

ESTIMACIÓN A CORTO PLAZO DE LA TEMPERATURA DEL AGUA. APLICACIÓN EN SISTEMAS DE PRODUCCIÓN EN MEDIO ACUÁTICO

Juan Carlos Gutiérrez-Estrada¹, Emiliano De Pedro Sanz², Rafael López-Luque³ e Inmaculada Pulido-Calvo¹

Resumen:

El control y la predicción de parámetros físico-químicos del agua en tanques de cultivo de plantas de producción en medio acuático es un aspecto fundamental del buen funcionamiento de este tipo de instalaciones. En este trabajo se propone la estimación de la temperatura del agua en las próximas 24 horas en una planta de producción de anguilas europeas de carácter intensivo mediante regresiones múltiples y modelos univariantes de series temporales (modelos de suavizado y ARIMA). Se cuenta con datos de las temperaturas diarias en distintas series de tanques correspondientes a los años 1997 al 2001. Los modelos se calibran considerando exclusivamente la relación de los datos presentes y pasados de la temperatura, asumiéndose de esta forma que la variabilidad de otros factores que pueden influir en este parámetro está contenida en la propia serie de datos. Las mejores validaciones proporcionan niveles de varianza explicada en la mayor parte de los casos superiores al 95% y errores en la predicción inferiores a 1° C.

Palabras clave: Regresión múltiple, análisis de series temporales, modelos ARIMA, temperatura, acuicultura

INTRODUCCIÓN

Uno de los factores más importantes que afecta al éxito o fracaso de una inversión en un sistema de producción en medio acuático es el de la calidad del agua. Cada especie piscícola posee unos límites para los diversos parámetros considerados en la calidad del agua, tales como la temperatura, oxígeno disuelto, sustancias nitrogenadas, pH, salinidad, etc. De forma ideal, una piscifactoría debe operar dentro de los niveles óptimos de cada parámetro para conseguir así un rápido crecimiento de la biomasa y un comportamiento eficiente de la instalación. La variación significativa de cualquiera de estos parámetros fuera del rango de tolerancia de la especie provoca a corto-medio plazo una disminución del bienestar y salud de los animales, lo que incide de forma directa sobre la producción final. En esta situación, la corrección hasta valores tolerables o la amortiguación de efectos indeseables sólo es posible si el gestor cuenta con información en tiempo real del parámetro considerado y de su posible comportamiento a corto plazo.

De esta forma, el control y predicción de la variación de los principales parámetros físico-químicos constituye un aspecto fundamental del buen funcionamiento de este tipo de explotaciones (Allan y Maguire, 1991; Bejda *et al.*, 1992; Alcaraz y Espina, 1995; Burel *et al.*, 1996; Culberson y Piedrahita, 1996).

De entre todos los parámetros físico-químicos que pueden tener influencia en el crecimiento de la biomasa en un piscifactoría, uno de los más importantes es la temperatura del agua (Fiogbé y Kestemont, 2003). Esto es debido a que los peces son seres poiquiloterms, lo que implica que la temperatura corporal depende de las variaciones de temperatura del ambiente en el que se desenvuelven. Como consecuencia, la temperatura del agua afecta a la movilidad, comportamiento, alimentación, crecimiento, reproducción y actividad fisiológica de todas las especies de peces (Soderberg, 1990; Wootton, 1991; Hart y Purser, 1995; Hart *et al.*, 1996;

¹Departamento de Ciencias Agroforestales, Universidad de Huelva, EPS, Campus Universitario de La Rábida, 21819 Palos de la Frontera (Huelva), Spain, e-mail: juanc@uhu.es y ipulido@uhu.es

²Departamento de Producción Animal, Universidad de Córdoba, ETSIAM, Avda. Menéndez Pidal s/n, 14080 Córdoba, Spain, e-mail: emiliano.depedro@uco.es

³Departamento de Física Aplicada, Universidad de Córdoba, ETSIAM, Avda. Menéndez Pidal s/n, 14080 Córdoba, Spain, e-mail: fallolur@uco.es

Artículo recibido el 30 de septiembre de 2004 y aceptado para su publicación el 13 de enero de 2005. Pueden ser remitidas discusiones sobre el artículo hasta seis meses después de la publicación del mismo siguiendo lo indicado en las "Instrucciones para autores". En el caso de ser aceptadas, éstas serán publicadas conjuntamente con la respuesta de los autores.

Elliott y Hurley, 1997; Bevelhimer y Bennett, 2000; Graynoth y Taylor, 2000). Por otra parte, la temperatura del agua no sólo tiene un efecto directo sobre la fisiología de los peces, sino que puede interactuar con otros factores produciendo efectos indirectos no deseables. Así por ejemplo, la toxicidad química de algunos compuestos como el amoníaco o nitritos, la activación de determinados agentes patológicos o el nivel de actividad de la población bacteriana en las unidades de filtración (si existen) están determinados por la temperatura del agua entre otros factores (Cairns *et al.*, 1975; Alcaraz y Espina, 1995; Taoukis *et al.*, 1999).

La resolución de la modelación y predicción de la temperatura del agua ha sido abordada mediante el desarrollo de diferentes técnicas en función del objetivo y la escala temporal y espacial. En general, la mayor parte de los autores han utilizado aproximaciones para la modelación de la temperatura del agua que se pueden clasificar como deterministas y estocásticas (Marceau *et al.*, 1986). Los modelos deterministas son aproximaciones conceptuales en las que se establece una clara relación causa efecto entre las condiciones ambientales y de manejo de la planta y su influencia sobre la temperatura del agua. Como alternativa a los modelos deterministas, las aproximaciones estocásticas pueden ser usadas para establecer correlaciones entre variables, *a priori* desconocidas (p.e.: temperatura del agua y temperatura del aire en el interior de la planta). Tanto unos como otros presentan ventajas e inconvenientes en su aplicación. Así, los modelos deterministas son muy útiles cuando se pretende analizar el comportamiento de una o varias variables en distintos escenarios (Caissie *et al.*, 2001). Por regla general, la principal desventaja de este tipo de modelos es su complejidad y el número de parámetros de entrada. En este sentido, los modelos estocásticos requieren pocas variables de entrada, simplificándose de esta forma su aplicación. Sin embargo, estos últimos son muy sensibles al conjunto de datos a partir del cual se obtienen sus estimadores, por lo que la calidad de los datos constituye un aspecto fundamental.

A pesar de la importancia que para una instalación de este tipo supone el contar con modelos de predicción de la temperatura del agua, pocos son los estudios llevados a cabo en este sentido. La mayor parte de los trabajos realizados se han centrado en las variaciones de temperatura-oxígeno en estanques de cultivos de carácter semiintensivo. De este modo, Boyd *et al.* (1978),

Romaire y Boyd (1979), Meyer y Brune (1982), Klemetson y Rogers (1985) y Madenjian *et al.* (1987) entre otros, obtuvieron resultados bastante satisfactorios mediante la aplicación de modelos deterministas. Sin embargo, el gran número de parámetros requeridos por estos modelos así como el volumen y calidad de los datos necesarios ha limitado significativamente su aplicación práctica (Culberson y Piedrahita, 1996). De este modo, el objetivo del presente trabajo es desarrollar modelos estocásticos de temperatura del agua de fácil aplicación (regresión múltiple, modelos de suavizado y ARIMA de series temporales) cuya calibración se lleve a cabo a partir de los valores pasados de la variable que se trata de predecir, y que permitan llevar a cabo una correcta predicción a corto plazo de las temperaturas medias diarias en los tanques de cultivo en una piscifactoría de carácter intensivo. De este modo, se supondrá que la posible influencia que otros parámetros físico-químicos (temperatura del aire, caudal circulante, radiación, etc.) tienen sobre la temperatura del agua en los tanques de cultivo está contenida en la variabilidad de los valores pasados de la temperatura del agua.

MATERIAL Y MÉTODOS

Área de estudio

El estudio se ha llevado a cabo en Hidrorecursos S.A. Esta piscifactoría se localiza en la mitad norte de la provincia de Córdoba y centra toda su producción en el engorde de anguilas europeas. Situada en la margen izquierda del embalse de Puente Nuevo, toma el agua necesaria para su producción de dos fuentes principales: a) el embalse de Puente Nuevo (agua fría) y, b) el canal de refrigeración de la Central Térmica de Puente Nuevo (agua caliente).

El flujo de agua en el interior de la instalación es de tipo mixto, es decir, parte de los tanques de cultivo están incluidos dentro de un sistema de flujo abierto mientras que otros se encuentran dentro en un sistema de recirculación. En el sistema abierto hay 2 series de 12 tanques circulares de 3,2 m³ (series C y D), correspondientes a la zona de alevinaje-preengorde y una serie de 14 tanques rectangulares de 110 m³ (serie G) que se corresponde con la zona de engorde. Por otra parte, en el sistema con recirculación se encuentran 2 series de 12 tanques circulares de 3,2 m³ (series A y B), que pertenecen a la zona de alevinaje y 20 tanques rectangulares de 16 m³ (serie EF) de la zona de preengorde.

El proceso de recirculación es posible gracias a la acción de tres unidades de filtración (biofiltros). Dos de ellas están asociadas a las series A y B respectivamente mientras que la tercera filtra el agua procedente de las dos series de preengorde.

Estimación de la temperatura del agua. Regresión múltiple

El análisis de regresión múltiple pretende obtener una ecuación lineal que permita estimar la variable dependiente o criterio e , conocidos los valores que presentan las q variables independientes o predictivas, $x_1, \dots, x_q$:

$$e = \beta_0 + \beta_1 x_1 + \dots + \beta_q x_q + \varepsilon \quad (1)$$

donde el término β_0 es una generalización del término bivalente de ordenada en el origen, los coeficientes $\beta_1, \dots, \beta_q$ son los denominados coeficientes de regresión parcial y el valor ε es el término de error que ajusta la predicción del modelo al valor exacto de e .

Se admite que el error ε , ante una aplicación repetida del modelo, representa pequeños desajustes distribuidos normalmente alrededor de una media cero. Asimismo, los coeficientes $\beta_0, \beta_1, \dots, \beta_q$ son los valores ideales que configurarían el modelo exacto para la población en la que el número de datos tiende a ser infinito. Ya que la muestra de datos es limitada, habrá que conformarse con una estimación de estos parámetros ($b_0, b_1, \dots, b_q$) a partir de la ecuación:

$$e = b_0 + b_1 x_1 + \dots + b_q x_q \quad (2)$$

donde e representa el valor medio estimado para todos aquellos casos con un determinado perfil de $x_1, \dots, x_q$, y los parámetros $b_0, b_1, \dots, b_q$ se calculan mediante un ajuste de mínimos cuadrados de forma que sea mínima la suma de cuadrados de los desajustes entre los valores reales de e en cada individuo de la muestra y los valores teóricos que proporciona la ecuación buscada. Para aceptar con una seguridad cuantificada la validez del modelo diseñado se analiza la significación estadística global de la relación de e con las variables predictivas $x_1, \dots, x_q$, mediante el análisis de la varianza (Hair *et al.*, 1999).

Estimación de la temperatura del agua. Métodos de suavizado y modelos ARIMA

En el análisis univariante de series temporales se trata de hacer previsiones de valores futuros

de una variable, utilizando como información únicamente la contenida en los valores pasados de la serie temporal que mide la evolución de la variable objeto de estudio. En estos análisis se pueden considerar dos grandes grupos: métodos de descomposición y modelos ARIMA. Los métodos de descomposición utilizados en este trabajo son el suavizado exponencial simple y el suavizado lineal exponencial de Holt (Uriel, 1995).

El suavizado exponencial simple consiste en determinar los valores del futuro de una variable d en función de una media ponderada de sus valores pretéritos. Si la variable d es sometida a un proceso de alisado exponencial simple se obtiene como resultado la variable alisada S_t (ecuación 3), siendo (4) la ecuación de predicción:

$$S_t = \alpha_d d_t + (1 - \alpha_d) S_{t-1} \quad (3)$$

$$e_{t+1} = S_t \quad (4)$$

La ponderación se efectúa mediante un parámetro α_d ($0 < \alpha_d < 1$). Si α_d tiene un valor próximo a cero, se da mucho peso a las observaciones pasadas a través del término S_{t-1} ; por el contrario, si α_d está próximo a la unidad, se da más importancia a la observación actual de la variable d . En el período de calibración se prueba con distintos valores de α_d y se elige el que dé la mejor predicción. En la asignación del valor inicial de S_t (S_0) se toma la media de los valores del parámetro de producción diario del período descriptivo (Uriel, 1995). Ambos parámetros serán los utilizados en la generalización.

El método de Holt es también un método de alisado exponencial que utiliza dos parámetros de alisado α_d y β_d , y asimismo, se calculan dos variables de alisado para cada instante de tiempo t , S_t y T_t :

$$S_t = \alpha_d d_t + (1 - \alpha_d) (S_{t-1} + T_{t-1}) \quad (5)$$

$$T_t = \beta_d (S_t - S_{t-1}) + (1 - \beta_d) T_{t-1} \quad (6)$$

siendo la ecuación de predicción:

$$e_{t+1} = S_t + T_t \quad (7)$$

Los valores iniciales para comenzar la recursión (S_0 y T_0) se obtienen a partir de los coeficientes obtenidos en el ajuste de una recta por mínimos cuadrados con los datos disponibles en el período de calibración.

Asimismo, se prueban distintos valores de α_d y β_d , y se eligen los que den el mejor ajuste del modelo descriptivo (Uriel, 1995). Estos parámetros serán los utilizados en el período de generalización o validación externa.

El modelo ARIMA(p,d,q)(P,D,Q)^s de Box-Jenkins puede representar la correlación de la estructura de la serie temporal con un mínimo de parámetros, proporcionando una alta eficiencia en la predicción. La formulación considerada es:

$$\Phi_p(B^s) \cdot \phi_p(B) \cdot (1-B)^d \cdot (1-B^s)^D \cdot (Z_t - \mu) = \Theta_Q(B^s) \cdot \theta_q(B) \cdot a_t \quad (8)$$

siendo Z_t el valor observado del parámetro físico-químico en el instante t ; μ la media de la serie, a_t es el ruido blanco en el instante t ; B el operador retroceso que asigna a una variable su valor en el instante anterior: $BZ_t = Z_{t-1}$ y $B^m Z_t = Z_{t-m}$; ϕ , θ , Φ y Θ los parámetros del modelo; p , d y q los órdenes no estacionales del modelo; P , D y Q los órdenes estacionales del modelo; d el orden de diferenciación no estacional; D el orden de diferenciación estacional y S el orden de estacionalidad. A partir de esta formulación general, si el modelo no tiene estacionalidad se trata como un proceso ARIMA (p,d,q).

La selección de los valores p y q se lleva a cabo mediante el análisis de las funciones de autocorrelación y autocorrelación parcial de la serie de datos originales (Uriel, 1985; Holton-Wilson y Keating, 1996).

La estimación de los parámetros ϕ y θ del modelo descriptivo se realiza mediante la teoría de los mínimos cuadrados, y se ha de comprobar el nivel de significación de éstos. Estos parámetros se utilizan para la estimación de los valores diarios de la temperatura del agua en la fase de generalización.

Estos tres modelos muestran su bondad de ajuste a través de un análisis de residuos donde se estudian las funciones de autocorrelación de los mismos (Uriel, 1985; Uriel, 1995; Moreu, 1999).

Calibración y validación de los modelos

La calibración de los modelos se ha llevado a cabo para aquellas series que se encuentran dentro del sistema de recirculación, es decir, las series A y B de la zona de alevinaje y la serie EF de la

zona de preengorde. En la fase de calibración se han empleado la serie de datos correspondiente a la temperatura diaria media del agua en cada serie durante los años 1997, 1998 y 1999. Durante la fase de validación externa se han empleado los datos correspondientes a los años 2000 y 2001.

Magnitudes de error. Criterios de selección de modelos

Una de las magnitudes habitualmente empleadas en la selección de los mejores modelos es el denominado coeficiente de determinación (R^2). Este coeficiente entraña el problema de que invariablemente se incrementa con el número de regresores. De esta forma, el R^2 siempre favorece la selección de aquellos modelos que presentan un gran número de variables explicativas, o en nuestro caso, un gran número de retrasos sobre la serie de datos. Este problema es resuelto mediante la utilización del coeficiente de determinación ajustado o R^2 ajustado de Theil ($\bar{R}^2$), el cual corrige el problema con un ajuste de los grados de libertad.

$$\bar{R}^2 = 1 - \frac{\text{SEC}}{\sum (y_i - \bar{y})^2} \quad (8)$$

donde N es el número de observaciones, m es el número de parámetros en el modelo y SEC es la suma de los errores (valores observados menos valores estimados) al cuadrado o varianza residual. Es decir:

$$\text{SEC} = \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (9)$$

La magnitud más empleada en la literatura para medir el error cometido en la fase de validación externa de un modelo es el llamado porcentaje de error estándar de predicción o error estándar de predicción (%SEP ó SEP), que es una generalización del error cuadrático medio (ECM) y viene dado por:

$$\text{ECM} = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad \%SEP = \frac{100}{\bar{y}} \text{ECM} \quad (10)$$

donde y_i es el valor observado; $\hat{y}_i$ es la salida estimada por el modelo; N es el número total de observaciones e $\bar{y}$ es el valor medio de los valores observados del conjunto de predicción. La principal ventaja de este coeficiente estriba en su adimensionalidad,

que lo hace apto para realizar comparaciones entre modelos obtenidos para la resolución de problemas en los que se manejan datos de dimensiones muy distintas (Ventura, 1996). El coeficiente de eficiencia (E) así como el coeficiente ARV, también se usan en este trabajo para ver como el modelo explica la varianza total de los datos. Las magnitudes E y ARV representan la proporción de variación de los datos observados considerada por el modelo, y se expresan como (Kitanidis y Bras, 1980):

$$E = \frac{S_{obs} - SEC}{S_{obs}} \quad ARV = \frac{SEC}{S_{obs}} \quad (11)$$

$$S_{obs} = \sum_{i=1}^N (y_i - \bar{y})^2 \quad (12)$$

siendo S_{obs} la medida de la variabilidad de los valores observados frente a la media. El coeficiente de eficiencia E varía entre 1 y $-\infty$ indicando una buena predicción cuando se encuentre muy próximo a 1. Por contra, el coeficiente ARV varía entre ∞ y 0 e indica una buena predicción cuando su valor se aproxima a 0.

Otros de los más comunes métodos utilizados en la identificación de los mejores modelos lineales y no lineales son los denominados Índices de Información de Akaike (AIC) y Bayesiano (BIC) (Qi y Zang, 2001):

$$\begin{aligned} AIC &= \log(\hat{\sigma}_{MVE}^2) + \frac{2m}{T} \\ BIC &= \log(\hat{\sigma}_{MVE}^2) + \frac{m \log(T)}{T} \\ \hat{\sigma}_{MVE}^2 &= \frac{SEC}{T} \end{aligned} \quad (13)$$

donde $\hat{\sigma}_{MVE}^2$ denota la máxima vecindad estimada de la varianza del término residual. Como se puede observar la primera parte del índice mide la bondad de ajuste del modelo a los datos mientras que la segunda penaliza la sobreparametrización. De esta forma, tanto AIC como BIC establecen un balance entre el ajuste del modelo y la parsimonia de éste. Según estos índices, el mejor modelo es aquel que minimiza sus valores.

Los componentes periódicos de las series temporales, especialmente útiles en el análisis de los residuos durante la generalización de los modelos,

pueden ser extraídos mediante el análisis espectral de la serie de residuos. Para ello, se ha usado una técnica conocida como Transformada de Fourier Rápida o FFT. Esta transformación para series de tiempo discreto se define como:

$$F(k) = \sum_{n=0}^{N-1} f(t) \cdot e^{(-jv_k t)} \quad (14)$$

donde $f(t)$ es serie temporal discreta, $F(k)$ es la transformada de Fourier de $f(t)$, v es la frecuencia y N es el número de datos (Otnes y Enochson, 1978; Park, 1998). Al tratarse de series de tiempo discretas se ha establecido la frecuencia de barrido de la serie entre los límites 0 y 0,5 para evitar de esta forma efectos de rebote de frecuencias (*aliasing*) (Bloomfield, 1976). La FFT proporciona un par de valores para cada frecuencia de onda (coeficientes de Fourier $-F(k)-$), que se consideran como un número complejo con un componente cosenoidal (parte real) y otro senoidal (parte imaginaria). Ambos valores pueden combinarse para el cálculo del periodograma (15).

$$\begin{aligned} \text{Periodograma} &= (\text{Parte real } F(k))^2 \cdot \\ &\quad \cdot (\text{Parte imaginaria } F(k))^2 \cdot \frac{N}{2} \end{aligned} \quad (15)$$

RESULTADOS

Estimación del número de variables independientes

La Figura 1 muestra las funciones de autocorrelación y autocorrelación parcial de las series de datos originales de temperatura registradas en los tanques de cultivo de las zonas de alevinaje (series 'A' y 'B') y la zona de preengorde (series 'EF' o series de preengorde). Como se puede observar, las funciones de autocorrelación de cada una de las series de tanques son típicas funciones correspondientes a datos con tendencia, es decir, inicialmente las autocorrelaciones son significativamente mayores a cero y gradualmente van disminuyendo hacia el valor cero en relación con el número de retrasos. De esta forma, el valor medio de la serie de datos cronológicos cambia en función del tiempo, lo que indica que la serie de datos de temperatura del agua de los tanques de cultivo es una serie no estacionaria. Por tanto, es necesario la transformación previa de los datos como condición previa a la identificación de los modelos.




Figura 1. Funciones de autocorrelación y autocorrelación parcial de los datos originales de temperatura del agua de las series 'A', 'B' y 'Preengorde'.

La no estacionalidad de la serie de datos puede ser eliminada eficazmente mediante un proceso de diferenciación. Ésta consiste en restar de cada observación el valor de la observación precedente. En nuestro caso, la primera diferencia fue suficien-

te para eliminar la tendencia de los datos en las series 'A' y 'B', mientras que en las series de preengorde fue necesario probar con un segundo orden de diferenciación. Las nuevas funciones de autocorrelación y autocorrelación parcial de la serie

de datos se muestran en la Figura 2. En las series de tanques 'A' y 'B' se observa una pauta común caracterizada por una autocorrelación claramente significativa para 1 retraso y una autocorrelación parcial significativa al menos para 7 retrasos, de

entre los que destacan los dos primeros. En el caso de la serie de tanques de la zona de preengorde, la autocorrelación se muestra significativa para 1, 5 y 7 retrasos, mientras que la autocorrelación parcial es evidente para 1, 2, 3, 5, 6 y 7 retrasos.




Figura 2. Funciones de autocorrelación y autocorrelación parcial de los datos diferenciados para las series 'A', 'B' y 'Preengorde'.

Esta situación, en la que la función de autocorrelación desciende bruscamente hasta el cero y en la que la función de autocorrelación parcial desciende de forma exponencial puede identificarse como un proceso ARMA(1,1). De esta forma, *a priori*, el modelo que mejor puede aproximarse a la temperatura de las series 'A' y 'B' es el ARIMA(1,1,1), mientras que en preengorde sería el ARIMA(1,2,1). Sin embargo, debido a que los coeficientes de autocorrelación y autocorrelación parcial en procesos ARMA(1,1) no presentan un comportamiento fijo se han probado otros modelos ARIMA cuyos órdenes autoregresivos y de media móviles han oscilado entre 1 y 2.

En el caso de las regresiones múltiples, ya que no existe un criterio particular en la selección del número de retrasos, se ha optado por seleccionar hasta un máximo de 5 días retrasados en el tiempo como variables independientes.

Temperatura en la serie 'A'

La regresión múltiple que presenta como variable dependiente la temperatura del agua en el sistema 'A' y como variables independientes la

temperatura del agua en el mismo sistema en los cinco días anteriores, ha proporcionado resultados estadísticamente satisfactorios en el proceso de calibración ($R^2=0,9078$; $F(5;869)=1712,200$; $p_\alpha<0,001$; $N=875$). Durante el proceso de validación (temperatura del agua estimada frente a la temperatura del agua observada) también se obtienen buenos resultados al alcanzarse un coeficiente de correlación superior a 0,97 ($R^2_{ajus}=0,9545$; $F(1;131)=7204,900$; $p_\alpha<0,001$; $N=333$) (Figura 3). La validación del modelo se ve corroborada por un error estándar de predicción inferior al 5 % y por unos coeficientes E y ARV de 0,9551 y 0,0449 respectivamente (Tabla 1).

El análisis de los residuos existentes entre los valores observados y estimados frente a valores estimados durante la validación ha dado como resultado una nube de puntos compacta centrada en el cero, lo que indica la falta de autocorrelación entre residuos. Asimismo, el análisis espectral de la serie temporal de residuos muestra la ausencia de frecuencias significativamente importantes por lo que no se detecta periodicidad en la serie (Figura 3).




Figura 3. Validación para la serie 'A' del modelo de regresión que presenta como variables independientes la temperatura de los cinco días anteriores. a) Representación punto a punto de los valores de temperatura observada y estimada por el modelo; b) temperatura estimada frente a residuos y c) periodograma de la serie de residuos.

ESTIMACIÓN A CORTO PLAZO DE LA TEMPERATURA DEL AGUA. APLICACIÓN EN SISTEMAS DE PRODUCCIÓN EN MEDIO ACUÁTICO

En la tabla 1 puede observarse que tres de las cinco variables independientes son estadísticamente significativas (temperatura del agua (t-1), (t-3) y (t-5)). Éstas explican de forma significativa una mayor parte de la varianza de la variable dependiente, por lo que se repite el análisis de regresión utilizando como variables independientes las temperaturas del agua del primer, tercer y quinto días anteriores. Los resultados son similares aunque se obtienen magnitudes de error ligeramente mejores ($R^2_{ajus}=0,9549$; $F(1;131)=7212,100$; $p_{\alpha}<0,001$; $N=333$; $ECM=0,9860$; $\%SEP=4,6362$; $E=0,9551$; $ARV=0,0449$; $AIC=-0,0065$; $BIC=-0,0018$).

Los parámetros de estimación de la temperatura del agua a través del suavizado exponencial simple, suavizado lineal exponencial y modelos ARIMA se muestran en la Tabla 2.

En los modelos de suavizado exponencial simple, lineal exponencial y todos los modelos ARIMA, el porcentaje de varianza explicada supera el 91 % mientras que los términos de error se encuentran alrededor del 5 % (SEP). A pesar de que durante el proceso de validación, el mejor modelo *a priori* durante la fase de identificación [ARIMA(1,1,1)], muestra buenos valores en todos los términos de error, no se ha seleccionado como el mejor debido a que tanto el parámetro autoregresivo como de media móvil no presenta niveles significativos. Por otra parte, el modelo que presenta la mayor bondad de ajuste [ARIMA(2,1,2)] tiene todos sus parámetros autoregresivos y de media móvil significativos. Sin embargo, los valores absolutos de los parámetros ϕ_1 y θ_1 son claramente superiores a 1, lo que puede indicar que para los órdenes $p=2$ y $q=2$, el proceso no se comporte como estacionario.

Tabla 1. Resultados de la calibración y validación del modelo de regresión múltiple para la serie 'A' considerando la temperatura de cinco días antes

Resumen de la regresión múltiple en la calibración del modelo			
$R=0,9525$; $R^2=0,9078$; $F(5;869)=1712,200$; $p_{\alpha}<0,001$; $N=875$			
Variable dependiente	Variable independiente	$b_i(i=0,1,...,q)$	p_{α}
Temperatura del agua (t)	Intersección (b_0)	0,9083	0,0005**
	Temperatura del agua (t-1)	0,8964	0**
	Temperatura del agua (t-2)	0,0467	0,3049
	Temperatura del agua (t-3)	-0,0975	0,0322*
	Temperatura del agua (t-4)	0,0359	0,4300
	Temperatura del agua (t-5)	0,0810	0,0165*
Resumen de la regresión en la validación del modelo			
$R=0,9778$; $R^2_{ajus}=0,9545$; $F(1;331)=7204,900$; $p_{\alpha}<0,001$; $N=333$ $ECM=0,9862$; $\%SEP=4,6372$; $E=0,9551$; $ARV=0,0449$; $AIC=0,0059$; $BIC=0,0137$			
Variable dependiente	Variable independiente	$b_i(i=0,1,...,q)$	p_{α}
Temperatura del agua observada (t)	Intersección (b_0)	-0,5320	0,0434*
	Temperatura del agua estimada (t)	1,0193	0**

* $p<0,05$; ** $p<0,001$

Tabla 2. Estadísticos de validación del modelo de suavizado exponencial simple, suavizado lineal exponencial y modelos ARIMA en la serie 'A'

Modelo	Parámetros	Validación						
		R^2_{ajus}	ECM	%SEP	E	ARV	AIC	BIC
Suavizado exponencial simple	$S_0=24,1300$; $\alpha_d=0,9210$	0,9528	1,0166	4,7780	0,9522	0,0478	0,0346	0,0485
Suavizado lineal exponencial	$S_0=27$; $T_0=-0,0040$ $\alpha_d=0,9290$; $\beta_d=0$	0,9520	1,0247	4,8162	0,9515	0,0485	0,0545	0,0576
ARIMA(1,1,1)	$\phi_1=0,0202$; $\theta_1=-0,0289$	0,9528	0,9994	4,6966	0,9531	0,0469	0,0171	0,0218
ARIMA (1,1,2)	$\phi_1=0,7311^{**}$; $\theta_1=0,7287^{**}$ $\theta_2=0,1126^{*}$	0,9542	0,9818	4,6139	0,9546	0,0453	-0,0078	-0,0015
ARIMA (2,1,2)	$\phi_1=1,2954^{**}$; $\theta_1=-1,2536^{**}$ $\phi_2=-0,7736^{**}$; $\theta_2=-0,6386^{**}$	0,9556	0,9663	4,5407	0,9561	0,0439	-0,0295	-0,0216
ARIMA (2,1,1)	$\phi_1=0,8285^{**}$; $\theta_1=-0,8001^{**}$ $\phi_2=-0,1490^{**}$	0,9543	0,9812	4,6111	0,9547	0,0452	-0,0088	-0,0025

* $p<0,05$; ** $p<0,001$

De los modelos restantes [ARIMA(1,1,2) y ARIMA(2,1,1)] el que presenta un mejor ajuste de sus términos de error es el ARIMA (2,1,1).

De entre los dos modelos de suavizado y el ARIMA (2,1,1), tan sólo el suavizado lineal exponencial presenta una ausencia total de significación en todos los coeficientes de autocorrelación residual, aunque los términos de error sean ligeramente peores que los del modelo ARIMA (2,1,1) (Figura 4).

Temperatura en la serie 'B'

La regresión lineal simple entre la temperatura en la serie 'A' y en la serie 'B' se muestra en la Figura 5.

Ya que existe una alta correlación significativa entre la temperatura del agua en ambas series, se han utilizado los mismos parámetros de regresión y de los modelos de series temporales en el proceso de predicción de la temperatura en la serie 'B' para el mismo período de validación. Así, en el caso de las regresiones múltiples se han obtenido en todas las ocasiones coeficientes de correlación superiores a 0,95 y magnitudes de error por debajo del 5 % (Tabla 3). De la misma forma que en el proceso de validación de la estimación de la temperatura del agua en la serie 'A', el modelo de regresión con el que se han obtenido los mejores resultados se corresponde con el que utiliza como variables independientes las temperaturas del agua del primer, tercero y quinto




Figura 4. Representación punto a punto y función de autocorrelación residual durante el periodo de validación para la serie 'A' de los modelos a) suavizado exponencial simple; b) suavizado lineal exponencial y c) ARIMA(2,1,1).

día anteriores. Asimismo, no se han observado frecuencias significativas tras la aplicación de la transformada de Fourier a los residuos de validación ni ningún tipo de tendencia de los residuos frente a los valores estimados.




Figura 5. Regresión lineal entre la temperatura del agua en la serie 'A' y la temperatura en la serie 'B'.

Las estimaciones de la temperatura del agua en la serie 'B' a partir de los parámetros obtenidos a través del suavizado exponencial simple y el suavizado lineal exponencial de las temperaturas de la serie 'A', también ofrecen ajustes estadísticamente aceptables y magnitudes de error pequeñas (Tabla 4). De forma general, los modelos ARIMA proporcionan coeficientes de determinación superiores a 0,90 y errores alrededor del 5 %, siendo en esta ocasión el modelo ARIMA (1,1,2) el que ofrece mejores resultados (Tabla 4).

Temperatura en las series 'E' y 'F'

Para la estimación de la temperatura del agua en las series correspondientes a la zona de preengorde (series 'E' y 'F'), se ha procedido de la misma forma que en la estimación de la temperatura del agua en la serie 'B'. Se ha llevado a cabo, por tanto, la regresión simple entre la temperatura en la serie 'A' y preengorde y entre la serie 'B' y preengorde para el período de calibración. Los resultados obtenidos son estadísticamente aceptables aunque en el mejor de los casos el porcentaje de varianza explicada no supera el 62 % (Figura 6).

Al ser los errores sensiblemente mayores a los encontrados en la estimación de la temperatura del agua en las series 'A' y 'B', se ha procedido a la calibración y validación de los modelos de estimación de la temperatura del agua en las series 'E' y 'F' de forma independiente a las dos series anteriores. De esta forma, el nivel de predicción obtenido es tan satisfactorio como los conseguidos para las series 'A' y 'B'.

En el caso de las regresiones múltiples encontramos pequeñas diferencias en cuanto a la significación de las variables independientes implicadas durante la calibración del modelo. Así, en una primera estimación de la temperatura del agua a partir de las temperaturas existentes en los cinco días previos, las variables que significativamente explican una mayor parte de la varianza de la variable dependiente son la temperaturas del primer, segundo y quinto día anteriores.

Tabla 3. Estadísticos de validación de los modelos de regresión múltiple calibrados en la serie 'A' aplicados en la serie 'B'

Variable dependiente: Temperatura del agua observada en la serie 'B'

Variable independiente: Temperatura del agua estimada en la serie 'B'

Modelo	Validación								
	F	p	R ² _{ajus}	ECM	SEP	E	ARV	AIC	BIC
Temperatura de los 5 días anteriores	(1;308)=6190,9	0**	0,9514	1,0065	4,7125	0,9514	0,0486	0,0274	0,0514
Temperatura de 1 ^{er} , 3 ^{er} y 5 ^o días anteriores	(1;308)=6264,2	0**	0,9518	1,0014	4,6886	0,9519	0,0481	0,0217	0,0265

**p<0,05

Tabla 4. Estadísticos de validación de los modelos de suavizado exponencial simple, suavizado lineal exponencial y ARIMAs calibrados en la serie 'A' aplicados en la serie 'B'

Modelo	Validación						
	R ² _{ajus}	EMC	SEP	E	ARV	AIC	BIC
Suavizado exponencial simple	0,9476	1,0452	4,8939	0,9476	0,0524	0,0833	0,0849
Suavizado lineal exponencial	0,9466	1,0534	4,9322	0,9468	0,0532	0,1032	0,1064
ARIMA (1,1,2)	0,9545	0,9749	4,5644	0,9544	0,0456	-0,0120	-0,0041
ARIMA (2,1,1)	0,9533	0,9884	4,6279	0,9532	0,0468	0,0056	0,0119




Figura 6. Regresiones lineales entre la temperatura del agua en las series 'A' y 'B' y la temperatura en las series de preengorde ('E' y 'F').

La validación de los modelos de regresión múltiple ha proporcionado muy buenos resultados, ya que en todos los casos el coeficiente de determinación se encuentra por encima de 0,97 y los errores no superan el 3,8 % (SEP). De todos ellos, el que presenta un mayor ajuste con los datos reales es el que considera como variables independientes las temperaturas de los cinco días anteriores (Tabla 5; Figura 7). A pesar de ello, el análisis de los residuos parece mostrar una varianza no constante sobre todo alrededor de 18 °C. Este anormal aumento de la varianza puede tener influencia en los valores obtenidos en el periodograma para frecuencias bajas, lo que puede indicar un desajuste en el modelo.

Figura 7. Validación para las series de preengorde del modelo de regresión que presenta como variables independientes la temperatura de los cinco días anteriores. a) Representación punto a punto de los valores de temperatura observada y estimada por el modelo; b) temperatura estimada frente a residuos y c) periodograma de la serie de residuos.

Tabla 5. Resultados de la validación de los modelos de regresión múltiple para la serie 'EF' considerando la temperatura de cinco días anteriores y la temperatura del primer, segundo y quinto día anterior.

Variable dependiente: Temperatura del agua observada en la serie 'E' y 'F'

Variable independiente: Temperatura del agua estimada en la serie 'E' y 'F'

Modelo	Validación								
	F	p	R ² _{ajus}	ECM	SEP	E	ARV	AIC	BIC
Temperatura de los 5 días anteriores	(1;371)=14195,6	0**	0,9723	0,8687	3,7909	0,9726	0,0274	-0,2178	-0,2101
Temperatura de 1 ^{er} , 3 ^{er} y 5 ^o días anteriores	(1;371)=14145,0	0**	0,9724	0,8697	3,7953	0,9725	0,0275	-0,2265	-0,2219

**p<0,001

ESTIMACIÓN A CORTO PLAZO DE LA TEMPERATURA DEL AGUA. APLICACIÓN EN SISTEMAS DE PRODUCCIÓN EN MEDIO ACUÁTICO

Tabla 6. Estadísticos de validación del modelo de suavizado exponencial simple, suavizado lineal exponencial y modelos ARIMA en la serie 'EF'

Modelo	Parámetros	Validación						
		R^2_{ajus}	EMC	SEP	E	ARV	AIC	BIC
Suavizado exponencial simple	$S_0=25,4300$; $\alpha_d=0,8040$	0,9742	0,8427	3,7704	0,9742	0,0258	-0,2918	-0,2902
Suavizado lineal exponencial	$S_0=26$; $T_0=-0,0010$ $\alpha_d=0,8040$; $\beta_d=0$	0,9742	0,8424	3,7688	0,9742	0,0258	-0,2871	-0,2841
ARIMA (2,1,1)	$\phi_1=0,1021^*$; $\theta_1=-0,9466^{**}$ $\phi_2=-0,4916^{**}$	0,9621	1,0144	4,5369	0,9625	0,0375	0,0509	0,0585

* $p<0,05$; ** $p<0,001$




Figura 8. Representación punto a punto y función de autocorrelación residual durante el periodo de validación para las series de preengorde de los modelos a) suavizado exponencial simple; b) suavizado lineal exponencial y c) ARIMA(2,2,1).

De la misma forma que las regresiones múltiples, los modelos de suavizado han dado como resultado muy buenos ajustes entre valores reales y estimados en validación, de tal forma que se consigue explicar más del 97% de la varianza de la variable dependiente.

De entre todos los ARIMA probados destaca como el mejor el ARIMA (2,2,1) con el que se consigue explicar casi un 97% de la varianza de la variable dependiente y con el que se alcanza un error de predicción del 4,5% (Tabla 6). Sin embargo, al igual que en la regresión múltiple,

el análisis de los coeficientes de autocorrelación residual mostró un valor significativo para cuatro retrasos, lo que puede indicar nuevamente un desajuste del modelo (Tabla 6; Figura 8).

DISCUSIÓN

Tanto los modelos de regresiones múltiples como los modelos univariantes de series temporales han presentado una significativa capacidad predictiva, lo que confirma la validez de los modelos estocásticos en la predicción a corto plazo de temperatura del agua en tanques de cultivo. Otros autores como Caissie *et al.* (2001), obtuvieron resultados similares en la modelación mediante regresiones múltiples y modelos autoregresivos basados en procesos de segundo orden de Markov, en la simulación de las temperaturas máximas de pequeños arroyos de Canadá, aspecto de crucial importancia en el manejo de recursos acuáticos.

En nuestro caso, la utilización de este tipo de modelos en plantas de producción en medio acuático puede convertirse en una importante arma de gestión para los responsables técnicos de la explotación ya que, por una parte, permiten establecer con antelación pautas de comportamiento y evolución de la biomasa almacenada y, por otra, son fáciles de utilizar e implementar. De este modo, el conocimiento de la temperatura del agua en un plazo de 24 horas facilita la determinación de factores de conversión, tasas instantáneas de crecimiento, raciones de alimento por tanques así como el establecimiento de las posibles medidas de alarma en el caso de previsión de cambios bruscos de temperatura o la detección de temperaturas excesivamente altas o baja. Por otra parte, la facilidad de utilización e implementación de este tipo de modelos se ve aumentada al no necesitar las series originales un proceso de filtrado previo, tal y como sucede con otro tipo de parámetros químicos (Gutiérrez-Estrada, 2004).

Durante la validación externa, los términos de error alcanzados por los mejores modelos se han encontrado muy cercanos a sus valores óptimos. Así, de forma general se puede decir que el error estándar de predicción se ha encontrado por término medio por debajo del 5%. Esto supone que en un rango de variación de la temperatura del agua de 20°C el error en la predicción por término medio es de 1°C, como se puede extraer de los valores de ECM. Este error no es debido a predicciones incorrectas puntuales si no que es

consecuencia de pequeños errores equitativos a lo largo del proceso de validación. Es decir, es consecuencia de un fenómeno de retraso temporal entre la serie real y la estimada durante la generalización.

El efecto de retraso temporal ha sido claramente observado en los trabajos de otros autores que trataban de predecir parámetros que evolucionan en función del tiempo mediante distintas metodologías univariantes. De esta forma, Thirumalaiah y Deo (2000) estimaron tanto la escorrentía superficial horaria y el estado de los niveles diarios de ríos en la zona central de la India a través de redes neuronales computacionales, observándose el retraso en las estimaciones y provocando que en la mayor parte de los modelos calibrados los coeficientes de eficiencia no superasen el nivel 0.8. También Yang *et al.* (1997) muestran el retraso en alguno de sus modelos de redes neuronales para la predicción del drenaje superficial en tierras de cultivo. Los modelos de regresión de ventana móvil y ARIMA calibrados por Junttila (2001) sobre la predicción de la inflación, sufren retraso en la validación en función de la anticipación en la predicción aplicada durante la calibración, lo que implica valores del coeficiente de desigualdad de Theil que en todo momento se encuentran por encima de 0.8. Por otra parte, Prybotuk *et al.* (2000), tratando de predecir la concentración de ozono en la ciudad de Houston mediante modelos ARIMA y regresiones múltiples, obtuvieron errores estándar de predicción durante la generalización superiores al 90 %. Este elevado error está íntimamente relacionado con el fenómeno de retraso temporal. Asimismo, Pulido-Calvo (2001), Pulido-Calvo *et al.* (2002) y Pulido-Calvo *et al.* (2003) detectan el fenómeno de retraso al predecir las demandas diarias de agua en una comunidad de regantes de la provincia de Córdoba. La explicación de las causas del fenómeno de retraso en los modelos ARIMA puede venir determinada por la influencia de variables externas cuya variabilidad no haya sido recogida por las series de temperaturas. De este modo, Park (1998) explica el retraso entre las series de capturas real y estimada de una especie piscícola a través de un modelo ARIMA como consecuencia de la influencia de factores bióticos y abióticos no tenidos en cuenta en el modelo. En el caso de la regresiones múltiples y modelos de suavizado, el retraso de la serie puede venir determinado por el efecto combinado del tratamiento del modelo como un proceso autoregresivo puro y la multicolinealidad entre variables independientes.

CONCLUSIONES

Los modelos de regresión múltiple, suavizado y ARIMA, se han mostrado como buenos estimadores a corto plazo de la temperatura del agua en tanques de cultivo. Los resultados obtenidos (con errores de predicción inferiores a 1 °C), unidos a la facilidad de implementación de los modelos calibrados en cualquier aplicación de propósito general de manejo de plantas de acuicultura, permiten al gestor o responsable técnico de la planta contar con información en tiempo real de la temperatura en los tanques de cultivo en las próximas 24 horas. De esta forma, se facilita el trabajo de distribución de tareas entre operarios y se mejora la eficiencia en el establecimiento de los niveles de alarma en el caso de un desajuste en los valores del parámetro considerado.

REFERENCIAS

- Alcaraz, G. y S. Espina (1995) Acute toxicity of nitrite in juvenile grass carp modified by weight and temperature. *Bulletin of Environmental Contamination and Toxicology*, 55: 473-478.
- Allan, G.L. y G.B. Maguire (1991) Lethal levels of low dissolved oxygen and effects of short-term oxygen stress on subsequent growth of juvenile *Panaeus monodon*. *Aquaculture*, 94: 27-37.
- Bejda, A.J., B.A. Phelan y A.I. Studholme (1992) The effect of dissolved oxygen on the growth of young-of-the-year winter flounder, *Pseudopleuronectes americanus*. *Environmental Biology of Fishes*, 34: 321-327.
- Bevelhimer, M. y W. Bennett (2000) Assessing cumulative thermal stress in fish during chronic intermittent exposure to high temperatures. *Environmental Science and Policy*, 3: 211-216.
- Bloomfield, P. (1976) *Fourier analysis of time series: an introduction*. Edita: John Wiley & Sons. New York.
- Boyd, C.E., R.P. Romaine y E. Johnston (1978) Predicting early morning dissolved oxygen concentrations in channel catfish ponds. *Transactions of the American Fisheries Society*, 107: 484-492.
- Burel, C., J. Person-le Ruyet, F. Gaumet, A. Le Roux, A. Severe y G. Boeuf (1996) Effects of temperature on growth and metabolism in juvenile turbot. *Journal of Fish Biology*, 49: 678-692.
- Cairns, J., A.G. Heath y B.C. Parker (1975) The effects of temperature upon the toxicity of chemical to aquatic organisms. *Hydrobiology*, 47: 135-171.
- Caissie, D., N. El-jabi y M.G. Satish (2001) Modelling of maximum daily water temperatures in a small stream using air temperatures. *Journal of Hydrology*, 251: 14-18.
- Culberson, S.D. y R.H. Piedrahita (1996) Aquaculture pond ecosystem model: temperature and dissolved oxygen prediction – mechanism and application. *Ecological Modelling*, 89: 231-258.
- Elliott, J.M. y A. Hurley (1997) Functional model for maximum growth of Atlantic salmon parr, *Salmo salar*, from two populations in northwest England. *Functional Ecology*, 11: 592-603.
- Fiogbé, E.D. y P. Kestemont (2003) Optimum daily ration for Eurasian perch *Perca fluviatilis* L. reared at its optimum growing temperature. *Aquaculture*, 216: 243-252.
- Graynoth, E y M.J. Taylor (2000) Influence of different rations and water temperatures on the growth rates of shortfinned eels and longfinned eels. *Journal of Fish Biology*, 57: 681-699.
- Gutiérrez-Estrada, J.C., E. De-Pedro-Sanz, R. López-luque y I. Pulido-Calvo (2004) Comparison between traditional methods and artificial neural networks for ammonia concentration forecasting in an eel (*Anguilla anguilla* L.) intensive rearing system. *Aquacultural Engineering* (en prensa)
- Hair, J.F., R.E. Anderson, R.I. Tatham y W.C. Black (1999) *Análisis multivariante*. Edita: Prentice Hall. Madrid.
- Hart, P.R. y G.R. Purser (1995). Effects of salinity and temperature on eggs and yolk sac larvae of the greenback flounder (*Rhombosolea tapirina* Günther, 1862). *Aquaculture*, 136: 221-230.
- Hart, P.R., W.G. Hutchinson y G.J. Purser (1996) Effects of photoperiod, temperature and salinity on hatchery-reared larvae of the greenback flounder (*Rhombosolea tapirina* Günther, 1862). *Aquaculture*, 144: 303-311.
- Holton-Wilson, J. y B. Keating (1996) *Previsiones en los negocios*. Edita: IRWIN. Illinois.
- Junttila, J. (2001) Structural breaks, ARIMA model and finnish inflation forecasts. *International Journal of Forecasting*, 17: 203-230.
- Kitanidis, P.K. y R.L. Bras (1980) Real time forecasting with a conceptual hydrological model. 2. Applications and results. *Water Resources Research*, 16: 1034-1044.
- Klemetson, S.L. y G.L. Rogers (1985) Aquaculture pond temperature modeling. *Aquaculture Engineering*, 4: 191-208.
- Madenjian, C.P., G.L. Rogers y A.W. Fast (1987) Predicting night time dissolved oxygen loss in prawn ponds of Hawaii: Part II. A new method. *Aquaculture Engineering*, 6: 209-225.
- Marceau, P., D. Cluis y G. Morin (1986) Comparaison des performances relatives à un modèle déterministe et à un modèle stochastique de température de l'eau en rivière. *Canadian Journal of Civil Engineering*, 13(3): 352-364.
- Meyer, D. y D.E. Brune (1982) Computer simulation of the diurnal oxygen levels in a stillwater aquaculture pond. *Aquaculture Engineering*, 1: 245-261.

- Moreu, P. (1999) Estadística Informatizada. Edita: Paraninfo. Madrid.
- Otnes, R.K. y L. Enochson (1978) Applied time series analysis. Edita: Wiley Interscience. New York.
- Park, H.H. (1998) Analysis and prediction of walleye pollock (*Theragra chalcogramma*) landings in Korea by time series analysis. Fisheries Research, 38: 1-7.
- Prybotuk, V.R., Y. Junsu y D. Mitchell (2000) Comparison of neural models with ARIMA and regression models for prediction of Houston's daily maximum ozone concentrations. European Journal of Operational Research, 122: 31-40.
- Pulido-Calvo, I. (2001) Diseño y gestión óptimos de sistemas de impulsión y de almacenamiento de agua para riego. Tesis Doctoral. Universidad de Córdoba.
- Pulido-Calvo, I., J. Roldán, R. López-Luque y J.C. Gutiérrez-Estrada (2002) Técnicas de predicción a corto plazo de la demanda de agua. Aplicación al uso agrícola. Ingeniería del Agua, 9(3): 319-331.
- Pulido-Calvo, I., J. Roldán, R. López-Luque y J.C. Gutiérrez-Estrada (2003) Demand forecasting for irrigation water distribution systems. Journal of Irrigation and Drainage Engineering, 129(6): 422-431.
- Qi, M. y G.P. Zhang (2001) An investigation of model selection criteria for neural network time series forecasting. European Journal of Operational Research, 132: 666-680.
- Romaire, R.P. y C.E. Boyd (1979) Effects of solar radiation on the dynamics of dissolved oxygen in channel catfish ponds. Transactions of the American Fisheries Society, 108: 472-478.
- Soderberg, R.W. (1990) Temperature effects on the growth of blue tilapia in intensive aquaculture. The progressive Fish-Culturist, 52: 155-157.
- Taoukis, P.S., K. Koutsoumanis y G.J.E. Nychas (1999) Use of time-temperature integrators and predictive modeling for shelf life control chilled fish under dynamic storage conditions. International Journal of Food Microbiology, 53: 21-31.
- Thirumalaiah, K. y M.C. Deo (2000) Hydrological forecasting using neural networks. Journal of Hydrologic Engineering, 5: 180-189.
- Uriel, E. (1985) Análisis de series temporales. Modelos ARIMA. Edita: Paraninfo. Madrid.
- Uriel, E. (1995) Análisis de datos. Series temporales y análisis multivariante. Edita: AC. Madrid.
- Ventura, S. (1996) Diseño de redes neuronales en métodos cinéticos. Tesis Doctoral. Universidad de Córdoba.
- Wootton, R.J. (1991) Ecology of teleost fishes. Edita: Chapman and Hall. Londres.
- Yang, C.C., S.O. Prasher, R. Lacroix, S. Sreekanth, N.K. Patni y L. Masse (1997) Artificial neural network model for subsurface-drained farmlands. Journal of Irrigation and Drainage Engineering, 123(4): 285-292.