

TÉCNICAS DE PREDICCIÓN A CORTO PLAZO DE LA DEMANDA DE AGUA. APLICACIÓN AL USO AGRÍCOLA

Inmaculada Pulido-Calvo¹, José Roldán², Rafael López-Luque³ y Juan Carlos Gutiérrez-Estrada¹

Resumen

La demanda de agua es la magnitud de referencia en la gestión óptima de los sistemas de distribución. En este trabajo se propone la estimación de la demanda en las próximas 24 horas en un sistema de distribución de agua para riego, y se utilizan, junto con los métodos tradicionales de predicción de regresión múltiple y de modelos univariantes de series temporales (ARIMA), las Redes Neuronales Computacionales (RNCs). Se dispone de los datos de las demandas diarias de agua de las campañas de riegos 1987/88, 1988/89 y 1990/91 de la zona regable de Fuente Palmera (Córdoba). Los modelos se establecen considerando la relación de los datos presentes y pasados de la demanda, aunque también se analiza la influencia de datos climáticos (temperatura máxima, temperatura media, temperatura mínima, precipitación, humedad relativa, horas de sol y velocidad del viento). Las mejores estimaciones se consiguen con la RNC que considera como variables de entrada las demandas y las temperaturas máximas de los dos días anteriores al de estimación.

Palabras clave: estimación demanda, regresión múltiple, análisis series temporales, red neuronal computacional, sistema de riego, control en tiempo real

INTRODUCCIÓN

Para el control en tiempo real de un sistema de distribución de agua, es fundamental la capacidad de predecir el comportamiento de la demanda. Con esta previsión y unos criterios de gestión determinados, se podrán establecer las estrategias de control del estado de grupos de bombeo, depósitos y válvulas (modo de trabajo previsto del sistema de distribución). Normalmente, este esquema de operación se planifica para las próximas 24 horas, debido a que las curvas de demanda tienen ciclos diarios y a que los intervalos horarios son la base de los sistemas de discriminación de la tarificación de la energía eléctrica (Jowitt y Xu, 1992; León et al., 2000). Cuando se produzcan perturbaciones no controladas se deberá buscar un nuevo óptimo en posiciones próximas al punto de trabajo previsto.

De este modo, en este estudio se propone la estimación de demanda diaria total en las próximas

24 horas en sistemas de distribución de agua. Posteriormente se deberán aplicar el/los perfil/es de demanda horaria correspondientes para tener la distribución temporal. Generalmente, estos modelos van a tener mejores resultados en los sistemas de distribución de agua con depósitos/balsas de regulación, ya que el adaptar las horas de bombeo a la discriminación horaria de los contratos del suministro eléctrico, implica un almacenamiento de agua que suaviza las puntas instantáneas de demanda y, desde el punto de vista de los esquemas de bombeo óptimos, una reducción de la importancia de las puntas de consumo de pequeña duración (Shvartser et al., 1993).

Para resolver la modelación de la demanda a corto plazo en redes urbanas, fundamentalmente se han desarrollado dos técnicas. La primera consiste en establecer modelos matemáticos basados en la correlación entre los datos de demanda y factores demográficos y ambientales (Maidment et al.,

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

² Departamento de Agronomía, ³ Departamento de Física Aplicada, Universidad de Córdoba, ETSIAM, Apdo. 3048, 14080 Córdoba, e-mail: jroldan@uco.es y fallolur@uco.es

Artículo recibido el 3 de septiembre de 2001, recibido en forma revisada el 19 de marzo de 2002 y aceptado para su publicación el 2 de abril de 2002. 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.

1985; Saporta y Muñoz, 1994; Rüfenatch y Guibentif, 1997), mientras que la segunda modela la relación entre datos presentes y pasados de la demanda (análisis estocástico de series temporales) (Coulbeck et al., 1985; Hartley y Powell, 1991; Jowitz y Xu, 1992; Shvartser et al., 1993; Saporta y Muñoz, 1994; Molino et al., 1996; Nel y Haarhoff, 1996). La primera metodología es poco usual, dado que recoger los datos referentes a factores considerados determinantes es igual o si cabe más complicado que recoger los propios datos de consumo, y la inclusión de estos factores se contempla de forma implícita a través de las observaciones de la demanda (Saporta y Muñoz, 1994).

Entre las herramientas generalmente utilizadas para tales fines destacan las regresiones lineales y la metodología de Box-Jenkins de análisis de series temporales (modelos ARIMA), y en este trabajo junto con estos métodos tradicionales de predicción, se propone el uso de Redes Neuronales Computacionales (RNCs) ya que han demostrado conseguir muy buenos resultados en el campo de las técnicas de control inteligente.

Las RNCs están siendo ampliamente utilizadas en el ajuste de funciones y en el modelado de sistemas altamente no lineales, ya que realizan una transformación de este tipo entre los datos de entrada y salida, lo que supone importantes ventajas frente a las metodologías estadísticas convencionales tales como la regresión lineal múltiple o la regresión en componentes principales en las que la relación entre los datos ha de ser lineal. Asimismo, no precisan de una ecuación para la relación empírica entre los datos como así ocurre en otras técnicas estadísticas paramétricas tales como la regresión no lineal o el filtro de Kalman. Por otro lado, se caracterizan por identificar la información relevante sobre una ingente cantidad de datos, discriminando la que es inconsistente, ambigua o incompleta.

Desde principios de la década de los 90, los modelos de RNCs se han aplicado en muchos campos de las ciencias y de la ingeniería, obteniéndose resultados bastante satisfactorios (French et al., 1992; Ranjithan et al., 1993; Rizzo y Dougherty, 1994; Álvarez y Bolado, 1996). Hsu et al. (1995) desarrollaron RNCs para modelar la relación entre la lluvia y la escorrentía de una cuenca, consiguiendo mejores resultados que con los modelos lineales de series temporales ARMAX y que con el modelo físico conceptual SAC-SMA. Thirumalaiah y Deo (2000) mostraron la capacidad de las RNCs en la

estimación del régimen de caudales de un curso de agua, y su importancia en el control y la gestión de cuencas propensas a las inundaciones. El comportamiento de las redes neuronales fue superior que el de los modelos autoregresivos AR y las regresiones múltiples. Raman y Chandramouli (1996) utilizaron las RNCs como una herramienta alternativa a los modelos de regresión para la gestión de embalses de agua. Con una red neuronal, Griño (1992) desarrolló una aproximación para predecir demandas diarias en un sistema urbano de distribución de agua. Los valores de demanda diaria de las dos semanas previas se seleccionaron como entradas a la RNC. Sus resultados mostraron la capacidad de la RNC de identificar la no linealidad de las demandas diarias de agua.

MATERIAL Y MÉTODOS

Área de estudio

Con objeto de contrastar las metodologías desarrolladas en este trabajo, éstas se aplican a la zona regable de Fuente Palmera, con aproximadamente unas 5,000 ha regables pertenecientes a los términos municipales de Fuente Palmera, Hornachuelos, Posadas y Guadalcazar en la provincia de Córdoba, y de Ecija en la provincia de Sevilla. Las necesidades medias de la zona son $16.5 \pm 5.9 \text{ hm}^3$ de agua anuales que es preciso derivar del río Guadalquivir por su margen izquierda.

Se trata de una zona regada por aspersión a la demanda. En el proyecto, el tiempo de aplicación del riego previsto en el período de máximo consumo es de 10 a 11 horas, con dos riegos diarios y un caudal continuo bruto sobre cada hectárea de 0.896 l/s. Pero por ser un sistema a la demanda, la frecuencia de los riegos se adapta a las necesidades en función de los cultivos, de la época del año y de las condiciones climáticas. El agricultor, basándose en su propia experiencia, determina la duración del riego. La duración media de la campaña es de 183 ± 24 días.

Analizando la evolución de los cultivos de mayor extensión superficial e importancia económica de la zona regable desde la campaña de riegos 1984/85 hasta la 1997/98 (Memorias Anuales de la Comunidad de Regantes de Fuente Palmera), la alternativa media de cultivos consta de un 43.31 ± 18.68 % de algodón, 23.78 ± 11.60 % de girasol, 14.30 ± 8.30 % de trigo, 3.37 ± 2.79 % de remolacha, 2.81 ± 3.47 % de olivar, 2.61 ± 3.39 % de ma-

íz, $1.41 \pm 2.52 \%$ de sorgo, $1.23 \pm 1.07 \%$ de cítricos y $1.12 \pm 1.07 \%$ de melón/sandía.

El sistema de impulsión se divide en dos etapas: estación de bombeo de extracción o de toma, y estación de impulsión o de puesta en carga. La primera se realiza hasta un depósito apoyado en el suelo de $5,000 \text{ m}^3$ que se constituye en cámara de aspiración de la segunda impulsión. Este depósito tiene un volumen que no permite el independizar el régimen de funcionamiento de las dos estaciones de bombeo, con lo que su papel se relega a dar presión a la red principal de tuberías que es ramificada y que lleva el agua desde la estación de puesta en carga hasta 78 agrupaciones y, desde aquí, el agua se distribuye a las parcelas mediante una red secundaria enterrada y fija. De la boca de riego situada en cada unidad de explotación, parten los ramales de aspersión.

Predicción de la demanda diaria de agua mediante la aplicación de Redes Neuronales Computacionales (RNCs)

Las Redes Neuronales Computacionales (RNCs) son modelos matemáticos que copian la estructura de los sistemas neuronales biológicos 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 procedente 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. Las conexiones que unen a las neuronas tienen asociado un peso numérico, y el aprendizaje se realiza con la actualización de tales pesos (Figura 1).

Las neuronas de entrada reciben los datos de partida, sin llevar a cabo ninguna operación matemática, solamente transfieren los valores a la siguiente capa. Cada neurona de las capas intermedias (capas ocultas) y de la capa de salida realiza la suma I_j de los valores ponderados sobre los datos que recibe como entrada. De este modo, dado un conjunto de entradas x_{ji} ($i = 1, \dots, q$) en la neurona j , estos valores se multiplican por el conjunto de pesos W_{ji} (conexión del nodo i con el nodo j) (Figura 1).

$$I_j = \sum_{i=1}^q x_{ji} W_{ji} \quad (1)$$

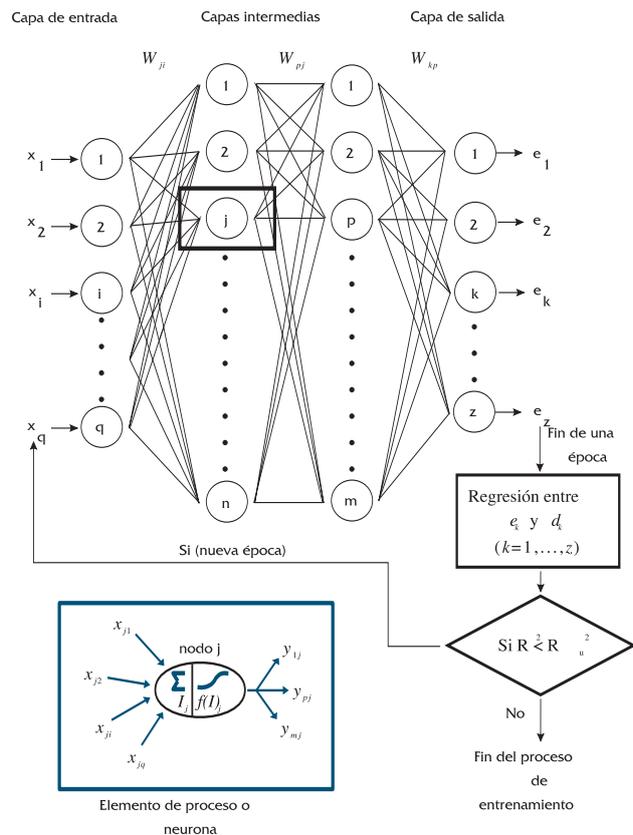


Figura 1. Red neuronal computacional con una capa de entrada de q neuronas, dos capas intermedias de n y m neuronas, respectivamente, y una capa de salida de z neuronas ($q:n:m:z$). Variables de entrada: x_1, \dots, x_q . Variables de salida de la red: e_1, \dots, e_z . Variables deseadas de salida: d_1, \dots, d_z .

Posteriormente la neurona j calcula una respuesta y_{pj} ($p = 1, \dots, m$) con una función de transferencia $f(I_j)$. Esta respuesta es transmitida a cada una de las neuronas p de la siguiente capa, que vuelve a efectuar la misma operación hasta alcanzar a las neuronas de salida (Figura 1). La selección de la función de transferencia de las neuronas es arbitraria, mientras que cumpla la condición de ser una función acotada. En este trabajo, se han utilizado para las neuronas de salida la función lineal (1) y para cada neurona de las capas intermedias la función de transferencia logística, también conocida como sigmoide (s):

$$y_{pj} = f(I_j) = \frac{1}{1 + e^{-I_j}} \quad (2)$$

La ecuación (2) se ha seleccionado sobre la base de que la respuesta de cada neurona de la red (incluida la salida) se encontrará entonces en el intervalo $[0,1]$ para cualquier entrada $(-\infty, \infty)$, lo que es coherente con el escalado de los datos experimentales del que se hace uso en este trabajo:

$$V_b^* = \frac{V_b - V_{min,b}}{V_{max,b} - V_{min,b}} \quad (2)$$

donde V_b^* es la variable adimensional reducida o valor escalado de la variable V_b (variables de entrada y de salida); $V_{min,b}$ es el valor mínimo de la variable V_b minorado en un 15 %; y $V_{max,b}$ es el valor máximo de la variable V_b aumentado en un 15%. Con este porcentaje del 15 % se previene que valores mayores o menores a los utilizados en el entrenamiento o aprendizaje de la red den respuestas inadecuadas en la validación del modelo.

La determinación de un conjunto de pesos que permita a la red realizar el tipo de procesamiento deseado se denomina aprendizaje. Este proceso consiste en un cálculo iterativo en el que un conjunto de pares de datos (entradas-salidas objetivo o patrones de entrenamiento) es procesado, comparando la respuesta calculada por la red con la salida objetivo correspondiente y ajustando los coeficientes de peso de las neuronas para minimizar la diferencia entre la respuesta de la red y la salida objetivo. El algoritmo de aprendizaje utilizado en el presente trabajo es una variación del modelo de retropropagación estándar (Rumelhart et al., 1986), conocido como delta-barra delta extendida (Extended Delta-Bar Delta, EDBD) (Minai y Williams, 1990).

El cambio en el coeficiente de peso $W_{ji}(t)$ del tiempo t al tiempo $t+1$ de la conexión que une la neurona i con la neurona j se calcula iterativamente, a partir de (4) y (5):

$$\Delta W_{ji}(t+1) = \alpha(t) \delta_j(t) y_{ji}(t) + \mu(t) \Delta W_{ji}(t) \quad (4)$$

$$W_{ji}(t+1) = W_{ji}(t) + \Delta W_{ji}(t+1) \quad (5)$$

con $\delta_j(t)$ el término de error de la neurona j en el tiempo t , $\alpha(t)$ un coeficiente de proporcionalidad en el tiempo t denominado tasa o coeficiente de aprendizaje que controla la velocidad con la que converge el algoritmo, y $\mu(t)$ el término de momento en el tiempo t que tiende a mantener los cambios de los pesos en la misma dirección y obviar la permanencia en mínimos locales, para así alcanzar la convergencia rápidamente.

En el algoritmo estándar de retropropagación, el coeficiente de aprendizaje y el término de momento son los mismos para la corrección de todos los pesos de conexión, lo que ocasiona lentitud de convergencia. La evidencia empírica sugiere que

cada dimensión del espacio de pesos puede ser bastante diferente en términos de la superficie de error total; específicamente cada conexión de una red debería tener sus propios coeficientes de aprendizaje y de momento, ya que el tamaño de paso apropiado para una dimensión de peso puede no serlo para todas las otras dimensiones. Por esto, será deseable que estos parámetros varíen con el tiempo para cada conexión, como así se lleva a cabo en el algoritmo EDBD.

Para implementar las reglas heurísticas de aumento o disminución del coeficiente de aprendizaje $\alpha(t)$ y del término de momento $\mu(t)$, se usa una media ponderada del término de error de cada neurona j :

$$\bar{\delta}_j(t) = (1-\theta) \delta_j(t) + \theta \delta_j(t-1) \quad (6)$$

donde θ es un factor de ponderación ($0 < \theta < 1$).

La actualización del coeficiente de aprendizaje se realiza considerando los siguientes aspectos: a) si el componente del término de error actual y la media ponderada del componente del término de error anterior son del mismo signo, se aumenta la tasa de aprendizaje en función del valor absoluto de $\bar{\delta}_j(t)$; b) si por el contrario sus signos son distintos, se disminuye el coeficiente de aprendizaje en una cantidad proporcional a su valor actual: $-\varphi_\alpha \alpha(t)$ (ecuación (7)). Para el término del momento se usa una regla semejante (ecuación (8)):

$$\Delta \alpha(t) = \begin{cases} \kappa_\alpha e^{(\gamma_\alpha |\bar{\delta}_j(t)|)} & \text{si } \bar{\delta}_j(t-1) \delta_j(t) > 0 \\ -\varphi_\alpha \alpha(t) & \text{si } \bar{\delta}_j(t-1) \delta_j(t) < 0 \\ 0 & \text{en otro caso} \end{cases} \quad (7)$$

$$\Delta \mu(t) = \begin{cases} \kappa_\mu e^{(\gamma_\mu |\bar{\delta}_j(t)|)} & \text{si } \bar{\delta}_j(t-1) \delta_j(t) > 0 \\ -\varphi_\mu \mu(t) & \text{si } \bar{\delta}_j(t-1) \delta_j(t) < 0 \\ 0 & \text{en otro caso} \end{cases} \quad (8)$$

siendo κ_α y κ_μ factores de escalado para los coeficientes de aprendizaje y momento, respectivamente; γ_α y γ_μ factores exponenciales para el incremento de estos coeficientes; φ_α y φ_μ factores de decremento. Los valores usados de estos parámetros son: $\theta = 0.7$; $\kappa_\alpha = 0.095$; $\gamma_\alpha = 0.1$; $\varphi_\alpha = 0.1$; $\kappa_\mu = 1$; $\gamma_\mu = 0.05$ y $\varphi_\mu = 0.01$, los cuales aseguran un entrenamiento óptimo en un gran número de casos (Ventura et al., 1995). Asimismo, para evitar grandes osci-

laciones en el espacio de pesos se limitan los valores máximos de $\alpha(t)$ y $\mu(t)$, siendo los recomendados por Minai y Williams (1990) de 2 y 0.9, respectivamente.

Se denomina época al período de tiempo que comprende todas las iteraciones realizadas al presentar todos los patrones una sola vez. La actualización de los pesos se realiza al final de cada época. Un aspecto fundamental es la capacidad de la red neuronal de generalizar a partir de ejemplos. Por generalización se entiende la capacidad de la red de proporcionar una respuesta correcta ante patrones que no han sido empleados en su entrenamiento. De este modo, dada una arquitectura de red, ésta deberá entrenarse hasta alcanzar el punto óptimo en el que el error de generalización es mínimo. En este trabajo se propone un aprendizaje controlado por un coeficiente de determinación umbral (R_u^2) (Pulido-Calvo, 2001). Al final de cada época, se comparan los valores estimados por la RNC y los valores observados mediante una regresión lineal. Si la determinación del coeficiente de esta regresión (R^2) es menor que R_u^2 , se lleva a cabo una nueva época. El proceso de entrenamiento termina cuando R^2 es mayor o igual que R_u^2 (Figura 1). Se prueban diversos valores de R_u^2 y se selecciona el que de un menor error en la generalización.

Las magnitudes utilizadas para medir el error cometido en la fase de generalización son el coeficiente de determinación de la regresión entre los valores observados y los estimados (R^2), el 'porcentaje de error estándar de predicción' (percent standard error of prediction, %SEP) (Ventura et al., 1995) y el 'coeficiente de eficiencia' (E) (Kitanidis y Bras, 1980). El porcentaje de error estándar de predicción para la neurona de salida k viene dado por:

$$\%SEP_k = \frac{100}{\bar{d}_{kg}} \sqrt{\frac{\sum_{g=1}^N (d_{kg} - e_{kg})^2}{N}} \quad (9)$$

donde d_{kg} es la salida deseada k del patrón g ; e_{kg} es la salida estimada por la neurona k para el patrón g ; N es el número total de patrones del conjunto de generalización y \bar{d}_{kg} es el valor medio de las salidas deseadas del conjunto de predicción.

Y el coeficiente de eficiencia se expresa como:

$$E = \frac{S_{obs} - S}{S_{obs}} \quad (10)$$

$$S_{obs} = \sum_{g=1}^N (d_{kg} - \bar{d}_{kg})^2; \quad S = \sum_{g=1}^N (d_{kg} - e_{kg})^2 \quad (11)$$

siendo S_{obs} la medida de la variabilidad de los valores observados frente a la media y S la medida de la asociación entre los valores observados y los estimados. Para admitir como aceptable la bondad del ajuste, los valores de R^2 y E deben aproximarse a 1 y los valores de %SEP a 0.

Aunque una red neuronal de una única capa intermedia puede representar cualquier función continua (Cybenko, 1989), en este trabajo se utilizan redes con dos capas ocultas (aproximador universal de cualquier función: Cybenko, 1989) ya que a priori no se conoce el tipo de relación entre las variables. Asimismo, puede ocurrir que con una sola capa intermedia el número de neuronas ocultas para alcanzar una cierta cota de error sea tan elevado que su aplicación resulte inabordable en la práctica. Se prueban distintas estructuras de la red neuronal y se elige la que de un menor error de generalización.

Se dispone de datos diarios de demanda de agua y climáticos (temperatura máxima, temperatura media, temperatura mínima, precipitación, humedad relativa, horas de sol y velocidad del viento) (estación meteorológica del Aeropuerto, Córdoba) de las campañas de riegos 1987/88, 1988/89 y 1990/91. Los patrones utilizados en el entrenamiento se corresponden con los datos de las temporadas 1987/88 y 1988/89, y en la generalización del modelo con los de la campaña 1990/91. Los modelos propuestos se han llevado a cabo con el programa de simulación de redes neuronales computacionales Redgen V 1.0 (Pulido-Calvo, 2001) para MS Windows® desarrollado en lenguaje MS Visual Basic® y Borland C++®.

Comparación con análisis multivariantes de 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 :

$$e = b_0 + b_1 x_1 + \dots + b_q x_q \quad (12)$$

donde los parámetros b_0, b_1, \dots, b_q representan las contribuciones de cada variable independiente a la

predicción de la variable dependiente. 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).

Con los análisis de regresiones múltiples se someten los datos a un proceso semejante al de las RNCs: 1) elaboración del modelo con los datos de demanda de las campañas de riegos 1987/88 y 1988/89 (modelo descriptivo o calibración del modelo); 2) predicción de la variable dependiente (demanda diaria de agua) usando los datos de la temporada de riegos 1990/91 (validación del modelo), para asegurar que los resultados del modelo son generalizables a la población y que no son específicos de la muestra utilizada en la calibración.

Comparación con modelos univariantes de series temporales (ARIMA)

El modelo ARIMA(P,D,Q) de Box-Jenkins (AutoRegressive-Integrated-Moving Average) (Box y Jenkins, 1976) 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 para simular el comportamiento de la demanda diaria es:

$$(1 - \Phi_1 B - \dots - \Phi_P B^P)(1 - B^D) d_t = (1 - \Theta_1 B - \dots - \Theta_Q B^Q) A_t \tag{13}$$

siendo d_t el valor observado de la demanda diaria de agua en el instante t; A_t la diferencia en valor ab-

soluta entre la demanda observada y estimada en el instante t; B el operador retroceso que asigna a una variable su valor en el instante anterior: $Bd_t = d_{t-1}$ y $B^m d_t = d_{t-m}$; Φ_i ($i = 1, \dots, P$) y Θ_j ($j = 1, \dots, Q$) los parámetros del modelo; y P, D y Q los órdenes del modelo.

Los valores de P, D y Q suelen variar entre 0 y 2 (Moreu, 1999), por lo que para la identificación de los órdenes óptimos se van aumentando cada uno en una unidad y se observa el comportamiento del nuevo modelo con respecto a los demás, eligiendo el que de una mejor aproximación. La estimación de los parámetros Φ_i y Θ_j del modelo descriptivo (campañas de riegos 1987/88 y 1988/89) se realiza mediante la teoría de los mínimos cuadrados, y se ha de comprobar el nivel de significación de éstos (aceptables si $P_\alpha < 0.05$). Estos parámetros se utilizan para la estimación de la demanda diaria en el período de validación (temporada de riegos 1990/91). Este modelo muestra su bondad a través de un análisis de residuos donde se estudian las funciones de autocorrelación de los mismos (Moreu, 1999).

RESULTADOS

Análisis de regresión múltiple

Al aplicar el procedimiento de regresión en la predicción de la demanda diaria de agua mediante las variables independientes representadas por las demandas de los cinco días anteriores al de estimación, en los períodos de calibración y validación se tienen unos resultados aceptables (Tabla 1), y asimismo, se cumplen los supuestos de linealidad del fenómeno medido, homocedasticidad (varianza

Tabla 1. Estimación de la demanda diaria de agua mediante análisis de regresión múltiple con las variables independientes representadas por las demandas de los cinco días anteriores

Resumen de la regresión múltiple en el modelo descriptivo o calibración			
Resumen de la regresión múltiple R = 0.9810; R ² = 0.9624; F(5;219) = 1,119.9; P _α < 0.001; N = 225			
Demanda (t)	Variables independientes	b_i (i = 0,1,...,q)	P_α
	Interceptación (b ₀)	1,847.927	0.1423
	Demanda (t-1)	1.309	0*
	Demanda (t-2)	-0.415	0.0002*
	Demanda (t-3)	0.197	0.0879
	Demanda (t-4)	-0.039	0.7419
	Demanda (t-5)	-0.069	0.3507
Resumen de la regresión en la validación del modelo			
R = 0.8287; R ² = 0.6867; F(1;117) = 256.5; P _α < 0.001; N = 119			
Variable dependiente	Variable independiente	b_i (i = 0,1,...,q)	P_α
Demanda estimada (t)	Interceptación (b ₀)	24,090.34	0.0009*
	Demanda observada (t)	0.80	0*

*Pa < 0.001

Tabla 2. Bondad de ajuste de los análisis de regresión múltiple

Modelo (variables independientes)	Nº pará- metros	Calibración		Validación						
		R	R ²	R	R ²	F*	%SEP	E	Test t _{ts}	
									t _{ts}	P _α
Demandas 5 días an- teriores	6	0.9810	0.9624	0.8287	0.6867	F(1;117)= 256.50	35.92	0.642	-0.144	0.886
Demandas 2 días an- teriores	3	0.9806	0.9615	0.8462	0.7161	F(1;117)= 295.07	33.89	0.681	-0.268	0.789
Climatología 5 días anteriores	36	0.7913	0.6262	0.8145	0.6633	F(1;142)= 279.80	38.14	0.629	-1.836	0.068
Temperaturas máxi- ma, media y mínima día anterior	4	0.7843	0.6152	0.8205	0.6732	F(1;142)= 292.45	36.32	0.663	-1.256	0.211
Demandas y temperaturas máximas 2 días anteriores	5	0.9851	0.9703	0.8512	0.7245	F(1;117)= 307.73	32.84	0.701	0.807	0.422

*Pa < 0.001

constante del término de error), independencia de los términos de error y normalidad de la distribución del término de error.

Como sólo dos de las variables independientes (demandas de los dos días anteriores) son estadísticamente significativas ($P_{\alpha} < 0.05$) (Tabla 1), éstas explican una parte significativa de la varianza de la variable dependiente y, por tanto, se repite el análisis de regresión múltiple para estimar la demanda diaria de agua a partir sólo de las demandas de los dos días anteriores, obteniendo mejores resultados en la validación tanto en el coeficiente de correlación (R), como en los errores (%SEP) y en las eficiencias (E) correspondientes. Asimismo, ambos modelos de regresión no presentan diferencias significativas (test de Student t_{st} ; $P_{\alpha} > 0.05$) entre los valores estimados y observados en validación (Tabla 2).

Si se consideran como variables independientes los datos climáticos (temperatura máxima, temperatura media, temperatura mínima, precipitación, humedad relativa, horas de sol y velocidad del viento) de los cinco días anteriores para estimar la demanda diaria de agua, se obtienen peores resultados que en los casos precedentes, al igual que si se repite el análisis de regresión sólo con las variables climáticas que resultan significativas (temperaturas máxima, media y mínima del día anterior) (Tabla 2).

Por último, se plantea el análisis de regresión múltiple en la estimación de la demanda diaria de agua a partir de las demandas y las temperaturas máximas de los dos días anteriores, ya que las tem-

peraturas son las variables climáticas significativas y en algunas predicciones de la demanda de agua en redes urbanas se busca la relación de ésta con la variable externa temperatura. En este caso, se elige arbitrariamente la temperatura máxima ya que el análisis de redundancia de los datos de temperaturas máximas, mínimas y medias muestra la alta multicolinealidad de estas variables. Se consiguen los mejores resultados de la estimación con este último modelo ya que en validación se tiene el mayor coeficiente de determinación y la menor magnitud de error (Tabla 2 y Figura 2).

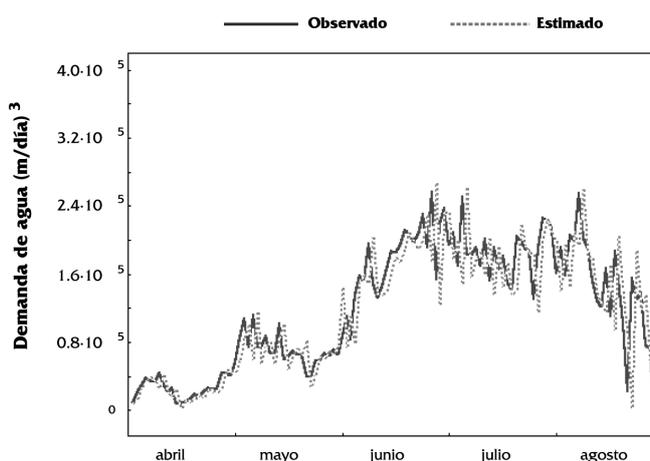


Figura 2. Demandas diarias de agua observadas y estimadas en el período de validación considerando en el análisis de regresión múltiple las variables independientes demandas y temperaturas máximas de los dos días anteriores

Redes Neuronales Computacionales

En el modelo de red neuronal que considera como entradas las demandas de agua de los cinco días anteriores se han evaluado diseños de red desde (5:2s:2s:11) hasta (5:12s:12s:11) con incrementos de un nodo en cada capa oculta, coeficientes de determinación umbral R_u^2 desde el 80 % hasta el 96 % con incrementos del 1 %, y los mismos patrones en la calibración (entrenamiento en el caso de RNC) y la validación (generalización en el caso de RNC) que en la regresión múltiple que estima la demanda diaria de agua mediante las variables independientes demandas de agua de los cinco días anteriores. Se elige la red neuronal con la menor magnitud de error y, a su vez, que no presente diferencias significativas entre los valores observados y los estimados en la validación del modelo. A título de ejemplo, se muestran en la Tabla 3 algunos de los casos analizados. Los mejores resultados se obtienen con la arquitectura (5:10s:10s:11) con un entrenamiento controlado por $R_u^2 = 0.94$. Asimismo, no se tienen diferencias significativas (test t_{st} : $P_\alpha > 0.05$) entre los valores observados y los estimados, aunque si las hay entre los coeficientes de correlación R de la RNC y la regresión múltiple en la generalización (test R: $P_\alpha < 0.05$).

Es interesante resaltar el comportamiento de las redes neuronales en la generalización en función del error que se quiere alcanzar en el entrenamiento. Si por ejemplo en la Tabla 3 nos fijamos en la red (5:8s:8s:11), a mayores valores de R_u^2 se obtienen mejores ajustes, llegando al óptimo cuando $R_u^2 = 95$ %, que además presenta diferencias significativas entre los coeficientes de correlación de la red neuronal y la regresión múltiple. De este modo, se aprecia como la red neuronal se adapta progresivamente al conjunto de aprendizaje y mejora la generalización. Con $R_u^2 = 96$ % ya el sistema se ha

ajustado demasiado a las particularidades de los patrones empleados en el entrenamiento, por lo que se tienen mayores errores y diferencias significativas entre los valores observados y los estimados ante patrones diferentes (Figura 3).

En los modelos de red neuronal que consideran como entradas las demandas de agua de los dos días anteriores al de estimación, y las demandas y las temperaturas máximas de los dos días anteriores, los intervalos considerados en la arquitectura son de (2:2s:2s:11) hasta (2:12s:12s:11) y de (4:5s:5s:11) hasta (4:15s:15s:11), respectivamente, y en el coeficiente de determinación umbral del 80 % hasta el 96 % con incrementos del 1 %. Si las entradas a la RNC son los datos climáticos de los cinco días anteriores, y las temperaturas máxima, media y mínima del día anterior, se han evaluado arquitecturas desde (35:5s:5s:11) hasta (35:15s:15s:11), y desde (3:5s:5s:11) hasta (3:17s:17s:11), respectivamente, y coeficientes de determinación umbral del 60 % al 90 %. En la Tabla 4 se presenta la bondad del ajuste de las redes neuronales que dan los mejores resultados para cada uno de los modelos considerados. La mejor estimación se consigue con la red neuronal que tiene como entradas las demandas y las temperaturas máximas de los dos días anteriores con doce nodos en cada capa oculta y un coeficiente de determinación umbral del 94 %.

En todos los modelos se consiguen mejores estimaciones con las redes neuronales que con las regresiones múltiples, a excepción del modelo que considera como variables de entrada a la red (o variables independientes de la regresión múltiple) las temperaturas máxima, media y mínima del día anterior al de estimación. Sólo se obtienen diferencias significativas entre los coeficientes de correlación de la red neuronal y de la regresión múltiple en los

Tabla 3. Resultados del entrenamiento y generalización de las redes neuronales computacionales considerando como entradas las demandas de agua de los cinco días anteriores

Red	Nº Parámetros	Entrenamiento			Generalización						
		R_u^2	Épocas	Tiempo	R^2	F(1;117)	%SEP	E	Test t_s		Test R
									t_{st}	P_α	P_α
(5:8s:8s:11)	112	0.90	14	24s	0.7882	435.35	45.08	0.435	-9.535*	0*	0.042*
(5:8s:8s:11)	112	0.94	145	4min, 3s	0.7772	408.02	28.59	0.773	-1.342	0.182	0.065
(5:8s:8s:11)	112	0.95	72	2min, 1s	0.7847	426.38	28.19	0.779	-1.261	0.210	0.049*
(5:8s:8s:11)	112	0.96	565	15min, 23s	0.7498	350.61	31.15	0.730	-2.717*	0.008*	0.157
(5:10s:10s:11)	160	0.90	1	2s	0.8036	478.76	38.84	0.581	-8.101*	0*	0.021*
(5:10s:10s:11)	160	0.94	26	58s	0.8071	489.66	26.48	0.805	-0.353	0.725	0.017*
(5:10s:10s:11)	160	0.95	48	1min, 41s	0.7894	438.52	27.81	0.785	-1.048	0.297	0.040*
(5:12s:12s:11)	216	0.94	11	31s	0.8047	482.04	26.61	0.803	-0.608	0.545	0.016*
(5:12s:12s:11)	216	0.95	66	2min, 51s	0.7803	415.48	29.14	0.764	-2.787*	0.006*	0.059

* $P_\alpha < 0.05$ ** $P_\alpha < 0.001$

TÉCNICAS DE PREDICCIÓN A CORTO PLAZO DE LA DEMANDA DE AGUA. APLICACIÓN AL USO AGRÍCOLA

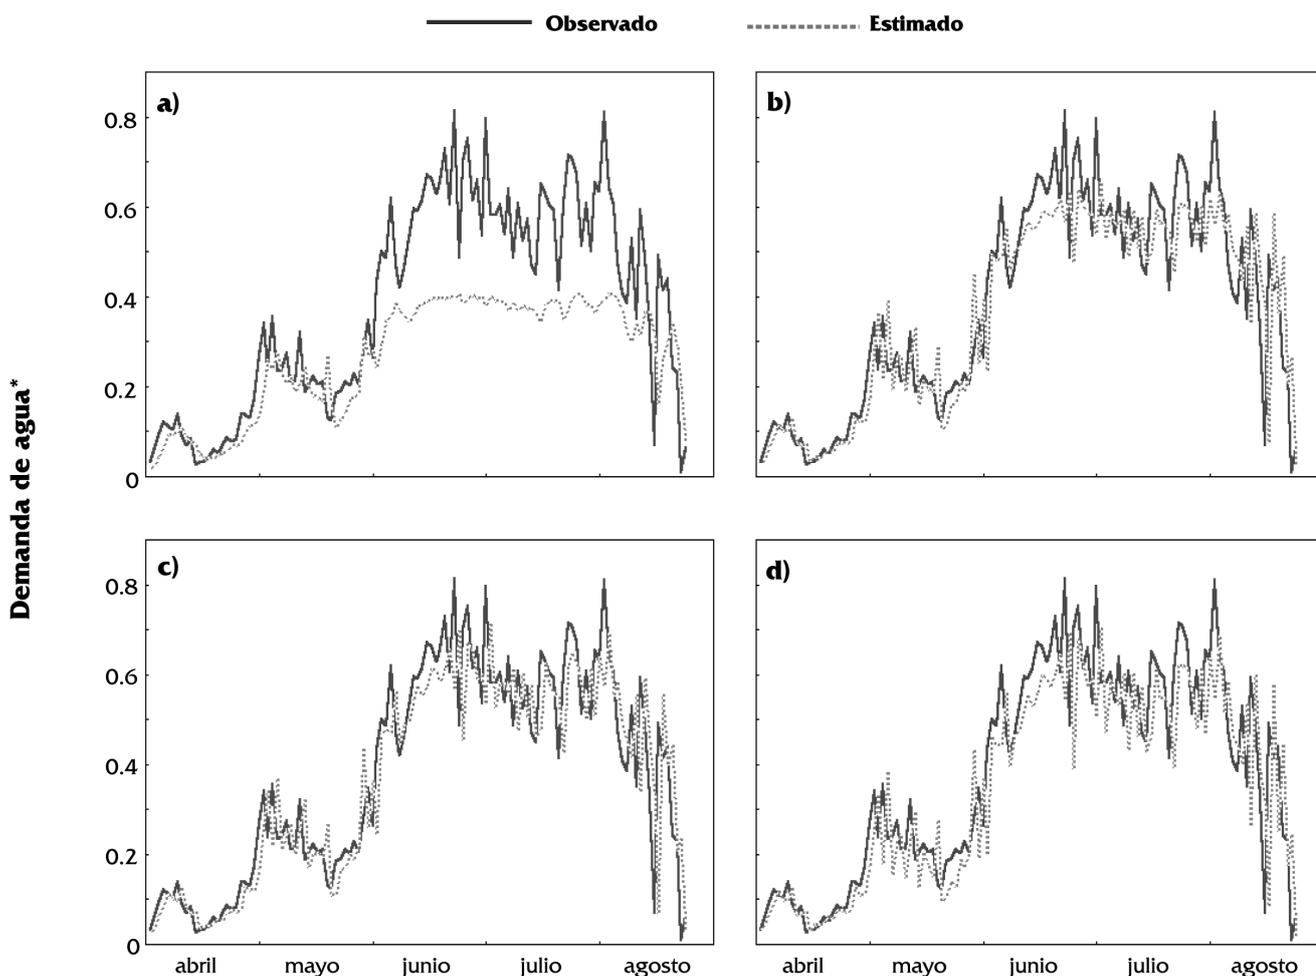


Figura 3. Demandas diarias de agua observadas y estimadas (valores escalados) en validación por la red neuronal (5:8s:8s:11) con entradas las demandas de los cinco días anteriores y entrenamientos controlados por: a) $R_u^2 = 0.90$; b) $R_u^2 = 0.94$; c) $R_u^2 = 0.95$; d) $R_u^2 = 0.96$

Tabla 4. Bondad de ajuste de las redes neuronales computacionales que dan los mejores resultados para los modelos considerados

Modelo (variables entrada)	Red	Nº Pará- metros	Entrenamiento			Generalización						
			R_u^2	Épocas	Tiempo	R^2	F^{**}	%SEP	E	Test t_s		Test R
										t_{st}	P_α	P_α
Demandas 5 días anteriores	(5:10s:10s:11)	160	0.94	26	58s	0.8071	$F(1;117)$ =489.66	26.48	0.805	-0.353	0.725	0.017*
Demandas 2 días anteriores	(2:10s:10s:11)	130	0.94	26	54s	0.8081	$F(1;117)$ =492.68	26.44	0.806	-0.795	0.428	0.045*
Climatología 5 días anteriores	(35:13s:13s:11)	637	0.75	237	25min, 35s	0.6808	$F(1;142)$ =302.93	35.62	0.676	-0.580	0.563	0.393
Temp. máxi- ma, media y mínima día anterior	(3:15s:15s:11)	285	0.64	2044	2h, 17min, 53s	0.6617	$F(1;142)$ =277.72	36.61	0.658	-0.561	0.576	0.429
Dem. y temp. máx. 2 días anteriores	(4:12s:12s:11)	204	0.94	10	24s	0.8218	$F(1;117)$ =539.39	25.50	0.819	-0.506	0.614	0.031*

* $P_\alpha < 0.05$ ** $P_\alpha < 0.001$

modelos función de los datos de demanda y de los datos de demanda y de temperatura máxima de los dos días anteriores. Las RNCs estiman valores menos extremos que las regresiones múltiples, lo que supone mejores ajustes debido al desplazamiento (adelanto de un día) de las curvas estimadas sobre las observadas (Tablas 2 y 4; Figuras 2 y 4).

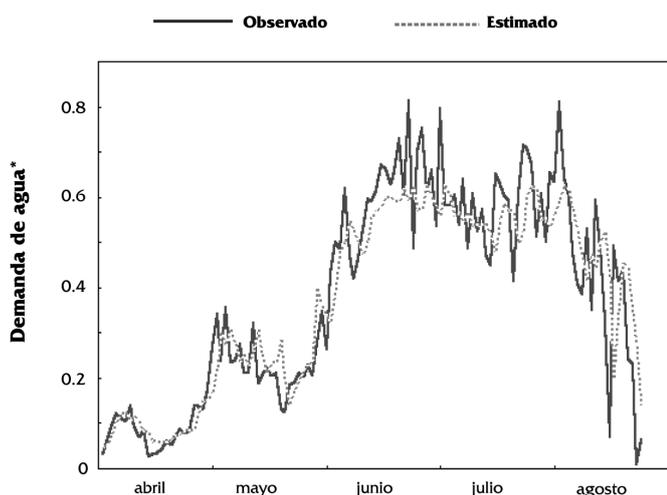


Figura 4. Demandas diarias de agua observadas y estimadas (valores escalados) en validación considerando como variables de entrada de la RNC las demandas y temperaturas máximas de los dos días anteriores

Modelos ARIMA de series temporales

En la Tabla 5 se presentan los resultados de los modelos ARIMA(P,D,Q) cuyos parámetros tienen un nivel de significación aceptable ($P_\alpha < 0.05$) y no presentan diferencias significativas (test t_{st} : $P_\alpha > 0.05$) entre los valores observados y los estimados en validación. Las mejores estimaciones se consiguen con el modelo ARIMA(1,1,2) que ade-

más de presentar la menor magnitud de error, los coeficientes de autocorrelación de los errores de predicción no son estadísticamente significativos, es decir, están prácticamente no correlacionados (Figura 5). El modelo ARIMA(1,1,2) tiene una magnitud de error en validación de 1.31 puntos mayor que la mejor red neuronal y de 6.03 puntos menor que la mejor regresión múltiple. Asimismo el modelo ARIMA no presenta diferencias significativas en el coeficiente de correlación con la RNC ($P_\alpha = 0.1642$), y si las tiene con la regresión múltiple ($P_\alpha = 0.0017$).

DISCUSIÓN

En este trabajo se muestra el potencial de las redes neuronales computacionales en el control en tiempo real de los volúmenes diarios a bombear en redes de distribución de agua para riego, ya que son buenas estimadoras de la demanda diaria al encontrarse durante la generalización correlaciones del 90.65 % y magnitudes de error del 25.5 %, cuando las variables de entrada a la red son las demandas y las temperaturas máximas de los dos días anteriores al de estimación, con doce nodos en cada una de las capas ocultas y un coeficiente de determinación umbral del 94 %. Las RNCs son superiores (menor magnitud de error %SEP y mayor coeficiente de eficiencia E) en la estimación de la demanda diaria de agua a las regresiones múltiples y a los análisis univariantes de series temporales (modelos ARIMA). Las RNCs muestran también superioridad en el coeficiente de correlación R con respecto a las regresiones múltiples. Sin embargo, el mejor modelo ARIMA tiene un R mayor que la mejor RNC, pero estadísticamente no hay diferencias significativas. Estos resultados son semejantes a los obtenidos por Thirumalaiah y Deo (2000) en la estimación del régimen de caudales de un río.

Tabla 5. Bondad de las estimaciones de los modelos ARIMA de series temporales

Modelo	Parámetros	Validación					Test t_{st}	
		R^2	F^{**}	%SEP	E	t_{st}	P_α	
ARIMA (1,0,0)	$\Phi_1 = 0.9669^*$	0.7823	F(1;143)=513.80	30.24	0.772	1.370	0.173	
ARIMA (2,0,0)	$\Phi_1 = 0.5754^*$; $\Phi_2 = 0.4049^*$	0.8134	F(1;143)=623.17	27.66	0.809	0.912	0.363	
ARIMA (1,0,1)	$\Phi_1 = 0.9951^*$; $\Theta_1 = 0.5587^*$	0.8211	F(1;143)=656.22	26.98	0.819	0.731	0.466	
ARIMA (1,1,0)	$\Phi_1 = -0.4148^*$	0.8580	F(1;142)=858.07	27.66	0.805	0.052	0.958	
ARIMA (0,1,1)	$\Theta_1 = 0.5640^*$	0.8574	F(1;142)=853.48	26.92	0.815	0.236	0.814	
ARIMA (1,1,2)	$\Phi_1 = -0.9627^*$; $\Phi_2 = -0.3918^*$; $\Theta_2 = 0.4987^*$	0.8577	F(1;142)=856.17	26.81	0.816	0.200	0.842	
ARIMA (2,2,0)	$\Phi_1 = -0.9219^*$; $\Phi_2 = -0.3499^*$	0.7227	F(1;141)=367.41	34.98	0.680	-0.107	0.915	
ARIMA (1,2,0)	$\Phi_1 = -0.6862^*$	0.6997	F(1;141)=328.58	37.30	0.636	-0.065	0.949	
ARIMA (0,2,2)	$\Theta_1 = 0.7209^*$; $\Theta_2 = 0.2786^*$	0.7150	F(1;141)=353.68	35.30	0.674	-0.284	0.777	

* $P_\alpha < 0.05$ ** $P_\alpha < 0.001$

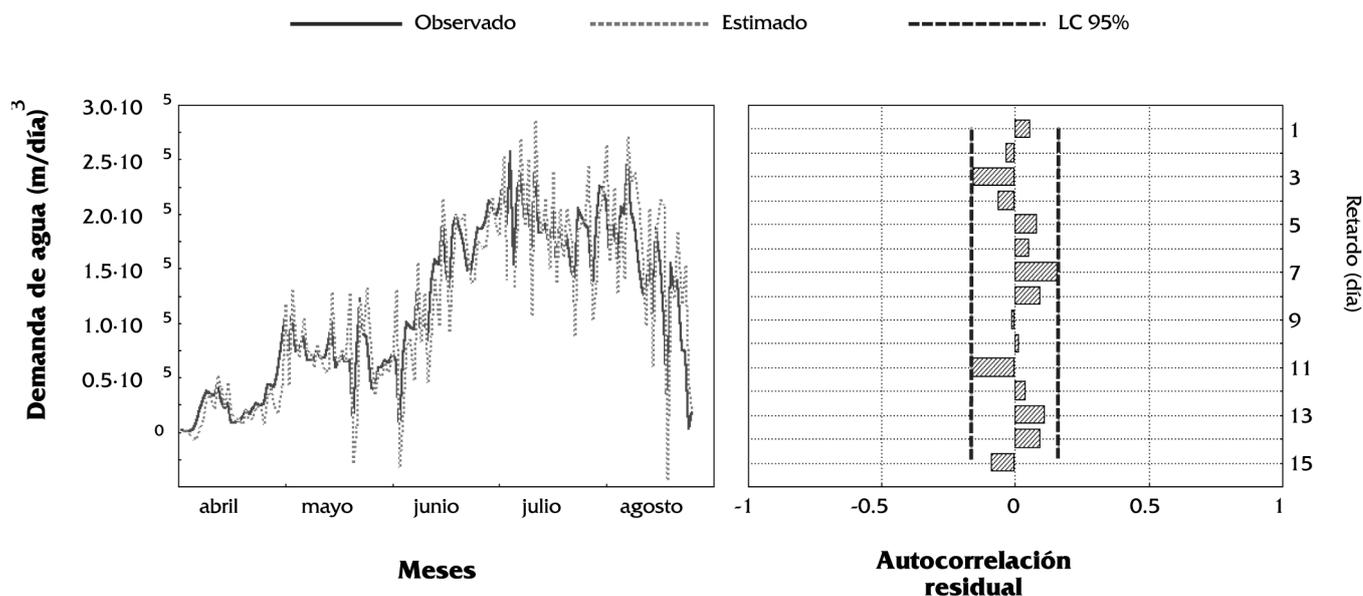


Figura 5. Demandas diarias de agua observadas y estimadas, y autocorrelación residual en validación según el modelo de series temporales ARIMA(1,1,2) (LC 95% = límite de confianza al 95 %)

Si a priori parecería evidente que una lluvia condicionaría el uso de agua de riego en la modelación a corto plazo, los resultados de la regresión múltiple considerando como variables independientes los datos climáticos muestran que sólo son variables significativas las temperaturas máxima, media y mínima del día anterior. Esto se debe a la escasa precipitación de las campañas de riego estudiadas, y por tanto, podría ser muy interesante analizar en futuros trabajos campañas de riego con períodos de lluvia más abundantes para así evaluar la sensibilidad de la variable precipitación. Por otro lado, los resultados obtenidos pueden indicar que la inclusión del factor precipitación se contempla de forma implícita en las observaciones de la demanda de agua (Saporta y Muñoz, 1994).

En los modelos de RNC y de regresión múltiple se tienen las curvas estimadas desplazadas (adelanto de un día) con respecto a las curvas observadas, pero la RNC estima valores menos extremos, es decir, más centrados alrededor de un valor medio, lo que supone principalmente una infraestimación de los valores altos de demanda. Esto puede ser consecuencia de la falta de valores de esas características en el conjunto de datos de entrenamiento, como igualmente sugieren Yang et al. (1997) que señalan la importancia de la calidad de este conjunto. El desplazamiento anteriormente citado se debe a que la variable demanda de agua del día anterior es la que muestra la mayor significación en los análisis de la varianza. Asimismo, el modelo ARIMA(1,1,2) no presenta este desplaza-

miento (ya que incluye en su formulación los errores de la predicción), pero la estimación de los valores extremos máximos y mínimos se aleja de los valores observados, como también les ocurre a Hsu et al. (1995) en la simulación de la escorrentía. Estos resultados sugieren que cuando las curvas de demanda sean más uniformes (es decir, no presenten continuas y bruscas variaciones de las demandas de dos días consecutivos) las estimaciones de los tres métodos serán similares, y consecuentemente, se debería utilizar la regresión múltiple al ser el análisis más simple e intuitivo.

El número de épocas empleado durante el entrenamiento de las RNCs ha sido sensiblemente inferior a los obtenidos por otros autores (Ranjithan et al., 1993; Rizzo y Dougherty, 1994; Álvarez y Bolado, 1996). Estas diferencias pueden deberse a que se estimen diferentes parámetros, y a que en este trabajo se ha utilizado una variante del modelo de retropropagación estándar (EDBD) como algoritmo de aprendizaje, que aumenta el ritmo de aprendizaje efectivo en determinadas direcciones.

El método de entrenamiento propuesto en función de coeficientes de determinación umbrales se ha mostrado muy eficiente durante la generalización, ya que las redes han proporcionado una respuesta correcta ante patrones que no han sido empleados en el entrenamiento, es decir, no se incurre en un sobreajuste de los ejemplos presentados durante la fase de calibración, como igualmente concluyen Gutiérrez-Estrada et al. (2000).

El principal problema asociado a las RNCs desarrolladas en este trabajo ha sido la identificación de la arquitectura y del coeficiente de determinación umbral que implican un menor error de generalización. Esto ha supuesto un mayor tiempo de procesamiento de los datos en comparación con las otras técnicas alternativas. Siendo los sistemas neuronales modelos heurísticos, no se pueden dar reglas concretas sobre el control de la convergencia, del diseño de la red, y de la inicialización y cambio de pesos para resolver un problema concreto. En la bibliografía lo único que se encuentra son unas cuantas pautas generales deducidas de la experiencia de numerosos autores. Por ello, es necesario conocer de antemano la naturaleza de la situación problema, condición no necesaria en otros muchas técnicas estadísticas de predicción. Por esto, en este trabajo se inician los análisis con la regresión múltiple, la cual identifica las variables independientes que influyen significativamente sobre la variable dependiente, al igual que otros autores realizan análisis de componentes principales para el preprocesamiento de los datos (Ventura et al., 1997) o calculan el máximo retraso de las variables de entrada usando la metodología de Box-Jenkins (Griño, 1992).

CONCLUSIONES

Las Redes Neuronales Computacionales se han mostrado buenas estimadoras de la demanda diaria de sistemas de distribución de agua para riego, considerando como variables de entrada las demandas y las temperaturas máximas de los dos días anteriores al de estimación. Sus resultados son superiores a los obtenidos con las regresiones múltiples y con los modelos ARIMA de series temporales. Actualmente se está trabajando en la influencia en la estimación de datos de cultivos (superficies y coeficientes de cultivo) y en la sensibilidad de la variable precipitación al considerar campañas de riego con distintos episodios de lluvia.

Los resultados obtenidos sobre el control de la convergencia, del diseño de la red, de los pesos y de las variables significativas pueden servir de pauta para facilitar la aplicación de los modelos de redes neuronales en la estimación de la demanda diaria de agua en otras zonas regables.

Esta caracterización de la demanda a corto plazo tiene como objetivo principal su utilización como entrada en métodos y/o programas de gestión en tiempo real de sistemas de distribución de agua,

pero asimismo, supone un mejor ajuste de los volúmenes a bombear con la demanda real de la red de distribución y, por consiguiente, un uso más racional de los recursos de agua y de energía.

LISTA DE SÍMBOLOS

A_t	diferencia en valor absoluto entre la demanda observada y estimada en el instante t ;
B	operador retroceso;
b_i	parámetro i de la regresión múltiple;
D	orden del factor diferenciación;
\bar{d}_{kg}	salida observada k del patrón g ;
d_{kg}	valor medio de las salidas observadas del conjunto de predicción;
E	coeficiente de eficiencia;
e	variable dependiente;
e_{kg}	salida estimada por la neurona k para el patrón g ;
F	estadístico de Snedecor;
$f()$	función de transferencia;
I_j	suma ponderada de los datos de entrada en la neurona j ;
I	función de transferencia lineal;
S	medida de la asociación entre los valores observados y estimados;
s	función de transferencia sigmoide;
S_{obs}	medida de la variabilidad de los valores observados de la media;
SEP	error estándar de predicción;
N	número total de patrones;
P	número de parámetros autorregresivos;
P_α	nivel estadístico de significación;
Q	número de parámetros de medias móviles;
R	coeficiente de correlación;
R^2	coeficiente de determinación;
R_u^2	coeficiente de determinación umbral;
RNC	red neuronal computacional;
t	tiempo;

REFERENCIAS

- ÁLVAREZ, J. y S. BOLADO (1996) Descripción de los procesos de infiltración mediante redes neurales artificiales. *Ingeniería del Agua*, 3: 39-46.
- BOX, G.E.P. y G.M. JENKINS (1976) *Time series analysis: forecasting and control*. Holden-Day, San Francisco, CA.
- CYBENCO, G. (1989) Approximation by superpositions of a sigmoidal function. *Math. Controls, Signals, and Systems*, 2: 303-314.
- COULBECK, B., S.T. TENNANT y C.H. ORR (1985) Development of a demand prediction program for use in optimal control of water supply. *Systems Sci.*, 11: 59-66.

- FRENCH, M.N., W.F. KRAJEWSKI y R.R. CUYKENDALL (1992) Rainfall forecasting in space and time using a neural network. *J. Hydrol.*, 137: 1-31.
- GRIÑO, R. (1992) Neural networks for univariate time series forecasting and their application to water demand prediction. *Neural Network World*, 437-450.
- GUTIÉRREZ-ESTRADA, J.C., I. PULIDO-CALVO y J. PRENDA (2000) Gonadosomatic index estimates of an introduced pumpkinseed (*Lepomis gibbosus*) population in a Mediterranean stream, using computational neural networks. *Aquat. Sci.*, 62: 350-363.
- HAIR, JR., J.F., R.E. ANDERSON, R.L. TATHAM y W.C. BLACK (1999) Análisis de regresión múltiple. En Análisis multivariante. Prentice Hall Iberia, 5ª ed., Madrid, 4: 143-226.
- HARTLEY, J.A. y R.S. POWELL (1991) The development of a combined demand prediction system. *Civ. Engrg. Systems*, 8: 231-236.
- HSU, K., H.V. GUPTA y S. SOROOSHIAN (1995) Artificial neural network modeling of the rainfall-runoff process. *Water Resour. Res.*, 31: 2517-2530.
- JOWITT, P.W. y C. XU (1992) Demand forecasting for water distribution systems. *Civ. Engrg. Systems*, 9: 105-121.
- KITANIDIS, P.K. y R.L. BRAS (1980) Real time forecasting with a conceptual hydrological model. 2. Applications and results. *Water Resour. Res.*, 16: 1034-1044.
- LEÓN, C., S. MARTÍN, J.M. ELENA y J. LUQUE (2000) EXPLORE-Hybrid expert system for water networks management. *J. Water Resour. Planning and Mgmt.*, 126: 65-74.
- MAIDMENT, D.R., S.P. MIAOU y M.M. CRAWFORD (1985) Transfer function models for daily urban water use. *Water Resour. Res.*, 21: 425-432.
- MINAI, A.A. y R.D. WILLIAMS (1990) Acceleration of back-propagation through learning rate and momentum adaptation. *Int. Joint Conf. Neural Networks*, 1: 676-679.
- MOLINO, B., G. RASULO y L. TAGLIATELA (1996) Forecast model of water consumption for Naples. *Water Resour. Mgmt.*, 10: 321-332.
- MOREU, P. (1999) Series temporales. En Estadística Informatizada. Paraninfo, 11: 93-108.
- NEL, D. y J. HAARHOFF (1996) Sizing municipal water storage tanks with Monte Carlo simulation. *J. Water SRT&Aqua*, 45: 203-212.
- PULIDO-CALVO, I. (2001) Diseño y gestión óptimos de sistemas de impulsión y de almacenamiento de agua para riego. Tesis Doctoral, Dpto. de Agronomía, Universidad de Córdoba.
- RAMAN, H. y V. CHANDRAMOULI (1996) Deriving a general operating policy for reservoirs using neural networks. *J. Water Resour. Plng. and Mgmt.*, 122: 342-347.
- RANJITHAN, S., J.W. EHEART y J.H. GARRET JR. (1993) Neural network-based screening for groundwater reclamation under uncertainty. *Water Resour. Res.*, 29: 563-574.
- RIZZO, D.M. y D.E. DOUGHERTY (1994) Characterization of aquifer properties using artificial neural networks: neural kriging. *Water Resour. Res.*, 30: 483-497.
- RÜFENATCH, H.P. y H. GUIBENTIF (1997) A model for forecasting water consumption in Geneva canton, Switzerland. *J. Water SRT&Aqua*, 46: 196-201.
- RUMELHART, D.E., G.E. HINTON y R.J. WILLIAMS (1986) 'Learning' representations by backpropagation errors. *Nature*, 323: 533-536.
- SAPORTA, D. y M. MUÑOZ (1994) El consumo en redes de distribución. Predicción diaria de la demanda. En Mejora del rendimiento y de la fiabilidad en sistemas de distribución de agua. Aguas de Valencia y U.D. Mecánica de Fluidos (UPV), 2: 43-75.
- SHVARTSER, L., U. SHAMIR y M. FELDMAN (1993) Forecasting hourly water demands by pattern recognition approach. *J. Water Resour. Planning and Mgmt.*, 119: 611-627.
- THIRUMALAIK, K. y M.C. DEO (2000) Hydrological forecasting using neural networks. *J. Hydrol. Engrg.*, 5: 180-189.
- VENTURA, S., M. SILVA, D. PÉREZ-BENDITO y C. HERVÁS (1995) Artificial neural networks for estimation of kinetic analytical parameters. *Anal. Chem.*, 67: 1521-1525.
- VENTURA, S., M. SILVA, D. PÉREZ-BENDITO y C. HERVÁS (1997) Computational neural networks in conjunction with principal component analysis for resolving highly nonlinear kinetics. *J. Chem. Inform. and Computer Sci.*, 37: 287-291.
- 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. *J. Irrig. and Drain. Engrg.*, 123: 285-292.