

PREDICTION OF THE FLOW OF THE RIVER IN SHORT PERIODS OF TIME THROUGH NEURONAL NETWORKS

PREDICCIÓN DEL CAUDAL EN PERIODOS CORTOS DE TIEMPO MEDIANTE REDES NEURONALES

Ing. Nestor Ruiz Bautista, PhD. Jose Orlando Maldonado, Msc. Luis Armando Portilla

Universidad de Pamplona

Grupo de Investigación en Ciencias Computacionales CICOM, Programa de Ingeniería de Sistemas, Universidad de Pamplona

Tel.: 57-7-5685303, Fax: 57-7-5685303, Ext. 144

{nestor.ruiz, orlmaldonado, laporti}@unipamplona.edu.co

Abstract: In this document shows an experimental work that evaluates neural networks as a useful model for forecasting time series in the field of hydrology, where real test data will be analyzed as a case study, to obtain a model that is optimal in its implementation with a minimum margin of error. The data used correspond to periods of time between three months and one year with frequencies of between three minutes and daily average, respectively, for which it is a question of evaluating the margin of error obtained to make predictions with the data obtained in short periods of time, time, which are those that are available in a large number of sampling stations.

Keywords: Neural networks, procedures, forecasting time series, hydrology.

Resumen: En el presente documento se muestra un trabajo experimental que evalúa las redes neuronales como modelo útil para el pronóstico de series temporales en el campo de la hidrología, donde se analizan datos reales de prueba como caso de estudio, para obtener como propuesta un modelo que sea óptimo en su implementación con un margen de error mínimo. Los datos utilizados corresponden a periodos de tiempo comprendidos entre tres meses y un año con frecuencias de entre tres minutos y promedio diario, respectivamente, por lo cual se trata de evaluar el margen de error obtenido para hacer predicción con los datos obtenidos en periodos cortos de tiempo, que son los que están disponibles en una gran cantidad de estaciones de muestreo

Palabras clave: Redes neuronales, predicción de series temporales, hidrología.

1. INTRODUCCION

Diferentes disciplinas que van desde la economía, ciencias e ingeniería, desde hace muchos años acogen a la predicción de series de tiempo como respuesta a problemas que requieren de toma de decisiones de corto mediano y largo plazo. Una serie de tiempo es el registro de una secuencia de datos históricos ordenados de un determinado proceso con un intervalo de tiempo común, cuyos valores futuros son dependientes de los valores pasados. Con

estos valores es posible predecir un comportamiento futuro utilizando modelos estadísticos y matemáticos. Años atrás, antes de los avances tecnológicos actuales se utilizaban métodos estadísticos como los de Holt-Winters y Box-Jenkins (Gázquez Abad, Jiménez Guerrero, & Sánchez Fernández, 2006) para predecir datos en series de tiempo los cuales son adecuados para trabajarlos en series de tiempo lineales, pero con limitaciones en series de tiempo no lineales.

Para dar solución a series de tiempo que tienen una naturaleza no lineal se hace necesario implementar técnicas no estadísticas, obteniendo modelos más eficientes utilizando como alternativa a las redes neuronales artificiales (RNA), usadas en el campo de la investigación como una herramienta eficaz para el modelado y la predicción de series de tiempo, pues las RNA tienen la característica de capturar relaciones lineales y no lineales demostrando ser más robustas, además las redes neuronales poseen la capacidad de aprender y procesar gran cantidad de información ya sea que este completa o incompleta y con alto grado de tolerancia al ruido presente en los datos.

2. TRABAJOS RELACIONADOS

(Camposano Parra, 2011) realizó en su tesis ‘Análisis de la robustez de un modelo de redes neuronales para la predicción de caudales en la cuenca alta del río Paute’ un análisis sobre la robustez del método de redes neuronales para predecir caudales, con la cual se evaluaron las variaciones respuesta del modelo teniendo en cuenta las variables de entrada y la capacidad de predicción del modelo, el análisis se realizó a la sensibilidad y la incertidumbre como cumplimiento de sus objetivos, la sensibilidad ayudó a estudiar cada variable del modelo mientras que la incertidumbre aportó al estudio de la predicción del caudal, análisis posteriores advierten sobre la calidad de los datos que se utilizan como entradas de datos deben ser de buena calidad, datos erróneos pueden ser causantes de ruido generando alteración en el modelo.

(Gomez Vargas, Obregón Neira, & Socarras Quintero, 2010) realizaron su trabajo ‘Aplicación del modelo neurodifuso ANFIS vs redes neuronales, al problema predictivo de caudales medios mensuales del río Bogotá en Villapinzón’ comparando seis tipos de modelos para el sistema neurodifuso ANFIS en el cual observan el tipo de comportamiento que estos modelos tendrán, utilizando datos de caudales medios, los resultados serán comparados con un modelo de red neuronal de tipo perceptron, en este trabajo observaran si los resultados son dependientes de la cantidad de entradas a los modelos, de estos resultados se evalúa si los modelos son factibles para la implementación en el campo de la hidrología.

(Gómez Gallego, 2012) propone en su trabajo ‘Redes neuronales para la simulación, estimación y control de caudales impulsados por estaciones de bombeo en zonas regables’ la demanda en un

sistema de distribución de agua, donde aplica inicialmente métodos estadísticos tradicionales como regresión lineal y modelo de redes neuronales, utilizando datos históricos de caudales diarios de los cuales se tiene que definir una relación de datos pasados y futuros, de igual manera tiene en cuenta factores externos como lo son las temperaturas, el viento, radiación solar, precipitación y evo transpiración potencial, el objetivo del trabajo será definir el modelo más viable que sea capaz de predecir según los objetivos, la demanda en un tiempo definido de 24 horas, para ello utiliza datos históricos de todas las variables que influyen en sistema del caudal.

(Matinez Gomez & Pedraza Caballero, 2012) proponen en su trabajo ‘Implementación web de redes neuronales artificiales aplicadas de la predicción de series de tiempo’ una plataforma web donde implementaran dos tipos de red neuronales artificiales, el perceptron multicapa y la red neuronal basada en función de base radial para el análisis de series de tiempo, este trabajo se realiza con el fin de establecer resultados para la simulación de los resultados, teniendo en cuenta los datos recolectados, estos resultados se analizaran con el fin de saber si los valores de las variables utilizadas crecen o decrecen y bajo que costo computacional se logran los resultados.

(Moscoso Barrera, 2015) presenta la comparación entre modelos físicos (Hec-Ras) y modelos inteligentes (redes neuronales – redes ANFIS), utilizadas para la predicción, se realiza la comparación de diferentes modelos tanto físicos como inteligentes para encontrar el modelo que arroje buenos resultados, tomando datos históricos de la cuenca del río Bogotá comprendidos desde 2009 a 2013, con estos modelos se desea determinar el modelo que más se aproximan a los datos reales, estos resultados son analizados y con ellos se determina según los objetivos que se plantean, generar datos que ayuden a pronosticar zonas inundadas.

(Pierini, Gomez, & Telesca, 2012) realizan en su trabajo ‘Predicción de caudales en río Colorado, Argentina’ el análisis de resultados a partir de pruebas realizadas con redes neuronales y modelo autorregresivo, los datos a utilizar en estas pruebas corresponden a datos históricos de 18 años del caudal estudiado, en el trabajo se realizará el modelado y la predicción de las fluctuaciones diarias del caudal, los dos modelos a trabajar se compararan con el fin de determinar cual está sujeta a trabajar de manera eficiente y que los resultados obtenidos sean fiables, ya que dependiendo de los resultados se puede determinar por ejemplo la regularización de los embalses y centrales hidroeléctricas, y el

abastecimiento de agua en ciudades como Bahía Blanca.

(Ocampo & Vélez, 2014) plantean en su trabajo ‘Análisis comparativo de modelos hidrológicos de simulación continua en cuencas de alta montaña: caso del río Chinchiná’ la implementación de un modelo capaz de gestionar el recurso hídrico en alta montaña, en el trabajo se plantea un análisis multimodelo para capturar incertidumbre asociada mediante la aplicación de siete modelos hidrológicos con diferentes niveles de complejidad, el análisis realizado a los resultado se hicieron mediante métodos gráficos y estadísticos, los datos estadísticos, los hidrógramas y curvas de duración permiten analizar la esorrentía en cuencas de alta montaña.

3. MARCO TEORICO

3.1 Ciclo hidrológico

El ciclo hidrológico (Aparicio Mijares, 1992) son una serie de estados del agua presentes en la naturaleza, los cuales se ejecutan simultáneamente de forma continua y no tienen un principio o un fin, como foco central de la hidrología, este ciclo puede estudiarse de manera adecuada mediante su representación esquemática, la cual describe todos los procesos presentes en el. Partiendo de cualquier punto del esquema del ciclo, puede iniciarse por la evaporación del agua de los océanos o desde la superficie terrestre debido a la radiación solar y el viento para llegar a la atmósfera, este vapor de agua forma nubes y se condensa, luego se precipita sobre la superficie terrestre o los océanos. Durante su trayecto de agua precipitada esta puede volver a evaporarse o ser interceptada por plantas, convertirse en flujo superficial sobre el suelo, infiltrarse en él, volverse flujo por debajo del suelo y luego poder descargarse en ríos. El agua que se intercepta y la que corre por la superficie regresa a la atmósfera mediante la evaporación. De la que se precipita y llega a las corrientes parte de esta se infiltra profundamente para recargar aguas subterráneas de donde pueden emerger en forma de manantiales o se pueden deslizar hacia los ríos para que circulen libremente sobre la superficie, fluyendo hacia el mar o se evapora hacia la atmósfera. Del agua infiltrada, otra parte es absorbida por las plantas y posteriormente es transpirada, casi en su totalidad y a medida que continua el ciclo hidrológico.




figura 1. Ciclo Hidrológico

3.2 Cuenca Hidrológica

La cuenca es la unidad básica de estudio del ciclo hidrológico, es un terreno ancho y profundo cuyas aguas llegan a un punto en común, es decir una cuenca hidrológica define a una red hídrica. Las cuencas pueden ser superficiales o subterráneas, las superficiales tienen a drenar las gotas de lluvia por un sistema de corrientes hacia un mismo punto de salida, y la cuenca subterránea, es semejante a la superficial ya que poseen la misma definición, diferenciándose en el punto de vista de su salida, ya que pueden haber dos tipos de cuencas: las cuencas endorreicas tienen un punto de salida que está dentro de los límites de la misma cuenca y generalmente es un lago, y las cuencas exorreicas cuyo punto de salida se encuentra en los límites de la cuenca y está en otra corriente o en el mar.




figura 2. Tipos de Cuenca

3.3 Clasificación de los modelos hidrológicos

Modelos físicos: poseen modelos a escala (ej: tamaño reducido de una presa mediante modelo hidráulico) y modelos análogos (ej: movimiento de fluido viscoso para modelar flujo a través de un acuífero).

Modelos abstractos: representación matemática del sistema, describiendo las operaciones mediante ecuaciones, relacionando las variables de entrada y las de salida, variables que pueden ser funciones de espacio y tiempo.

Trabajar con variables aleatorias es una tarea ardua, para ello se simplifican los modelos para que sea más práctico, despreciando algunas

fuentes de variación, estos modelos hidrológicos pueden clasificarse como:

- 2.1) Modelo determinístico: no considera aleatoriedad, una entrada dada produce siempre una misma salida.
- 2.2) Modelo estocástico: tiene salidas que son por lo menos parcialmente aleatorias.

Los modelos determinísticos hacen pronósticos, mientras que los modelos estocásticos hacen predicciones.

3.4 Redes Neuronales Artificiales




Figura 3. Ejemplo del perceptrón multicapa

El objetivo de las redes neuronales es llegar a diseñar máquinas con elementos neuronales de procesamiento paralelo, de modo que se llegue a emular con la red, de forma similar a como lo hacen los sistemas neuronales de los animales.

3.5 Redes feedforward

Son aquellas redes que se enfocan en, lo que se puede hacer mejor o distinto en un futuro y la forma en que la información fluye es unidireccional desde las neuronas de entrada a la(s) capa(s) de procesamiento, existiendo así dos tipos de redes las monocapa y multicapa hasta llegar a la capa de salida.

Existen dos modelos (Isasi Viñuela & Galván León, 2004) de redes feedforward el primero es el perceptrón simple el cual es una red monocapa la cual es una red formada por una sola capa de neuronas desconectadas entre sí, y una o varias células de salida, las conexiones determinan las superficies de discriminación del sistema es decir utiliza formas lineales como funciones discriminantes, su limitación está en que solo puede sintetizar clasificadores lineales, discriminando solo conjuntos linealmente separables.

El segundo modelo es el perceptrón multicapa o red multicapa con conexiones hacia adelante, este es una generalización del perceptrón simple, y que nace en consecuencia de la limitación que tiene la arquitectura del sistema simple referente al problema de separabilidad no lineal, las

conexiones del perceptrón multicapa siempre están dirigidas hacia adelante, es decir, las neuronas de una capa se conectan a una capa siguiente, de ahí surge el nombre de redes alimentadas hacia adelante o redes feedforward desde la capa de entrada existen conexiones a la primera capa oculta y de esta a otra capa, se dice entonces que la red está totalmente conectada.

Cuando se desea abordar un problema con el perceptrón multicapa, uno de los pasos a seguir es realizar la arquitectura de la red, es decir, determinar la función de activación a emplear ya sea una función sigmoide, definir el número de neuronas y el número de capas de red, no importa la función de activación que se elija, esto no influye en la solución del problema sino en el recorrido que se desee utilizar.

36. Redes de Neuronas de base radial

Son redes multicapa de base radial (Isasi Viñuela & Galván León, 2004) con conexiones hacia adelante con similitud al perceptrón multicapa al ser aproximadores universales ya que pueden aproximar cualquier función continua, caracterizado porque están formadas por una única capa oculta y cada neurona de la capa posee carácter local, haciendo que cada neurona oculta de la red se active en una región diferente del espacio de patrones de entrada. El carácter local es dado por el uso de funciones de base radial como por ejemplo la función gaussiana como función de activación, estas redes realizan una combinación lineal de las activaciones de las neuronas ocultas, es decir, solo unas pocas neuronas ocultas pueden ser procesadas para nuevos patrones de entrada.

Cada neurona de la red de base radial construye una aproximación local y no lineal en una determinada región del espacio de entrada, ya que la salida de la red es una combinación lineal de las funciones de base radial, las aproximaciones que constituyen las redes de base radial son combinaciones lineales de múltiples funciones locales y no lineales, lo que hace que relaciones complejas se vuelvan colecciones locales menos complejas diferenciándose de las aproximaciones globales del perceptrón, el cual hace que se pueda aplicar al campo del análisis de las series temporales.

Las redes de base radial están formadas por tres capas de neuronas, la capa de entrada la cual recibe señales de exterior, transmitiendo a la siguiente capa sin realizar procesos sobre las señales, en la capa oculta se reciben las señales

de la capa de entrada y realizan la transformación local y no lineal de las señales, y la capa de salida quien es la que realiza la combinación lineal de las activaciones de las neuronas ocultas, actuando también como salida de la red.




figura 4. Arquitectura de la red de base radial

el número de neuronas ocultas en la red se puede determinar a modo de prueba y error, el número de neuronas se puede variar hasta que se pueda conseguir una red que pueda ser capaz de resolver el problema, la diferencia de esta red con un perceptrón multicapa es que en la red de base radial al añadirse o eliminarse neuronas de la capa oculta influye significativamente en los resultados obtenidos para la red.

4. MODELO DE PREDICCIÓN HIDROLÓGICO

Para el desarrollo del proyecto se opta por trabajar con el modelo autorregresivo (García Martos, 2012) y modelos autorregresivo con variable exógena, para ello se tiene que tener en cuenta que un modelo autorregresivo es un modelo de regresión en el que las variables explicativas, son la misma variable dependiente retardada.

Este indica que X_{t-1} es conocido en t y a^t no es conocido. a^t constituye el valor de innovación.

Se debe tener en cuenta que tipo de modelo se debe implementar, para ello se observa los diferentes modelos estacionarios con el modelo

4.1 Tipo de modelos estacionarios a implementar.

Modelo Autorregresivo. AR.: Se utilizará este modelo ya que la condición se ajusta a las necesidades de utilizar valores pasados y que este solo dependa de los valores que se tengan a

disposición, y que ninguna otra variable externa esté presente en el modelo a comparación de los modelos autorregresivos de media móvil que dependen de valores actuales y variables externas estocásticas que afecten el comportamiento de la implementación del modelo

Lo que nos dice el modelo autorregresivo es que se tomaran datos pasados de una serie de tiempo y según estos datos pasados se podrá determinar el valor futuro a predecir para ello se tomara un conjunto de datos llamado Ventana de predicción que será un conjunto de datos que de desee tomar y el valor futuro será determinado según el modelo:

Modelos Autorregresivos con entrada exógena

ARX: este otro modelo es útil cuando la variable a predecir no solo dependerá de valores pasados sino también dependerá de otra ventana de predicción con variables exógenas cuyos valores tengan relación con los datos utilizados en la ventana de predicción principal.

Para entender este método se puede utilizar como ejemplo a (Agudelo, López Lezama, & Velilla, 2015) trabajo se basó en predicción se desea determinar el precio de energía de la bolsa, teniendo como entradas exógenas la demanda, la relación, generación hidráulica-térmica, fenómeno del niño y volumen diario de energía.

4.2 Datos de prueba

Como datos de prueba se utilizaran los datos de recolección de la estación hidrométrica llamada GLENAMOY, estación la cual se encuentra en uno de los afluentes en Irlanda, estos datos están disponible en la web; Los datos que se tomaron corresponden a dos series de tiempo la primera tiene la característica de ser una serie de datos que fueron registrados cada 15 minutos durante 3 meses con una totalidad de 8531 filas con los datos de registro de cada medición, de las cuales cada una posee, la fecha y el momento en que fue tomada la medición además de tener el valor de la medición, la segunda serie corresponde a una serie que contiene 365 datos, cada fila tiene el valor de caudal tomado durante 1 año.

4.3 Experimentación con diferentes arquitecturas y validación cruzada

Para implementar redes con arquitectura de red feedforward backpropagation se utiliza la toolbox de redes neuronales de Matlab, y específicamente la estructura de red con función newff de la cual ya se conoce el tipo de

parámetros que recibe dicha función para la creación de la red neuronal.

Antes de iniciar las pruebas se debe tener a disposición los datos hidroclimáticos que están disponibles en la web con los cuales se va a trabajar, inicialmente se guardan en un tipo de archivo .MAT para su posterior utilización en cualquiera de los datos, para la interpretación de los datos se hace necesario antes de aplicar cualquier función, la normalización de los datos para que estos puedan ser analizados de forma apropiada cuando se obtengan resultados de forma gráfica, de igual manera en la interpretación de los error que arrojen las pruebas, graficando los resultados obtenidos.

Se trata de predecir Caudal en $t+1$, con los datos de Caudal observados en tiempo t , $t-1$, $t-2$, ..., $t-10$. La figura 5 muestra el error de predicción y la serie obtenida de la última red entrenada.

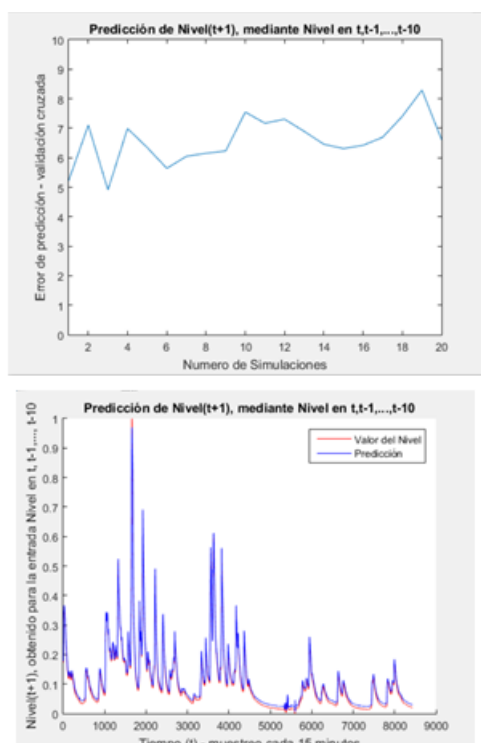


Figura 5. Error de predicción del caudal ($t+1$) y Predicción del caudal ($t+1$).

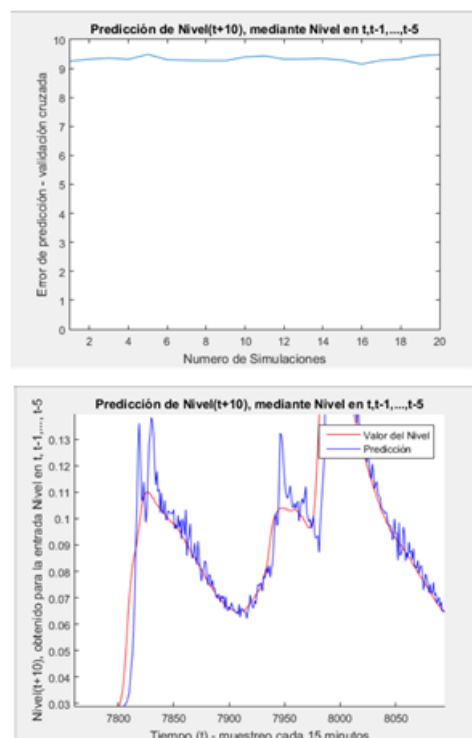


Figura 6. Error de predicción del caudal ($t+10$) y Predicción del caudal ($t+10$).

La figura 6 muestra los resultados obtenidos para un error de predicción del caudal ($t+10$), para la ventana de predicción con el caudal en t , $t-1$, ..., $t-5$, junto con la predicción del caudal en ($t+10$), también se aprecia el error obtenido en cada una de las iteraciones, así como la gráfica obtenida por la simulación de la red, comparada con la serie original. Se ha realizado zoom sobre la imagen para observar en detalle las diferencias entre el Caudal que la red predice, y el Caudal en la serie original. La predicción tiene un cierto ruido añadido producto del error de predicción. Sin embargo, se observa que se mantienen la tendencia y estacionalidad de la serie, el error medio obtenido en esta prueba es 9.3329 %.

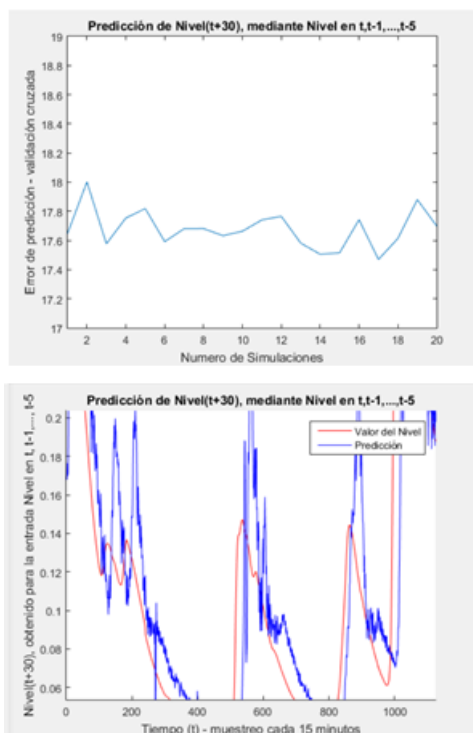


Figura 7. Error de predicción del caudal ($t+30$) y Predicción del caudal ($t+30$).

La figura 7 muestra los resultados obtenidos para un error medio de predicción del caudal ($t+30$), para la ventana de predicción con el caudal en t , $t-1$, ..., $t-5$, junto con la predicción del caudal en ($t+30$) comparándola con la serie original del caudal, donde se observa la distorsión de la red resultante por el ruido, la prueba arrojó un error de predicción del 17.6781%.

4.4 Resultados con red de retropropagación clásica

La recopilación de los errores en las diferentes predicciones desde $t+1$ a $t+50$ con intervalos de tiempo definidos, para tiempo futuro son mostradas en la tabla 1.

Predicción	t+1	t+2	t+5
Error medio	6.5326	6.9539	6.2131
Predicción	t+10	t+15	t+20
Error medio	9.3329	12.2376	14.4997
Predicción	t+30	t+40	t+50
Error medio	17.6781	19.8771	21.3199

Tabla 1 Error medio para predicciones tiempo futuro con una red de retropropagación

4.5 Prueba con red de retropropagación en cascada

Se realiza el entrenamiento, y simulación utilizando una red FeedForward en Cascada. Esta es una red con una arquitectura similar a las

redes FeedForward (Perceptrón multicapa, pero incluyen una conexión desde la entrada y cada capa anterior, a la siguientes capa. Nuevamente se realiza la predicción futura para los valores $t+i$, con $i = 1, 2, 5, 10, 15, 20, 30, 40$ y 50 . Los mejores resultados se obtienen al utilizar una red de dos capas ocultas con 10 neuronas en cada una de ellas.

La siguiente tabla 3, muestra los resultados obtenidos del error promedio para cada uno de los valores, teniendo en cuenta que se realizaron 20 simulaciones para cada valor de i .

Predicción	t+1	t+2	t+5
Error medio	2.327	3.242	5.815
Predicción	t+10	t+15	t+20
Error medio	9.404	12.215	14.480
Predicción	t+30	t+40	t+50
Error medio	17.657	19.841	21.364

Tabla 2 Error medio para predicciones tiempo futuro con una red de retropropagación en cascada.

4.6 Prueba con red de función de base radial

Se realiza la predicción futura para los valores $t+i$, con $i = 1, 2, 5, 10, 15, 20, 30, 40$ y 50 , utilizando una red neuronal de función de base radial, la cual se caracteriza por un aproximador universal de funciones, cuyo entrenamiento suele darse en menor tiempo que el de un perceptrón multicapa, para este caso se utiliza un ancho de gaussiana de 0.15. Este parámetro indica que se realiza una aproximación fina, lo cual requiere mayor número de iteraciones para reducir el error.

La siguiente tabla 3 muestra los resultados obtenidos del error promedio para cada uno de los valores, teniendo en cuenta que se realizaron 20 simulaciones para cada valor de i .

Predicción	t+1	t+2	t+5
Error medio	18.564	18.707	19.056
Predicción	t+10	t+15	t+20
Error medio	19.402	20.045	20.718
Predicción	t+30	t+40	t+50
Error medio	22.093	23.21	24.001

Tabla 3 Error medio para predicciones tiempo futuro con una red de base radial

5. ANALISIS DE RESULTADOS

En un pimer experimento se trata de determinar la capacidad de una red feedforward, es decir un perceptrón multicapa, para predecir el caudal en

el tiempo $t+1$, utilizando como entrada el valor del nivel de caudal en el tiempo t . Es decir, el caso más sencillo de predicción. En este caso se esperan los mejores resultados. Se realizaron 20 simulaciones. El error promedio está en 7%. Se realizaron simulaciones con diferentes arquitecturas de red (aumentando diferentes combinaciones y números de neuronas), y se optó por una arquitectura de 2 capas con 10 neuronas cada 1, con buen rendimiento en términos de coste computacional / Error de predicción.

En un segundo experimento se realizó el entrenamiento y simulación de la red para predecir el caudal en el tiempo ($t+1$), utilizando como entradas los valores de la serie en varios tiempos anteriores, para lo cual se definieron diferentes ventanas de predicción:

Ventana 1. Se trata, de predecir el caudal $t+1$, utilizando como entradas el caudal en t , $t-1$, $t-2$.

Ventana 2. Se trata de predecir el caudal $t+1$, utilizando como entradas el caudal en t , $t-1$, $t-2$, $t-3$, $t-4$, $t-5$.

Ventana 3. Se trata de predecir el caudal $t+1$, utilizando como entradas el caudal en t , $t-1$, $t-2$, ..., $t-10$.

Ventana 4. Se trata de predecir el caudal $t+1$, utilizando como entradas el caudal en t , $t-1$, $t-2$, ..., $t-20$.

En la tabla 7. se muestra los resultados de error promedio en la predicción del caudal en t , con las diferentes entradas.

Retrazos	Ven.1	Ven.2-	Ven.3	Ven.4
Error promedio	6.963	6.83%	6.58%	7.159%

Tabla 4. Error promedio para la predicción del caudal en el tiempo t , con diferentes retrasos en la dirección de entrada

Los resultados de la tabla indican que si se toma una ventana amplia como información de entrada en la red neuronal, los retrasos más viejos generan cierto ruido en la entrada, que empeora el error de predicción.

Por lo anterior, en un tercer experimento se decide utilizar como entradas para la predicción de datos futuros, solo los valores del caudal en t , $t-1$, ..., $t-5$. Luego se desea predecir valores de caudal para tiempos de futuro más distantes, y no solo la $t+1$. En concreto se entrena el modelo para predecir los valores de caudal en los tiempos $t+2$, $t+5$, $t+10$, $t+15$, $t+20$, $t+30$, $t+40$ y $t+50$. Para cada valor futuro a predecir, se realizan 20 entrenamientos y simulaciones, para determinar la estabilidad del error obtenido. Se observa estabilidad en su variación, por lo cual se

toma el valor promedio como referencia. Teniendo en cuenta que el muestreo en la serie es de cada 15 minutos, se puede interpretar que el error de predicción del caudal en 12.5 horas, tiene un error de 21.3%.

En un cuarto experimento, se repite el modelo de predicción anterior, utilizando otro tipo de red neuronal. Es decir predecir el valor del caudal en los tiempos futuros $t+2$, $t+5$, $t+10$, $t+15$, $t+20$, $t+30$, $t+40$ y $t+50$, utilizando la información del pasado en t , $t-1$, ..., $t-5$. Para ellos se utiliza una red neuronal de Función de Base Radial, la cual se caracteriza por ser un aproximador universal de funciones. Los resultados obtenidos se muestran en la tabla 3. Se observa que el error de predicción aumenta, de manera que la predicción empeora con respecto a los resultados obtenidos en el caso de la red feedforward de tipo perceptrón multicapa. El error más bajo obtenido se encuentra para $t+2$, siendo del 18.56% y el valor mas alto se tiene en $t+50$ siendo este del 24.

En un quinto experimento se prueba el mismo modelo, pero con una red de tipo feedforward escalonada. En este modelo de red neuronal, cada capa de la red se conecta con todas las subsiguientes directamente, generando un modelo altamente conectado. En este caso el error de predicción mejora con respecto a las redes neuronales previamente utilizadas. En el mejor de los casos el error es de 2.32%, en $t+2$, mejorando notablemente los resultados anteriores. El peor valor del error está en $t+5$, siendo de 21.36%, mejor que en el caso de la red de Función de Base Radial, y casi idéntico a la obtenida por el perceptrón multicapa convencional.

6. CONCLUSIONES

Se ha desarrollado un modelo para la predicción de caudales medios utilizando redes neuronales y se ha evaluado su desempeño para diferentes ventanas temporales.

El modelo utiliza la técnica de validación cruzada para mostrar la independencia de los resultados respecto a la selección de los datos de entrenamiento y datos de prueba de la serie de datos disponibles.

La serie de datos utilizada muestra la captura del caudal de agua realizada en una estación particular, durante tres meses, en intervalos de 15 minutos. El modelo sin embargo se puede aplicar a series con diferentes periodos de captura y frecuencias de muestreo, pero los resultados aquí mostrados son particulares de los datos utilizados. Los modelos de redes neuronales seleccionados son la red neuronal feedforward de tipo

perceptrón multicapa, la red neuronal de Función de Base Radial y la red neuronal feedforward en cascada.

El modelo diseñado permite entrenar la red utilizando diferentes retrasos para la predicción, es decir permite utilizar como entrada diferentes intervalos de tiempo pasado, así como predecir el caudal para diferentes ventanas de tiempo futuro. Las pruebas preliminares determinan que al utilizar valores de tiempo pasado mayores a $t-5$, no aporta mejores resultados en cuanto al error de predicción, por lo cual se fijó el intervalo $t-1, \dots, t-5$ como dato de entrada para predecir caudales futuros.

Se realizaron las predicciones en el tiempo futuro $t+2, t+5, t+10, t+15, t+20, t+30, t+40$ y $t+50$. Es decir las predicciones de caudal obtenidas fueron para los siguientes 30 minutos, 1 hora 15 minutos, 2 horas 30 minutos, 3 horas 45 minutos, 5 horas, 7 horas 30 minutos, 10 horas y 12 horas 30 minutos.

Los mejores resultados fueron obtenidos por la red neuronal feedforward en cascada, que obtuvo un error de predicción del 2.32% para el caudal en los siguientes 30 minutos y un error del 21.3% para predecir el caudal en las siguientes 12 horas 30 minutos.

Por el tipo de datos utilizados y con los resultados obtenidos se puede apreciar que un modelo basado en la predicción a través de redes neuronales puede ser implantado dentro de un sistema que permita prever el comportamiento en periodos cortos de tiempo (12 horas), con un error aceptable. El modelo puede aplicar en casos en los que las estaciones de monitoreo han sido recientemente instaladas y con datos en un intervalo de al menos 3 meses.

La capacidad de predicción puede mejorar si se cuenta con información adicional, por ejemplo la obtenida en estaciones meteorológicas, pero en este trabajo no se tuvo acceso a dicha información. También es posible mejorar los resultados incluyendo variables exógenas en los datos de entrada como el nivel de agua, pero en este caso se ha utilizado un modelo exclusivamente AR, autorregresivo.

REFERENCIAS

Marbello Pérez, R. (s.f.). Manual de practicas de laboratorio de hidráulica. En **HIDROMETRÍA Y AFORO DE CORRIENTES NATURALES** (pág. 242). Medellín

Agudelo, A., López Lezama, J., & Velilla, E. (2015). Predicción del precio de la electricidad en la bolsa mediante un modelo neuronal no lineal autorregresivo con

entradas exógenas. Información Tecnológica, 1.

Aparicio Mijares, F. J. (1992). fundamentos de hidrología de superficie. México D.F: Grupo Noriega Editores.

Campozaño Parra, L. V. (2011). Análisis de la robustez de un modelo de redes neuronales para la predicción de caudales en la cuenca alta del río Paute. Cuenca, Ecuador.

Demuth, H., & Beale, M. (10 de 06 de 1998). Neural network toolbox for use with matlab (3 ed.). The mathWorks. Obtenido de producto MATLAB.

García Martos, D. (2012). Procesos autorregresivos. En *Econometría II, grado en finanzas y contabilidad*. Madrid, España.

Gázquez Abad, J. C., Jiménez Guerrero, J. F., & Sánchez Fernández, R. (2006). La capacidad predictiva en los métodos Box-Jenkins y Holt-Winters: una aplicación al sector turístico. *Revista europea de dirección y economía de la empresa*, 15(3), 185-198.

Gómez Gallego, M. (2012). Redes neuronales para la simulación, estimación y control de caudales impulsados por estaciones de bombeo en zonas regables. Huelva, España.

Gómez Vargas, E., Obregón Neira, N., & Socarras Quintero, V. (2010). Aplicación del modelo neurodifuso ANFIS vs redes neuronales, al problema predictivo de caudales medios mensuales del río Bogotá en Villapinzón. *Tecnura*, 14(27), 18 - 29.

Isasi Viñuela, P., & Galván León, I. (2004). *Redes de Neuronas Artificiales un enfoque práctico*. Madrid, España: Pearson.

Levin, R., & Rubin, D. (2004). *Estadística para administración y economía* (Vol. 7). Mexico: Pearson Educación.

Matinez Gomez, E. J., & Pedraza Caballero, L. E. (2012). Implementación web de redes neuronales artificiales aplicadas de la predicción de series de tiempo. Barranquilla, Colombia.

Mediero Orduña, L. (2007). Pronóstico probabilístico de caudales de avenida mediante redes bayesianas aplicadas sobre un modelo hidrológico distribuido. Madrid, España.

Moscó Barrera, W. D. (2015). Análisis de la relación entre variables hidrometeorológicas y zonas inundables por medio de sistemas inteligentes artificiales en un tramo del río Bogotá comprendido entre estaciones de puente florencia (Gachancipá) y Tocancipá. Chia, Colombia.

- N. Koivo, H. (2008). Neural Networks: Basics usign Matlab Neural Network Toolbox. Espoo, Finland.
- Neural Network Toolbox. (s.f.). Recuperado el 01 de 04 de 2019, de <https://edoras.sdsu.edu>
- Ocampo, O. L., & Vélez, J. J. (Enero-Junio de 2014). Análisis comparativo de modelos hidrológicos de simulación continua en cuencas de alta montaña: caso del rio Chinchiná. Ingenierías Universidad de Medellín, 13(24), 214.
- Pierini, J., Gomez, E., & Telesca, L. (2012). Predicción de caudales en rio Colorado , Argentina. Bahia Blanca, Argentina.
- Ruiz Suarez, S. (2016). Métodos de clasificación supervisada aplicados a datos de radares metereologicos. Buenos Aires, Argentina.
- Spiegel, M., & Stephens, L. (s.f.). Estadística (4 ed.). Mexico: McGraw-Hill.
- Te Chow, V., R. Maidment, D., & W. Mays, L. (1994). Hidrología Aplicada. Santafé de Bogotá, Colombia: McGraw-Hill.