

PRONÓSTICO DE CAUDALES MEDIOS MENSUALES DEL RIO ILAVE USANDO MODELOS DE REDES NEURONALES ARTIFICIALES

Efrain Lujano¹, Apolinario Lujano², José Pitágoras Quispe², René Lujano³

¹Servicio Nacional de Meteorología e Hidrología – Puno; elujano28@gmail.com ²Autoridad Nacional del Agua - Administración Local de Agua Huancané

³Estudiante de Ingeniería de Sistemas, Universidad Nacional del Altiplano Puno - Perú.

INFORMACIÓN DEL ARTICULO

Art. Recibido 18 de mayo 2014
Art. Aceptado 03 de junio 2014
Publicado: 30 Junio del 2014

PALABRAS CLAVE:

* Backpropagation
* caudales medios
* redes neuronales artificiales río
* Ilave

ARTICLE INFO

Article Received May 18, 2014
Article Accepted June 3, 2014
Published: June 30, 2014

KEY WORDS:

* artificial neural networks
* back propagation
* Ilave river
* mean flows

RESUMEN

La presente investigación se realizó en la cuenca del río Ilave, ubicado dentro de la región Hidrográfica del Titicaca (Perú), teniendo como objetivo pronosticar los caudales medios mensuales del río Ilave usando Modelos de Redes Neuronales Artificiales, aplicado al problema del pronóstico mensual de esta variable, cuyo resultado puede emplearse en la planificación y gestión de los recursos hídricos en cuencas hidrográficas. La información hidrometeorológica utilizada, corresponde al Servicio Nacional de Meteorología e Hidrología con un período de registro de 1965 al 2007, de donde se plantearon 06 modelos que están en función de precipitaciones y caudales, cuya fase de entrenamiento, validación y prueba, se realizaron con el 70%, 15% y 15% del total de datos respectivamente, con una red de entrenamiento designada Perceptrón Multicapa (MLP) y el algoritmo «back-propagación». La significación estadística de los indicadores de desempeño de eficiencia de Nash-Sutcliffe (NSE) y la raíz del error cuadrático medio (RMSE), fueron evaluados usando el método de bootstrap incorporado en el código FITEVAL y como indicadores complementarios de evaluación tradicional, el coeficiente de determinación (R^2) y el error cuadrático medio normalizado (ECMN). Los resultados de validación y prueba indican calificativos de buenos a muy buenos, así tenemos que en la fase de pronóstico para los modelos seleccionados MRNA5, MRNA2 y MRNA3, los coeficientes de Eficiencia de Nash-Sutcliffe son de 88.0%, 87.9% y 87.1%; la raíz del error medio cuadrático son de 18.87%, 18.96% y 19.56% respectivamente. Se concluye que el pronóstico de caudales medios mensuales del río Ilave utilizando modelos de Redes Neuronales Artificiales, muestran un buen desempeño en la estimación de fenómenos de comportamiento no lineal como los caudales.

AVERAGE FLOW-MONTHLY FORECAST OF THE ILAVE RIVER USING ARTIFICIAL NEURAL NETWORK MODELS

ABSTRACT

This research was conducted in the Ilave river basin located within the hydrographic region of Titicaca (Peru), aiming to predict the average monthly flow of the river Ilave using Artificial Neural Networks models applied to forecast the monthly variable flow of this river. The results of this type of forecasting can be used in the planning and management of water resources in river basins. The hydrometeorological information used, corresponds to the National Meteorological and Hydrological Service registries between 1965 – 2007. 06 models were proposed that are based on rainfall and riverflow, whose training, validation and testing phases were realized with 70%, 15% and 15% of the total data respectively. A training network titled Multilayer Perception (MLP) as well as algorithm and «back-propagation» techniques were used. The statistical significance of the performance indicators Nash (NSE) and the Root Mean Square Error (RMSE), were assessed using the bootstrap method incorporated in the FITEVAL code. The coefficient of determination (R^2) and Normalized Root Mean Square Error (NRMSE) were used as complementary to indicators of traditional assessment. The results of test descriptions and validation indicate good to very good results, so in the forecast phase for selected models MRNA5, MRNA2 and MRNA3, Nash coefficients are 88.0%, 87.9% and 87.1%; mean square root error are 18.87%, 18.96% and 19.56% respectively. We conclude that the average monthly flow forecast of the river Ilave, using Artificial Neural Network models, show a good performance in estimating nonlinear phenomena such as flow behavior.

INTRODUCCIÓN

Uno de los problemas comunes en la planificación y gestión de los recursos hídricos en cuencas hidrográficas, es el conocimiento sobre la disponibilidad del agua para la atención de las demandas de los diferentes usos, por lo que se hace necesario conocer la disponibilidad futura, que nos permita plantear propuestas para una adecuada gestión de los recursos hídricos.

En la actualidad se han abierto las posibilidades de la utilización de modelos de inteligencia artificial como las redes neuronales artificiales que permiten capturar la naturaleza no lineal de los fenómenos a pronosticar. Se presentan como un nuevo modelo empírico (o del tipo «caja negra») que permite aproximar cualquier función (Bravo *et al.*, 2004). Vienen a ser sistemas de procesamiento de la información cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas (Hilera y Martínez, 2000). Las redes neuronales funcionan según el principio de aprendizaje del conjunto de entrenamiento. Antes de la formación, la red no tiene ningún conocimiento sobre el problema, lo que esto hace que a medida del entrenamiento las redes aprenden y sean capaces de proporcionar resultados exitosos. Pueden considerarse como una herramienta estadística completa para el análisis de datos, (Bishop, 1995).

Su utilización en el pronóstico de caudales es relativamente nueva, en los últimos años se han utilizado con muy buenos resultados en el pronóstico de caudales nivales (Dolling y Varas, 2000), el modelado lluvia-escorrentía (Tokar y Johnson, 1999, Thirumalaiah y Deo, 2000), el establecimiento de relaciones nivel-caudal (Jain y Chaitgaonkar, 2000), predicción del nivel de agua (Patrick y Collins 2002, Huang *et al.*, 2003), pronóstico de caudales de crecidas en tiempo real (Gonzales, 2003 y Rodríguez, 2008), pronóstico de evolución de niveles de agua (Hillman *et al.*, 2004), modelización aplicados a la Hidrología, Aerobiología y modelización de procesos (Castellano, 2009), modelización y previsión de caudales (Laqui, 2010), pronóstico de caudales (Barria, 2010), predicción de caudales no aforados (Besaw *et al.*, 2010, Dolling y Varas 2002, Dastorani y Wright 2002, Wright *et al.*, 2002), estimación de caudales (Yilmaz *et al.*, 2011), simulación de niveles de agua (Rabindra *et al.*, 2010) y entre muchas más. Hoy en día existen numerosas aplicaciones en hidrología, dedicadas a predecir y modelar los fenómenos de precipitación-escorrentía en cuencas hidrográficas de distintas características, utilizando datos de entrada tales como precipitación y caudal. El éxito de la modelación depende en gran medida de la calidad y cantidad de datos disponibles para los procesos de aprendizaje, validación y calibración (Hillman *et al.*, 2004).

El trabajo presenta el uso de redes neuronales artificiales para el pronóstico de caudales medios mensuales del río llave, lo cual es muy esencial para resolver un amplio número de problemas de planificación y gestión de los recursos hídricos, surgiendo la necesidad de adoptar estos nuevos modelos de inteligencia artificial como instrumento de pronóstico.

El objetivo del presente trabajo de investigación fue establecer modelos basados en redes neuronales artificiales que permitan pronosticar con cierta exactitud los caudales medios mensuales del río llave en función de variables como precipitación y caudal.

MATERIALES Y MÉTODOS

Descripción del área de estudio

La cuenca del río llave geográficamente se ubica entre las coordenadas UTM (WGS 84); Este (352,353 – 452,052 m), Norte (8'104,770 – 8'248,751 m) y altitud comprendida entre (3,805 - 5,400 msnm). La zona de estudio forma parte de la Región Hidrográfica del Titicaca (lado Peruano). Se caracteriza como un sistema de cuenca endorreica, ubicada en las provincias de Puno, El Collao y Chucuito en el departamento de Puno - Perú. La superficie total de la cuenca del río llave es de 7,832.53 Km², el régimen hidrológico es pluvial, presentándose caudales mayores en los meses de enero hasta abril generalmente en los meses con bastante precipitación.



Figura 1. Ubicación del área de estudio

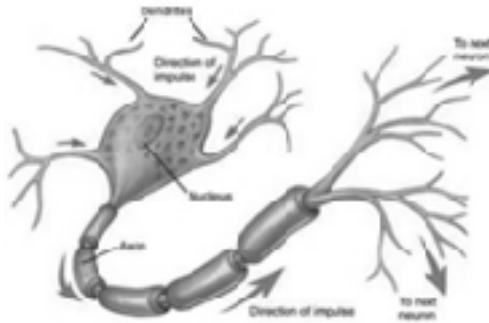
Tipo de investigación

Cuantitativo, No experimental y de corte longitudinal pretérito. Es una investigación cuantitativa que estudia el comportamiento de las descargas medias mensuales. Es no experimental porque son fenómenos que no se pueden manipular. Es de corte longitudinal pretérito porque las descargas medias mensuales son fenómenos que han sucedido a través del tiempo.

Población y muestra

Se considera como población al total de las descargas medias mensuales de las cuencas de los ríos en estudio en cada estación de año. Se considera muestra el conjunto de datos recopilados de cada estación hidrológica. Estos datos son considerados como muestreo aleatorio. Se utilizaron 03 estaciones hidrológicas (Puente llave, Ramis y Huancané) y 17 estaciones meteorológicas que están ubicadas dentro y alrededor de la cuenca (llave, Juli, Ichuña, Pizacoma, Pampa Umalzo, Capazo, Chilligua, Yunguyo, Rincon de

la Cruz, Laraqueri, Puno, Mañazo y Vilacota), las cuales pertenecen al Servicio Nacional de Meteorología e Hidrología (Senamhi), (Yorohoco y Pocoaque) Proyecto Binacional del Lago Titicaca (Pelt) y las estaciones (Chichillapi, Coypa Coypa), pertenecientes al Proyecto Especial Tacna (Pet), con un periodo de registro de enero 1965 hasta diciembre del 2007.



Redes Neuronales Artificiales

En el presente estudio se utilizó el perceptron multicapa la cual es una red neuronal formada por múltiples capas y esto permite resolver problemas que no son linealmente separables.




Figura 2. De la neurona biológica a la artificial

Modelamiento con redes neuronales artificiales

Hastie *et al.*, (2008), señalan que es difícil dar una regla general sobre cuantas observaciones se desea asignar a cada conjunto; para el entrenamiento de los modelos de redes neuronales artificiales, se utiliza el 70% de datos disponibles, y 15% para la validación y prueba (Baria, 2010) de precipitaciones y caudales. El rango de iteración de las neuronas en la capa oculta se fijó bajo la restricción de no calibrar más parámetros que un 75% de las observaciones con que se cuenta (Dölling y Varas, 2000).

El algoritmo de aprendizaje para el tipo de red perceptrón multicapa, es el de propagación del error hacia atrás (Backpropagation), empleando una función de transferencia sigmoidea, con una tasa de aprendizaje igual a 0.25 y un factor momento igual a 0.90. En general, el valor de la tasa de aprendizaje (α) suele estar comprendida entre 0.05 y 0.25, (Hilera y Martínez, 2000) y el factor momento suele tomar un valor próximo a 1 por ejemplo 0.9 (Rumelhart *et al.*, 1986 y Dolling y Varas, 2002).

Para la construcción, entrenamiento, validación y prueba de los modelos se utiliza el programa Alyuda NeuroIntelligence 2.2 versión trial, desarrollado por ALYUDA Research Company, este programa permite de una forma rápida escoger el número de neuronas ocultas teniendo como base las entradas y salidas de la red.

Arquitectura del perceptron multicapa (MLP)

En la práctica no existe una regla definida para establecer el número de neuronas en la capa de entrada. Un procedimiento útil para la selección de las variables relevantes (Masters, 1993), consiste en entrenar la red con todas las variables de entrada necesarias y a continuación ir eliminando una variable de entrada cada vez y reentrenar la red.

La idea de combinar varios perceptrones para poder conseguir relaciones no lineales, consiguió delimitar un proceso de aprendizaje

que fuera capaz de modificar los pesos de la red de un modo eficiente, a esta regla de aprendizaje se le llamó algoritmo backpropagation o regla delta generalizada y es, hoy en día, uno de los algoritmos de aprendizaje más utilizado y estudiado para todo tipo de redes.




Figura 3. Arquitectura red neuronal artificial perceptron multicapa

Aprendizaje

Alegre (2003), indica que una de las características de las redes neuronales artificiales es su capacidad de aprender a partir de ciertos datos. Una vez que ha sido elegida la arquitectura de red para un determinado problema, los pesos de las conexiones se ajustan para codificar la información contenida en un conjunto de datos de entrenamiento. Según Hilera y Martínez (2000), para que la red aprenda se debe seguir 06 pasos importantes:

Paso 1: Inicializar los pesos de la red con valores pequeños aleatorios.

Paso 2: Presentar un patrón de entrada, $X_p: x_{p1}, x_{p2}, \dots, x_{pN}$, y especificar la salida deseada que debe generar la red: d_1, d_2, \dots, d_M .

Paso 3: Calcular la salida actual de la red; para ello presentamos las entradas a la red y vamos calculando la salida que presenta cada capa hasta llegar a la capa de salida esta será la salida de la red y_1, y_2, \dots, y_M , los pasos son los siguientes:

- Se calculan las entradas netas para las neuronas ocultas procedentes de las neuronas de entrada. Para una neurona j oculta:

$$\text{net}_{pj}^h = \sum_{i=0}^N w_{ji}^h x_{pi} + \theta_j^h \quad (1)$$

En donde el índice h se refiere a magnitudes de la capa oculta (hidden); el subíndice p , al p -ésimo vector de entrenamiento, y j a la j -ésima neurona oculta. El término θ puede ser opcional, pues actúa como una entrada más.

- Se calculan las salidas de las neuronas ocultas utilizando una función de activación f .

$$y_{pj}^h = f_j^h(\text{net}_{pj}^h) \quad (2)$$

- Se realizan los mismos cálculos para obtener las salidas de las neuronas de salida (capa 0: output)

$$\text{net}_{pk}^o = \sum_{j=1}^N w_{kj}^o y_{pj}^h + \theta_k^o \quad (3)$$

$$y_{pk}^o = f_k^h(\text{net}_{pk}^o) \quad (4)$$

Para minimizar el error (fórmula en el Paso 6) la función f debe ser derivable, lo que implica la imposibilidad de utilizar la función escalón. En general se utilizan dos tipos de función de activación: la función lineal ($f(\text{net}_{jk}) = (\text{net}_{jk})$) y la función sigmoidea definida por la ecuación:

$$f(\text{net}_{jk}) = \frac{1}{1 + e^{-\text{net}_{jk}}} \quad (5)$$

La elección de esta función depende de la forma en que se decida representar los datos: si se desea que las neuronas de salida sean binarias, se utiliza la función sigmoidea, puesto que la función es casi biestable y además, derivable.

Paso 4: Calcular los términos de error para todas las neuronas. Después que todas las neuronas de la red tienen un valor de activación asociado para un patrón de entrada dado, el algoritmo continúa encontrando el error que se presenta para cada neurona, excepto las de la capa de entrada. Para una neurona k de la capa

de salida, si la respuesta es (y_1, y_2, \dots, y_M) , dicho error (δ) se puede escribir como:

$$\delta_{pk} = (d_{pk} - y_{pk}) f'_k(\text{net}_{pk}) \quad (6)$$

y para la función sigmoidea en particular:

$$\delta_{pk} = (d_{pk} - y_{pk}) y_{pk} (1 - y_{pk}) \quad (7)$$

Si la neurona j no es de salida, entonces la derivada parcial del error no puede ser evaluada directamente. Por tanto, se obtiene el desarrollo a partir de valores que son conocidos y otros que pueden ser evaluados.

La expresión obtenida en este caso es:

$$\delta_{pj}^h = x_{pi} (1 - x_{pi}) \sum_k \delta_{pk} w_{kj} \quad (8)$$

observamos que el error en las capas ocultas depende de todos los términos del error de la capa de salida. De aquí el nombre de propagación hacia atrás. En particular para la función sigmoidea.

Donde k se refiere a todas las neuronas de la capa superior a la de la neurona j . Así el error que se produce en una neurona oculta es proporcional a la suma de los errores conocidos que se producen en las neuronas a las que está conectada la salida de la misma, multiplicando cada uno por el peso de la conexión. Los umbrales internos de las neuronas se adaptan de forma similar, considerando que están conectados con pesos desde entradas auxiliares de valor constante.

Paso 5: Actualización de pesos

Para ello utilizamos el algoritmo recursivo, comenzando por las neuronas de salida y trabajando hacia atrás hasta llegar a la capa de entrada, ajustando los pesos de la forma siguiente:

Para los pesos de las neuronas de la capa de salida:

$$w_{kj}(t+1) = w_{kj}(t) + \Delta w_{kj}^o(t+1); \quad (9)$$

$$\Delta w_{kj}^o(t+1) = \alpha \delta_{pk} y_{pj}^h \quad (10)$$

y para los pesos de las neuronas de la capa oculta:

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}^h(t+1); \quad (11)$$

$$\Delta w_{ji}^h(t+1) = \alpha \delta_{pj}^h y_{pi} \quad (12)$$

En ambos casos, para acelerar el proceso de aprendizaje, se incluye una tasa de aprendizaje que varía entre 0 y 1, dependiendo del problema a solucionar. También se puede añadir un término de momento, para corregir la dirección del error, de valor: $\gamma((w_{kj}(t) - w_{kj}(t-1)))$ en el caso de una neurona de salida y $\gamma((w_{ji}(t) - w_{ji}(t-1)))$, cuando se trata de una neurona oculta; la constante γ

es la tasa de momento; y un tercer parámetro β para acelerar la convergencia del proceso.

Paso 6: El proceso se repite hasta que el término de error, resulta aceptablemente pequeño para cada uno de los patrones aprendidos.

$$E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2 \quad (13)$$

Una vez que ha terminado el proceso de aprendizaje y los pesos de la red han sido calculados, es importante comprobar la calidad del modelo resultante y validar los modelos planteados, (Alegre, 2003).

Evaluación estadística de los modelos

Raíz del error cuadrático medio (RMSE)

Siguiendo la recomendación de Legates y McCabe (1999), para evaluar la capacidad predictiva de los modelos se representara los valores observados frente a los calculados ilustrando así el grado con el que los puntos se distribuyen sobre la recta 1:1 o de ajuste perfecto. El error en las predicciones del modelo se cuantificara en términos de las unidades de la variable calculada mediante la raíz del error cuadrático medio (RMSE). Este indicador es usado frecuentemente y su definición viene dada por:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (14)$$

Eficiencia de Nash-Sutcliffe (NSE)

El criterio numérico utilizado para cuantificar los resultados fue el propuesto por (Nash y Sutcliffe, 1970) como indicador adimensional de la bondad de ajuste, el cual relaciona los caudales observados con los calculados por el modelo. Se trata de un indicador ampliamente utilizado en la evaluación de modelos hidrológicos, caracterizado por su flexibilidad para ser aplicado a diversos tipos de modelos matemáticos (McCuen *et al.*, 2006).

El criterio de Nash-Sutcliffe, mide cuánto de la variabilidad de las observaciones es explicada por la simulación. Si la simulación es perfecta, NSE=1; si se intentase ajustar las observaciones con el valor promedio, entonces NSE=0.

$$NSE = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (15)$$

Donde:

- y_i : Valor observado
- \hat{y}_i : Valor calculado
- \bar{y} : Promedio de los datos observados

La significancia estadística de estos indicadores, fundamentalmente la eficiencia de Nash-Sutcliffe y la raíz del error cuadrático medio, fue evaluada mediante la técnica de Bootstrap automatizada en el código FITEVAL del MATLAB, (Ritter y Muñoz-Carpena, 2013).

Asimismo se describen los principales indicadores estadísticos habitualmente utilizados para medir la efectividad de modelos (Espíldora *et al.*, 1975).

Error cuadrático medio normalizado (ECMN)

$$ECMN = \frac{n-1}{n} \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (16)$$

Donde:

- n : Número de observaciones

Corresponde al error cuadrático medio, pero normalizado por la varianza de los datos. Mientras más cercano a 0, mejor ajuste de los valores a los reales y por tanto mejor es el modelo evaluado y contrariamente mientras más se aleje a 0 menos representativo es del fenómeno observado.

Coefficiente de determinación (R²)

Este índice de desempeño, representa la fracción de variación de la variable dependiente explicada por el modelo.

$$R^2 = 1 - ECMN \quad (17)$$

En el caso de un predictor perfecto el coeficiente R² debiera ser 1. Si se obtiene valores cercanos a la unidad se tiene un modelo adecuado.

RESULTADOS

Modelamiento con Redes Neuronales Artificiales

Planteamiento de modelos

Se plantearon 06 modelos de redes neuronales artificiales cuyas variables de entrada (capas de entrada) tienen diferentes combinaciones de precipitación $P_{(k)}$ para $k = 0, 1, 2$ y caudales afluentes Q_{ik} para $k = 1, 2, 3, 4$ y como variable de salida el caudal medio mensual Q_t .

Tabla 1. Variables de entrada y salida

Modelo	Variabes de Salida	Variabes de Entrada
MRNA 1	$Q(t)=$	$f(P(t); Q(t-1))$
MRNA 2	$Q(t)=$	$f(P(t); Q(t-1); Q(t-2))$
MRNA 3	$Q(t)=$	$f(P(t); Q(t-1); Q(t-2); Q(t-3))$
MRNA 4	$Q(t)=$	$f(P(t); P(t-1); Q(t-1); Q(t-2); Q(t-3); Q(t-4))$
MRNA 5	$Q(t)=$	$f(P(t); P(t-1); Q(t-1); Q(t-2))$
MRNA 6	$Q(t)=$	$f(P(t); P(t-1); P(t-2); Q(t-1); Q(t-2); Q(t-3))$

Arquitectura

En el trabajo de investigación se tiene dos variables de entrada la cual está representado por la precipitación media del área de influencia y los caudales medios mensuales, donde la arquitectura

de la red ha sido conformada por una capa de entrada, una oculta y una de salida. Las neuronas en la capa de entrada varían de 2 a 6, mientras que en la capa oculta varían de 1 a 15.




Figura 3. Arquitectura de la red

Entrenamiento de modelos

Para el entrenamiento de los modelos, se realizó con el 75% del total de datos observados, desde enero de 1965 hasta diciembre del 1995. En la tabla 2, se presenta el número de conexiones de los

modelos de redes neuronales artificiales que varía de 5 a 105, mientras que el número de iteraciones de 16 a 11006 y que fueron necesarios para minimizar el término de error ($Epd \leq 0.00000001$ o $Epd \leq 10^{-7}$).

Tabla 2. Números de iteraciones y conexiones

Mes	Nº	MRNA 1	MRNA 2	MRNA 3	MRNA 4	MRNA 5	MRNA 6
Ene	Iteraciones	6816	4591	2576	2351	4769	1384
	Conexiones	21	16	20	63	35	63
Feb	Iteraciones	3157	2009	1688	3092	2704	1336
	Conexiones	15	20	20	21	15	42
Mar	Iteraciones	1978	20	8976	3544	1590	500
	Conexiones	6	32	40	84	50	70
Abr	Iteraciones	1123	501	1414	1701	9229	2027
	Conexiones	15	16	30	21	15	42
May	Iteraciones	2252	3190	3611	4506	2032	1442
	Conexiones	9	32	40	105	50	42
Jun	Iteraciones	1814	704	1450	3401	1759	1809
	Conexiones	9	12	30	105	15	84
Jul	Iteraciones	733	2408	2051	41	2267	2677
	Conexiones	6	12	50	84	50	14
Ago	Iteraciones	35	6269	2391	2342	3858	632
	Conexiones	18	16	50	56	50	21
Sep	Iteraciones	19	5232	1380	1181	3629	3375
	Conexiones	21	24	50	56	50	63
Oct	Iteraciones	11006	7748	16	1647	5468	3010
	Conexiones	18	32	15	105	40	77
Nov	Iteraciones	2064	833	136	3259	22	932
	Conexiones	9	12	5	35	50	105
Dic	Iteraciones	1093	4405	5541	4395	4351	3962
	Conexiones	21	12	45	63	50	49

Validación de resultados

Para la validación de los modelos, se realizó con el 15% del total de datos observados, para ello se ha realizado una simulación de caudales desde enero de 1996 hasta diciembre del 2001.




Figura 4. Qobs vs Qsim (MRNA5)

En la Figura 4, se muestra la representación gráfica de la comparación de los valores observados y simulados de la serie de caudales medios mensuales del río Ilave, estación Puente Ilave correspondientes al periodo 1996-2001, para el modelo MRNA5, los caudales simulados son muy similares a los caudales observados.

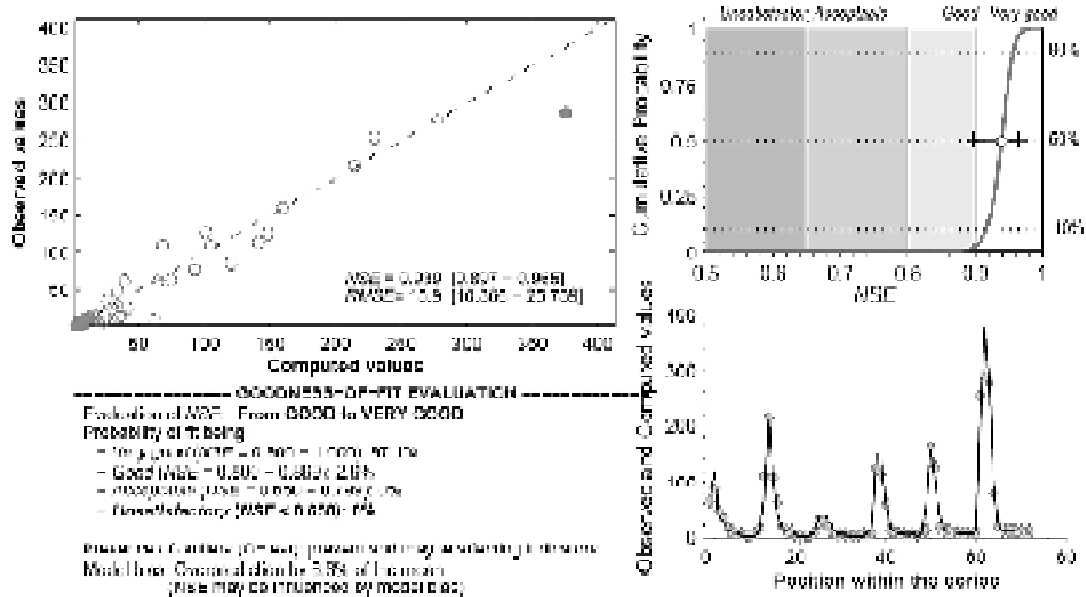


Figura 5. Evaluación de la bondad de ajuste de modelos fase de validación Qobs vs Qsim (MRNA5)

En la figura 5, se ilustra los resultados obtenidos para la fase de validación entre los caudales observados y los caudales simulados, para el modelo MRNA5, la figura muestra un muy buen ajuste con una eficiencia de Nash-Sutcliffe (NSE) = 0,939 (0.897 – 0.965) y con valores de la raíz del error cuadrático medio (RMSE) = 15.9%.

Evaluación estadística y selección de modelos

Los modelos de MRNA simulados en la tabla 3 presentaron una eficiencia de Nash-Sutcliffe (NSE) de 84.4% a 93.9%, mientras que el error cuadrático medio normalizado (ECMN) tiene errores de 6.0 a 14.9%, y el coeficiente de determinación (R^2) varía entre 85.2% a 95.0%.

Tabla 3. Evaluación de los modelos

Modelo	RMSE [%]	NSE [%]	ECMN [%]	R ² [%]
MRNA1	24.8	85.2	14.6	85.4
MRNA2	16.9	93.1	6.8	93.2
MRNA3	22.4	87.9	11.9	88.1
MRNA4	25.1	84.8	14.9	85.1
MRNA5	15.9	93.9	6.0	94.0
MRNA6	24.6	85.4	14.4	85.6

La selección de modelos para el pronóstico, se realizó mediante los resultados de calidad de los indicadores estadísticos. Según la tabla 3 de evaluación, se seleccionaron los modelos MRNA5, MRNA2 y MRNA3 por presentar mejores índices de desempeño, en comparación al resto de modelos, debido a los bajos errores, y altos coeficientes de eficiencia de Nash-Sutcliffe (NSE), los cuales serán utilizados para el pronóstico de caudales medios mensuales del río llave.

Pronóstico de caudales medios mensuales

El pronóstico de caudales medios mensuales se realizó con el 15% del total de datos observados, periodo comprendido desde enero del 2002 a diciembre del 2007.

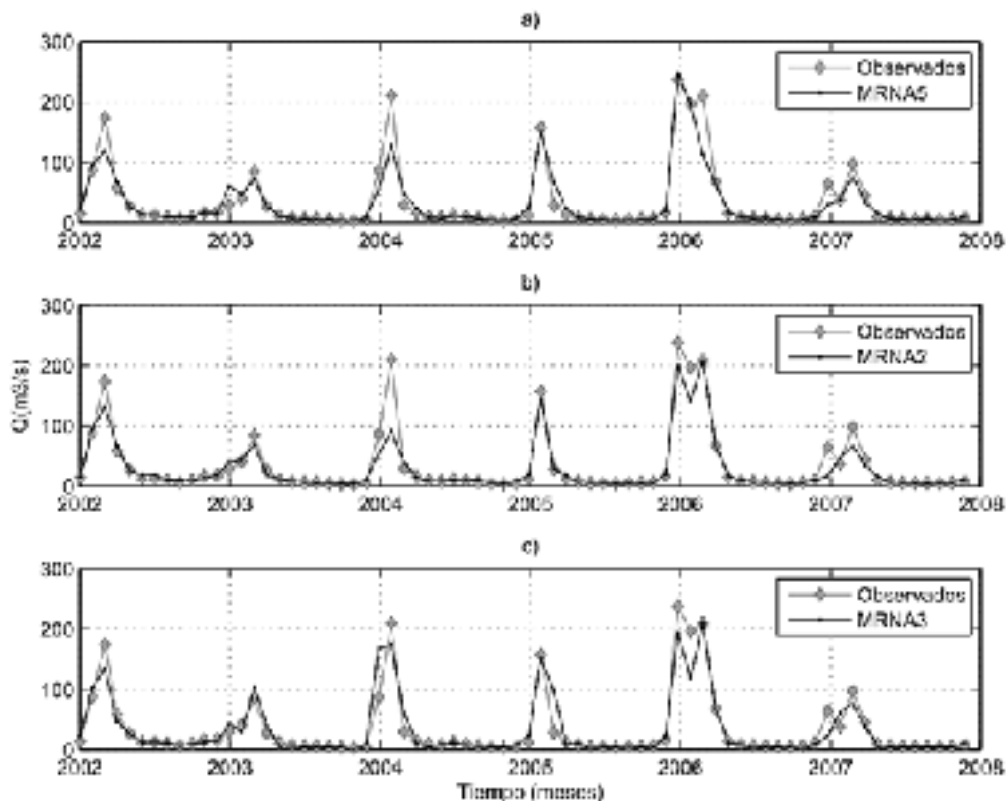
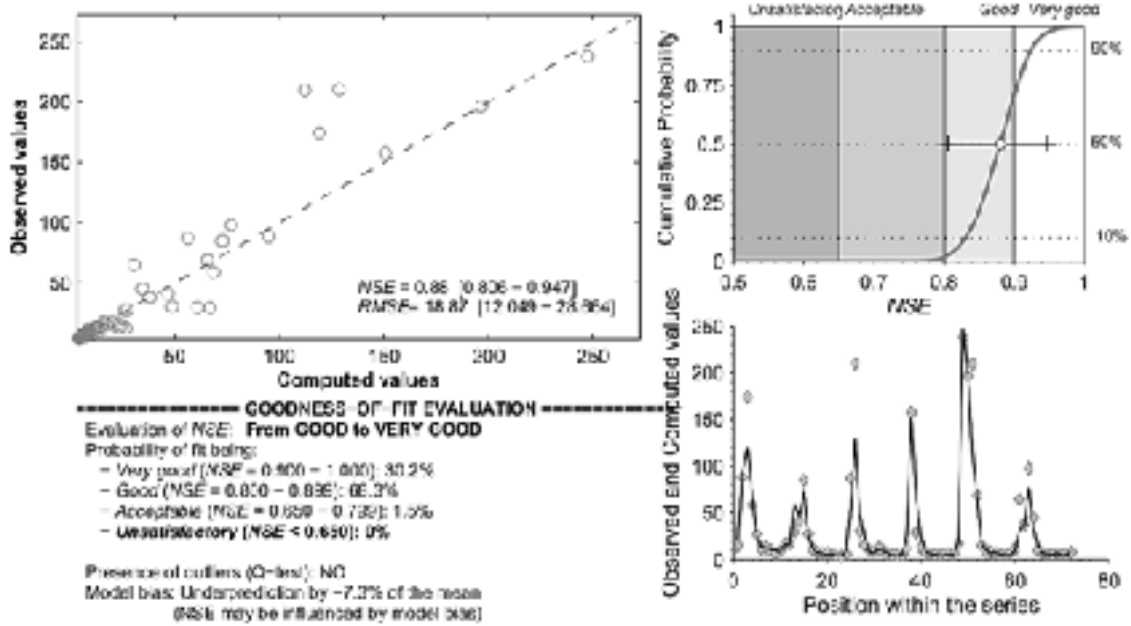



Figura 6. Qobs vs Qpron a) MRNA5, b) MRNA2 y c) MRNA3

En la Figura 6a, 6b y 6c, se muestra la representación gráfica de la comparación de los valores observados y pronosticados de la serie de caudales medios mensuales del río llave, para los modelos seleccionados MRNA5, MRNA2 y MRNA3, correspondientes al periodo 2002 - 2007.

a)



b)



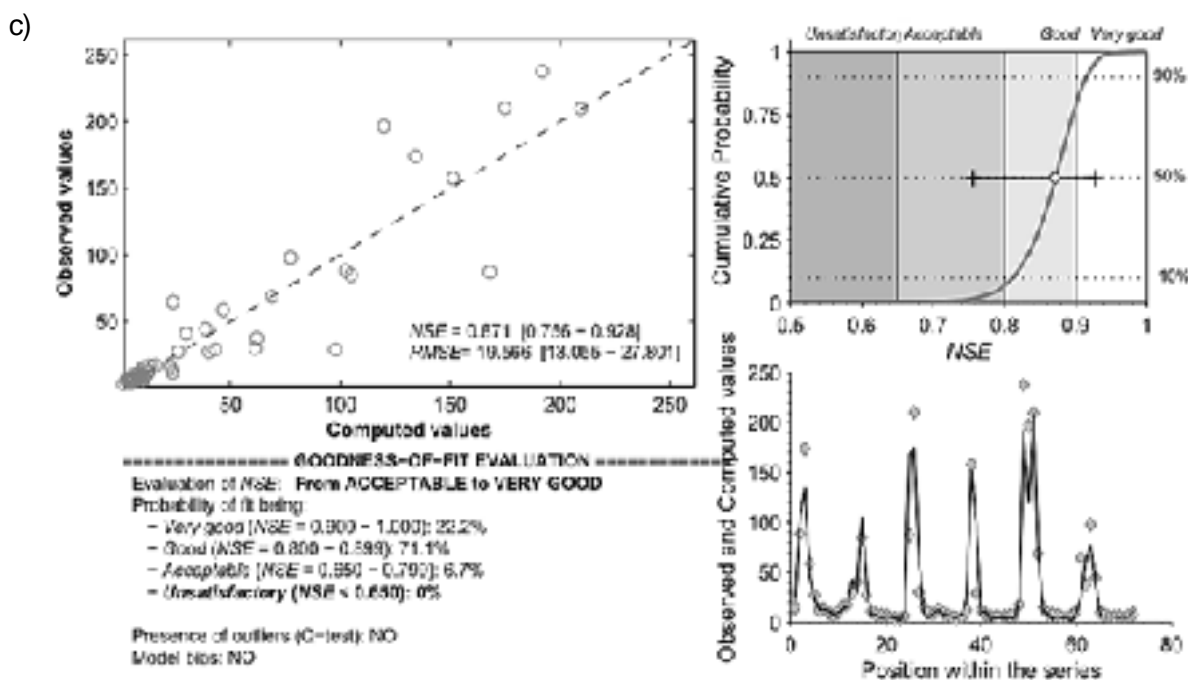


Figura 7. Evaluación de la bondad de ajuste de modelos para el pronóstico Qobs vs Qpron a) MRNA5, b) MRNA2 y c) MRNA3

En la figura 7, se ilustra los resultados de evaluación de la bondad de ajuste de modelos para la fase de pronóstico entre los caudales observados y los caudales pronosticados, la figura 7a para el modelo MRNA5, muestra un ajuste de la eficiencia de Nash-Sutcliffe (NSE) = 0.88 (0.806 – 0.947), mientras que en la figura 7b corresponde al modelo MRNA2, cuyos resultados de ajuste es NSE = 0.879 (0.669 – 0.953), sin embargo en la figura 7c el ajuste del modelo MRNA3 la eficiencia de Nash-Sutcliffe (NSE) = 0.871 (0.756 – 0.928), los modelos propuestos muestran un ajuste de bueno a muy bueno.

Asimismo en las figuras 7a, 7b y 7c se presenta los valores de la raíz del error cuadrático medio (RMSE) de 18.87%, 18.96% y 19.56%, considerándose los modelos muy buenos.

Evaluación de los modelos de pronóstico

En esta fase de prueba se entrega el error real cometido con los modelos seleccionados en la fase de validación.

Tabla 4. Evaluación de modelos

Modelo	RMSE [%]	NSE [%]	ECMN [%]	R ² [%]
MRNA5	18.87	88.0	11.8	88.2
MRNA2	18.96	87.9	11.9	88.1
MRNA3	19.56	87.1	12.7	87.3

Según la tabla 4, se muestra la comparación de los diferentes indicadores de evaluación de modelos, empleados para el pronóstico de los caudales medios mensuales del río llave, para los modelos de redes neuronales artificiales seleccionados MRNA5, MRNA2 y MRNA3, los valores para la raíz del error cuadrático medio (RMSE) muestran valores de 18.87%, 18.96% y 19.56%, considerándose los modelos seleccionados muy buenos. Mientras que según la evaluación de la eficiencia de Nash (NSE) muestra valores de 88.0%, 87.9% y 87.1%, según la clasificación se consideran de bueno a muy bueno para los modelos de pronóstico. Sin embargo según los indicadores de evaluación como es el error cuadrático

medio normalizado (ECMN) se tiene valores de 11.8%, 11.9% y 12.7% respectivamente. Asimismo el coeficiente de determinación (R²) presenta valores de 88.2%, 88.1% y 87.3% para la fase de pronóstico, corroborándose que los modelos seleccionados tienen un buen desempeño.

DISCUSIONES

Espíndora *et al.* (1975), indica que el coeficiente de determinación, representa la fracción de variación de la variable dependiente explicada por el modelo. En el caso de un predictor perfecto el

coeficiente de determinación (R^2) debiera ser 1 (ó 100 expresado en términos de porcentaje). Si se obtiene valores cercanos a la unidad se tiene un modelo adecuado. Para la validación de caudales medios mensuales del río llave con aplicación de modelos de redes neuronales artificiales, se utilizaron variables de entrada tales como precipitación y caudal, presentando coeficientes de determinación que varían de 85.1% a 94% para todos los modelos, resultando los más óptimos aquellos modelos con coeficiente de determinación (R^2) igual a 94% (MRNA5), 93.2% (MRNA2) y 88.1% (MRNA3) de ajuste respectivamente. Laqui (2010), en sus modelos de previsión de caudales medios, utiliza variables de entrada tales como precipitación, evaporación y descargas, presentando coeficientes de determinación en la fase de validación de todos los modelos entre 79% y 85% de ajuste, por otro lado también presenta la evaluación de modelos para la fase de validación utilizando como entradas solo las variables de caudales, mostrando resultados de ajuste comprendidos entre 60% y 78%. Mientras que en la fase de pronóstico el coeficiente de determinación muestra porcentajes de ajuste de 88.2% (MRNA5), 88.1% (MRNA2) y 87.3% (MRNA3) respectivamente, de esta manera los modelos seleccionados muestran buen desempeño, resultados similares para el pronóstico de fenómenos hidrológicos son obtenidos por (Hillman *et al.*, 2004, Barria 2010, Rojo 2011); corroborándose en el presente trabajo de investigación que los modelos planteados, cumplen estas características para ser funciones adecuadas para el pronóstico de caudales medios mensuales del río llave.

En cuanto al indicador de desempeño de eficiencia de Nash-Sutcliffe (NSE), la evaluación de los modelos MRNA5, MRNA2, MRNA3 para el pronóstico de caudales, presentan eficiencias de 88.0%, 87.9% y 87.1% respectivamente, siendo un calificativo bueno (Ritter y Muñoz-Carpena, 2013), similares resultados de desempeño de eficiencia de Nash-Sutcliffe son obtenidos por (Rabindra *et al.*, 2010). De la misma forma en cuanto a términos de error, la raíz del error cuadrático medio (RMSE), presenta valores de 18.87% (MRNA5), 18.96% (MRNA2) y 19.56% (MRNA3), considerados muy buenos según la clasificación (Ritter y Muñoz-Carpena, 2013), un alto valor de (RMSE) generalmente indica una deficiencia en la generalización de la red debido a una mala selección del número de neuronas ocultas o un proceso de aprendizaje débil (Dolling y Varas, 2002). Asimismo según los indicadores de evaluación como es el error cuadrático medio normalizado (ECMN), se tiene que para los modelos de pronóstico seleccionados son de 11.8% (MRNA5), 11.9% (MRNA2) y 12.7% (MRNA3) respectivamente, resultados similares son obtenidos por (Barria, 2010) en su investigación.

CONCLUSIONES

Mediante la presente investigación se establecieron 03 modelos de redes neuronales artificiales que están en función de la precipitación y el caudal los cuales permiten pronosticar con cierta exactitud y probabilidad los caudales medios mensuales del río llave, estos modelos son: MRNA5 ($Q_{(t)} = f(P_{(t)}, P_{(t-1)}, Q_{(t-1)}, Q_{(t-2)})$), MRNA2 ($Q_{(t)} = f(P_{(t)}, Q_{(t-1)}, Q_{(t-2)})$), y el modelo MRNA3 ($Q_{(t)} = f(P_{(t)}, Q_{(t-1)}, Q_{(t-2)}, Q_{(t-3)})$), los mismos que muestran un excelente comportamiento al ser evaluados con los indicadores, además se logra reproducir los valores picos observados de la variable en estudio, por lo tanto se considera que esta metodología es muy eficiente en la estimación de fenómenos de comportamiento no lineal como son los caudales.

La utilización de las técnicas de Inteligencia Artificial, como es la aplicación de redes neuronales artificiales al pronóstico de caudales medios mensuales, puede dar lugar a una nueva etapa en la planificación y gestión de los recursos hídricos en cuencas hidrográficas.

AGRADECIMIENTOS

A nuestra Alma Mater, la Universidad Nacional del Altiplano – Puno, así como nuestro agradecimiento al Comité editor de LA REVISTA INVESTIGACIONES ALTOANDINAS RIA, por la publicación del presente trabajo de investigación.

REFERENCIAS BIBLIOGRAFICAS

- Alegre, A. (2003). «Simulación de Redes Neuronales Artificiales». Trabajo final de aplicación. Universidad Nacional del Nordeste. Facultad de Ciencias Exactas, Naturales y Agrimensura. Corrientes – Argentina.
- Barria, P. (2010). «Pronóstico de caudales medios mensuales en las cuencas de los ríos Baker y Pascua». Memoria para optar el título de ingeniero civil. Universidad de Chile. Facultad de Ciencias Físicas y Matemáticas. Santiago de Chile.
- Besaw, L. E., Rizzo, D. M., Bierman, P. R. y Hackett, W. R. (2010). «Advances in ungauged streamflow prediction using artificial neural networks». *Journal of Hydrology*, 386, 27-37.
- Bishop, C. (1995). «Neural Networks for Pattern Recognition». Oxford: Clarendon Press.
- Bravo, J. Jorge, P. y Depetris, C. (2004). «Utilización de un modelo de redes neuronales en la obtención de la curva de descarga de la obra control del río Negro en Laguna Blanca». Universidad Nacional del Nordeste. Corrientes: Argentina.
- Castellano, M. (2009). «Modelización estadística con Redes Neuronales. Aplicados a la Hidrología, Aerobiología y Modelización de procesos». Tesis Doctoral Universidad de Coruña, Departamento de Matemáticas. Coruña.
- Dastorani, M.T. y Wright, N.G. (2002). «Artificial Neural Network Based Real-time River Flow Prediction, in the Proceedings of Hydroinformatics».
- Dolling, O.R. y Varas E.A. (2002). «Artificial neural networks for streamflow prediction». *Journal of Hydraulic Research*, 40(5):547-554.
- Dölling, O.R. y Varas, E.A. (2000). «Pronóstico de Caudales Nivales Usando Redes Neuronales Artificiales». XIX Congreso Latinoamericano de Hidráulica. Córdoba: Argentina.
- Espíldora, B., Brown, E., Cabrera, G. y Iseensee, P. (1975). «Elementos de Hidrología». Centro de Recursos Hidráulicos. Universidad de Chile: Santiago.
- Hastie, T., Tibshirani, R. y Friedman, J. (2008). «The Elements of Statistical Learning». Data Mining, Inference, and Prediction. Second Edition. Stanford California.
- Hilera, J. y Martínez, V. (2000). *Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones*. Madrid, España. Editorial Alfaomega.
- Hillman, G., Dolling, O., Pagot, M., Pozzi, C. y Plencovich, G. (2004). «Aplicación de redes neuronales para el pronóstico de evolución de niveles de agua para la laguna de mar

- chiquita». *Mecánica Computacional*. Vol. XXIII. Bariloche: Argentina. 1245-1259.
- Huang, W., Murray, C., Kraus, N. y Rosati, J. (2003). «Development of a Regional Neural Network Prediction for Coastal Water Level Prediction». *Ocean Engineering*, 30: 2275-2295.
- Jain, S.K. y Chalisgaonkar, D. (2000). «Setting Up Stage Discharge Relations Using ANN». *Journal of Hydrologic Engineering*, 5(4):428-433.
- Laqui, F. (2010). «Aplicación de Redes Neuronales Artificiales a la Modelización y Previsión de Caudales Medios Mensuales del Río Huancané». *Revista Peruana Geo-Atmosférica RPGA, SENAMHI – Perú*. (2), 30-44.
- Legates, D.R. y McCabe, G.J. (1999). «Evaluating the use of 'goodness-of-fit' measures in hydrologic and hydroclimatic model validation». *Water Resour. Res.* 35, 233–241.
- Lujano, E. (2012). «Pronóstico de caudales medios mensuales del río Ilave utilizando modelos de redes neuronales artificiales». Tesis de Pregrado. Universidad Nacional del Altiplano – Puno. Escuela Profesional de Ingeniería Agrícola.
- Nash, J.E. y Sutcliffe, J.V. (1970). «River flow forecasting through conceptual models», part I: A discussion of principles. 282-290.
- Masters, T. (1993). «Practical neural networks recipes in C++». London: Academic Press.
- McCuen, R.H., Knight, Z. y Cutter, A.G. (2006). «Evaluation of the Nash Sutcliffe Efficiency Index». *J. Hydrol. Eng* 11, 597-602.
- Patrick, A.R., Collins, W.G., Tissot, P.E., Dritakis, A., Stearns J., Michaud, P.R. y Cox, D.T. (2002). «Use of the NCEP MesoEta Data in a Water Level Predicting Neural Network». Presented in 19 th Conf. On weather Analysis and Forecasting/15 th Conf. on Numerical Weather Prediction.
- Rabindra K. P., Niranjana P. y Biplab B. (2010). «Simulation of river stage using artificial neural network and MIKE 11 hydrodynamic model», *Computers & Geosciences*, Volume 36, Issue 6, Pages 735-745, ISSN 0098-3004.
- Ritter, A. y Muñoz-Carpena, R. (2013). «Performance evaluation of hydrological models: Statistical significance for reducing subjectivity in goodness-of-fit assessments», *Journal of Hydrology*, Volume 480, Pages 33-45, ISSN 0022-1694, <http://dx.doi.org/10.1016/j.jhydrol.2012.12.004>.
- Rodríguez, F. (2008). «Modelo de pronóstico de caudales en crecida en tiempo real mediante redes neuronales artificiales para el río Maipo en la región Metropolitana». Trabajo de titulación. Universidad de Santiago de Chile. Facultad de Ingeniería.
- Rojo, J. (2011). «Desarrollo de un sistema experto para la predicción de caudales medios mensuales en Colombia». Tesis de Maestría. Universidad Nacional de Colombia. Facultad de minas.
- Rumelhart, D.E., Hinton, G.E. y Williams, R.J. (1986). «Learning internal representations by error propagation». En: D. E. Rumelhart DE, McClelland J.L. (Eds.). *Parallel distributed processing*. Cambridge, MA: MIT Press.
- Tokar, A.S. y Johnson, P.A. (1999). «Rainfall-Runoff Modeling Using Artificial Neural Networks». *Journal of Hydrologic Engineering*, 4(3):223-239.
- Thirumalaiah, K. y Deo, M.C. (2000). «Hydrological Forecasting Using Neural Network». *Journal of Hydrologic Engineering*, 5(2):180-189.
- Wright, N.G., Dastorani, M.T., Goodwin, P. y Slaughter, C.W. (2002). «A Combination of Neural Networks and Hydrodynamic Models for River Flow Prediction, in the Proceedings of Hydroinformatics».
- Yilmaz, A. G., Imteaz, M. A. y Jenkins, G. (2011). «Catchment flow estimation using Artificial Neural Networks in the mountainous Euphrates Basin». *Journal of Hydrology*, 410, 134-140.