

Research Article

Discriminación de variables ambientales que influyen la captura por unidad de esfuerzo: el caso de la pesquería de krill antártico

Juan Carlos Quiroz¹, Rodrigo Wiff¹, Mauricio A. Barrientos² & Francisco Contreras¹

¹División de Investigación Pesquera, Instituto de Fomento Pesquero, P.O. Box 8-V
Valparaíso, Chile

²Instituto de Matemáticas, Pontificia Universidad Católica de Valparaíso, Blanco Viel 596
Cerro Barón, Valparaíso, Chile

RESUMEN. Para emplear la captura por unidad de esfuerzo (CPUE) como índice de abundancia se debe realizar normalmente un proceso de estandarización que consiste en aislar desde las series de tiempo de CPUE todos aquellos efectos exógenos a las variaciones temporales de la abundancia. Dentro del conjunto de efectos exógenos, como aquellos generados por modificaciones en la eficiencia de las embarcaciones pesqueras, variaciones en las estrategias de pesca y variaciones ambientales, la elección de estos últimos ha sido considerada una de las etapas más difícil, arbitraria y menos documentada, debido a que los efectos ambientales varían en diferentes escalas temporales de forma autocorrelacionada y no aleatoria, influenciando a la CPUE por medio de un proceso causa-efecto. Los modelos de función de transferencia (MFT) fueron construidos para describir estadísticamente la relación causa-efecto entre dos series de tiempo y se proponen en este artículo como una herramienta válida para i) discriminar efectos ambientales que influyen la CPUE y ii) describir la forma en que estos efectos deben ser incluidos en un modelo lineal generalizado (MLG). Se analizó la CPUE de krill antártico para el período agosto 1989-julio 1999, y como posibles efectos causales el Índice de Oscilación Antártico (IOA) y las Presiones Atmosféricas al Nivel del Mar (PANM). El MFT muestra que las PANM bajo un desfase anual (PANM₁₂), influyen la CPUE de krill antártico; mientras que la IOA no tiene un efecto significativo. La utilización de la PANM₁₂ en un MLG incrementó en 31% la explicación de la devianza respecto a la serie sin desfase. Se concluye que los MFT son herramientas promisorias para incluir efectos ambientales en la estandarización de la CPUE resultando en índices de abundancia menos sesgados y más precisos.

Palabras clave: CPUE, causa-efecto, estandarización, índices de abundancia, *Euphausia superba*, Océano Austral.

Discrimination of environmental variables that influence the catch per unit effort: the case of the Antarctic krill fishery

ABSTRACT. The use of the catch per unit effort (CPUE) as an index of abundance usually requires a standardization process consisting of isolating all those exogenous factors from temporal variations in abundance from the CPUE time-series. These exogenous factors include those generated by modifications in fishery vessel efficiency, variations in fishing strategies, and environmental fluctuations. The selection of the latter has been considered to be one of the most difficult, arbitrary, and poorly documented stages since the environmental effects vary on different temporal scales in autocorrelated and non-random manners, influencing the CPUE through a cause-effect process. Transfer function models (TFM) were constructed to describe statistically the cause-effect relationship between two time-series and herein we propose that TFM are a valid tool for: i) discriminating environmental effects that influence the CPUE and ii) describing how these effects should be included in a generalized lineal model (GLM). We analyzed the Antarctic krill CPUE from August 1989 to July 1999, and as possible causal effects, the Antarctic Oscillation Index (AOI) and atmospheric pressure at sea level (APSL). TFM shows that the APSL, with an annual lag (APSL₁₂), influences the CPUE of Antarctic krill, whereas the AOI did not have a significant effect. The use of APSL₁₂ in the GLM increased the explanation of the deviance by 31% as compared with the APSL with no lag. We concluded that TFM constitute a promising tool for including environmental effects in the standardization of the CPUE that would result in less biased and more accurate indexes of abundance.

Keywords: CPUE, cause-effect, standardization, abundance index, *Euphausia superba*, Southern Ocean.

Corresponding author: Juan Carlos Quiroz (jquroz@ifop.cl)

INTRODUCCIÓN

En pesquerías donde no se realizan cruceros orientados a estimar abundancia, la captura por unidad de esfuerzo (CPUE) estandarizada es empleada frecuentemente como índice relativo de los cambios temporales en la abundancia. El objetivo del proceso de estandarización es aislar desde las series de tiempo de CPUE todos aquellos efectos exógenos a las variaciones naturales de la abundancia, como aquellos generados por modificaciones en la eficiencia de las embarcaciones pesqueras (Quiroz *et al.*, 2005), variaciones en las estrategias de pesca (Wiff *et al.*, 2008) y variaciones ambientales (Hinton & Nakano, 1996; Maunder & Punt, 2004). Sin embargo, una de las etapas más dificultosas, arbitraria y menos documentada es la elección de estos efectos exógenos, seleccionados muchas veces en base a juicio experto o a la disponibilidad de información.

En el caso de variables ambientales es conocido que la calidad y cantidad de información es una limitante para la implementación de modelos robustos de estandarización (Bigelow *et al.*, 2002), sin embargo, el juicio experto podría ser cuestionado debido a la forma en como los criterios de selección de variables son definidos, analizados e incorporados en el proceso de estandarización, sin obviar la calidad de la opinión experta en si misma. Por ejemplo, es conocido que las variables ambientales influyen la CPUE por medio de un proceso causa-efecto que comúnmente ocurre bajo diferentes desfases temporales y escalas espaciales (Hinton & Nakano, 1996), por tanto, los criterios empleados por el juicio experto para la incorporación de variables ambientales en el proceso de estandarización podrían estar sesgados si previamente no se cuenta con argumentos estadísticos suficientes para su discriminación. Así mismo, es frecuente que un conjunto de series ambientales (e.g. temperatura y extensión de la capa hielo) muestren altas correlaciones (Mueter *et al.*, 2002), y por tanto, la decisión de cuales series ambientales deben ser incluidas en el modelo de estandarización no sólo debe ser justificada en términos de juicio experto, también deben obedecer a principios estadísticos detrás de la selección de modelos. En efecto, la construcción de índices de abundancia basados en la CPUE comúnmente se realiza mediante modelos lineales generalizados de la forma $E(Y) = \eta = X\beta$ donde el valor esperado $E(Y)$

corresponde a la CPUE predicha y $X\beta$ al predictor lineal que incorpora diferentes factores exógenos, entre ellos los factores temporales empleados para construir los índices de abundancia (Campbell, 2004). En el caso de variables ambientales, el predictor lineal puede ser extendido hasta p variables ambientales de la forma $\eta = \sum_{i=1}^p \beta_i X_{ni}$, sin embargo, la parsimonia del modelo puede verse seriamente perjudicada si estos nuevos predictores no contribuyen a maximizar la verosimilitud del modelo.

En este artículo se propone la aplicación de modelos de series de tiempo para explorar la influencia de variables ambientales sobre la CPUE de krill antártico, proporcionando un criterio estadístico para discriminar variables que pueden contribuir como predictores de un modelo de estandarización. A modo de caso de estudio se implementó un modelo ARIMAX (Auto-Regressive Integrated Moving Average with Exogenous Input) en su versión bivariada (Chatfield, 2000), conocido como Modelo de Función de Transferencia (MFT), para describir la relación causa-efecto entre i) el Índice de Oscilación Antártico (IOA) y ii) las Presiones Atmosféricas a Nivel del Mar (PANM) locales y la serie de CPUE del krill antártico *Euphausia superba* en la región circumpolar antártica. La dinámica poblacional de krill es influenciada por la variabilidad interanual de procesos ambientales característicos del ecosistema marino antártico, como es la extensión y duración de la cubierta de hielo durante los meses de invierno (Siegel & Loeb, 1995), la reducción de ozono e intensidad de los vientos del oeste (Naganobu *et al.*, 1999) y las rutas de transporte de larvas (Hofmann *et al.*, 1998; Lascara *et al.*, 1999). Sin embargo, aún no se ha examinado, hasta donde se conoce, cómo las oscilaciones atmosféricas de gran escala semejantes al IOA y las PANM locales, influyen la variabilidad temporal de dicha CPUE.

MATERIALES Y MÉTODOS

Series de tiempo

Utilizando un MFT se exploró la influencia de la IOA y las PANM sobre el promedio mensual de la CPUE (toneladas/horas de arrastre) de krill para el período agosto 1989-julio 1999, obtenida desde las operaciones de pesca comercial realizadas en las subáreas estadísticas 48.1, 48.2 y 48.3 (Figs. 1 y 2a) de la




Figura 1. Mapa de las áreas estadísticas 48.1, 48.2 y 48.3 de la Comisión para la Conservación de los Recursos Vivos Marinos Antárticos (CCRVMA) en el océano Austral.

Figure 1. Map of the 48.1, 48.2 and 48.3 of the Commission for the Conservation of Antarctic Marine Living Resources (CCAMLR) statistics areas in the Southern Ocean.




Figura 2. Series temporales de la CPUE de krill antártico, IOA y PANM en las áreas estadísticas 48.1, 48.2 y 48.3 de la CCRVMA.

Figure 2. CPUE of Antarctic krill, IOA and PANM time series in the 48.1, 48.2 and 48.3 CCAMLR statistics areas.

Convención para la Conservación de los Recursos Vivos Marinos Antárticos (CCRVMA). El IOA (Fig. 2b) cuantifica el promedio de la diferencia de presiones a nivel del mar entre los 40° y 65°S normalizado para toda la zona circumpolar (Gong & Wang, 1998), proporcionando un índice para describir la oscilación atmosférica denominada Oscilación Antártica (OA). Puesto que Gong & Wang (1999) describen la OA como un proceso atmosférico a macroescala que envuelve regiones mayores que el área estadística 48, es posible que las diferencias de escala entre el área cubierta por el IOA y la CPUE encubran la relación causa-efecto entre éstas. Para soslayar esta diferencia de escala y explorar la influencia de nodos locales de variabilidad ambiental sobre la CPUE de krill, se utilizaron las PANM obtenidas desde el re-análisis NCEP/NCAR (Kalnay *et al.*, 1996) para las subáreas estadísticas 48.1, 48.2 y 48.3 (Fig. 2c), como un indicador de las variaciones ambientales locales. Cabe señalar que el área estadística 48 corresponde al sector de mayor captura de krill antártico (Siegel *et al.*, 1998; Kawaguchi & Nicol, 2007).

Descripción y aplicación del MFT

Teóricamente un MFT describe la relación causa-efecto entre una variable predictora independiente y una variable $\delta_r(B) = (1 - \delta_1 B - \dots - \delta_r B)$ respuesta dependiente, asumiendo que la variable independiente (IOA, PANM) tiene un efecto en la variable dependiente (CPUE) sobre un número finito de retardos temporales. El MFT fue planteado a través de polinomios de bajo orden para generar un proceso lineal parsimonioso, en el cual la serie de tiempo dependiente CPUE (y_t) es influenciada por las series de tiempo independientes IOA y PANM (x_t) en la forma,

$$y_t = \frac{\omega_s(B)}{\delta_r(B)} x_{t-d} + \frac{\theta_q(B)}{\phi_p(B)} z_t \quad (1)$$

donde $\omega_s(B) = (\omega_0 + \omega_1 B + \dots + \omega_s B)$ y $\delta_r(B) = (1 - \delta_1 B - \dots - \delta_r B)$ son polinomios de orden s y r respectivamente, d representa el retardo de la influencia de las series ambientales (serie independiente) sobre la CPUE (serie dependiente), B es el operador de retardo definido como, $B^i x_t = x_{t-i}$ mientras que $\phi_p(B)$ y $\theta_q(B)$ son los polinomios autorregresivo y de media móvil de un modelo ARMA de orden p y q con error de modelo z_t (Box & Jenkins, 1976).

La estimación de los parámetros que describen el MFT (ecuación 1) requiere efectuar a lo menos tres pasos. El primero es verificar que las series de tiempo incluidas en el modelo cumplan con la condición de

estacionariedad e invertibilidad, restricción indispensable en procesos estocásticos lineales. El segundo paso engloba la identificación: i) del retardo temporal de tamaño d entre las series ambientales y la CPUE, ii) el orden preliminar de los polinomios ω y δ asociados con las series independientes, iii) el orden de los polinomios θ y ϕ referidos al modelo ARIMA predictivo de la CPUE, definidos por $\{s,r\}$ y $\{q,p\}$, respectivamente. El último paso es la selección de un método de estimación, que en muchos casos corresponde a la máxima verosimilitud condicionada o exacta, o más recientemente a la estimación bayesiana. La selección final del modelo debe compensar parsimonia y bondad de ajuste, empleando para esto los criterios de información tales como Akaike y Bayesiano (Chatfield, 2000).

Identificación y estimación del MFT

Se exploraron las series temporales para verificar estacionariedad e invertibilidad, y en caso que estas condiciones estén presentes se procedió a transformar las series eliminando su tendencia y centralizando la varianza. La identificación del retardo d de la influencia de las series ambientales (AIO y PANM) sobre la CPUE, se seleccionó escogiendo el primer entero positivo k tal que $|\rho_{x,y}(k)| > 2/\sqrt{N-k}$ (Barnett & Turkman, 1993), donde $\rho_{x,y}$ corresponden a los N coeficientes de la función de correlación cruzada entre la IOA/PANM y la CPUE. Sin embargo, mientras exista autocorrelación, estas funciones son difíciles de interpretar ocasionando relaciones espurias (Tyler, 1992) y sobrestimación de la varianza en la correlación cruzada (Chatfield, 2000). Este problema se abordó preblanqueando la serie x_t en una nueva serie α_t , por medio de un proceso que descorrelaciona la variable independiente tal que

$$\phi'_r(B)x_t = \theta'_r(B)\alpha_t \quad (2)$$

donde los polinomios ϕ'_r y θ'_r corresponden respectivamente a los términos autorregresivo y media móvil de un modelo ARIMA. Los polinomios de la ecuación 2 son utilizados para transformar y preblanquear la serie dependiente y_t , a una nueva serie temporal β_t por medio de $\beta_t = \phi'_r(B) / \theta'_r(B) y_t$. Teóricamente estas nuevas series (α_t, β_t) no presentan autocorrelación y por tanto se emplearon para obtener los coeficientes de la función de correlación cruzada para los retardos $\pm k$, donde valores no significativos ($P \geq 0.05$) cumplen con la restricción $-2/\sqrt{N-k} \leq \rho_{\alpha,\beta}(k) \leq 2/\sqrt{N-k}$ (Box & Jenkins, 1976).

El orden preliminar de los polinomios en la ecuación 1 representados por los valores r, s, p y q , fueron obtenidos desde los polinomios ϕ'_r y θ'_r de la ecuación 2, como también el examen de las funciones

de autocorrelación y autocorrelación parcial de las series α_t y β_t que estructuran el modelo ARIMA identificado en el proceso de preblanqueo (Chatfield, 2000). El proceso de identificación y estimación de los modelos ARIMA consiste en analizar las funciones de autocorrelación y autocorrelación parcial, como también la utilización de estimadores máximo verosímiles cuando el orden de los polinomios autorregresivos y de media móvil han sido identificados (Koutroumanidis *et al.*, 2006).

En el proceso de estimación se utilizó máxima verosimilitud condicionada para estimar los coeficientes de los polinomios de orden r , s , p y q . Como medida de la bondad de ajuste y validación se verificó que los residuales del MFT cumplan con la condición de ruido blanco $z_t \sim N(0, \sigma^2)$ y que no exista significancia estadística entre los coeficientes de la correlación cruzada entre los residuales del MFT (ecuación 1) y los residuales del modelo ARIMA de preblanqueo (ecuación 2) (Akaike & Kitagawa, 1999). De los diferentes modelos que convergen a una estimación y pueden ser validados, la selección final se basa en el mínimo valor de los criterios de información de Akaike (AIC) y Bayesiano (SBC).

Modelamiento de la CPUE

La hipótesis de estudio indica que la utilización de un MFT posibilitará discriminar series ambientales para ser empleadas como predictores en un modelo de estandarización. A objeto de someter a prueba esta hipótesis se implementó un modelo lineal generalizado (MLG) empleando como predictores los factores discretos año y mes, así como los factores continuos IOA y PANM. De acuerdo a nuestra conjetura, las series ambientales incluidas en el MFT y que explican significativamente la variabilidad de la CPUE deberían ser candidatas para modelar la serie de CPUE por medio de un MLG, aún más cuando en el MLG es incluido el retardo de acción entre la serie climática y la CPUE (parámetro d del MFT, ecuación 1). Para explorar esto, se implementó un MLG en la forma $E(CPUE) = \mu = g^{-1}(X\beta)$, donde $E(CPUE)$ es el valor esperado de la CPUE, $X\beta$ es el predictor lineal y g es la función enlace. Aquí el predictor lineal se define como,

$$g(X\beta) = \eta = \beta_0 + \beta_1 X_{n1} + \beta_2 X_{n2} + \beta_3 (X_{n3})^3 + \beta_4 (X_{n4})^3 \quad (3)$$

donde X_{n1} : Año, X_{n2} : Mes, X_{n3} : IOA y X_{n4} : PANM son los predictores para los n meses que contiene la serie de CPUE y g es la función identidad. Los predictores climáticos fueron incorporados como funciones potencia (orden 3) a objeto de suavizar su participación en el valor esperado y ocasionar un efecto similar al que hubiese obtenido por medio de un modelo aditivo generalizado, donde comúnmente se

emplean variables continuas suavizadas por medio de funciones no-paramétricas. Al contrario de un modelo de estandarización, donde el foco es la estandarización de los poderes de pesca (por medio de la incorporación de predictores que incluyan las características de las embarcaciones) y la descripción de la variabilidad de los factores temporales bajo la ausencia de factores exógenos, en este caso de estudio la exploración de MLG se centra en los aportes de los predictores climáticos a la calidad del ajuste estadístico en la forma $-2 \sum_{i=1}^n (\log(X_i) - \log(\mu))^2$, expresión conocida de su término en inglés como devianza.

RESULTADOS

Relación entre el IOA y la CPUE de krill antártico

El IOA cumple con la condición de estacionariedad e invertibilidad, no requiriendo una transformación de la serie temporal. Durante el preblanqueo las funciones de autocorrelación y autocorrelación parcial (no mostradas aquí) indican que el modelo ARIMA(0,1,1) es adecuado para la descorrelación del IOA (Tabla 1, Mod-1), tanto por arrojar el menor valor en los criterios de información (Fig. 3a), como por presentar residuos que cumplen con la condición de ruido blanco (Fig. 3b). Este mismo modelo (Mod-1 en Tabla 1) fue utilizado para preblanquear la serie de CPUE.

El análisis de correlación cruzada entre las series preblanqueadas evidencia que existe correlación significativa para el retardo 13 (Fig. 4a), sugiriendo que la influencia mensual de la serie IOA se encuentra desfasada 13 meses sobre la CPUE mensual de krill. Utilizando este retardo ($d = 13$), se ajustó un MFT (Tabla 1, Mod-2) donde todos los parámetros (coeficientes) asociados con los polinomios de orden s , r y p fueron significativos ($P < 0.05$). Se debe señalar que para este MFT la CPUE no posee componente de media móvil ($\theta_{q=0}$). Si bien la selección del modelo se basó en la minimización de los criterios de información y el análisis de los residuales (Fig. 4b), el MFT explica reducidamente la varianza de la serie CPUE ($R^2 = 0,076$).

Relación entre la variabilidad de las PANM en las subáreas 48 y la CPUE de krill antártico

La serie PANM no presenta tendencias en su media y posee una estructura de varianza visualmente constante en el tiempo. Los valores de las funciones de autocorrelación y autocorrelación parcial (no mostrados acá) evidencian un proceso de media móvil de orden 1. Por otro lado, los gráficos de las funciones de autocorrelación de la serie diferenciada en un orden

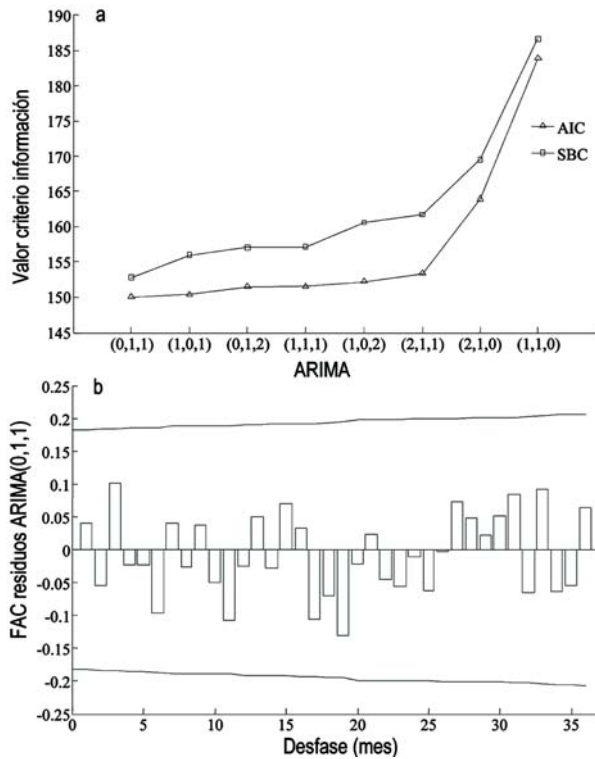


Figura 3. a) Criterios de información para diferentes modelos ARIMA ajustados a la serie IOA, b) función de autocorrelación (FAC) para los residuos del modelo ARIMA(0,1,1) utilizado para el preblanqueo de las serie IOA y CPUE.

Figure 3. a) Information criteria for fitted ARIMA models to the IOA time series, b) autocorrelation function (FAC) and residuals for the ARIMA (0,1,1) model used for the prewhitening process of the IOA and CPUE time series.

indican un proceso autorregresivo de orden 1. Por lo tanto, se ajustó un modelo ARIMA(1,0,1) (Tabla 1, Mod-3) con parámetros significativos ($P < 0.05$), seleccionado por presentar el menor valor en los criterios de información (Fig. 5a) y residuales bajo la condición de ruido blanco (Fig. 5b). El modelo ARIMA(1,0,1) es utilizado para preblanquear las serie de CPUE. El análisis de correlación cruzada entre las series preblanqueadas muestra correlaciones significativas positivas para los desfases 12, 13 y 24 meses (Fig. 6a), sugiriendo que la influencia mensual de la serie PANM actúa con un período de desfase anual sobre la disponibilidad de krill antártico en las subareas 48.1, 48.2 y 48.3. Utilizando el retardo de 12 meses entre la influencia mensual de la PANM sobre la CPUE de krill, se ajustó un MFT (Tabla 1, Mod-4) donde los residuos cumplen con la condición de ruido blanco (Fig. 6b) y supera el porcentaje de varianza

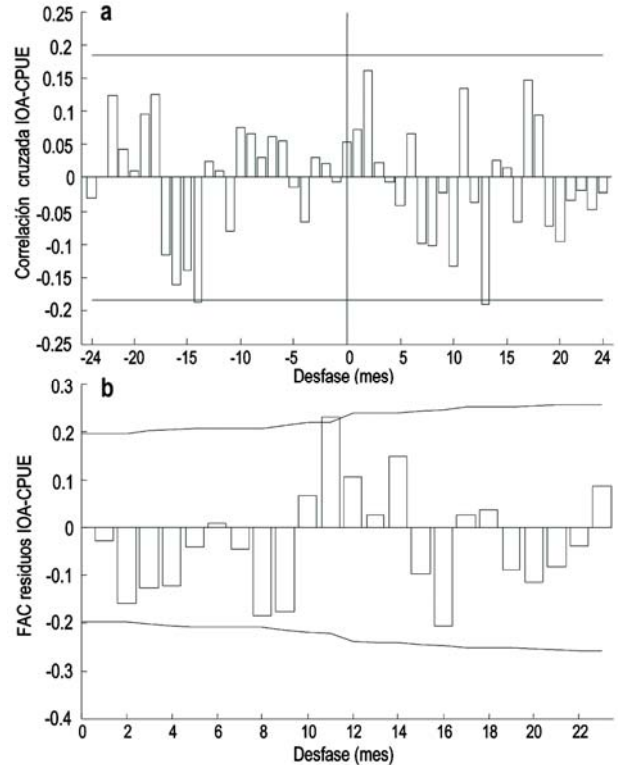


Figura 4. a) Correlación cruzada entre las serie0s IOA y CPUE preblanqueadas por el modelo ARIMA(0,1,1), b) función de autocorrelación (FAC) para los residuos del modelo de transferencia ajustado a las series CPUE e IOA.

Figure 4. a) Cross-correlation between IOA and CPUE time prewhitened by the ARIMA(0,1,1) model, b) autocorrelation function (FAC) for the residuals of the transference model fitted to the CPUE and the IOA time series.

($R^2 = 0,413$) explicado por el MFT ajustado a las series IOA y CPUE ($R^2 = 0,076$).

Modelamiento de la CPUE

La aplicación del MLG descrito en la ecuación 3 posibilita describir cambios significativos en la CPUE mensual cuando se utilizan como predictores los efectos discretos Año y Mes (Tabla 2). Los resultados indican diferencias significativas entre meses ($F = 12.41$, $P < 0.05$) y años ($F = 45.51$, $P < 0.05$), lo que puede ser confirmado al contrastar las devianzas entre el modelo que incorpora únicamente el predictor Año y el modelo Año+Mes, obteniendo una mejora predictiva del modelo en torno al 58% (Tabla 2). Si bien el diagnóstico de residuales contra los valores ajustados para el modelo Año+Mes descarta alguna tendencia de la varianza residual que indique una inadecuada especificación del modelo (Fig. 7a), como también, el gráfico de normalidad indica que un

Tabla 1. Modelos seleccionados durante el proceso de preblanqueo y ajuste de los MFT a la serie de CPUE, empleando como predictores las series IOA y PANM. Se detalla el orden de los polinomios, el mínimo valor t para los coeficientes de los polinomios con un nivel de significancia al 5% y el desfase descriptivo de los polinomios.

Table 1. Selected models during prewhitening process and TFM fitted to the CPUE using IOA and PANM time series as predictors. A detail is given on the polynomial order, minimum t value for the coefficient of the polynomials with a significance of 5% and a descriptive lags of the polynomials.

Abreviatura	Etapa	$\omega(B)$	$\delta(B)$	$\phi(B)$	$\theta(B)$	Valor t	Pr > t	Retardo
Mod-1	Preblanqueo IOA	–	–	0	1	0,03943	< 0,001	–
Mod-2	MFT IOA-CPUE	1	2	1	0	-3,26	< 0,001	12 meses
Mod-3	Preblanqueo PANM	–	–	1	1	-3,26	< 0,001	–
Mod-4	MFT PANM-CPUE	3	2	0	1	-15,09	< 0,001	12, 13 y 24 meses




Figura 5. a) Criterios de información para diferentes modelos ARIMA ajustados a la serie PANM, b) función de autocorrelación (FAC) para los residuos del modelo ARIMA(1,0,1) utilizado para el preblanqueo de las serie PANM y CPUE.

Figure 5. a) Information criteria for the different ARIMA models fitted to the PANM time series, b) autocorrelation function (FAC) for the residuals of the ARIMA (1,0,1) model fitted for the prewhitening processes of the PANM and CPUE time series.

conjunto importante de residuales proviene de una distribución normal (Fig. 7b), aún persisten valores residuales altos (por fuera del rango [-2,2]) que sugieren la incorporación de otros predictores.

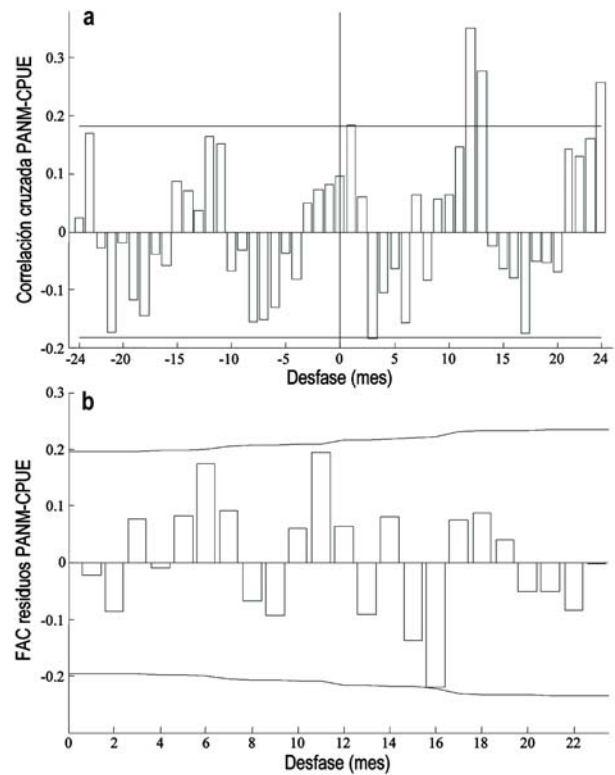


Figura 6. a) Correlación cruzada entre las series PANM y CPUE preblanqueadas por el modelo ARIMA (1,0,1), b) función de autocorrelación (FAC) para los residuos del modelo de función de transferencia ajustado a las series CPUE y PANM.

Figure 6. a) Cross-correlation between PANM and CPUE time series prewhitened by the ARIMA (1,0,1) model, b) autocorrelation function (FAC) for the residuals of the transfers function model fitted to the PANM and CPUE time series.

Cuando un tercer predictor, en este caso la serie climática PANM se incorpora al MLG (Año+Mes+PANM, Tabla 2) la devianza residual se reduce en un 16% con respecto al modelo Año+Mes,

Tabla 2. Comparación de diferentes MLG utilizados para predecir la CPUE de krill antártico empleando los predictores Año, Mes, PANM, PANM₁₂ (serie PANM desfasada 12 meses) e IOA.

Table 2. Comparison of the different GLM applied to predict CPUE of the Antarctic krill using as predictor Year, Month, PANM, PANM₁₂ (PANM time series with a lag of 12 months) and IOA.

	Gl residuales	Devianza residual	Aporte relativo en devianza	$P (> \chi^2)$
glm(Año)	109	0,03943		
glm(Año + Mes)	98	0,01648	58%	< 0,001
glm(Año + Mes + PANM)	97	0,01367	16%	< 0,001
glm(Año + Mes + PANM ₁₂)	97	0,01121	31%	< 0,001
glm(Año + Mes + PANM ₁₂ + IOA)	96	0,01121	< 0,5%	> 0,5

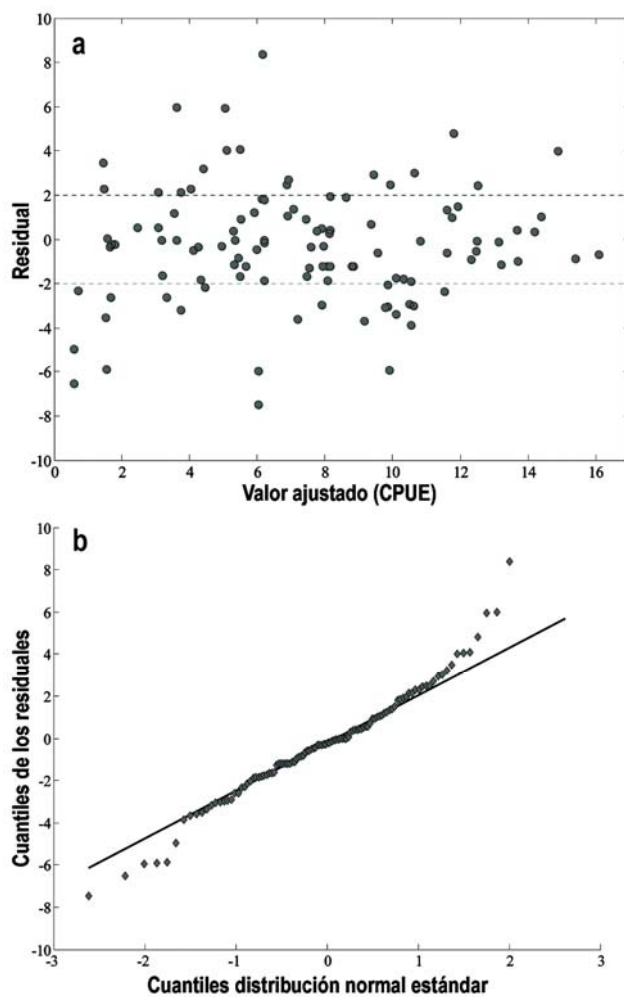


Figura 7. a) Residuos *versus* los valores ajustados, b) gráfico de normalidad para los residuales estandarizados del Modelo Lineal Generalizado que incluye los predictores año + mes.

Figure 7. a) Residuals *versus* fitted values, b) normal plot for the standardized residuals of the Generalized Linear Model including year + month as predictors.

que al ser sometido a prueba bajo una distribución χ^2 indica que el predictor PANM mejora significativamente la predicción de la CPUE de krill. Al modificar el MLG e incluir la PANM con un desfase de 12 meses (Año+Mes+PANM₁₂, Tabla 2), la devianza residual se reduce en torno al 31% mejorando aún más la capacidad predictiva del modelo. Contrario a la significancia estadística de la serie PANM, la incorporación del IOA en el MLG (Año+Mes+PANM₁₂+IOA, Tabla 2) reduce mínimamente la devianza residual y bajo una distribución χ^2 no se encuentran diferencias estadísticas con respecto al MLG que únicamente incorpora la serie PANM como predictor de la CPUE de krill antártico.

DISCUSIÓN

La elección de los efectos incorporados en un modelo de estandarización regularmente responde a la disponibilidad de datos y normalmente bajo ningún análisis previo, donde la inclusión o no en el modelo final se decide de acuerdo a la parsimonia y bondad de ajuste de los modelos candidatos. Formalmente, un análisis de estandarización de la CPUE comienza con un modelo que considera los posibles efectos exógenos que influyen las tasas de captura (modelo saturado), para luego ir descartando, en pasos sucesivos, los efectos de menor parsimonia. Sin embargo, este esquema de selección contribuye a que en muchos casos los efectos ambientales sean descartados del modelo de estandarización, por cuanto estos efectos comúnmente no presentan una causalidad instantánea con los procesos poblacionales, sino que estos tienden a propagar su efecto con algún desfase temporal (Walters, 1990).

Steele & Henderson (1984) indican que las series ambientales varían en diferentes escalas de tiempo de forma autocorrelacionada y no aleatoria. Por consi-

guiente, la estructura de los modelos comúnmente usados en la estandarización no permite el estudio de la causalidad entre los efectos ambientales y las tasas de capturas, sin conocer previamente los desfases de acción (parámetro d , ecuación 1). Así, los MFT emergen como una herramienta para el análisis previo de los efectos ambientales que influyen a la CPUE, posibilitando modelar la causa-efecto con sus efectivos desfases de acción y seleccionar cuales de éstos deberían ser incluidos en el modelo de estandarización. Aunque la incorporación de la PANM₁₂ en un MLG presenta una mayor contribución (en términos de devianza) que la serie con desfase cero PANM, el proceso de selección de los diferentes MLG candidatos aún indica que la PANM por sí misma es un adecuado predictor de la CPUE (Tabla 2). En un análisis tradicional de estandarización, esto indicaría una causalidad instantánea de la PANM sobre la CPUE. Sin embargo, esta causalidad a desfase cero fue descartada durante la fase de identificación y estimación del MFT, sugiriendo que la retención de la PANM a desfase cero en el MLG obedece más bien a una correlación espuria que a un adecuado predictor de la CPUE. Esto queda de manifiesto cuando la PANM es incorporada al MLG utilizando el desfase identificado por el MFT (PANM₁₂), al aumentar la explicación de devianza cerca del doble (de 16 a 31%, Tabla 2) con respecto a la utilización del predictor PANM. Esto demuestra que los efectos ambientales diferenciados en coherencia con el principal desfase de acción deberían ser retenidos en la selección del modelo final de estandarización, evitando que su efecto en la CPUE sea transferido al predictor temporal. Como resultado se obtiene una mejor explicación de devianza por el modelo de estandarización, en concomitancia con un índice de abundancia más preciso y menos sesgado.

Por otro lado, los MFT no sólo posibilitan la construcción de índices de abundancia más precisos, también lograrían contribuir al conocimiento biológico de las especies por medio del levantamiento de hipótesis sobre los mecanismos que influenciarían los cambios en la abundancia. En este contexto, los resultados de este trabajo demuestran la existencia de correlaciones positivas entre la variabilidad de las PANM en el sector de pesca más significativo (70°-30°W, 60°-80°S) y el promedio mensual de la CPUE nominal entre 1989 y 1999, existiendo un desfase de aproximadamente un año entre la influencia de las PANM sobre la CPUE. En base a dos procesos climáticos y oceanográficos ampliamente documentados que ocurren en la Antártica (Lascara *et al.*, 1999; Naganobu *et al.*, 1999), se postula que un alto valor de las PANM durante un invierno ocasionaría un

importante incremento en la fracción de reclutas a la pesquería al año siguiente, manifestado en altos niveles de CPUE. El primer proceso tiene relación con la variabilidad de las presiones atmosféricas a nivel del mar y su representación por medio de los vientos geostroóficos. Es conocido que la intensificación de los vientos geostroóficos sobre las aguas antárticas incrementa el transporte Ekman e induce el desplazamiento de las masas de aguas superficiales hacia el norte extendiendo la capa de hielo. Cuando se registran fuertes vientos geostroóficos, la cubierta de hielo se hace menos densa permitiendo la penetración de la luz solar y la aparición de microalgas adheridas a la capa de hielo (Lascara *et al.*, 1999). El segundo proceso es de carácter oceano-gráfico e indica que el transporte Ekman durante el verano induce la surgencia costera de aguas profundas más cálidas que las superficiales, aportando alta producción primaria y desencadenando aumentos en la biomasa fitoplanctónica (Naganobu *et al.*, 1999). Estos dos procesos favorecerían la supervivencia de larvas y juveniles de krill antártico y por consiguiente la mayor disponibilidad a las actividades pesqueras. Este mecanismo de influencia de la PANM sobre la abundancia de krill es consistente con el propuesto por Siegel & Loeb (1995), quienes utilizaron una extensa serie de reclutamientos anuales estimada por cruceros de investigación (1977-1994), para indicar que el éxito de los reclutamientos de individuos de +1 años en krill esta relacionado con las condiciones de la cubierta hielo durante la estación de invierno anterior. En definitiva, es concluyente que los análisis que contribuyen a la incorporación de variables ambientales en la modelación de poblaciones pueden ser particularmente importante en poblaciones explotadas, toda vez que estas pueden mostrar respuestas amplificadas a cambios ambientales de pequeña y mediana escala espacio-temporal (Wiff & Quiñones, 2004). Esto es aún de mayor importancia en aquellas pesquerías pelágicas y de ciclos de vida relativamente cortos, donde los reclutamientos son mayormente influenciados por factores denso-independientes (Páramo *et al.*, 2003) y donde la pesquería depende de la fuerza de la clase anual (Cubillos *et al.*, 2001).

Existen numerosos ejemplos de aplicaciones de series de tiempo en las ciencias pesqueras, destacándose las aproximaciones por medio de filtros de Kalman realizadas por Gudmundsson (1994) para describir las no-linealidades entre las tasas de mortalidad y la abundancia de stocks fuertemente explotados. Sin embargo, uno de los temas con mayor importancia ha sido el estudio de la autocorrelación en series de tiempo biológicas y ambientales, como por

ejemplo la autocorrelación en el reclutamiento como consecuencia de la denso-dependencia función de la abundancia y mortalidad (Pyper & Peterman, 1998; Fox *et al.*, 2000; Pierce & Boyle, 2003). Otra de las aplicaciones basadas en series de tiempo es el análisis de descomposición en series de tiempo pesqueras, como desembarques y CPUE (Zuur *et al.*, 2003; Zuur & Pierce, 2004; Erzini *et al.*, 2005), los que inclusive combinan modelos ARIMA y redes neuronales artificiales (Gutiérrez-Estrada *et al.*, 2007). Una de las transversalidades en todas estas metodologías es la remoción de la autocorrelación e identificación de correlación cruzada a objeto de describir los efectos causales entre series de tiempo consideradas independientes, como fue el caso de estudio en este trabajo. Sin embargo, la aplicación de metodologías de series de tiempo aun deja un amplio trecho para la investigación y mejoras en las metodologías orientadas a la construcción de indicadores de cambios de abundancia de especie explotadas.

AGRADECIMIENTOS

Los autores agradecen las facilidades prestadas por el Instituto de Fomento Pesquero para el logro de la publicación de esta investigación. Agradecemos los importantes comentarios entregados por Rodrigo Abarca del Río en la etapa inicial del manuscrito. Por último, deseamos agradecer a dos revisores anónimos cuyos comentarios y sugerencias enriquecieron el presente manuscrito.

REFERENCIAS

- Akaike, H. & G. Kitagawa. 1999. The practice of time series analysis. Springer, New York, 386 pp.
- Barnett, V. & K. Turkman. 1993. Statistics for the environment. Wiley, Chichester, 427 pp.
- Bigelow, K.A., C.H. Boggs & X. He. 2002. Environmental effects on swordfish and blue shark catch rates in the US North Pacific longline fishery. *Fish. Oceanogr.*, 8: 178-198.
- Box, G.E.P. & G.M. Jenkins. 1976. Time series analysis: forecasting and control. Holden-Day, San Francisco, 575 pp.
- Campbell, R. 2004. CPUE standardisation and the construction of indices of stock abundance in a spatially varying fishery using general linear models. *Fish. Res.*, 70: 209-227.
- Chatfield, C. 2000. Time-series forecasting. Chapman & Hall, New York, 519 pp.
- Cubillos, L.A., D.F. Arcos, D.A. Bucarey & M. Canales. 2001. Seasonal growth of small pelagic fish off Talcahuano (37°S-73°W), Chile: a consequence of their reproductive strategy to seasonal upwelling? *Aquat. Living Resour.*, 14: 115-124.
- Erzini, K., C.A.O. Inejih & K.A. Stobberup. 2005. An application of two techniques for the analysis of short, multivariate non-stationary time series of Mauritanian trawl survey data. *ICES J. Mar. Sci.*, 62: 353-359.
- Fox, C.J., B. Planque & C.D. Darby. 2000. Synchrony in the recruitment time-series of plaice (*Pleuronectes platessa L.*) around the United Kingdom and the influence of sea temperature. *J. Sea Res.*, 44: 159-168.
- Gong, D.Y. & S.W. Wang. 1998. Antarctic Oscillation: concept and applications. *Chinese Sci. Bull.*, 43: 734-738.
- Gong, D.Y. & S.W. Wang. 1999. Definition of Antarctic Oscillation index. *Geophys. Res. Lett.*, 26: 459-462.
- Gudmundsson, G. 1994. Time series analysis of catch-at-age observations. *Appl. Statist.*, 43: 117-126.
- Gutiérrez-Estrada, J.C., C. Silva, E. Yáñez, N. Rodríguez & I. Pulido-Calvo. 2007. Monthly catch forecasting of anchovy *Engraulis ringens* in the north area of Chile: non-linear univariate approach. *Fish. Res.*, 86: 188-200.
- Hinton, M.G. & H. Nakano. 1996. Standardizing catch and effort statistics using physiological, ecological, or behavioral constraints and environmental data, with an application to blue marlin (*Makaira nigricans*) catch and effort data from Japanese longline fisheries in the pacific. *Inter-Am. Trop. Tuna Comm. Bull.*, 21: 171-197.
- Hofmann, E., J. Klinck, R. Locarnini, B. Fach & E. Murphy. 1998. Krill transport in the Scotia Sea and environs. *Antarct. Sci.*, 10: 406-415.
- Kalnay, E., M. Kanamitsu, R. Kistler, W. Collins, D. Deaven, L. Gandin, M. Iredell, S. Saha, G. White, J. Woollen, Y. Zhu, M. Chelliah, W. Ebisuzaki, W. Higgins, J. Janowiak, K.C. Mo, C. Ropelewski, J. Wang, A. Leetmaa, R. Reynolds, R. Jenne & D. Joseph. 1996. The NCEP/NCAR 40-year reanalysis project. *B. Am. Meteorol. Soc.*, 77: 437-471.
- Kawaguchi, S. & S. Nicol. 2007. Learning about Antarctic krill from the fishery. *Antarct. Sci.*, 19: 219-230.
- Koutroumanidis, T., L. Iliadis & G.K. Sylaios. 2006. Time-series modeling of fishery landings using ARIMA models and Fuzzy Expected Intervals software. *Environ. Model. Softw.*, 21: 1711-1721.
- Lascara, C., E. Hofmann, R. Ross & L. Quetin. 1999. Seasonal variability in the distribution of Antarctic

- krill, *Euphausia superba*, west of the Antarctic Peninsula. Deep-Sea Res., 46: 951-984.
- Maunder, M.N. & A.E. Punt. 2004. Standardizing catch and effort data: a review of recent approaches. Fish. Res., 70: 141-159.
- Mueter, F.J., D.M. Ware & R.M. Peterman. 2002. Spatial correlation patterns in coastal environmental variables and survival rates of Pacific salmon in the Northeast Pacific Ocean. Fish. Oceanogr., 11: 205-218.
- Naganobu, M., K. Kutsuwada, Y. Sasai, S. Taguchi & V. Siegel. 1999. Relationships between Antarctic krill (*Euphausia superba*) variability and westerly fluctuations and ozone depletion in the Antarctic Peninsula area. J. Geophys. Res., 104: 651-665.
- Páramo, J., R.A. Quiñones, A. Ramírez & R. Wiff. 2003. Relationship between biomass density of small pelagic and environmental factor in the Colombian Caribbean Sea: an analysis based on hydroacoustic information. Aquat. Living. Resour., 16: 239-245.
- Pierce, G.J. & P.R. Boyle. 2003. Empirical modelling of interannual trends in abundance of squid (*Loligo forbesi*) in Scottish waters. Fish. Res., 59: 305-326.
- Pyper, B.J. & R.M. Peterman. 1998. Comparison of methods to account for autocorrelation in correlation analysis of fish data. Can. J. Fish. Aquat. Sci., 55: 2127-2140.
- Quiroz, J.C., R. Wiff & C. Montenegro 2005. Factores que afectan las tasas de captura de langostino amarillo (*Cervimunida johni*) en la zona norte de Chile. Invest. Mar., Valparaíso, 33: 43-55.
- Siegel, V. & V. Loeb. 1995. Recruitment of Antarctic krill *Euphausia superba* and possible causes for its variability. Mar. Ecol. Prog. Ser., 123: 45-56.
- Siegel, V., V. Loeb & J. Gröger. 1998. Krill (*Euphausia superba*) density, proportional and absolute recruitment and biomasa in the Elephant Island region (Antarctic Peninsula) during the period 1977 to 1997. Polar Biol., 19: 393-398.
- Steele, J.H. & E.W. Henderson. 1984. Modeling long-term fluctuations in fish stocks. Science, 224: 985-987.
- Tyler, A.V. 1992. A context for recruitment correlations: why marine fisheries biologists should still look for them. Fish. Oceanogr., 1: 97-107.
- Walters, C.J. 1990. A partial bias correction factor for stock-recruitment parameters in the presence of autocorrelated environmental effects. Can. J. Fish. Aquat. Sci., 47: 516-519.
- Wiff, R., J.C. Quiroz, R. Tascheri & F. Contreras. 2008. Effect of fishing tactics on the standardization of cardinalfish (*Epigonus crassicaudus*) catch rates in the demersal multispecies fishery off central Chile. Cienc. Mar., 34: 143-154.
- Wiff, R. & R.A. Quiñones. 2004. Parametrización ambiental en modelos biológico-pesqueros. Una revisión. Gayana, 68: 111-127.
- Zuur, A.F., I.D. Tuck & N. Bailey. 2003. Dynamic factor analysis to estimate common trends in fisheries time series. Can. J. Fish. Aquat. Sci., 60: 542-552.
- Zuur, A.F. & G. Pierce. 2004. Common trends in Northeast Atlantic squid time series. J. Sea Res., 52: 57-72

Received: 8 April 2010; Accepted: 16 December 2010