

APROXIMACIONES NEURONALES UNIVARIANTES PARA LA PREDICCIÓN DE CAUDALES DIARIOS EN CUENCAS PORTUGUESAS

I. Pulido-Calvo

Dpto. Ciencias Agroforestales, EPS
Campus Universitario de La Rábida, Universidad de Huelva
21819 Palos de la Frontera (Huelva), España
e-mail: ipulido@uhu.es

M. Manuela Portela

Dpto. Engenharia Civil, SHRH
Instituto Superior Técnico (IST)
Avda. Rovisco Pais, 1049-001 Lisboa, Portugal

Resumen: Desde hace unos años, las redes neuronales computacionales están siendo una de las herramientas más prometedoras para la estimación de caudales en cuencas. La mayoría de los trabajos de la literatura utilizan para las predicciones, junto con los datos registrados de caudales, otras variables de entrada de carácter hidro-meteorológico. En este estudio se analizó el funcionamiento de redes neuronales de retropropagación para la estimación de caudales diarios en cuencas portuguesas, considerando que sólo los datos de caudal de días previos están disponibles para la calibración de los modelos. Además de los modelos tradicionales de redes neuronales que tienen como variables de entrada los caudales en días previos, se realizó un procedimiento de convolución en las neuronas de la capa de entrada y se probó una metodología híbrida combinando redes neuronales computacionales y modelos ARIMA. Los modelos neuronales complementados con un proceso de convolución dieron las mejores estimaciones considerando los caudales de los tres días previos como variables de entrada. También se realizó un análisis preliminar de la capacidad de esta aproximación para estimar caudales diarios en una cuenca diferente a la utilizada para la calibración de los modelos, obteniéndose resultados satisfactorios.

INTRODUCCIÓN

El desarrollo y la implementación de herramientas para la planificación óptima de los recursos hídricos requiere generalmente el análisis de los flujos de caudal en las cuencas para la evaluación de problemas de ingeniería y ambientales tales como el control de inundaciones, la operación en tiempo real de embalses, la generación hidroeléctrica, el control de la calidad del agua y de los ecosistemas de los ríos, etc.

Durante muchos años se ha estudiado la transformación de lluvia en escorrentía para obtener series de caudales en cuencas y así determinar futuros eventos o caracterizar cuencas sin registros. Las dos principales aproximaciones utilizadas en la literatura especializada para la evaluación del proceso lluvia-escorrentía son los modelos conceptuales (o físicos) y los modelos de "caja negra".

Usualmente, un modelo conceptual tiene como objetivo formular el proceso físico basándose en cada una de las variables que intervienen, y en este caso puede ser la interceptación, la infiltración, el agua superficial y subterránea, la percolación, la evaporación, la transpiración, etc. De este modo, este tipo de modelos normalmente es complejo y necesita de muchos requerimientos de datos para que se apliquen de forma general en distintas situaciones prácticas (Jakeman y Hornberger, 1993; Abrahart y See, 2000). Asimismo, la exactitud de las predicciones se ve influenciada por componentes subjetivas como el establecimiento de los parámetros del modelo que generalmente depende de la experiencia del usuario (Duan *et al.*, 1992, 1993, 1994; Sorooshian *et al.*, 1993; Hsu *et al.*, 1995; Yapo *et al.*, 1996; Tokar y Johnson, 1999; Chang y Chen, 2001).

En las aproximaciones de "caja negra" se iden-

tifica una relación entre las variables de entrada y salida sin tener en cuenta la estructura interna del proceso físico. En comparación con un modelo conceptual, un modelo de "caja negra" tiene muchos menos requerimientos de datos. Muchas situaciones prácticas pueden no justificar el tiempo y el esfuerzo requerido para desarrollar, validar e implementar un modelo conceptual, cuando el principal objetivo es tener un sistema de respuestas lo suficientemente aproximado aunque no se profundice en el análisis del proceso físico. Una de estas situaciones prácticas puede ser la estimación en tiempo real de caudales en cuencas (Hsu *et al.*, 1995; Lorrai y Sechi, 1995).

Se debe puntualizar que la disponibilidad de los datos generalmente determina la elección del tipo de modelo. Así, medidas continuas de precipitación y caudal pueden ser fácilmente obtenidas en comparación con medidas continuas de características de suelo, humedad inicial del suelo, infiltración y características de aguas subterráneas. Por lo tanto, una aproximación de "caja negra" que use datos disponibles puede ser mucho más apropiado para propósitos de predicciones que un modelo físico (Tokar y Johnson, 1999).

Las Redes Neuronales Artificiales o Computacionales (RNAs o RNCs) pueden ser clasificadas como modelos "caja negra" y son modelos heurísticos incluidos en el campo de conocimiento denominado "soft-computing". Algunas aplicaciones de RNCs en el manejo y la gestión de los recursos hídricos incluyen la caracterización del proceso lluvia-escurrimiento (Hsu *et al.*, 1995; Lorrai y Sechi, 1995; Mason *et al.*, 1996; Abrahart *et al.*, 1999; Tokar y Johnson, 1999; Thirumalaiah y Deo, 2000; Tokar y Markus, 2000; Chiang *et al.*, 2004; Moradkhani *et al.*, 2004; Anctil y Rat, 2005), estimación a corto plazo del estado de ríos (Thirumalaiah y Deo, 1998, 2000; Abrahart y See, 2000, 2002; See y Openshaw, 2000; Cameron *et al.*, 2002), predicción de lluvias (French *et al.*, 1992; Zhang *et al.*, 1997; Kuligowski y Barros, 1998; Palazón y García, 2004), modelación de aguas subterráneas (Roger y Dowla, 1994; Yang *et al.*, 1997), predicción de demandas de agua en sistemas de abastecimiento urbano y zonas regables (Griño, 1992; Pulido-Calvo *et al.*, 2002, 2003, 2005), descripción de procesos de infiltración (Álvarez y Bolado, 1996), análisis de sequías (Shin y Salas, 2000), etc. Otras muchas aplicaciones de RNCs en hidrología se detallan en ASCE (2000a, 2000b).

En la estimación de series temporales obser-

vaciones pasadas de una o más variables se registran e introducen como datos de entrada en un modelo que describe las relaciones entre estas variables y permite estimar estados futuros (Zhang, 2003). Recientemente, RNCs han sido extensamente aplicadas para la predicción de series temporales (Griño, 1992; Al-Saba y El-Amin, 1999; Abrahart y See, 2000; Zhang *et al.*, 2001; Zhang, 2003; Gutiérrez-Estrada *et al.*, 2004).

En este estudio, RNCs se aplicaron para la predicción a corto plazo de caudales diarios en ríos portugueses. Tres aspectos distinguen los análisis realizados de las típicas aplicaciones de redes neuronales. Uno de ellos está relacionado con el área de la cuenca: mientras muchos de los resultados presentados en la literatura se limitan a pequeñas cuencas, las aproximaciones desarrolladas en este trabajo se aplicaron en grandes cuencas.

Otro aspecto está relacionado con los datos de entrada. Las aplicaciones típicas de RNCs para la estimación a corto plazo de caudales consideran como datos de entrada caudales y precipitaciones en períodos anteriores de tiempo. También, datos de evapotranspiración potencial y/o temperatura del aire se consideran en algunos trabajos. En las aplicaciones realizadas en este trabajo sólo se han considerado datos diarios de caudal (series temporales de caudales) como datos de entrada. Otras medidas, como variables climáticas o características de la cuenca, no se incluyeron porque por un lado no son tan fáciles de obtener como los datos de caudal y, por otra parte, porque los resultados logrados con sólo los datos de caudal suministraron suficiente exactitud.

Asimismo, en las aplicaciones típicas, la calibración y la validación de los modelos de RNCs se lleva a cabo en la misma cuenca donde se requieren las estimaciones de caudal, y normalmente para este propósito se necesita una cantidad suficiente de datos. Esta condición a menudo limita el uso de RNCs. Por esto, el estudio realizado incluyó el análisis del funcionamiento de RNCs con parámetros calibrados en una cuenca dada con una cantidad de datos suficiente en otra cuenca diferente. De este modo, se evaluó la generalidad del modelo y su posible aplicación en cuencas con datos insuficientes.

Junto con las anteriores diferencias señaladas, varios procedimientos con RNCs se combinaron para mejorar las predicciones. De este modo, se evaluó el funcionamiento de modelos de redes neuronales de retropropagación entrenadas con el algoritmo Levenberg-Marquard

(Shepherd, 1997) para la predicción a corto plazo de caudales diarios. Asimismo para comprobar si mejores resultados podían conseguirse, dos variaciones de los modelos típicos de RNCs se probaron: a) Se realizó un proceso de convolución de las variables de entrada al modelo de RNC (De Vries y Principe, 1991); y b) Se desarrolló una metodología híbrida combinando RNC y modelos ARIMA para aprovechar las cualidades de ambas metodologías en el modelado no lineal y lineal, respectivamente (Wedding y Cios, 1996; Hansen y Nelson, 1997; Zhang, 2003).

MATERIAL Y MÉTODOS

Modelos de Redes Neuronales Computacionales

Una red neuronal computacional (RNC) es un modelo heurístico que copia la estructura de un sistema neuronal biológico con el fin de alcanzar una funcionalidad similar. El procesador elemental o neurona es un dispositivo simple de cálculo que, a partir de un vector de entrada del exterior o de otras neuronas, proporciona una única respuesta o salida. En general, una red neuronal consiste en el establecimiento de un conjunto de nodos o neuronas agrupadas en varias capas e interconectadas entre sí (capa de entrada, capas ocultas o intermedias y capa de salida). Las conexiones que unen a las neuronas tiene asociado un peso numérico, y el aprendizaje se realiza con la actualización de tales pesos. Se denomina época al período de tiempo que comprende todas las iteraciones realizadas al presentar todos los patrones (conjunto de datos de entrenamiento o calibración) una sola vez. La actualización de los pesos se realiza al final de cada época.

Para la calibración y validación de los modelos de RNCs se ha utilizado el módulo correspondiente del software STATISTICA 6.0 (Statsoft, Inc., 1984 2002). Para las neuronas de la capa de salida se propuso como función de transferencia de la información entre neuronas la función lineal (l) y para cada neurona de las capas intermedias la función de transferencia logística, también conocida como sigmoide (s). De este modo, para que la respuesta de cada neurona de la red (incluida la salida) se encuentre en el intervalo $[0,1]$ para cualquier entrada $(-\infty, \infty)$, los datos de caudales utilizados en este trabajo se sometieron a un proceso de escalado. El al-

goritmo de aprendizaje seleccionado para la calibración y posterior validación de los modelos es el algoritmo supervisado de segundo orden de Levenberg-Marquardt (LM) (Shepherd, 1997).

El algoritmo de aprendizaje de retropropagación estándar o *backpropagation* (Rumelhart *et al.*, 1986) es el algoritmo supervisado más empleado en sistemas neuronales y su funcionamiento se basa en modificar los valores de los pesos proporcionalmente al gradiente de la función de error con objeto de alcanzar un mínimo local (algoritmo de descenso por el gradiente). Ya que la velocidad de convergencia de este algoritmo es lenta, se han propuesto pasos adicionales para acelerar esta convergencia haciendo uso de información de segundo orden de la función de error, esto es, de sus derivadas segundas o, en forma matricial, de su Hessiano (algoritmos de segundo orden). En el caso particular de una función de error a minimizar cuadrática, el Hessiano puede ser aproximado usando sólo las derivadas primeras de las salidas del sistema neuronal, como hace el algoritmo Gauss-Newton. Ya que este algoritmo puede presentar inestabilidad cuando la aproximación no es definida positiva, el algoritmo LM resuelve este problema introduciendo un término adaptativo, por lo que es recomendado como primera opción a ensayar por muchos autores (Tan y van Cauwenberghe, 1999; Martín-del-Brío y Sanz-Molina, 2001; Anctil y Rat, 2005).

Un aspecto fundamental de una red neuronal es su capacidad de generalizar a través de ejemplos. Por generalización se entiende la capacidad de la red de proporcionar una respuesta correcta ante patrones de comportamiento (conjunto de datos de validación) que no han sido empleados en su entrenamiento o calibración. De este modo, dada una arquitectura de red, ésta deberá entrenarse hasta alcanzar el punto óptimo en el que el error de generalización o validación es mínimo. En este trabajo se ha utilizado un aprendizaje controlado mediante el método de la validación interna (Tsoukalas y Uhrig, 1997; Gutiérrez-Estrada *et al.*, 2004), es decir, que en el proceso de calibración de los modelos neuronales tras entrenar un número de épocas determinado, se recupera el conjunto de pesos que mejores resultados proporciona sobre el conjunto de validación interna (20 % de los datos del conjunto de calibración seleccionados al azar).

Parámetro	Río Tua	Río Côa
Estación hidrométrica	Castanheiro	Cidadelhe
Cuenca principal	Duero	Duero
Latitud	41°14'28"	40°54'49"
Longitud	7°23'25"	7°5'57"
Área de drenaje (km ²)	3718	1685
Descarga media (m ³ /s)	44.80	15.82
$\bar{H}$ (mm) ^a	366±216	360±177
Período de registros	Oct. 1958-Sept. 1996	Oct. 1958-Sept. 1997

^a Media del caudal anual expresado como altura de agua sobre la cuenca (altura de caudal anual medio) y su desviación estándar correspondiente (Portela y Quintela, 2000, 2002a, 2002b, 2005)

Tabla 1. Información general de las cuencas




Figura 1. Etapas: a) Calibración y validación con los registros de caudal diario de la estación de Castanheiro; b) Aplicación del mejor modelo calibrado en Castanheiro para la predicción de caudales diarios en la estación de Cidadelhe

Se probaron RNCs con 1 y 2 capas ocultas y con 2 a 14 nodos en cada una de las capas ocultas. Se seleccionó la red neuronal con el mejor funcionamiento en el período de validación realizando 30 repeticiones del proceso de calibración para cada estructura de RNC (Anctil y Rat, 2005; Pérez-Marín *et al.*, 2006) ya que el conjunto de pesos inicial con el que se empieza el entrenamiento es aleatorio y, por tanto, al final del proceso no se llega a conseguir el mismo conjunto de pesos que mejores resultados proporciona.

Datos e identificación de modelos

La Tabla 1 contiene la identificación de las dos cuencas utilizadas en este estudio así como algunas de sus características. Ambas cuencas pertenecen a afluentes del río Duero (norte de Portugal): el río Tua en la margen derecha y el río Côa en la margen izquierda.

Aunque estas dos cuencas tienen estaciones de medida de caudal (con datos suficientes), sólo los datos de Castanheiro se utilizaron para calibrar y validar los modelos de RNCs, así como para identificar la aproximación con el mejor funcionamiento. Posteriormente, este mejor modelo calibrado fue aplicado a la predicción de los

caudales diarios en la estación hidrométrica de Cidadelhe. El principal objetivo de este procedimiento fue analizar si una RNC con parámetros establecidos para una cuenca dada con una cantidad suficiente de datos, podría también suministrar estimaciones aproximadas en otra cuenca donde los datos disponibles son insuficientes para establecer los parámetros de la red neuronal.

Un esquema del procedimiento de predicción desarrollado se muestra en la Figura 1. Se denomina μ al modelo de red neuronal que tiene el mejor funcionamiento en el período de validación considerando los datos de la estación hidrométrica de Castanheiro y $[\mu]_{\text{Castanheiro}}$ el correspondiente conjunto de parámetros.

Debería indicarse que el esquema del procedimiento representado en la Figura 1 considera un criterio de regionalización de caudales aplicable al régimen hidrológico de Portugal. En varios estudios (Portela y Quintela, 2000, 2002a, 2002b, 2005) se muestra que cuencas portuguesas con alturas próximas de caudal anual medio (*mean annual flow depth*) (la altura de caudal anual medio es igual al caudal anual medio expresado como altura de agua sobre la cuenca) tienen regímenes de caudal diario, mensual y anual con similar variabilidad temporal cuando se expresan

de forma adimensional. De este modo, series adimensionales de caudal diario, mensual y anual en una cuenca dada pueden ser adoptados en otra cuenca siempre que las dos tengan alturas de caudal anual medio semejantes. Como se muestra en la Tabla 1 y en la Figura 1, las alturas de caudal anual medio en las estaciones de Castanheiro y Cidadelhe son muy similares.

Para identificar el modelo μ así como para estimar los parámetros correspondientes $[\mu]_{\text{Castanheiro}}$, se utilizaron 38 años de registros de caudales diarios de la estación hidrométrica de Castanheiro (de octubre de 1958 a septiembre de 1996 – Tabla 1). Este conjunto de datos se dividió en dos subconjuntos, uno para la calibración o entrenamiento de las redes neuronales (30 años de octubre de 1958 a septiembre de 1988) y otro para la validación o generalización de los modelos (8 años de octubre de 1988 a septiembre de 1996).

Los registros de caudales en cuencas portuguesas están disponibles vía Internet en <http://snirh.inag.pt/> (*Sistema Nacional de Informação de Recursos Hídricos, SNIRH*). Esta base de datos fue creada en 1995 por las autoridades portuguesas del agua (*Instituto da Água*) y suministran información relacionada con los caudales de más de 400 estaciones hidrométricas de Portugal.

Red Neuronal Computacional con variables de entrada los caudales de días anteriores (caso 1)

Como se ha mencionado con anterioridad, sólo se consideraron los caudales en días previos como variables de entrada a los modelos. Así, la variable dependiente en cada día t (variable de salida) fue el caudal a estimar en ese día y las variables independientes (variables de entrada) los caudales en días previos ($t-1, t-2$, etc.) (caso 1).

El número de días previos a considerar se determinó mediante el análisis de la función de autocorrelación parcial de la serie de caudales diarios de Castanheiro. La autocorrelación parcial mostró tres puntas significativas en los tres días previos. Esto caracteriza un proceso autorregresivo de orden tres, es decir, que el caudal en cada día puede ser considerado una función de sus propios valores pasados en los tres días previos (Wilson y Keating, 1996). Sin embargo, se evaluaron retrasos de hasta quince días previos para ver si mejoraba el funcionamiento del modelo durante la fase de validación.

Junto con RNCs típicas con datos de entrada

los caudales de días previos (caso 1), otras aproximaciones se evaluaron y compararon como se describe en los apartados siguientes.

Proceso de convolución de las variables de entrada de la Red Neuronal Computacional (caso 2)

Una red neuronal multicapa de retropropagación tiene una arquitectura estática. Para evaluar patrones temporales, la red neuronal debe tener una memoria apropiada que almacene la información pasada. La forma más simple de memoria consiste en una capa de entrada que contenga las variables en varios periodos de tiempo anteriores δ (en este caso, los caudales en los días previos $t-1, t-2$, etc., como se definió como caso 1 en el apartado anterior). Otra metodología es representar la memoria como una convolución de la secuencia de entrada de caudales diarios x_i con una función de suavizado (De Vries y Principe, 1991). En este trabajo se implementó la siguiente función de suavizado triangular (caso 2):

$$\bar{x}_i = \frac{\sum_{\tau=-\delta}^{\delta} R_{t/t-\tau} x_{i-\tau}}{\sum_{\tau=-\delta}^{\delta} R_{t/t-\tau}} \quad \forall i = \delta \text{ to } M - \delta \quad (1)$$

donde M es el número total de observaciones del conjunto de datos de entrenamiento o calibración, y $R_{t/t-\tau}$ es el coeficiente de correlación entre la serie de datos en el tiempo t y en el tiempo $t-\tau$ ($\tau = -\delta, \dots, 1, \dots, \delta$). De este modo, estas series $\bar{x}_i$ se suministran al modelo como datos de entrada durante el proceso de entrenamiento o calibración. Una vez entrenada la red neuronal, se tiene una configuración de pesos que son los que se utilizan en la validación considerando como variables de entrada los caudales diarios de los tres días anteriores (esta aproximación se añadió a la mejor RNC determinada con los entrenamientos del caso 1).

Modelo híbrido Red Neuronal y ARIMA (caso 3)

Frecuentemente se compara el funcionamiento de los modelos ARIMA y RNC en relación con su capacidad predictiva, sin llegar en la mayoría de las veces a aportar conclusiones claras (Zhang, 2003). Los modelos ARIMA asumen que una serie de tiempo es una combinación lineal de sus propios valores pasados y de valores actuales y pasados de un término de error (Box y Jenkins,

1976). En este trabajo se analizó una aproximación híbrida para la estimación de series temporales usando conjuntamente modelos de RNC y ARIMA. El principal objetivo de esta combinación es usar las características de cada modelo para capturar diferentes patrones en los datos. La metodología implementada cuenta con dos fases: a) En primer lugar, se desarrolla una red neuronal para predecir los caudales (en este caso, la mejor red neuronal determinada con los entrenamientos del caso 1); y b) En segundo lugar, un modelo ARIMA se usa para caracterizar los errores del modelo de RNC (Figura 2). El modelo ARIMA ayuda a interpretar la varianza no explicada por el modelo de RNC.




Figura 2. Esquema del modelo híbrido red neuronal-modelo ARIMA

El modelo combinado de RNC y ARIMA se formula como sigue:

$$Q_t = f(Q_{t-1}, Q_{t-2}, \dots, Q_{t-\delta} + \phi^{-1}(B)\theta(B)\eta_t \quad (2)$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (3)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (4)$$

donde f es una función determinada por la estructura de la red neuronal y los pesos de conexión; ϕ_j ($j = 1, \dots, p$) son los parámetros del modelo ARIMA asociados con cada observación previa ε_t (en las aplicaciones realizadas, los errores del modelo RNC); θ_j ($j = 1, \dots, q$) son los parámetros del modelo ARIMA asociados con cada uno de los términos de error previos; B es el operador retroceso que asigna un valor a una variable en el instante previo ($B \varepsilon_t = \varepsilon_{t-1}$ y $B^p \varepsilon_t = \varepsilon_{t-p}$); y η_t es el término de error en el instante t . La transformación de la diferenciación (d) se aplica con frecuencia para eliminar tendencias y estabilizar la varianza antes de fijar los parámetros de un modelo ARIMA.

En el modelo ARIMA (p, d, q) se evaluaron valores de p y q variando de cero a cinco (con intervalos unitarios), y valores de d variando de cero a dos (también con pasos unitarios). Se seleccionaron los valores de p, d , y q en relación con las medidas de evaluación presentadas en el apartado siguiente. La estimación de los parámetros ϕ_j y θ_j se realizó mediante la teoría de los mínimos cuadrados, y se comprobó el nivel de significación de éstos (aceptable si $P_\alpha < 0.05$).

Medidas de evaluación de los modelos (fase de validación)

Se han evaluado diversas medidas de error para asegurar el funcionamiento de las redes neuronales durante la fase de validación y así identificar el mejor modelo μ (Legates y McCabe Jr., 1999; Abrahart y See, 2000). El coeficiente de determinación (R^2) describe la proporción de la varianza total en los datos observados que pueden ser explicados por el modelo. Por otro lado, medidas de varianzas son el porcentaje de error estándar de predicción (*percent standard error of prediction, %SEP*) (Ventura *et al.*, 1995), el coeficiente de eficiencia (E) (Nash y Sutcliffe, 1970; Kitanidis y Bras, 1980) y la varianza relativa media (*average relative variance, ARV*) (Griño, 1992). Estos estimadores no están influenciados por el rango de variación de sus elementos y son empleados para ver hasta donde el modelo es capaz de explicar el total de la variación de los datos.

Asimismo, es apropiado cuantificar el error en términos de las unidades de la variable a estimar. Estas medidas, o medidas de errores absolutos, incluyen la raíz cuadrada del error cuadrático medio (*square root of mean square error, RMSE*) y el error absoluto medio (*mean absolute error, MAE*), dados por:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^N (Q_t - \hat{Q}_t)^2}{N}} = \sqrt{\text{MSE}} \quad (5)$$

$$\text{MAE} = \frac{\sum_{i=1}^N |Q_t - \hat{Q}_t|}{N}$$

donde Q_t es el caudal observado en el tiempo t ; $\hat{Q}_t$ es el caudal estimado en el mismo tiempo t ; y N es el número total de observaciones del conjunto de validación.

El porcentaje de error estándar de predicción, %SEP, se define como:

$$\%SEP = \frac{100}{\bar{Q}} \text{RMSE} \quad (6)$$

donde $\bar{Q}$ es la media de los caudales observados en el conjunto de validación. La principal ventaja de %SEP es su adimensionalidad que permite comparar estimaciones dadas por diferentes modelos. El coeficiente de eficiencia E_j y la varianza relativa media (*average relative variance*, ARV) representan la proporción de la variación de los datos observados considerados por el modelo, y se calculan como:

$$E_j = 1.0 - \frac{\sum_{i=1}^N |Q_t - \hat{Q}_t|^j}{\sum_{i=1}^N |Q_t - \bar{Q}|^j} \quad (7)$$

$$ARV = \frac{\sum_{i=1}^N (Q_t - \hat{Q}_t)^2}{\sum_{i=1}^N (Q_t - \bar{Q})^2} = 1.0 - E_2$$

La sensibilidad de los valores fuera de rango (*outliers*) debido al cuadrado de los términos diferencia se asocia con E_2 o, equivalentemente, con ARV. E_1 (denominado aquí el coeficiente de eficiencia modificado) reduce el efecto de los términos cuadrados. Un valor de cero para E_2 indica que el valor medio observado $\bar{Q}$ es un buen estimador como el modelo, mientras valores negativos indican que la media observada es un mejor estimador que el modelo (Legates y McCabe Jr., 1999).

Para admitir como aceptable la bondad del ajuste, los valores de R^2 y E_j deben aproximarse a uno y los valores de %SEP y ARV a cero.

También el índice de persistencia (*persistence index*, PI) se usó para la evaluación del funcionamiento del modelo (Kitanidis y Bras, 1980):

$$PI = 1 - \frac{\sum_{i=1}^N (Q_t - \hat{Q}_t)^2}{\sum_{i=1}^N (Q_t - Q_{t-L})^2} \quad (8)$$

donde Q_{t-L} es el caudal observado en el tiempo $t - L$ y L es el intervalo de tiempo. En las aplicaciones realizadas L fue igual a uno, ya que sólo se consideraron predicciones para el día siguiente. Un valor de PI de uno indica un ajuste perfecto entre los valores estimados y observados, y un valor de cero es equivalente a decir que el modelo no es mejor que un modelo “naïve”, el cual da siempre como predicción la observación previa. PI está bien diseñado para la evaluación de los modelos aplicados en este trabajo, ya que

los caudales en días previos son las variables de entrada de las redes neuronales. Un valor negativo de PI significaría que el modelo está alterando la información original, mostrando un funcionamiento peor que un modelo “naïve” (Anctil y Rat, 2005).

Otros índices usados para identificar los mejores modelos son el Criterio de Información de Akaike (*Akaike Information Criterion*, AIC) y el Criterio de Información Bayesiano (*Bayesian Information Criterion*, BIC) (Qi y Zhang, 2001), dados por:

$$AIC = \log(MSE) + \frac{2m}{N}$$

$$BIC = \log(MSE) + \frac{m \log(N)}{N} \quad (9)$$

En las ecuaciones previas m es el número de parámetros del modelo. En estas ecuaciones, los primeros términos de los segundos miembros miden la bondad de ajuste del modelo a los datos mientras que los segundos términos fijan una sanción por el exceso de parámetros del modelo. Se selecciona el modelo con valores mínimos de AIC y BIC.

RESULTADOS

Estación hidrométrica de Castanheiro. Selección del mejor modelo μ

La Figura 3 muestra los valores de las medidas de error utilizadas para los mejores modelos de cada uno de los casos evaluados. Se indican las medias y desviaciones estándar de cada una de estas magnitudes, ya que se han efectuado 30 repeticiones de cada uno de los modelos.

Para el caso 1, las mejores estimaciones se consiguieron cuando los caudales de los tres días previos fueron usados como datos de entrada en una red neuronal con 4 nodos en la primera y segunda capas ocultas [RNC(3,4s,4s,1f)] y 200 épocas en el proceso de entrenamiento. En la Figura 3 se distinguen dos conjuntos de resultados contradictorios en relación con el caso 1: algunas de las medidas de evaluación (R^2 , E_1 y E_2) tienden hacia un buen funcionamiento del modelo RNC mientras otras magnitudes (MAE, RMSE, %SEP y PI) sugieren lo contrario (funcionamiento pobre del modelo RNC). Un valor MAE de más de un tercio de la media de os caudales observados en periodo de validación (es decir, mayor que $33.28/3 \approx 11 \text{ m}^3/\text{s}$) indica modelos mediocres.




Figura 3. Representación esquemática de las medias y las desviaciones estándar de las magnitudes de evaluación de los modelos en la estación hidrométrica de Castanheiro (período de validación de octubre de 1988 a septiembre de 1996)

Un análisis detallado de los resultados mostró que el funcionamiento pobre de estos modelos de RNC (*caso 1*) se debió principalmente a la ocurrencia de un “esplazamiento” sistemático entre los caudales observados y estimados, como se muestra en la Figura 4. De este modo, el *caso 1* presenta sistemáticamente predicciones en el día t muy cercanas a los caudales observados en el día $t - 1$ (valores de PI cercanos a cero o incluso negativos y altos valores de MAE, RMSE y %SEP) (Figura 3).

Cuando se complementó el mejor modelo del *caso 1*, con el proceso de convolución de las va-

riables de entrada (*caso 2*) y la metodología híbrida RNC-ARIMA (*caso 3*) se consiguieron mejores funcionamientos en el periodo de validación, especialmente para el *caso 2*. Para todas las medidas de evaluación, se encontraron diferencias significativas entre los *casos 1* y *3* y el *caso 2* (Figura 3). Con el *caso 2* se obtuvieron valores de PI mayores a 0.5 y valores de MAE menores a $6 m^3/s$, lo que significó eliminar el “desplazamiento” sistemático entre los caudales observados y estimados mencionado en el *caso 1* (Figura 4).




Figura 4. Representación punto a punto de los caudales observados y estimados en el periodo de noviembre de 1989 a abril de 1990 (representación ampliada en el intervalo de caudales de 0 a 80 m³/s), y representación de los caudales observados versus los caudales estimados en todo el periodo de validación de las mejores repeticiones de los casos estudiados (estación hidrométrica de Castanheiro)

En el caso 3, las mejores predicciones se consiguieron con un modelo ARIMA(5,0,1) para caracterizar los errores del modelo RNC. Los parámetros ϕ_j y θ_j de este modelo ARIMA tienen un nivel de significación aceptable ($P_\alpha < 0.05$), y los coeficientes de autocorrelación de los errores de predicción no son estadísticamente significativos (es decir, están prácticamente no correlacionados) (Wilson y Keating, 1996). Los

parámetros del modelo ARIMA de la repetición con los mejores resultados son: $\phi_1 = 0.4783^a$; $\phi_2 = -0.1516^a$; $\phi_3 = 0.0746^a$; $\phi_4 = 0.0495^a$; $\phi_5 = 0.0789^a$; $\theta_1 = 0.4014^a$; $^a P_\alpha < 0.05$ (ecuaciones 2 a 4).

La representación de los caudales estimados versus los caudales observados de las mejores repeticiones de los casos estudiados en el periodo de validación se muestra en la Figura 4, junto

con el diagrama punto a punto de caudales observados y estimados de noviembre de 1989 a abril de 1990. El caso 1 presentó la mayor dispersión de la línea 1:1, mientras que los casos 2 y 3 tuvieron un ajuste más próximo a la línea 1:1. El caso 2 presentó el ajuste más cercano entre los caudales observados y estimados sobre todo el rango de caudales. Los casos 1 y 2 generalmente infraestiman los caudales altos mientras que el caso 3 sobreestima estos caudales.

El funcionamiento de los tres casos también se muestra en la Tabla 2, que contiene los valores de las magnitudes de evaluación para el intervalo completo de caudales diarios así como para sucesivos intervalos de caudales. Esta tabla indica que el mejor ajuste entre los caudales diarios observados y estimados ocurre principalmente en el intervalo de 0 a 50 m³/s. En general, las magnitudes de error son bastante aceptables para el intervalo completo de caudales. Es importante resaltar las diferencias del valor de %SEP cuando se calcula de forma global en todo el intervalo completo de caudales (caso 2: valor medio de 66 %) y de forma independiente en los diferentes intervalos de caudales (caso 2: valores medios de 25 %). Estos resultados son lógicos ya que el índice %SEP es inversamente proporcional al valor de la media de los caudales observados que en este caso es de 33.28 m³/s, media muy baja en comparación con los valores punta que llegan a ser de 1300 m³/s. Cuando se consideran diferentes intervalos de caudal, las medidas de evaluación son peores en los intervalos con valores altos de caudal. Este deterioro de los resultados se debe al menor número de datos en los intervalos con valores altos de caudal en

el periodo de calibración de los modelos, lo que dificulta al modelo RNC para “aprender” de las observaciones disponibles.

Con la excepción del caso 2, los valores de PI generalmente señalan una mala bondad de ajuste de los modelos, principalmente debida a la ocurrencia de los “desplazamientos” entre los caudales observados y estimados. En el caso 2, los valores de PI son bastante buenos aunque se aprecia una menor calidad en el intervalo de 0 a 50 m³/s (Tabla 2 y Figura 4), debido también al “desplazamiento” mencionado. El caso 2 estima valores menos extremos que el caso 3, lo cual implica mejores ajustes.

Se han probado modelos ARIMA (p, d, q) de análisis de series temporales para la estimación de los caudales diarios y así comparar los resultados con las aproximaciones neuronales. Se evaluaron valores de p y q variando de cero a cinco (con intervalos unitarios) y valores de d variando de cero a dos (también con pasos unitarios). Las mejores estimaciones se consiguieron con el modelo ARIMA (3,0,0). Los parámetros ϕ_j y θ_j de este modelo ARIMA tienen un nivel de significación aceptable ($P_\alpha < 0.05$), y los coeficientes de autocorrelación de los errores de predicción no son estadísticamente significativos. Los parámetros de este modelo ARIMA (3,0,0) son: $\phi_1 = 0.8934^a$; $\phi_2 = -0.1806^a$; $\phi_3 = 0.2280^a$; $^a P_\alpha < 0.05$. Las tres aproximaciones neuronales probadas (casos 1, 2 y 3) aportaron mejores resultados que el modelo clásico ARIMA de análisis de series temporales. En la Tabla 3 se comparan los valores de las magnitudes de evaluación del modelo ARIMA (3,0,0) y de la mejor aproximación neuronal (caso 2).

Caso	Intervalo ^a (m ³ /s)	R ²	RMSE (m ³ /s)	MAE (m ³ /s)	%SEP	E ₁	E ₂	ARV	PI	AIC	BIC
1	Todos los datos	0.82±0.03	32.26±2.69	8.88±1.83	96.96±8.10	0.76±0.05	0.82±0.03	0.18±0.03	0.03±0.17	3.04±0.07	3.05±0.07
	[0,50)	0.90±0.08	4.48±1.33	3.00±1.40	37.73±11.18	0.87±0.06	0.96±0.02	0.04±0.02	-0.94±1.37	1.30±0.21	1.32±0.21
	[50,150)	0.52±0.02	26.73±4.69	17.57±4.39	35.05±6.15	0.59±0.10	0.69±0.13	0.31±0.13	-0.28±0.53	3.01±0.13	3.06±0.13
	[150,450)	0.41±0.05	96.43±4.45	72.17±3.63	36.87±1.70	0.68±0.02	0.84±0.01	0.16±0.01	0.20±0.07	4.61±0.04	4.61±0.04
	≥ 450	0.004±0.005	290.69±35.56	230.48±30.96	44.81±5.48	0.63±0.05	0.79±0.06	0.21±0.06	-0.04±0.27	7.97±0.10	6.94±0.10
2	Todos los datos	0.92±0.003	21.98±0.30	5.19±0.29	65.95±0.90	0.86±0.01	0.92±0.002	0.08±0.002	0.55±0.01	2.71±0.01	2.72±0.01
	[0,50)	0.96±0.01	2.86±0.11	1.27±0.33	24.05±0.95	0.94±0.01	0.99±0.001	0.01±0.001	0.27±0.06	0.94±0.03	0.96±0.03
	[50,150)	0.71±0.01	15.66±0.57	9.01±0.34	20.54±0.75	0.79±0.01	0.90±0.01	0.10±0.01	0.57±0.03	2.56±0.03	2.61±0.03
	[150,450)	0.54±0.01	75.14±2.64	53.91±2.24	28.73±1.01	0.76±0.01	0.90±0.01	0.10±0.01	0.52±0.03	4.39±0.03	4.39±0.03
	≥ 450	0.24±0.03	186.79±5.86	157.41±5.39	28.80±0.90	0.74±0.01	0.91±0.01	0.09±0.01	0.58±0.03	7.59±0.03	6.56±0.03
3	Todos los datos	0.90±0.02	31.45±2.48	8.52±1.05	94.50±7.47	0.77±0.03	0.83±0.03	0.17±0.03	0.08±0.15	3.02±0.07	3.04±0.07
	[0,50)	0.92±0.02	4.26±0.64	2.72±0.62	35.92±5.40	0.88±0.03	0.97±0.01	0.03±0.01	-0.66±0.53	1.28±0.12	1.30±0.12
	[50,150)	0.40±0.12	26.71±4.34	17.75±3.86	35.03±5.69	0.59±0.09	0.70±0.11	0.30±0.11	-0.27±0.48	3.05±0.12	3.11±0.12
	[150,450)	0.49±0.06	92.85±3.65	69.56±2.51	35.51±1.40	0.70±0.01	0.85±0.01	0.15±0.01	0.26±0.06	4.70±0.03	4.70±0.03
	≥ 450	0.74±0.08	284.46±33.49	221.56±24.20	43.85±5.16	0.64±0.04	0.80±0.05	0.20±0.05	0.01±0.26	8.52±0.09	7.30±0.09

^a Para cada intervalo de caudal se indica el número de registros N: [0,50): N = 2423; [50,150): N = 375; [150,450): N = 100; ≥ 450: N = 21

Tabla 2. Medidas de evaluación para el intervalo completo de caudales y para sucesivos intervalos de caudales (periodo de validación)

Modelo	R^2	RMSE (m ³ /s)	MAE (m ³ /s)	%SEP	E_1	E_2	ARV	PI	AIC	BIC
RNC+convolución (caso 2)	0.92	21.98	5.19	65.95	0.86	0.92	0.08	0.55	2.71	2.72
ARIMA(3,0,0)	0.83	31.33	7.89	94.15	0.78	0.83	0.17	0.09	3.01	3.03

Tabla 3. Comparación de magnitudes de evaluación del modelo ARIMA (3,0,0) y la mejor aproximación neuronal (caso 2) en la estimación de caudales diarios en la estación hidrométrica de Castanheiro (periodo de validación)




Figura 5. Representación punto a punto de los caudales observados y estimados en el periodo de noviembre de 1989 a abril de 1990, y representación de los caudales observados versus los caudales estimados en todo el periodo de validación de la mejor repetición del caso 2 (estación hidrométrica de Cidadelhe)

Validación del caso 2 en la cuenca del río Côa (estación hidrométrica de Cidadelhe)

La mejor aproximación neuronal obtenida en la cuenca del río Tua, con los parámetros determinados en la estación de Castanheiro [μ]_{Castanheiro}, se aplicó en la cuenca del río Côa (estación hidrométrica de Cidadelhe con registro de caudales diarios de 39 años de octubre de 1958 a septiembre de 1997) para evaluar la generalidad del modelo. Como se mencionó con anterioridad, esta transposición/regionalización del modelo se justifica por la similitud de las alturas de caudales anuales medios en las dos estaciones hidrométricas consideradas.

Las medidas de evaluación obtenidas en el periodo de validación en la estación hidrométrica de Cidadelhe fueron las siguientes: $R^2 = 0.86 \pm 0.03$; $RMSE = 12.90 \pm 1.51$ m³/s; $MAE = 5.08 \pm 1.84$ m³/s; $\%SEP = 79.85 \pm 9.32$; $E_1 = 0.73 \pm 0.10$; $E_2 = 0.85 \pm 0.04$; $ARV = 0.15 \pm 0.04$; $PI = 0.35 \pm 0.16$; $AIC = 2.22 \pm 0.09$; $BIC = 2.23 \pm 0.09$.

En la Figura 5 se presentan los caudales dia-

rios estimados versus los caudales diarios observados para la mejor repetición del mejor modelo seleccionado. Esta figura también incluye, como ejemplo, un diagrama punto a punto de los caudales observados y estimados de noviembre de 1989 a abril de 1990.

DISCUSIÓN

En este trabajo se analizó la capacidad de los modelos de redes neuronales computacionales para estimar caudales diarios en grandes cuencas de Portugal, considerando que sólo los datos de caudal de días previos están disponibles para la calibración de los modelos. Las mejores estadísticas de error se consiguieron con un modelo RNC que tiene como datos de entrada los caudales de los tres días previos al de predicción y, que asimismo, se combina con un procedimiento de convolución de la secuencia de datos de entrada mediante una función de suavizado triangular (caso 2). Los resultados obtenidos del caso 2 fueron mejores que los determinados con un entrenamiento autoregresivo típico basado exclu-

sivamente en tener como datos de entrada los caudales de periodos de tiempo anteriores (*caso 1*).

Una red neuronal de retropropagación calibrada tiene una arquitectura (estructura) estática (pesos fijos) y la salida es exclusivamente determinada por el estado presente de las variables de entrada a la red y no por los estados pasados de las neuronas en la red. Aunque se añada memoria a la red neuronal considerando como variables de entrada los caudales en los tres días previos, las estimaciones obtenidas con el *caso 1* en cada día fueron sistemáticamente muy próximas a los caudales observados en el día anterior. Esta circunstancia es probablemente debida a que la correlación entre los caudales observados de dos días consecutivos es, la mayoría de las veces, muy alta ($R = 90.37\%$; $P_\alpha < 0.001$) y, por tanto, cada ocurrencia diaria es altamente responsable de lo que acontezca el día siguiente. Park (1998), Abrahart y See (2000), Pulido Calvo *et al.* (2002, 2003) y Gutiérrez-Estrada *et al.* (2005) también señalaron este “desplazamiento” de un periodo de tiempo entre los valores observados y los resultantes de modelos de regresión múltiple, ARIMA y/o redes neuronales aplicados a la predicción de diferentes tipos de series temporales. Una de las posibles soluciones para evitar este “desplazamiento” es mejorar la capacidad de aprendizaje de los modelos RNC mediante variables de entrada adicionales, tales como otras variables hidrológicas o climáticas relevantes.

El proceso de convolución de las variables de entrada (*caso 2*) se caracterizó por una infraestimación de valores altos de caudal y por un ligero “desplazamiento” en el intervalo de pequeños caudales. Las magnitudes de evaluación mostraron que el *caso 2* tuvo la mejor capacidad para describir la no linealidad inherente a los datos de caudal. La metodología híbrida RNC-ARIMA (*caso 3*) fue en general favorable ya que evitó el “desplazamiento” mencionado, aunque los resultados mostraron peores estimaciones de los caudales máximos y mínimos.

La mala bondad de ajuste de todos los modelos RNCs en los intervalos de altos caudales fue consecuencia del pequeño número de datos observados pertenecientes a estos intervalos. Esta circunstancia es debida al régimen hidrológico altamente irregular de los ríos portugueses, caracterizado por bajos caudales la mayoría de las veces y de forma excepcional por altos caudales en algunos periodos de tiempo. Esta poca cantidad de datos de altos caudales dificulta el

proceso de entrenamiento de las redes neuronales y, por tanto, la capacidad de predicción. Para evitar este problema, podría hacerse uso de datos de entrada distribuidos, es decir, de caudales de más de una estación hidrométrica. De este modo, un mayor número de caudales punta estarían disponibles para la calibración de los modelos. Otra alternativa podría estar basada en el uso de redes neuronales de retropropagación dinámicas. Chiang *et al.* (2004) demostraron el mejor funcionamiento de estos modelos cuando hay registros insuficientes de datos en la fase de calibración.

En el *caso 1*, las medidas de evaluación R^2 , E_j y ARV calculadas en el intervalo completo de caudales indican, en principio, un buen funcionamiento de los modelos, con valores medios de R^2 y E_j mayores a 0.7 y de ARV menores a 0.2. Sin embargo, esta información es contradictoria con la aportada por los errores RMSE, MAE, %SEP y PI. Esto sugiere que es necesario realizar una evaluación multicriterio del funcionamiento de los modelos basada en diferentes magnitudes de error aplicadas a diferentes intervalos de caudales. En general, los valores de las medidas de exactitud para el intervalo completo de caudales no son buenos indicadores de la capacidad de los modelos para predecir caudales punta debido a la gran cantidad de datos de ocurrencia de bajos caudales, como asimismo indican Abrahart y See (2000). Una posible solución a esta situación sería agrupar los datos originales en distintos tipos de eventos hidrológicos, y de este modo, cada grupo sería caracterizado por un modelo independiente (Abrahart y See, 2000).

Los resultados de los índices de evaluación de las aproximaciones neuronales univariantes utilizadas en este trabajo son similares a los obtenidos con las aplicaciones típicas de RNCs para la estimación a corto plazo de caudales considerando como datos de entrada caudales y precipitaciones en periodos anteriores de tiempo, e incluso datos de evapotranspiración potencial y/o temperatura del aire (Hsu *et al.*, 1995; Abrahart y See, 2000; Thirumalaiah y Deo, 2000; Tokar and Markus, 2000; Actil and Rat, 2005). De este modo, se puede concluir que los modelos presentados con sólo datos de caudal suministraron suficiente exactitud y la preferencia de su utilización puede estar justificada al tener un menor requerimiento de datos en comparación con las aplicaciones típicas mostradas en la bibliografía especializada.

También debería indicarse la capacidad del ca-

so 2 para estimar caudales diarios en una cuenca diferente a la utilizada para la calibración de los modelos. Esta propiedad reafirma los resultados de los estudios de regionalización hidrológica desarrollados en ríos portugueses y muestra la capacidad de generalización de los modelos neuronales para su posible aplicación en cuencas con datos insuficientes, aspectos ambos fundamentales en el manejo de recursos hídricos.

CONCLUSIONES

En este trabajo se muestran los modelos neuronales como una herramienta eficaz para la estimación a corto plazo de caudales diarios en grandes cuencas portuguesas utilizando muy pocos requerimientos de datos, sólo los datos de caudal de días previos.

Las estimaciones de caudal diario en otras cuencas con datos insuficientes es posible mediante la combinación de criterios de regionalización hidrológica con los modelos de redes neuronales computacionales.

Los resultados obtenidos junto con la facilidad de implementación de los modelos en cualquier aplicación de propósito general de manejo de recursos hídricos, permiten que los técnicos responsables puedan tener una información estimada para las próximas 24 horas y de esta forma se les puede facilitar la gestión de las operaciones correspondientes.

REFERENCIAS

- Abrahart, R.J., See, L. y Kneale, P.E., (1999). Using pruning algorithms and genetic algorithms to optimize network architectures and forecasting inputs in a neural network rainfall-runoff model. *J. Hydroinformatics*, 1(2), 103–114.
- Abrahart, R.J. y See, L., (2000). Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments. *Hydrol. Process.*, 14, 2157–2172.
- Abrahart, R.J. y See, L., (2002). Multi-model data fusion for river flow forecasting: an evaluation of six alternative methods based on two contrasting catchments. *Hydrol. Earth Syst. Sci.*, 6(4), 655–670.
- Al-Saba, T. y El-Amin, I., (1999). Artificial neural networks as applied to long-term demand forecasting. *Artif. Intell. Eng.*, 13(2), 189–197.
- Álvarez, J. y Bolado, S., (1996). Descripción de los procesos de infiltración mediante redes neuronales artificiales. *Ing. Agua*, 3(2), 39–46.
- American Society of Civil Engineering (ASCE) Task Committee on Application of Artificial Neural Networks in Hydrology, (2000a). Artificial neural networks in hydrology. I: Preliminary concepts. *J. Hydrol. Eng.*, 5(2), 115–123.
- American Society of Civil Engineering (ASCE) Task Committee on Application of Artificial Neural Networks in Hydrology, (2000b). Artificial neural networks in hydrology. II: Hydrologic applications. *J. Hydrol. Eng.*, 5(2), 124–137.
- Anctil, F. y Rat, A., (2005). Evaluation of neural network streamflow forecasting on 47 watersheds. *J. Hydrol. Eng.*, 10(1), 85–88.
- Box, G.E.P. y Jenkins, G.M., (1976). Time series analysis: Forecasting and control, Holden-Day, Oakland, California.
- Cameron, D., Kneale, P. y See, L., (2002). An evaluation of a traditional and a neural net modelling approach to flood forecasting for an upland catchment. *Hydrol. Process.*, 16, 1033–1046.
- Chang, F.-J. y Chen, Y.-C., (2001). A counter propagation fuzzy-neural network modeling approach to real time streamflow prediction. *J. Hydrol.*, 245, 153–164.
- Chiang, Y.-M., Chang, L.-C. y Chang, F.-J., (2004). Comparison of static-feedforward and dynamic-feedback neural networks for rainfall-runoff modeling. *J. Hydrol.*, 290, 297–311.
- De Vries, B. y Principe, J.C., (1991). A theory for neural networks with time delays, *Advances in neural information processing systems* 3, Morgan Kaufmann Publishers, California.
- Duan, Q., Sorooshian, S. y Gupta, V.K., (1992). Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resour. Res.*, 28(4), 1015–1031.
- Duan, Q., Gupta, V.K. y Sorooshian, S., (1993). A shuffled complex evolution approach for effective and efficient global minimization. *J. Optim. Theory Appl.*, 73(3), 501–521.
- Duan, Q., Sorooshian, S. y Gupta, V.K., (1994). Optimal use of SCE-UA global op-

- timization method for calibrating watershed models. *J. Hydrol.*, 158, 265–284.
- French, M.N., Krajewski, W.F. y Cuykendall, R.R., (1992). Rainfall forecasting in space and time using a neural network. *J. Hydrol.*, 137, 1–31.
- Griñó, R., (1992). Neural networks for univariate time series forecasting and their application to water demand prediction. *Neural Network World*, 2(5), 437–450.
- Gutiérrez-Estrada, J.C., de Pedro-Sanz, E., López-Luque, R. y Pulido-Calvo, I., (2004). Comparison between traditional methods and artificial neural networks for ammonia concentration forecasting in an eel (*Anguilla anguilla* L.) intensive rearing system. *Aquacult. Eng.*, 31, 183–203.
- Gutiérrez-Estrada, J.C., de Pedro-Sanz, E., López-Luque, R. y Pulido-Calvo, I., (2005). Estimación a corto plazo de la temperatura del agua. Aplicación en sistemas de producción en medio acuático. *Ing. Agua*, 12(1), 77–92.
- Hansen, J.V. y Nelson, R.D., (1997). Neural networks and traditional time series methods: a synergistic combination in state economic forecasts. *IEEE Tran. Neural Networks*, 8(4), 863–873.
- Hsu, K., Gupta, H.V. y Sorooshian, S., (1995). Artificial neural network modeling of the rainfall-runoff process. *Water Resour. Res.*, 31(10), 2517–2530.
- Jakeman, A.J. y Hornberger, G.M., (1993). How much complexity is warranted in a rainfall-runoff model? *Water Resour. Res.*, 29(8), 2637–2649.
- Kitanidis, P.K. y Bras, R.L., (1980). Real time forecasting with a conceptual hydrological model. 2: Applications and results. *Water Resour. Res.*, 16(6), 1034–1044.
- Kuligowski, R.J. y Barros, A.P., (1998). Experiments in short-term precipitation forecasting using artificial neural networks. *Mon. Wea. Rev.*, 126(2), 470–482.
- Legates, D.R. y McCabe Jr, G.J., (1999). Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. *Water Resour. Res.*, 35(1), 233–241.
- Lorrai, M. y Sechi, G.M., (1995). Neural nets for modelling rainfall-runoff transformations. *Water Resour. Manage.*, 9, 299–313.
- Martín-del-Brío, B. y Sanz-Molina, A., (2001). *Redes neuronales y sistemas borrosos*, Rama, Madrid.
- Mason, J.C., Tem'ne, A. y Price, R.K., (1996). A neural network model of rainfall-runoff using radial basis functions. *J. Recherches Hydrauliques*, 34(4), 537–548.
- Moradkhani, H., Hsu, K., Gupta, H.V. y Sorooshian, S., (2004). Improved streamflow forecasting using self-organizing radial basis function artificial neural networks. *J. Hydrol.*, 295, 246–262.
- Nash, J.E. y Sutcliffe, J.V., (1970). River flow forecasting through conceptual models. I: A discussion of principles. *J. Hydrol.*, 10, 282–290.
- Palazón, J. y García, A., (2004). Modelado de series climatológicas mediante una red neuronal artificial. *Ing. Agua*, 11(1), 41–52.
- Park, H.-H., (1998). Analysis and prediction of walleye pollock (*Theragra chalcogramma*) landings in Korea by time series analysis. *Fisheries Res.*, 38, 1–7.
- Pérez-Marín, D., Garrido-Varo, A., Guerrero, J.E. y Gutiérrez-Estrada, J.C., (2006). Use of artificial neural networks in near-infrared reflectance spectroscopy calibrations for predicting the inclusion percentages of wheat and sunflower meal in compound feedingstuffs. *Appl. Spect.*, 60(9), 1062–1069.
- Portela, M.M. y Quintela, A.C., (2000). A altura do escoamento anual médio numa bacia hidrográfica como parâmetro de regionalização de informação hidrométrica (Mean annual flow height as a regionalization parameter of hydrologic information), 1 Congresso sobre Aproveitamentos e Gestão de Recursos Hídricos em Países de Idioma Português, Rio de Janeiro, Brasil, 218–227.
- Portela, M.M. y Quintela, A.C., (2002a). Assessment of the streamflow characteristics under unavailability of discharge data: the mean annual flow depth over the watershed as a regionalization parameter. The Portuguese case, 2002, EGS Conference, Nice, Francia.
- Portela, M.M. y Quintela, A.C., (2002b). Evaluation of the water resources in Portuguese watersheds without streamflow data. International Conference of Basin Organizations, Madrid, España.

- Portela, M.M. y Quintela, A.C., (2005). Regionalization of hydrologic information: establishment of flow series at ungauged watersheds, *Water Resources Management* 2005, Third International Conference on Water Resources Management, Wessex Institute of Technology, UK, and University of Coimbra, Portugal.
- Pulido-Calvo, I., Roldán, J., López-Luque, R. y Gutiérrez-Estrada, J.C., (2002). Técnicas de predicción a corto plazo de la demanda de agua. Aplicación al uso agrícola. *Ing. Agua*, 9(3), 319–331.
- Pulido-Calvo, I., Roldán, J., López-Luque, R. y Gutiérrez-Estrada, J.C. (2003) Demand forecasting for irrigation water distribution system. *J. Irrig. Drain. Eng.*, 129(6), 422–431.
- Pulido-Calvo, I., Montesinos, P., Roldán, J. y Ruiz-Navarro, F.J., (2005). Estimación de la demanda de agua para riego: Regresiones lineales versus aproximaciones neuronales. *Avances en Recursos Hidráulicos*, 12, 7–19.
- Qi, M. y Zhang, G.P., (2001). An investigation of model selection criteria for neural network time series forecasting. *Eur. J. of Oper. Res.*, 132, 666–680.
- Roger, L.L. y Dowla, F.U., (1994). Optimization of groundwater remediation using artificial neural networks with parallel solute transport modeling. *Water Resour. Res.*, 30(2), 457–481.
- Rumelhart, D.E., Hinton, G.E. y Williams, R.J., (1986). "Learning representations by back-propagation errors. *Nature*, 323, 533–536.
- See, L. y Openshaw, S., (2000). A hybrid multi-model approach to river level forecasting. *Hydrol. Sci. J.*, 45(4), 523–536.
- Shepherd, A.J., (1997). *Second-Order Methods for Neural Networks*, Springer, Nueva York.
- Shin, H-S. y Salas, J.D., (2000). Regional drought analysis based on neural networks. *J. Hydrol. Eng.*, 5(2), 145–155.
- Sorooshian, S., Duan, Q. y Gupta, V.K., (1993). Calibration of rainfall-runoff models: Application of global optimization to the Sacramento soil moisture accounting model. *Water Resour. Res.*, 29(4), 1185–1194.
- Tan, Y. y van Cauwenberghe, A., (1999). Neural-network-based d-step-ahead predictors for nonlinear systems with time delay. *Eng. Applic. Artif. Intell.*, 12(1), 21–25.
- Thirumalaiah, K. y Deo, M.C., (1998). River stage forecasting using artificial neural networks. *J. Hydrol. Eng.*, 3(1), 26–32.
- Thirumalaiah, K. y Deo, M.C., (2000). Hydrological forecasting using neural networks. *J. Hydrol. Eng.*, 5(2), 180–189.
- Tokar, A.S. y Johnson, P.A., (1999). Rainfall-runoff modeling using artificial neural networks. *J. Hydrol. Eng.*, 4(3), 232–239.
- Tokar, A.S. y Markus, M., (2000). Precipitation-runoff modeling using artificial neural networks and conceptual models. *J. Hydrol. Eng.*, 5(2), 156–161.
- Tsoukalas, L.H. y Uhrig, R.E., (1997). *Fuzzy and neural approaches in engineering*, Wiley Interscience, Nueva York.
- Ventura, S., Silva, M., Pérez-Bendito, D. y Hervás, C., (1995). Artificial neural networks for estimation of kinetic analytical parameters. *Anal. Chem.*, 67(9), 1521–1525.
- Wedding II, D.K. y Cios, K.J., (1996). Time series forecasting by combining RBF networks, certainty factors, and the Box-Jenkins model. *Neurocomputing*, 10, 149–168.
- Wilson, J.H. y Keating, B., (1996). *Business forecasting*, Irwin, Londres.
- Yang, C.C., Prasher, S.O., Lacroix, R., Sreekanth, S., Patni, N.K. y Masse, L., (1997). Artificial neural network model for subsurface-drained farmland. *J. Irrig. Drain. Eng.*, 123(4), 285–292.
- Yapo, P.O., Gupta, H.V. y Sorooshian, S., (1996). Automatic calibration of conceptual rainfall-runoff models: sensitivity to calibration data. *J. Hydrol.*, 181, 23–48.
- Zhang, G.P., (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.
- Zhang, M., Fulcher, J. y Scofield, R.A., (1997). Rainfall estimation using artificial neural network group. *Neurocomputing*, 16, 97–115.
- Zhang, G.P., Patuwo, B.E. y Hu, M.Y., (2001). A simulation study of artificial neural networks for nonlinear time-series forecasting. *Comp. Oper. Res.*, 28(4), 381–396.