the network based on a set of the independent variable not previously presented to the network. Dots indicate predicted BT values, based on SIOT data, for months where survey data were not available.

Tabla 1. Modelos de redes de neuronas artificiales para la diagnosis y prognosis de la temperatura mensual en las áreas 7 y 11 de la red de muestreo CalCOFI, con base en registros de la temperatura en el muelle Scripps. Consultar el texto para la explicación de los modelos (a), (b) y (c). N = pares de datos comparados; r^2 = coeficiente de determinación entre datos reales y predicciones; RMC = raíz cuadrada de la media de las desviaciones al cuadrado de valores pronosticados; t = estadístico para la comparación de parejas de datos observados y pronosticados; NS = no significativo al nivel $\alpha = 5\%$.

Table 1. Artificial neural network models for the diagnosis and forecasting of monthly 10-m temperature in areas 7 and 11 of the CalCOFI survey grid, based on Scripps pier temperature records. Refer to text for explanation of models (a), (b) and (c). N = number of pairs of data compared; r^2 = coefficient of determination between actual and predicted data; RMC = mean square root of forecasted values; t = computed statistics for paired t -test comparison of actual and forecasted values; NS = not significant at the $\alpha = 5\%$ level.

Modelo	N	r^2	RMC	t
(a)	32	0.85	0.54	-0.77 (NS)
(b)	32	0.73	0.64	-1.24 (NS)
(c)	31	0.65	0.99	-1.94 (NS)

En los modelos (b) y (c) la calidad de los pronósticos deterioró a medida que se incrementó el horizonte de pronóstico. Los valores de RMC aumentaron y los de r^2 disminuyeron cuando el pronóstico se varió de cero a uno y dos meses en el futuro, aunque los datos pronosticados no difirieron significativamente de los datos reales (tabla 1). Durante el análisis de sensibilidad, las RNAs produjeron buenos pronósticos de BT usando datos de TIOS. En desfasamientos sucesivos de dos meses hasta nueve años no se observó tendencia alguna en los valores de r^2 (intervalo: 0.59 a 0.74) o RMC (intervalo: 0.92 a 1.55). Los 26 datos de temperatura pronosticados por cada una de las redes no difirieron significativamente de los valores reales, aun con un desfasamiento de nueve años (fig. 3).

Pronóstico de biomasa desovante de sardina

La red construida para el pronóstico de biomasa funcionó bien y, aunque pudo reproducir la tendencia general, mostró algunos problemas para los años 1962, 1970, 1985 y 1987 (fig. 4). La correlación entre datos reales y predicciones ($r^2 = 0.99, N = 30$) fue significativamente mayor ($P < 0.001$) que entre datos reales y pronosticados ($r^2 = 0.87, N = 9$), lo cual indica que la red funcionó mejor durante el entrenamiento que durante la fase de prueba. Pese a que el diferente tamaño de muestra pudiera haber afectado los resultados, ni las predicciones (estadístico $t = -0.63, 0.4 < P < 0.5$) ni los pronósticos (estadístico $t = 0.26, 0.3 < P < 0.4$) difirieron en forma significativa de los valores reales correspondientes.

DISCUSIÓN

Nuestros resultados indican el potencial de las RNAs para el pronóstico de biomasa de peces pelágicos menores y de su ambiente en zonas de afloramiento. Se pudo confirmar cómo la temperatura registrada en el muelle de Scripps es un buen índice de la temperatura en las regiones 7 y 11 de CalCOFI con resolución mensual. Las redes encontraron y aprendieron relaciones entre los datos aun con desfasamiento hasta de nueve años, lo cual tal vez se debe a

forecasts of BT using SIOT data. For a lag greater than two months and up to nine years no trend was observed, either in r^2 (range: 0.59 to 0.74) or RMS (range: 0.92 to 1.55). The 26 BT values forecasted by the networks were not significantly different to real values even at a lag of nine years (fig. 3).

Forecast of sardine spawning biomass

The network performed well for forecasting sardine biomass and, although it was able to forecast well the overall trend of the series, it showed some problems for 1962, 1970, 1985 and 1987 (fig. 4). Correlation between actual and predicted data ($r^2 = 0.99, N = 30$) was significantly greater ($P < 0.001$) than correlation between actual and forecasted values ($r^2 = 0.87, N = 9$), i.e., the network performed better during training than test phase. Different sample sizes might have to do with these results; nevertheless, neither predicted (t -value = $-0.63, 0.4 < P < 0.5$) nor forecasted (t -value = $0.26, 0.3 < P < 0.4$) values were significantly different than the corresponding actual values.

DISCUSSION

Our results indicate the potential of ANNs for forecasting small pelagic fishes and their environment in upwelling systems. It was confirmed that measurements taken at Scripps pier (SIOT) are useful indicators of temperature in CalCOFI areas 7 and 11 (BT) with monthly resolution. Even at a lag of nine years the networks found and learned patterns, which might be explained by the cyclic nature of both series of temperature. Although they did not differ significantly from real values, forecasted values were biased high, as can be observed in fig. 3.

The network we constructed to forecast sardine biomass performed relatively well, reflecting the trend and specific values within the series. The major problems shown for 1985 and 1987 probably reflect changes in the regime of the ecosystem (Lluch-Belda *et al.*, 1992). This also suggests that the data sets to train the networks were not long enough and/or that they did not include information from different regimes. One important aspect during

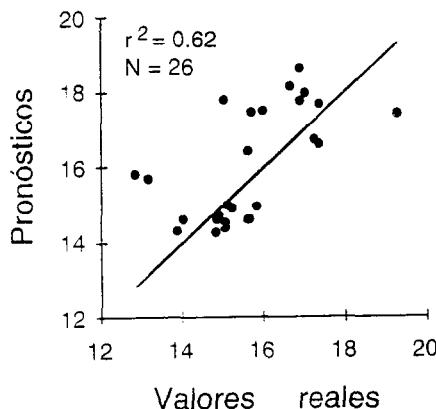


Figura 3. Temperatura superficial del mar observada en las regiones 7 y 11 de CalCOFI (TB) y pronósticos correspondientes usando una red de neuronas artificiales con base en la temperatura del mar registrada en el muelle de Scripps (TIOS). La red fue entrenada usando doce valores mensuales de TIOS como variables independientes y un valor mensual de TB nueve años después como variable dependiente. Cada dato representa un valor mensual.

Figure 3. Mean sea surface temperature observed in CalCOFI regions 7 and 11 (BT) and the corresponding forecasts by an artificial neural network using surface temperature taken at Scripps pier (SIOT). The net was trained using twelve monthly SIOT values as independent variables and one monthly BT value nine years later as the dependent variable. Each datum represents a monthly value.

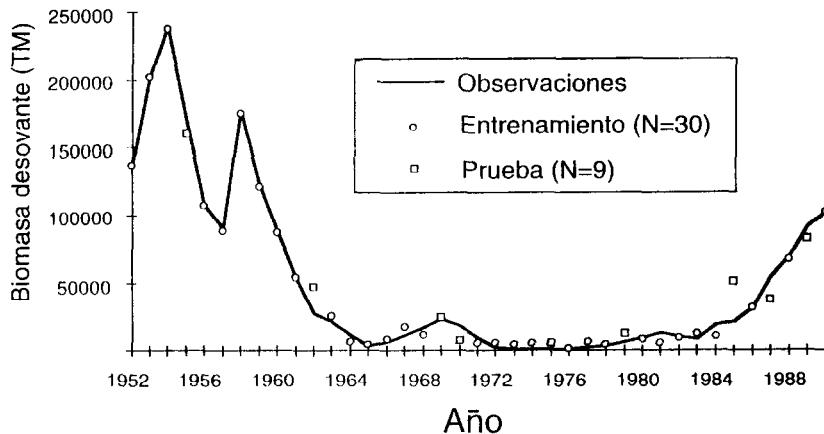


Figura 4. Ajuste y pronóstico, usando una red de neuronas artificiales, de la biomasa desovante anual de sardina del Pacífico en la Corriente de California. Los círculos indican valores de ajuste de la red a los datos reales (línea continua) y los cuadrados indican valores pronosticados.

Figure 4. Artificial neural network fit and forecast of annual spawning biomass of Pacific sardine in the California Current. Circles indicate fit of predicted values by the network to actual data (continuous line), while squares indicate forecasted values.

la naturaleza cíclica de las series de temperatura. Aunque no hubo diferencias significativas entre valores pronosticados y valores reales, se observó un sesgo positivo en los pronósticos (fig. 3).

La red diseñada para el pronóstico de biomasa de sardina funcionó relativamente bien en cuanto a la tendencia y valores específicos dentro de la serie original. Los mayores problemas observados para 1985 y 1987 probablemente reflejan un cambio en el régimen del ecosistema (Lluch-Belda *et al.*, 1992). Esto también sugiere que la longitud de las series no fue suficiente y/o que éstas no incluían suficiente información sobre regímenes diferentes. Un aspecto importante en el uso de RNAs es la longitud de las series, pues el aprendizaje durante el entrenamiento dependerá de la cantidad de ejemplos, o repeticiones del problema, presentados a la red. Debido a lo reducido de la serie en nuestro último ejemplo, en varios intentos preliminares con varias otras series de datos se obtuvieron redes sobreentrenadas con un ajuste excelente durante el entrenamiento pero pronósticos totalmente erróneos durante la prueba. Dado lo corto de la serie de biomasa, se optó por una red con el menor número posible de variables independientes.

Las RNAs comienzan a ser usadas en estudios sobre ecología, aunque algunos investigadores las consideran como "cajas negras" (ver discusión en Tan y Smeins, 1996). Debido al poco control que se tiene sobre los cálculos efectuados por las redes, realmente no se puede deducir qué mecanismos gobiernan los fenómenos investigados. Quizás las RNAs deban ser consideradas herramientas más para el ordenamiento que para la investigación científica. Sin embargo, su funcionamiento siempre dependerá de las decisiones tomadas por los usuarios. Para diseñar las redes se requiere conocer el sistema investigado para hacer supuestos implícitos o explícitamente incluir parámetros dependiendo de la estructura y tipo de datos de que se disponga.

Para el uso eficiente de RNAs se requiere combinar cuidadosamente más de una técnica de investigación. Un procedimiento útil es realizar un análisis preliminar de las series de datos mediante técnicas estadísticas comunes,

ANN modelling is the length of available time series, because learning during the training phase depends on the number of examples, or repetitions of the problem, presented to the network. Due to the shortness of the series in our final example, special care had to be taken to avoid over-training of preliminary networks using other data series. For example, in some instances we obtained a perfect fit of the network to actual values, while forecasted values during the test were completely wrong.

ANNs are starting to be used in ecological research, although some scientists still consider them as "black boxes" (see discussion in Tan and Smeins, 1996). Because one has limited control over the computations carried out by the networks, understanding of the mechanisms driving the phenomena under investigation is also limited. Strictly speaking, ANNs might be considered useful tools for management rather than scientific purposes, although performance of a specific network will depend upon decisions made by the users. Network design requires knowledge of the system under investigation to make implicit assumptions or explicit inclusion of parameters depending on the structure and nature of data available.

Efficient use of ANNs requires a careful combination of research approaches. An exploratory data analysis of time series by means of standard statistical techniques, testing sets of alternative hypotheses might prove useful. For example, when we included small zooplankton volume in a model in various ways, performance of the networks was always poor. While including zooplankton in the models we were testing the importance of food for adults and/or predation on early life stages of sardine. After several trials we discarded zooplankton abundance in our final network. We caution that this by no means implies dismissing zooplankton volume as an important factor driving future adult biomass of Pacific sardine; this result was probably due to the structure of the data series we used.

A different research approach would be to include all pertinent data series available and analyze the weighted values between connections in the trained network to infer which are the relevant parameters. Using this approach,

probando conjuntos de hipótesis alternativas. Por ejemplo, aunque en modelos preliminares se incluyó el volumen de zooplancton, las redes funcionaron mal. Al hacerlo se estaba probando la importancia de alimento para los adultos y/o de depredación para huevos y larvas de sardina como factores que determinan el tamaño de la biomasa futura. Después de varios intentos se descartó el volumen de zooplancton en nuestro modelo final. Esto no significa que la abundancia de zooplancton no es un factor ecológico importante para la sardina; más bien pudiera obedecer a la estructura de las series de datos utilizados.

Un enfoque diferente es incluir en las RNAs todos los datos potencialmente importantes de que se disponga e inferir *a posteriori* cuáles son los más relevantes, analizando los valores ponderados entre las conexiones de la red entrinada. De esta manera, Komatsu *et al.* (1994) concluyeron que el flujo y otras particularidades de la Corriente de Kuroshio son importantes para pronosticar la captura comercial de larvas de sardina japonesa.

Una limitante de las redes neuronales de la forma en que las utilizamos aquí es que no estimamos intervalos de confianza para los pronósticos. Aunque esto rebasaba nuestros objetivos, es posible hacerlo mediante métodos de remuestreo, como *bootstrap*. Por otro lado, la generalización de RNAs en la investigación ecológica y pesquera implica la comparación de resultados con los obtenidos usando técnicas comunes. Por ejemplo, Brey *et al.* (en prensa) compararon los pronósticos de la relación producción/biomasa usando RNAs y regresión múltiple. M.A. Cisneros-Mata, T. Brey y A. Jarre-Teichmann (sometido) usaron *bootstrap* para construir intervalos de confianza para pronósticos de biomasa de sardina y compararon resultados usando RNAs y regresiones.

Las RNAs serán herramientas útiles para la investigación pesquera en la medida en que se tomen en cuenta sus limitaciones y si se consideran aspectos fundamentales del sistema investigado. Por ejemplo, si una red produce pronósticos precisos de biomasa, disponibilidad o captura, se requiere aun de otra clase de datos, como el objetivo de la regulación (biológico, económico o social) y estructura de edad o

Komatsu *et al.* (1994) concluyeron que tipos de trayectorias y otras características de la Corriente de Kuroshio afectaron las predicciones de la captura comercial de larvas de sardina japonesa.

A caveat in ANN modelling as used here is the fact that we did not compute confidence intervals for forecasted values. Although this was beyond the objective of this work, it can be done by means of computer-intensive methods, such as bootstrapping. Also, extensive use of ANNs in ecology and fisheries science will require comparison of results with those using traditional techniques. For example, Brey *et al.* (in press) compared forecasts of production/biomass ratios using ANNs and multiple linear regression. M.A. Cisneros-Mata, T. Brey and A. Jarre-Teichmann (submitted) used bootstrapping to construct confidence intervals to predictions of Pacific sardine biomass using ANNs and compared results to those using regression models.

ANNs will be useful tools in fisheries research only if one keeps in mind their limitations as well as basic aspects of the system under investigation. For example, if a network yields accurate forecasts of biomass, availability or catch, other information such as the management goal (biological, economic or social), plus the age or size structure of the stock will still be required to implement regulatory measures.

A thorough comprehension of the mechanisms driving the dynamic behavior of small pelagic fish stocks is important for their adequate regulation. However, this poses complex problems while, for economic and ecological reasons, time is a limiting factor. Careful use of ANNs in forecasting biomass or availability is then a promising research tool for the management of these resources.

ACKNOWLEDGEMENTS

We are indebted to Paul Smith, Larry Jacobson and Gregory Hammann for providing data and useful comments, and to Lawrence Etim and two anonymous reviewers for constructive criticism. This work is dedicated to Enrique C.M. and to Ignacio del Valle. Alfred Wegener Institute publication No. 1114.

tallas de la población, para poner en práctica medidas de regulación.

Para lograr una administración adecuada es necesario conocer bien los mecanismos que determinan la dinámica de las poblaciones de pelágicos menores. Sin embargo, esto plantea problemas complejos y por razones económicas y ecológicas el tiempo es un factor limitante. Ante esta situación, el uso cuidadoso de RNAs en el pronóstico promete ser una alternativa viable para la administración de estos recursos.

AGRADECIMIENTOS

Agradecemos a Paul Smith, Larry Jacobson y Gregory Hammann el haber proporcionado las series de datos y atinadas observaciones, y a Lawrence Etim y dos revisores anónimos sus comentarios. Dedicado a la memoria de Enrique C.M. y de Ignacio del Valle L. Ésta es la publicación No. 1114 del Instituto Alfred Wegener.

REFERENCIAS

- Anonymous (1995). Review of some California fisheries for 1994. CalCOFI Rep., 36: 7-18.
- Azoff, E.M. (1994). Neural Network Time Series Forecasting of Financial Markets. John Wiley and Sons, New York, 196 pp.
- Bevetton, R.J.H. (1983). Science and decision-making in fisheries regulations. FAO Fish. Rep., 291(3): 919-936.
- Brey, T., Jarre-Teichmann, A. and Borlich, O. Artificial neural network versus multiple linear regression: predicting P/B ratios from empirical data. Mar. Ecol. Prog. Ser. (in press).
- Dayhoff, J.E. (1990). Neural Network Architectures. An Introduction. Van Nostrand Reinhold, New York, 259 pp.
- Deriso, R., Quinn, T.J. and Neal, P.R. (1985). Catch-at-age analysis with auxiliary information. Canadian J. Fish. Aquat. Sci., 42: 815-824.
- Hammann, M.G., Palleiro-Nayar, J.S. and Sosa-Nishizaki, O. (1995). The effects of the 1992 El Niño on the fisheries of Baja California, Mexico. CalCOFI Rep., 36: 127-133.
- Hunter, J.R. and Alheit, J. (eds.) (1995). International GLOBEC Small Pelagic Fishes and Climate Change Program. Report of the First Planning Meeting, La Paz, Mexico, June 20-24, 1994. GLOBEC Rep. No. 8, 72 pp.
- Jacobson, L.D. and MacCall, A.D. (1995). Stock-recruitment models for Pacific sardine (*Sardinops sagax*). Canadian J. Fish. Aquat. Sci., 52: 566-577.
- Jacobson, L.D., Lo, N.C.H. and Barnes, J.T. (1994). A biomass-based model for northern anchovy, *Engraulis mordax*. Fish. Bull., 92: 711-724.
- Jarre-Teichmann, A., Brey, T. and Haltof, H. (1995). Exploring the use of neural networks for biomass forecasts in the Peruvian upwelling ecosystem. NAGA, The ICLARM Quarterly, October 1995, pp. 38-40.
- Komatsu, T., Aoki, I., Mitani, I. and Ishii, T. (1994). Prediction of the catch of Japanese sardine larvae in Sagami Bay using a neural network. Fish. Sci., 60(4): 385-391.
- Kramer, D., Kalin, M.J., Stevens, E.G., Thrailkill, J.R. and Zweifel, J. (1972). Collecting and processing data on fish eggs and larvae in the California Current region. NOAA Tech. Rep., NMFS Circ. 370, 38 pp.
- Lluch-Belda, D., Crawford, R.J.M., Kawasaki, T., MacCall, A.D., Parrish, R.H., Schwartzlose, R.A. and Smith, P.E. (1989). Worldwide fluctuations of sardine and anchovy stocks: the regime problem. South African J. Mar. Sci., 8: 195-205.
- Lluch-Belda, D., Lluch-Cota, D., Hernández-Vázquez, S. and Salinas-Zavala, C.A. (1992). Sardine population expansion in eastern boundary systems of the Pacific Ocean as related to sea surface temperature. South African J. Mar. Sci., 12: 147-155.
- MacCall, A.D. (1979). Population estimates for the waning years of the Pacific sardine fishery. CalCOFI Rep., 20: 72-82.
- Methot, R.D. (1989). Synthetic estimates of historical abundance and mortality for northern anchovy. Am. Fish. Soc. Symp., 6: 66-82.

English translation by the authors.

- Moser, H.G., Charter, R.L., Smith, P.E., Ambrose, D.A., Charter, S.R., Meyer, C.A., Sandknop, E.M. and Watson, W. (1993). CalCOFI Atlas No. 31, 233 pp.
- Murphy, G.I. (1966). Population biology of the Pacific sardine (*Sardinops caerulea*). Proc. Calif. Acad. Sci., 34(1): 1-84.
- Saila, S. A guide to some computerized artificial intelligence methods. In: B. Negrey and E. Mokness (eds.), Computers in Fisheries Research. Chapman and Hall, London (in press).
- Smith, P.E. (1995). A warm decade in the Southern California Bight. CalCOFI Rep., 36: 120-126.
- Sokal, R.R. and Rohlf, F.J. (1995). Biometry. 3rd edition. W.H. Freeman and Co., New York, 887 pp.
- Tan, S.S. and Smeins, F.E. (1996). Predicting grassland community changes with an artificial neural network model. Ecological Modelling, 84: 91-97.
- Trippi, R.R. and Turban, E. (eds.) (1993). Neural Networks in Finance and Investing. Probus Publishing Co., Chicago, 513 pp.