

Redes Neuronales Artificiales (RNA) aplicadas en la predicción de caudales para intervalos de tiempo horarios

Veintimilla R. Jaime ^{*1 2} and Cisneros E. Felipe ^{**2}

¹Departamento de Ciencias de la Computación, Universidad de Cuenca

²Programa para el manejo del agua y el suelo (PROMAS), Universidad de Cuenca

Resumen

La aplicación de modelos matemáticos en el manejo de cuencas hidrográficas tiene requerimientos exigentes de información y en su mayoría no han sido desarrollados para ser aplicados en regiones de montaña. Por esta razón es necesario buscar e implementar modelos que no tengan estos requerimientos y que permitan establecer relaciones entre los datos de entrada y los de salida en una cuenca hidrográfica. Técnicas informáticas de inteligencia artificial permiten establecer relaciones entre los datos de entrada y los de salida en una cuenca hidrográfica. El proyecto busca evaluar diferentes modelos de Redes Neuronales Artificiales (RNA) con el fin de seleccionar uno e implementarlo, con esto se pretende obtener la posibilidad de manipular cada una de las conexiones del modelo de la red neuronal para buscar una convergencia rápida y la minimización del margen de error. Una vez que el modelo sea calibrado, se pretende realizar la predicción de caudales para intervalos de tiempo inferiores a 24 horas.

1. Introducción

El modelo, a más de predecir caudales para la producción de energía hidroeléctrica, está en capacidad de brindar soporte en la prevención de desastres ligados al control de avenidas a través de la laminación en embalses, y a la utilización más óptima de los recursos hídricos. Para el desarrollo de la investigación se utilizaron datos disponibles de la cuenca del río Tomebamba que han sido utilizados para entrenar y operar modelos de redes neuronales artificiales y posteriormente evaluar los resultados obtenidos en cada modelo. Cabe indicar

*:jaime.veintimilla@ucuenca.edu.ec

***:felipe.cisneros@ucuenca.edu.ec

que este tipo de herramienta cobra importancia en los actuales momentos en los que el mercado de energía eléctrica es a base de cupos asignados. La asignación de cupos se realiza a escala nacional, a través de SENACE para la cual las diferentes generadoras deben determinar la cantidad de energía serían capaces de generar. En este contexto la presente investigación ofrece a las generadoras del país las bases para la implementación de un modelo de predicción de mayor precisión que les permita optimizar su producción y ser más competitivos dentro del mercado eléctrico. La aplicación de modelos matemáticos en el manejo de cuencas hidrográficas tiene requerimientos exigentes de información y en su mayoría no han sido desarrollados para ser aplicados en regiones de montaña. Técnicas informáticas de inteligencia artificial permiten establecer relaciones entre los datos de entrada y los de salida en una cuenca hidrográfica.

El proyecto evaluó diferentes modelos de Redes Neuronales Artificiales (RNA) con el fin de seleccionar uno e implementarlo, con esto se obtiene la posibilidad de manipular cada una de las conexiones del modelo de la red neuronal para buscar una convergencia rápida y la minimización del margen de error.

2. Redes Neuronales Artificiales

2.1. Definición

Existen numerosas formas de definir lo que son las redes neuronales artificiales o RNA, desde definiciones cortas y genéricas hasta las que intentan explicar detalladamente lo que significa red neuronal o computación neuronal:

Una nueva forma de computación, inspirada en modelos biológicos. [9].

Un modelo matemático compuesto por un gran número de elementos de procesamiento organizados en niveles. [9].

... un sistema de computación hecho por un gran número de elementos simples, elementos de proceso muy interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas exteriores. [10].

2.2. El modelo biológico

Una neurona tiene un cuerpo celular más o menos esférico con un diámetro entre 5 y 10 micras. De este cuerpo principal salen una rama principal llamada axón y varias ramas más cortas, llamadas dendritas. A su vez el axón puede producir ramas en torno a su punto de arranque, y con frecuencia se ramifica extensamente cerca de su extremo. Las dendritas y el cuerpo celular reciben señales de entrada; el cuerpo celular las combina e integra y emite señales de salida. El axón transporta esas señales a los terminales axónicos que se encargan de distribuir información a un nuevo conjunto de neuronas. Una neurona recibe información de miles de neuronas y envía información a miles de neuronas más [9].

2.3. Elementos de una Red Neuronal Artificial

Las redes neuronales artificiales reproducen el comportamiento del cerebro, modelo en el que se consideran a las neuronas como unidades de procesamiento. Generalmente se pueden encontrar tres tipos de neuronas:

- Reciben estímulos o señales externas, toman la información del exterior, por lo que se les conoce como unidades de entrada.
- Elementos internos que se ocupan del procesamiento de la información de entrada. Se les conoce como unidades ocultas, pues no tienen relación directa con las unidades de entrada ni con las de salida.
- Unidades de salida, cuya misión es entregar la respuesta del sistema.

Cada neurona está caracterizada por un valor numérico o estado de activación y existe una función de salida f_i asociada a cada una de estas unidades, que transforman el estado actual de activación en una señal de salida y_i . Dicha señal es enviada a todos los canales de comunicación de la red (conexiones). En estos canales la señal se modifica de acuerdo con la sinapsis (el peso de la conexión) asociada a cada uno de ellos según una determinada regla. Las señales moduladas que han llegado a la unidad j -ésima se combinan entre sí generando así la entrada total Net_j . Una función de activación, F , determina el nuevo estado de activación $a_j(t+1)$ de la neurona, teniendo en cuenta la entrada total calculada y el anterior estado de activación $a_j(t)$. [9].

2.4. Estructura de una Red Neuronal Artificial

Las RNA están organizadas en función de:

- Número de niveles o capas
- Número de neuronas por nivel.
- Patrones de conexión.
- Flujo de información.

La distribución de neuronas dentro de la red se realiza formando niveles o capas de un número determinado de neuronas cada una. A partir de su situación dentro de la red, se pueden distinguir tres tipos de capas [9]:

De entrada: Es la capa que recibe directamente la información proveniente de las fuentes externas a la red.

Ocultas: Son internas a la red y no tiene contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de las capas ocultas pueden estar interconectadas de distintas maneras, lo que determina junto con su número, las distintas topologías de redes neuronales.

De salida: Transfieren información de la red hacia el exterior.

2.5. Algoritmos

2.5.1. Backpropagation

Como su nombre lo indica, consiste en la propagación del error hacia atrás, es un tipo de aprendizaje supervisado y está basado en la generalización de la regla delta. Una vez que se ha utilizado un patrón como entrada, éste se propaga desde la capa de entrada a las capas intermedias (ocultas) hasta obtener una salida. La salida obtenida se compara con la salida deseada y se calcula el error de cada una de las salidas de las neuronas. El error se propaga hacia atrás, partiendo de la salida pasando por cada una de las neuronas que aportan a la capa de salida. Las capas ocultas reciben una fracción del error, que es equivalente al error en la salida. Esto se realiza con cada una de las neuronas de la red, hasta que el error se haya distribuido completamente. Mediante esta distribución del error, se pueden manipular los pesos de conexión de cada neurona, con el fin de que el error disminuya, y obtener una correcta aproximación de los patrones en el entrenamiento.

2.5.2. OWO-HWO

El OWO - HWO es un algoritmo de capacitación alternativo de las redes neuronales de propagación hacia adelante, resuelve ecuaciones lineales para los pesos en las salidas y reduce la separación en la función de error de las capas ocultas con respecto a los pesos de las capas ocultas. En este sentido, una nueva función en la capa oculta es propuesta la cual da énfasis en las funciones de error que corresponden a un valor saturado de la función de activación. En efecto una taza de aprendizaje adaptativo basado en una forma local de la superficie del error es usada en el entrenamiento de la capa oculta. Una rápida convergencia en el aprendizaje ha sido experimentalmente verificada [17].

El algoritmo para la optimización de los pesos de salida - optimización de los pesos ocultos (OWO-HWO) es ampliamente usado en el entrenamiento de las redes neuronales con propagación hacia adelante tales como el perceptron multicapa (MLP). Trabaja bien para muchas aproximaciones y en los problemas de reconocimiento de patrones.

En OWO-HWO, se modifican alternativamente los pesos de salida y las unidades ocultas para reducir el error en el entrenamiento. Este modifica los pesos ocultos basándose en la minimización del Error Cuadrático Promedio (MSE por sus siglas en inglés) entre las deseadas y las actuales funciones de la red. Aunque OWO-HWO frecuentemente converge rápidamente éste no usa algunas técnicas efectivas, por ejemplo, prevención de saturación prematura, adaptación de la tasa de aprendizaje [17].

2.5.3. Algoritmos Genéticos

Los algoritmos genéticos son una técnica de resolución de problemas inspirada en la naturaleza. Están basados en el principio de Darwin, sobre la reproducción y supervivencia de los individuos más aptos.

En los últimos años, la comunidad científica internacional ha mostrado un creciente interés en una nueva técnica de búsqueda basada en la teoría de la evolución y que se conoce como el algoritmo genético. Esta técnica se basa en los mecanismos de selección que utiliza la naturaleza, de acuerdo a los cuales

los individuos más aptos de una población son los que sobreviven, al adaptarse más fácilmente a los cambios que se producen en su entorno. Hoy en día se sabe que estos cambios se efectúan en los genes (unidad básica de codificación de cada uno de los atributos de un ser vivo) de un individuo, y que los atributos más deseables (i.e., los que le permiten a un individuo adaptarse mejor a su entorno) del mismo se transmiten a sus descendientes, cuando éste se reproduce sexualmente [1].

Un investigador de la Universidad de Michigan llamado John Holland estaba consciente de la importancia de la selección natural, y a fines de los 60s desarrolló una técnica que permitió incorporarla en un programa de computadora. Su objetivo era lograr que las computadoras aprendieran por sí mismas. A la técnica que inventó Holland se le llamó originalmente "planes reproductivos", pero se hizo popular bajo el nombre "algoritmo genético" tras la publicación de su libro en 1975 [7].

Redes Neuronales Artificiales Evolutivas Las redes neuronales artificiales evolutivas se refieren a un tipo de redes neuronales artificiales a la que se le aplican técnicas evolutivas dentro del proceso de diseño y aprendizaje de la red. De forma general se puede afirmar que los algoritmos evolutivos se utilizan en el contexto de las redes neuronales en tres diferentes niveles: estimación de pesos de las conexiones, arquitecturas e implantación de reglas de aprendizaje. La estimación de los pesos de las conexiones introduce un método que sustituye o complementa a los métodos clásicos de optimización basados en el gradiente descendente que a menudo suelen quedar atrapados en mínimos locales y que ofrecen algunas dificultades cuando se aplican a redes neuronales recurrentes [17]. Por otra parte, el diseño de la estructura de la red permite a la red adaptar su topología a diferentes tareas permitiendo que la red se adapte fácilmente en entornos dinámicos, por lo que la intervención humana es mínima dentro del proceso de aprendizaje. La implantación de las reglas de aprendizaje permite que el propio sistema aprenda a aprender y el proceso de búsqueda sea más eficiente y eficaz.

Estimación de los pesos de las conexiones Dada una estructura de red, el entrenamiento de los pesos de las conexiones se formula en base a la minimización de la función de error. Como ya se ha dicho, los principales algoritmos de entrenamiento se basan en el descenso del gradiente de la función de error: retropropagación (BP). Dichos algoritmos aunque son muy eficientes, suelen quedar atrapados en mínimos locales dependiendo del punto de partida de la búsqueda. Además, estos algoritmos no se pueden utilizar cuando la función de error es multimodal y/o no diferenciable.

Por su parte, los algoritmos evolutivos realizan una búsqueda global del óptimo de forma más efectiva y pueden trabajar con superficies de error multimodal y no diferenciable. Al no necesitar ninguna información relacionada con el gradiente de la función de error, resultan métodos bastante útiles cuando esta información no está disponible. Este hecho es el que ha motivado la utilización de redes neuronales evolutivas en la resolución de numerosos problemas reales en los que con frecuencia la función de error es multimodal y presenta problemas de continuidad y de diferenciable. Por su parte, los algoritmos basados en el gradiente (retropropagación y gradiente conjugado) suelen ser más rápidos

en la búsqueda del óptimo que el entrenamiento evolutivo. Sin embargo, los métodos evolutivos son en general menos sensibles a las condiciones iniciales del entrenamiento.

Recientemente, ha aparecido una nueva metodología que combina los algoritmos evolutivos y los métodos de búsqueda local. En el contexto de las redes neuronales, esa metodología lleva a cabo un entrenamiento híbrido, combinando la capacidad de buscador global de un algoritmo evolutivo con la capacidad de afinar la solución que tienen los algoritmos de búsqueda local como los basados en el gradiente [1]. Dentro del proceso de estimación de los pesos de las conexiones de la red se distinguen dos fases fundamentales: Decidir la representación de los pesos de las conexiones y diseñar los operadores de mutación y cruce más adecuados para aplicar sobre los individuos representados en la forma elegida.

3. Sistema de predicción de caudales

3.1. Investigación y selección de los algoritmos

El presente trabajo de investigación surgió con la necesidad de continuar con el estudio del proyecto de investigación: Redes Neuronales Artificiales Aplicadas En La Predicción De Caudales En La Cuenca Del Río Paute [15], desarrollado en el año 2004 y parte del 2005. Como resultados del proyecto se obtuvieron predicciones con valores de caudal muy semejantes a los reales, además se planteó la posibilidad de continuar con el estudio de las redes neuronales con el fin de llegar a obtener una calibración mayor en dicho modelo. El proyecto anterior se desarrolló enteramente utilizando Backpropagation como tipo de red neuronal. El presente proyecto se planteó con la necesidad de determinar el tipo de RNA más idóneo para obtener predicciones con un mayor índice de confiabilidad. Con esto como base se procedió a realizar una investigación orientada a determinar los tipos de redes más utilizados en aplicaciones que realizan predicción de patrones.

Como fruto de esta investigación, se obtuvieron los siguientes tipos:

- Backpropagation
- OWO-HWO
- Genéticos

Cabe indicar además que los algoritmos OWO-HWO y Genético pueden usarse además con el fin realizar optimizaciones en los pesos de las conexiones de cada una de las neuronas que conforman las capas de las redes neuronales.

3.2. Selección de los escenarios

Una vez realizada la selección de los algoritmos, lo siguiente es establecer los escenarios a utilizarse durante la validación de cada uno de los modelos obtenidos de cada tipo de RNA. Tomando como base el proyecto de investigación anterior, y tomando en consideración que se van a predecir los caudales de ingreso a la cuenca del río tobebamba, los escenarios de los cuales se obtuvieron mejores resultados son los siguientes:

Escenario 1:

Escenario 1		
Caudal	Tomebamba en Ucubamba	Salida
Precipitacion	Est Cancan Soldados 1997 2009 i-3	Entrada
Precipitacion	Est Cancan Soldados 1997 2009 i-2	Entrada
Precipitacion	Est Cancan Soldados 1997 2009 i-1	Entrada
Precipitacion	Est El Portete 1997 2001 i-3	Entrada
Precipitacion	Est El Portete 1997 2001 i-2	Entrada
Precipitacion	Est El Portete 1997 2001 i-1	Entrada
Precipitacion	Est Gualaceo DJ Pamar 1997 2009 i-3	Entrada
Precipitacion	Est Gualaceo DJ Pamar 1997 2009 i-2	Entrada
Precipitacion	Est Gualaceo DJ Pamar 1997 2009 i-1	Entrada
Precipitacion	Est La Esmeralda 1997 2009 i-3	Entrada
Precipitacion	Est La Esmeralda 1997 2009 i-2	Entrada
Precipitacion	Est La Esmeralda 1997 2009 i-1	Entrada
Precipitacion	Est Matadero en Sayausi 1997 2009 i-3	Entrada
Precipitacion	Est Matadero en Sayausi 1997 2009 i-2	Entrada
Precipitacion	Est Matadero en Sayausi 1997 2009 i-1	Entrada
Precipitacion	Est Tarqui DJ Cumbe 1997 2009 i-3	Entrada
Precipitacion	Est Tarqui DJ Cumbe 1997 2009 i-2	Entrada
Precipitacion	Est Tarqui DJ Cumbe 1997 2009 i-1	Entrada
Precipitacion	Est Yanuncay en Pucan 1997 2009 i-3	Entrada
Precipitacion	Est Yanuncay en Pucan 1997 2009 i-2	Entrada
Precipitacion	Est Yanuncay en Pucan 1997 2009 i-1	Entrada
Precipitacion	Est Ucubamba en ETAPA 1998 2009 i-3	Entrada
Precipitacion	Est Ucubamba en ETAPA 1998 2009 i-2	Entrada
Precipitacion	Est Ucubamba en ETAPA 1998 2009 i-1	Entrada
Caudal	Tomebamba en Ucubamba i-3	Entrada
Caudal	Tomebamba en Ucubamba i-2	Entrada
Caudal	Tomebamba en Ucubamba i-1	Entrada

Cuadro 1: Escenario 1

El escenario 1, está compuesto únicamente de estaciones de precipitación, y además incluye tres días de datos hacia atrás y realiza una predicción de un día hacia adelante. Se debe indicar además que éste es el escenario que mejores resultados obtuvo en el proyecto de predicción de caudales anterior.

Escenario 2:

Escenario 2		
Precipitacion	Est Cancan Soldados 1997 2011 i-1	Salida
Precipitacion	Est El Portete 1997 2003 i-1	Entrada
Precipitacion	Est Gualaceo DJ Pamar 1997 2011 i-1	Entrada
Precipitacion	Est La Esmeralda 1997 2011 i-1	Entrada
Precipitacion	Est Matadero en Sayausi 1997 2011 i-1	Entrada
Precipitacion	Est El Portete 1997 2001 i-1	Entrada
Precipitacion	Est Tarqui DJ Cumbe 1997 2011 i-1	Entrada
Precipitacion	Est Yanuncay en Pucan 1997 2010 i-1	Entrada
Precipitacion	Est Ucubamba en ETAPA 1998 2011 i-1	Entrada
Caudal	Tomebamba en Ucubamba i-1	Entrada

Cuadro 2: Escenario 2

El escenario 2, consta únicamente de datos de la estación de caudal en donde se realiza la predicción de caudales. El conjunto de datos incluye una resolución de un día datos hacia atrás y permite obtener la predicción de caudales de un día hacia adelante.

3.3. Resultados**3.3.1. Fase de selección**

Con el objetivo de realizar la validación de los modelos creados a partir de los tipos de datos seleccionados, se procedió a generar los escenarios y establecer los parámetros necesarios para el entrenamiento.

Como se puede apreciar los mejores resultados de estas validaciones se registraron en

el escenario 1, lo cual nos indica que: La normalización¹ de los datos de entrada, no tiene mucha influencia cuando se está utilizando el algoritmo de backpropagation, pero si influye positivamente cuando se utiliza el OWO-HWO.

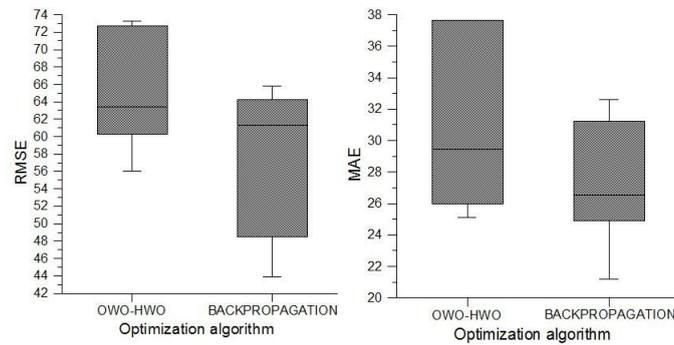


Figura 1: Cuadro gráfico del RMSE² (cuadro de la derecha) and MAE³ (cuadro del a izquierda) como una función el algoritmo optimizado de OWO-HWO y BACKPROPAGATION. La difusión por algoritmo es debido a la variación en el escenario (1, 2 o 3), entradas (4, 16 o 22), número de iteraciones (1000 o 9054) y normalización (si o no)

Al incrementar el número de iteraciones en el escenario 1 y utilizando el algoritmo backpropagation, se obtuvieron los mejores resultados, esto se puede ver de una manera más gráfica en la Figura 2

¹La normalización es el proceso en el cual todas las entradas que se utilicen en una red neuronal artificial son convertidas en valores que oscilan entre 0 y 1

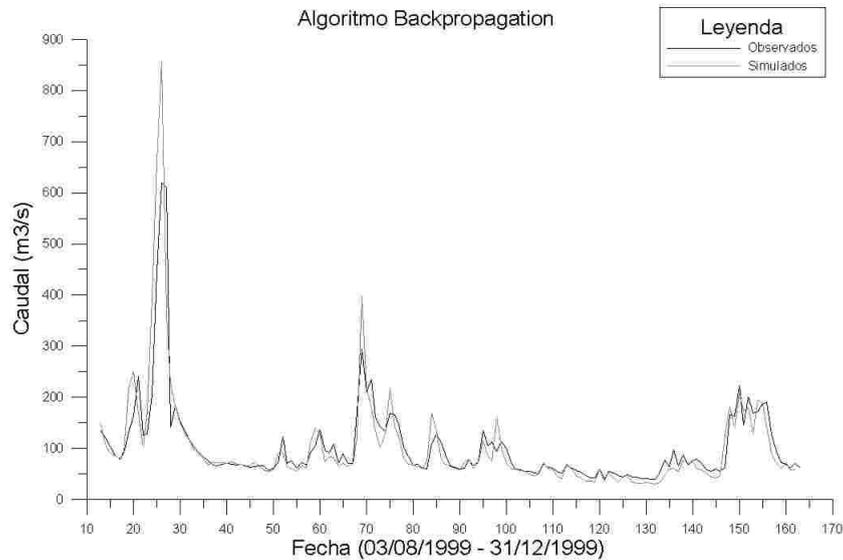


Figura 2: Comparación de los caudales diarios obtenidos en la RNA con los caudales diarios registrados en la estación Tomebamba en el período 3 de agosto de 1999 hasta el 31 de diciembre de 1999. Escenario 1, empleando el algoritmo Backpropagation

En base a lo anteriormente expuesto, se procedió a realizar la implementación de dicho algoritmo, con el fin de utilizar algoritmos para lograr un acople mucho mayor de los pesos de las conexiones de las neuronas. Este acople se planea realizarlo mediante la utilización de los algoritmos genéticos para la selección de los pesos. Esto es una buena opción debido a que backpropagation por defecto inicializa los pesos con valores seleccionados aleatoriamente. Con la utilización de los genéticos se puede obtener un conjunto de pesos mucho más representativos. Es por eso que el resultado de esta implementación ha permitido obtener un algoritmo híbrido entre el backpropagation y el genético.

3.3.2. Fase de implementación del algoritmo seleccionado

Para realizar las pruebas de la implementación de este algoritmo híbrido, se ha seleccionado únicamente los escenarios 1 y 2 por considerarse los que mejores resultados generaron. El objetivo principal es obtener los parámetros más adecuados para su correcto funcionamiento, razón por la cual se han variado los valores de:

- Capas ocultas
- Neuronas
- Tasa de aprendizaje
- Momento
- Iteraciones

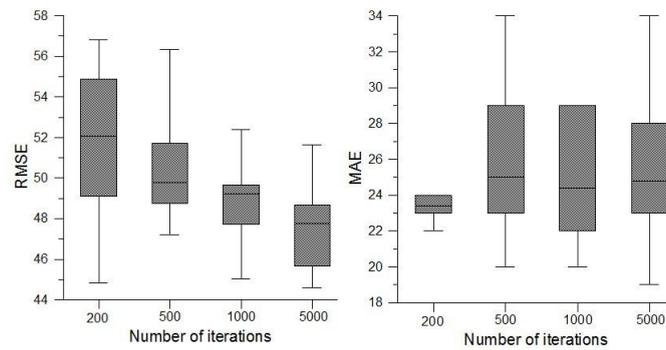


Figura 3: Gráfico del RMSE (cuadro derecho) y MAE (cuadro izquierdo) en función del número de iteraciones. La dispersión por el número de iteraciones es debido a la variación en el escenario (1 or 2), número de capas ocultas (1 o 2), número de neuronas (5, 10 o 13), tasas de aprendizaje (0.01, 0.1, 0.2 o 0.3) y momento (0, 0.05, 0.1 o 0.2)

En base a las pruebas realizadas con el modelo desarrollado, los mejores resultados indican que las siguientes características óptimas son:

- Iteraciones: 5000
- Capas ocultas: 2
- Neuronas: 10 en la primera y 5 en la segunda
- Taza de aprendizaje: 0.3
- Momento: 0.2

El acople en la validación de este modelo se lo puede ver claramente en la figura 4

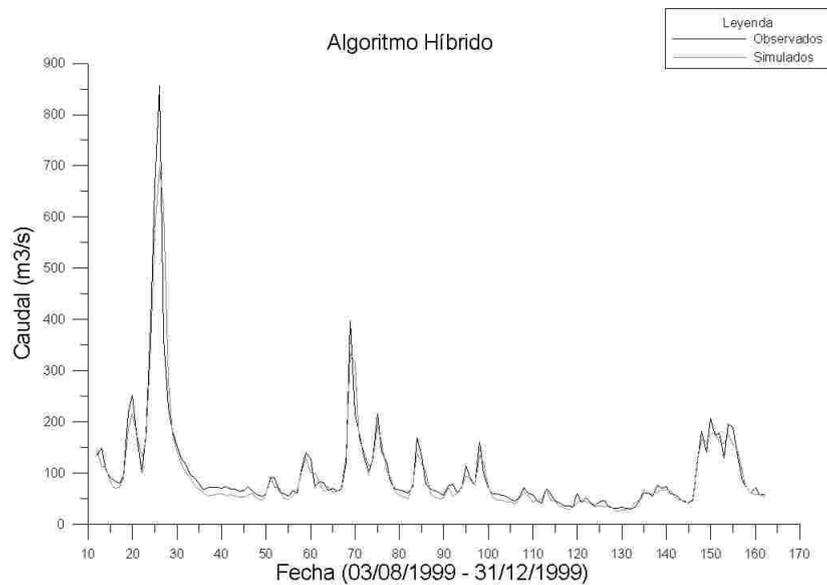


Figura 4: Resultados escenario 1, parámetros fijos 2 capas oculta (5 y 10 neuronas respectivamente), tasa de aprendizaje 0.3, momento 0.2, parámetros RMSE 30.52 y MAE 14.75.

En base a los resultados expuestos, se puede concluir que:

- A medida que aumenta las iteraciones, se presentan mejores resultados. El aumento
- en el número de capas ocultas mejoró los resultados de modelo.
- En las pruebas iniciales, la utilización de una tasa de aprendizaje de 0.1 entregó los mejores resultados. Cuando se aumentaba este valor, se incrementaba también el error MAE. Pero con la inclusión de una segunda capa oculta, se obtuvo una mejora en el MSE (Mean Square Error) y un valor aceptable de MAE. Por lo cual se puede decir que el valor de 0.3 para la tasa de aprendizaje combinado con un valor mayor a 1 en las capas ocultas es el óptimo para el modelo.
- El valor óptimo para el momento se lo ha establecido entre 0 y 0.2.

4. Conclusiones y futuros trabajos

4.1. Conclusiones del sistema de predicción de caudales

El algoritmo OWO-HWO requiere de un tiempo mayor para realizar el mismo número de iteraciones que con el algoritmo Backpropagation. De igual manera, el error medio cuadrático es menor con el Algoritmo Backpropagation que con el OWO-HWO. Al igualarse los tiempos de entrenamiento entre el Algoritmo OWO-HWO y el algoritmo Backpropagation, se puede observar que el algoritmo Backpropagation se reduce drásticamente el Error Medio Cuadrático (MSE) en comparación con el Algoritmo OWO-HWO. La normalización de datos (para valor entre 0 y 1) para el entrenamiento y el empleo del algoritmo OWO-HWO, produce una disminución del error cuadrático medio. El resultado de este conjunto de pruebas indica que el Algoritmo que ha presentado mejores resultados es el Algoritmo Backpropagation, por

cuanto tiene el menor error medio cuadrático. Se puede concluir adicionalmente que cuando se aumenta el tiempo de entrenamiento o se aumenta el número de iteraciones el error disminuye.

4.2. De los escenarios propuestos

Al realizar el entrenamiento y la simulación con el mismo conjunto de datos, los resultados en cuanto al error indica que el Algoritmo Backpropagation, tiene mejores resultados que el OWO-HWO.

Cuando en el entrenamiento se utiliza un conjunto de datos y en la predicción otros datos, lo que refleja el verdadero uso del sistema, los resultados presentados al usar el algoritmo Backpropagation fueron mejores al OWO-HWO en cuanto al error.

Referencias

- [1] R. R. Beasley, D., Bull, D. R., Martin. An Overview of Genetic Algorithms: Part 1, Fundamentals. Technical report, En University Computing, 1993.
- [2] E. Cantú-Paz. A survey of Parallel Genetic Algorithms. Technical Report Illinois Genetic Algorithms Laboratory. Technical report, University of Illinois at Urbana-Champaign, 1997.
- [3] Patricio Capelo. Sistema de telemetría diseñado para PROMAS - Universidad de Cuenca. Technical report, 2007.
- [4] C. Chinrungrueng. Evaluation of Heterogeneous Architectures of Artificial Neural Networks. Technical report, University of California at Berkeley, California, 1993.
- [5] Booch et Al. Proceso Unificado de Desarrollo de Software (UP). 2002.
- [6] R. F. Vázquez Z. & J. Feyen. Potencial evaporation: Its effect on the modelling of the hydrological cycle of a medium-sized catchment with the MIKE SHE code. 2002.
- [7] S. Forrest. Genetic Algorithms. *ACM Computer Survey*, 1996.
- [8] J. Fritsch. *Modular Neural Networks for Speech Recognition*. PhD thesis, Carnegie Mellon University, 1996.
- [9] J. R. Hiler V. J. Martínez. *Redes Neuronales Artificiales (Fundamentos, Modelos y Aplicaciones)*. Addison Wesley, 1998.
- [10] Hecht-Nielsen R. Counter-propagation networks. *J. Of Applied Optics*, 1987.
- [11] Frevert Donald Singh Vijay. *Mathematical Models of Small Watershed Hydrology and Applications*. 2002.

-
- [12] D.P. Solomatine. Genetic and other global optimization algorithms comparison and use in calibration problems. In *Proc. 3rd International Conference on Hydroinformatics*, 1998.
- [13] G.N. Paudyal S.Y. Liong, W.H. Lim. River Stage Forecasting in Bangladesh: Neural Network Approach. *Journal of Computing in Civil Engineering*, 2000.
- [14] P. Vanegas, P. De Bievre, B. Cisneros, F. Jerves, L. Lazo. Real time inflow prediction in the Paute River Basin. 2007.
- [15] Palacios F. Veintimilla J. *Redes Neuronales Artificiales Aplicadas En La Predicción De Caudales En La Cuenca Del Río Paute*. 2004.
- [16] G. Lewis W. Viessman. *Introduction to Hydrology*. HarperCollins College, New York, New York, USA, 1996 edition.
- [17] D. Whitley. *A Genetic Algorithm Tutorial*.
- [18] X. Yao. Evolutionary Artificial Neural Networks. *En International Journal of Neural Systems*, 1993.