

RED NEURONAL APLICADA AL PRONÓSTICO DE ALTURAS MEDIAS MENSUALES

Daniel Horacio Calvo

Instituto Nacional del Agua, Sistema de Alerta Hidrológica
AU Ezeiza – Cañuelas Tr. Jorge Newery Km 1,62. 4 480 4500. 4 480 9174. dcalvo@ina.gov.ar

RESUMEN

El presente trabajo propone una aplicación de modelos de redes neuronales en hidrología, y su comparación con modelación clásica ARIMA estacional.

La importancia de la estación de medición elegida es que integra el comportamiento hidrológico del Pantanal y la alta cuenca y determina el ingreso de caudales a la cuenca media.

El método de modelación aplicado combina algunas técnicas del análisis de series de tiempo (propias de los modelos ARIMA univariados y de función de transferencia), con los métodos propios del diseño de modelos de redes neuronales.

Con esta metodología se proponen modelos neuronales capaces de aceptar como entrada tanto datos de precipitación como datos de altura hidrométrica; esta alternativa de modelación resulta especialmente apta para manejar no linealidades involucradas en los procesos bajo estudio.

Los resultados obtenidos son comparables a los obtenidos con los clásicos ARIMA univariados, y conducen a profundizar la aplicación de la metodología de modelación neuronal en la medida en que se disponga de una mayor cantidad de datos de estimación satelital de la precipitación media areal.

Palabras clave: Río Paraguay. Series de tiempo. Redes Neuronales. ARIMA. Estacionalidad.

INTRODUCCIÓN

Objetivo del trabajo

El objetivo del presente trabajo es modelar mediante redes neuronales la serie de tiempo de niveles (alturas) hidrométricos medios mensuales en la estación de medición de Bahía Negra, en el río Paraguay (República del Paraguay) con fines de pronóstico en el contexto de las necesidades y usos del Sistema de Alerta Hidrológica del Instituto Nacional del Agua.

Asimismo se pretende comparar los resultados de los modelos mencionados con resultados de modelación ARIMA con componente estacional.

Descripción del fenómeno a modelar

Bahía Negra se ubica en la descarga del Pantanal al N de la República del Paraguay.

El Pantanal es una depresión inundable que recibe el aporte estacional de las precipitaciones, ocupa una superficie de casi 140.000 km² ; su efecto es el de atenuar la descarga de la alta cuenca del río Paraguay imponiendo una fuerte inercia en la respuesta hidrológica del sistema, determinando escasa sensibilidad a eventos específicos, y determinando marcada estacionalidad, (Ponce, 1995).

La importancia de Bahía Negra reside en que integra el comportamiento hidrológico del Pantanal y de la alta cuenca, y determina el ingreso de caudales a la cuenca media en territorio Paraguayo.

El fenómeno que se pretende modelar con redes neuronales es el comportamiento de la cuenca ante las precipitaciones.

Para este fin se considerará a la serie de nivel hidrométrico como la variable “respuesta” del sistema, y a las precipitaciones junto a la misma serie de niveles retardada como las variables “causa” de la dinámica del sistema.

INFORMACIÓN DISPONIBLE

Niveles hidrométricos medios mensuales

Los datos de niveles hidrométricos medios mensuales: h (cm), utilizados en el presente estudio, son el resultado de mediciones diarias de escala; de estas mediciones se ha calculado la media mensual disponiéndose así de niveles medios mensuales desde enero de 1998 hasta febrero de 2004.

Precipitación Acumulada Mensual Media Areal

La otra serie de datos utilizada en este estudio es la serie de precipitación media areal acumulada en cada mes en la subcuenca correspondiente a Bahía Negra: pp expresada en mm.

Las estimaciones de lluvia se han llevado a cabo componiendo datos de campo y satelitales, tanto de sensores de microondas como de infrarrojo térmico. La resolución espacial está dada por píxeles de un grado geográfico de lado. La información viene dada como intensidades medias diarias (mm/día píxel); el algoritmo de síntesis de los datos es ejecutado mensualmente por la NASA para producir la mejor estimación del campo de intensidad de precipitación.

Esta intensidad de precipitación por día y por píxel se integra mensualmente en un cubrimiento apropiado de la subcuenca de interés. El período en el que existen estimaciones de esta fuente comienza recién en 1998, y se encontraba disponible hasta febrero de 2004 al comenzar el trabajo.

En la figura 1 se muestra la ubicación geográfica de la estación de Bahía Negra en el río Paraguay; se ven, además, los centros de los píxeles periféricos correspondientes al cubrimiento de la cuenca.



Figura 1. Cuenca bajo estudio.

En la figura 2 se despliegan las series de datos temporales.




Figura 2. Series de tiempo.

Análisis de la correlación

Para construir el modelo neuronal se asume que las variaciones de nivel hidrométrico medio mensual en el mes en curso están causadas tanto por las variaciones en la precipitación acumulada como en el nivel hidrométrico medio en meses anteriores, y se hace abstracción de toda otra posible causa.

Se analiza en primer lugar el retardo (lag) entre la precipitación y el nivel hidrométrico. Para llevar a cabo este análisis se aplica la misma metodología que se usa para el desarrollo de modelos de “función de transferencia”.

No es el propósito de este trabajo modelar con función de transferencia, pero se hará uso de los aspectos analíticos de aquella metodología para la identificación de la estructura del modelo neuronal.

El modelo general de función de transferencia (Wei,1994) es:

$$y_t = n(B)x_t + h_t \quad [1]$$

donde:

$$n(B) = \sum_{j=0}^{\infty} n_j B^j \quad [2]$$

n_j son los pesos impulso – respuesta, B es el operador de retardos, y se asume que las series x_t e y_t son estacionarias y siguen procesos ARMA, por ejemplo para x_t :

$$f_x(B)x_t = q_x(B)a_t \quad [3]$$

donde a_t es ruido blanco. Como ni la serie de nivel hidrométrico medio mensual ni la de precipitaciones acumuladas son procesos estacionarios, se diferencian en forma ordinaria y/o

estacional hasta lograr estacionariedad:

$$x_t = (1 - B^{12}) pp_t \quad [4]$$

$$y_t = (1 - B)(1 - B^{12})h_t \quad [5]$$

Las series x_t e y_t diferenciadas y estacionarias pueden verse en la figura 3.




Figura 3. Series diferenciadas y estacionarias

La serie a_t :

$$a_t = \frac{f_x(B)}{q_x(B)} x_t \quad [6]$$

es habitualmente llamada serie “preblanqueada” de entrada. Aplicando la misma transformación de preblanqueo a la serie de salida, obtenemos la serie de salida “filtrada”:

$$b_t = \frac{f_y(B)}{q_y(B)} y_t \quad [7]$$

aplicando a h_t :

$$e_t = \frac{f_h(B)}{q_h(B)} h_t \quad [8]$$

el modelo de función de transferencia se convierte en:

$$b_t = n(B)a_t + e_t \quad [9]$$

En esta última ecuación $v(B)$ es la misma que en la ecuación inicial [1].

Las series a_t y b_t se muestran en la figura 4:




Figura 4. Series sin estructura

Los pesos impulso – respuesta de la función de transferencia pueden ahora ser expresados como:

$$n_k = \frac{s_b}{s_a} r_{ab}(k) \quad [10]$$

Esta expresión permite identificar el modelo de función de transferencia utilizando como recurso a la función de correlación cruzada estimada:

$$\hat{r}_{ab}(k)$$

que se puede ver en la figura 5:




Figura 5.ccf estimada

La expresión de la función de correlación cruzada es:

$$r_{xy}(k) = \frac{E[(x_t - m_x)(y_{t+k} - m_y)]}{s_x s_y} \quad [11]$$

donde el intervalo de confianza al 95% se ha calculado con la expresión de Fisher:

$$IC_{95\%} = \frac{-1 \pm 1.96\sqrt{N-k-1}}{N-k} \quad [12]$$

La figura 4 muestra aquellos lags en los que existe correlación lineal significativa entre las series a_t y b_t , que son $k=1$, y $k=2$; el lag $k=10$ con correlación apenas significativa se ignorará en virtud de la mayor simplicidad posible para el modelo.

La ecuación [2] se transforma ahora en:

$$n(B) = n_1 B + n_2 B^2 \quad [13]$$

y el modelo de función de transferencia de la ecuación [1] queda ahora expresado como:

$$y_t = n_1 x_{t-1} + n_2 x_{t-2} + h_t \quad [14]$$

De esta última expresión concluimos que el modelo neuronal en desarrollo deberá incluir como mínimo a la precipitación retardada en 1 y 2 meses.

Debido a que las series x_t e y_t son diferencias ordinarias y estacionales de ht y ppt es que lags de orden mayor o igual al período estacional también deberían estar presentes en el modelo neuronal, sin embargo estos lags se ignorarán para favorecer la sencillez del modelo y fundamentalmente debido a la cantidad de datos que se perderían, en cambio sí se incluirán en el modelo los valores correspondientes a la serie de precipitaciones diferenciada en los mismos retardos considerados antes.

Se analiza, a continuación, la autocorrelación lineal de la serie de niveles hidrométricos diferenciada hasta lograr estacionariedad: y_t , cuyo gráfico se ve en la figura 6.




Figura 6. Función de autocorrelación de y_t

Se observa un proceso estacionario con decaimiento oscilatorio amortiguado exponencialmente, tanto en su componente estacional como ordinaria.

La figura a continuación muestra la función de autocorrelación parcial para y_t :




Figura 7. Función de autocorrelación parcial de y_t

La figura 7 indica que los lags significativos son: $k = 1, 3, 4$, y 11 , donde el lag $k = 11$ es evidentemente un “satélite” (Uriel,1992) del primer lag estacional $k = 12$; nuevamente por sencillez del modelo se consideran solo los retardos ordinarios.

Concluimos del análisis de la autocorrelación de la serie de niveles hidrométricos que el modelo neuronal en desarrollo deberá incluir como mínimo a los niveles retardados en 1, 2, 3 y 4 meses.

Debido a que la serie y_t es diferencia ordinaria y estacional de h_t es que se incluirá en el modelo a las diferencias ordinarias para los lags antes mencionados; los lags del orden del período estacional se ignorarán.

MODELACIÓN NEURONAL

Concepto de red neuronal

Una red neuronal se puede definir como un sistema de computo compuesto por un gran número de elementos simples e interconectados, que procesan datos como respuesta a entradas externas (Hilera, 1995).

Cada neurona artificial (figura 8) consta de una “función de umbral” y de una “función de activación”, siendo la última generalmente una función no lineal.




Figura 8. Neurona artificial

La figura 8 muestra como una neurona individual procesa datos de entrada; primero obteniendo la suma ponderada de los datos (con los pesos w_{ij} de cada conexión); luego aplicando a esa suma la función de activación f :

Una función de activación muy usada en estos sistemas de procesamiento es la función “sigmoide”:

$$f(u) = \frac{1}{1 + e^{-u}} \quad [15]$$




Figura 9. Función de activación

El “peso” w_{ij} es el valor numérico por el que se multiplica la salida de la neurona j al ser sumada como entrada en la neurona i .

Las redes neuronales se organizan por capas: capa de entrada, capas ocultas y capa de salida, como se muestra en la figura 10.

Las redes de 3 capas (con una sola capa oculta) muestran buena adaptación a procesos con respuestas tanto lineales como no lineales (Dolling, 2002), por esta cualidad se ha elegido modelar con una red de tres capas.

La red neuronal es sometida a un proceso de entrenamiento supervisado en el cual modifica los pesos de conexión entre las neuronas; este proceso la “supervisión” consiste en presentar a la red un conjunto de datos de entrada y el, o los, correspondientes datos que se desearían tener a la salida; a este conjunto de datos de entrada / salida se lo denomina “patrones de entrenamiento”.

La red usa los patrones de entrenamiento para ajustar el valor de los pesos w_{ij} hasta lograr que la diferencia entre los datos de salida (supervisores) y los datos de salida calculados sea pequeña; esa pequeñez se mide por minimización de una función objetivo (Yu, 2000) como por ejemplo:

$$E = \frac{1}{NP} \sum_{p=1}^P \sum_{i=1}^N (t_{pi} - y_{pi})^2 \quad [16]$$

donde p indexa los patrones de entrenamiento, i indexa las neuronas (o nodos) de la capa de salida.

Con los pesos ajustados de modo de minimizar E , la red queda en condiciones de ser usada “hacia adelante”; es decir de recibir como entrada un lote de datos (patrones incompletos no utilizados en la etapa de entrenamiento supervisado) y obtener una estimación de la salida que correspondería al lote de entrada.

El método que le permite a la red aprender, es decir modificar las conexiones (w_{ij}) entre las neuronas, es el método de “retropropagación” (Nilson, 2001).

La cualidad de las redes neuronales que es explotada en el presente estudio es pues la de reconocer patrones presentes en series temporales, y de regenerar patrones (Dolling, 2003) temporales incompletos extendiéndolos hacia tiempo futuro.

En el campo de la modelación con redes neuronales existe más de un criterio de trabajo para lograr el desarrollo de un modelo suficientemente bueno y compatible con los objetivos del investigador.

En este estudio se adopta una metodología (Dolling, 2002) que parte desde el análisis de series de tiempo aprovechando sus conocidas ventajas para estimar funciones de correlación y retardos significativos (Wei, 1994); este análisis permite obtener un modelo neuronal robusto y subóptimo, dado que no se conoce una metodología que permita demostrar la existencia de una solución óptima y única de modelación para un dado problema.

Diseño de las capas de entrada y de salida

Partiendo del análisis de la correlación ya hecho es posible abordar el diseño de la capa externa incluyendo sólo las entradas significativas que contengan la mayor parte de la “causalidad” del fenómeno con la menor redundancia posible (ver figura 10).

Se propone que los datos más influyentes en la determinación del nivel hidrométrico del mes en curso son: $h(t-4)$, $h(t-3)$, $h(t-2)$, y $h(t-1)$, como el análisis se hizo con series estacionarias diferenciadas se incluirán también las diferencias ordinarias: $dh(t-4)$, $dh(t-3)$, $dh(t-2)$ y $dh(t-1)$.

La variable precipitación aporta a la capa de entrada con retardos 1 y 2, sin diferenciar y con su diferencia ordinaria; esta conclusión provenía del análisis de la función de correlación (lineal) cruzada entre las variables “preblanqueada” y “filtrada”; pero en base a argumentos físicos e hidrológicos se puede suponer la existencia de correlación no lineal entre pp_t y h_t presente tanto en los retardos 1 y 2 como en retardos mayores que 2; por este motivo se propone incluir a los retardos 3 y 4 de la serie de precipitaciones y de su diferencia ordinaria en la capa de entrada.

Los retardos correspondientes a diferencias estacionales no se incluirán en el modelo tanto por simplicidad como por ahorro de datos; al tomar esta decisión se asume que los datos de pp_t y dpp_t contienen suficiente información sobre la estacionalidad del proceso, para reforzar esto se incluye la variable “mes” tomando valores enteros de 1 a 12 y correspondiendo al mes de h_t (salida).

La capa externa de la red se diseña en función de las estimaciones que se espera que la red neuronal produzca, en este caso la capa de salida estará compuesta sólo por un neurona o nodo: h_t : nivel o altura hidrométrica en el tiempo t (a paso mensual).




Figura 10. Red Neuronal con una capa oculta.

Diseño de la capa oculta

Para determinar el número de nodos en la capa oculta se asume un criterio práctico que consiste en estudiar el desempeño de la red como herramienta de pronóstico sobre un conjunto de n datos de “validación” no presentes en el conjunto de patrones de entrenamiento.

Se elige el tamaño de capa oculta que optimiza el desempeño de la red neuronal luego de comparar 17 redes con capas ocultas cuya cantidad de nodos varía entre 1 y 17.

Existen diversos estadísticos para comparar modelos (Dolling, 2002), en este trabajo se usan:

- coeficiente de correlación lineal entre datos observados (validación) y calculados.
- raíz cuadrada del error cuadrático medio:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (obs_i - calc_i)^2}{n}} \quad [17]$$

error absoluto porcentual medio.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|obs_i - calc_i|}{obs_i} \quad [18]$$

Se busca maximizar el coeficiente de correlación, minimizar el RMSE y el MAPE, los gráficos de estos estadísticos se muestran a continuación:




Figura 11. Coeficiente de correlación




Figura 12. Raíz cuadrada del error cuadrático medio




Figura 13. Error absoluto porcentual medio

El modelo que optimiza los tres estadísticos es el que tiene una capa oculta de 5 nodos; el diseño final de la red neuronal se ve en la figura 10.

Transformación de los datos

Debido a que la función de activación (sigmoide) se satura fuera del intervalo $[-1, 1]$, y devuelve valores en $(0,1)$ es que los datos presentados a la red como en la capa de entrada deben ser escalados entre $[-1, 1]$, o bien entre $(0,1)$, según el algoritmo de retropropagación y el programa con el que se trabaje.

A causa de esta característica de esta función de activación es que las redes neuronales suelen tener mejor desempeño cuando los datos de entrada exhiben un histograma “campaniforme” o al menos simétrico; se aplica en este paso la transformación (monótona) de potencia:

$$x_{transf} = x^l / l \quad [19]$$

que mejor simetriza los histogramas de h_t , pp_t , dh_t y dpp_t .

Los histogramas se muestran en las siguientes figuras:




Figura 14. Histogramas de los datos sin transformar




Figura 15. Histogramas con datos de pp transformados.

El histograma de pp_t presenta cola hacia la derecha (figura 14), asimetría que se logra corregir con una transformación de potencia con $\lambda = 0.7$ (figura 15); como el histograma de h_t no presenta una asimetría grosera se deja sin transformar; en cuanto a las series dpp_t y dh_t se ve que su histograma es levemente asimétrico y campaniforme, y se elige no transformar.

Notar que al proceso de entrenamiento y ajuste de pesos de la red neuronal no le afecta que se aplique transformación de potencia a la serie de pp_t y no a la de dpp_t .

Se llega a un punto en el que se han diseñado las tres capas de la red neuronal y queda por decidir si se aplicará sobre datos transformados o no.

El método de toma de decisión es nuevamente probar la red entrenándola con datos transformados y sin transformar y aplicarla a conjuntos de validación también transformados y sin transformar.

En el proceso de entrenamiento y ajuste de pesos algunas variables pueden recibir peso final cercano a cero, en cada caso así ocurrido se ensaya sobre el conjunto de validación que corresponda a la red en cuestión sin incluir a esa variable; si los estadísticos mejoran sin la variable en la capa de entrada se la excluye definitivamente.

En la tabla 1 se resumen los estadísticos para la red neuronal diseñada aplicada a datos con y sin transformación y habiendo eliminado el nodo de entrada correspondiente a dpp_{t-1} :

Tabla 1

Modelos	# nodos capa oculta	Variables transformadas	Variables eliminadas	Coef. Corr.	RMSE	MAPE
Modelo 1	5	Ninguna	dpp(t-1)	0.989	18.25	6.28
Modelo 2	5	pp(t)	dpp(t-1)	0.991	17.18	6.15

Resultan mejores los estadísticos para la red con datos transformados (modelo 2), se continua el análisis comparando el desempeño predictivo de los modelos.

Capacidad de predicción de los modelos

Se muestra en las figuras 16 y 17 pronósticos a un mes (h^*) sobre el conjunto de validación; este conjunto abarca el período comprendido entre enero de 2003 y febrero de 2004.




Figura 16. Modelo 1: pronóstico a un mes.




Figura 17. Modelo 2: pronóstico a un mes.

Ambos modelos presentan un desempeño “a un mes” satisfactorio, notar el defecto en dic/03 y en ene/04.

Se muestran en las figuras a continuación los gráficos de los residuos estandarizados en función del nivel hidrométrico predicho y los histogramas correspondientes para los dos modelos.




Figura 18.




Figura 19.




Figura 20.




Figura 21.

Las figuras 18 a 21 indican que los residuos estandarizados de los modelos tienen comportamiento gausseano entre -3 y 3 sin tendencia o estructura aparente.

Ambos modelos tienen un comportamiento predictivo a un mes que resulta aceptable, se elige para pronósticos a pasos de tiempo mayores al modelo 2 (con variables transformadas) por sus mejores estadísticos comparativos.

A continuación se muestra un pronóstico a 14 meses, es decir sobre todo el conjunto de validación; para poder generarlo se ejecutan sucesivos pronósticos a un mes (comenzando por ene/03) y la salida de cada pronóstico a un mes se usa como entrada para el siguiente.

La serie de precipitaciones a utilizar surge de las que efectivamente han tenido lugar entre ene/03 a feb/04; naturalmente que esta no es una metodología útil para pronosticar dado que uno no conoce nunca con exactitud los valores de precipitación mensual acumulada areal pero servirá para ponderar la explosión del error de pronóstico al usar datos pronosticados como entradas sucesivas.

El pronóstico a 14 meses se muestra en la figura 22, (h^* (pred) es el nivel hidrométrico pronosticado), además se incluye la serie de precipitaciones sin transformar con el propósito de tener idea gráficamente de su evolución; notar que aunque en el gráfico figuren sin transformar, las precipitaciones necesitan ser transformadas antes de ser presentadas a la entrada del modelo2.




Figura 22.

Conclusión parcial

El pronóstico a un mes con modelo 2 (figura 17) ha resultado satisfactorio tanto en la crecida estacional como en el pico y en la mayor parte del la bajante; presentando errores severos en los meses de ene/03 y feb/04 de bajante e inicio de crecida.

Se observa en la figura 22 para el pronóstico a 14 meses un ajuste aceptable, levemente desfasado, que en ningún momento presenta una evolución explosiva del error, esto hace suponer que la serie causal de precipitaciones (datos ciertos sin error de pronóstico) ha sido correctamente aprendida y procesada por la red neuronal.

MODELACIÓN ARIMA

Modelo ARIMA estacional

Con el propósito de poder comparar se desarrolla un modelo ARIMA con componente estacional dado el fuerte patrón estacional del fenómeno.

Este tipo de modelo necesita más datos que los que fueron utilizados en los modelos neuronales; como no se hará uso de precipitaciones sino sólo de niveles hidrométricos no hay restricción de inicio de la serie de datos a enero de 1998.

Se considera la serie de niveles h_t que comienza en ene/74 y termina en feb/04 (figura 23).




Figura 23.

Identificación del modelo estacional

Las figuras 24 y 25 muestran las funciones de autocorrelación y de autocorrelación parcial para la serie h_t ya diferenciada: $(1-B_{12})(1-B)h_t$.




Figura 24




Figura 25

A partir de estas dos figuras se identifica un modelo ARIMA: $h_t \sim (2,1,1)(3,1,1)_{12}$.(modelo 3).

Diagnóstico del modelo estacional

Como es usual en el diagnóstico de modelos ARIMA se inspeccionan los residuos estandarizados en función del tiempo para toda la extensión de la serie usada, así como la función de autocorrelación de los residuos (figuras 26 y 27).




Figura 26.

Se observa en la figura precedente la presencia de tres residuos estandarizados fuera del intervalo $[-3,3]$, y ningún residuo fuera del intervalo $[-4,4]$.




Figura 27

La función de autocorrelación de residuos del modelo 3 muestra un solo lag significativo ($k=13$), sugiriendo la presencia de una mínima estructura estacional en los residuos.

Se diagnostica como aceptable al modelo 3.

Capacidad de predicción del modelo

Con el propósito de evaluar la capacidad predictiva del modelo 3 se elabora un pronóstico a un mes sobre el mismo conjunto de datos de validación de los modelos neuronales 1 y 2, que comienza en ene/03 y se extiende hasta feb/04; esto permite comparar a los modelos entre sí.

El desempeño del modelo 3 se muestra en la figura 28.




Figura 28.

Se ve un buen desempeño en la crecida estacional (figura 28), con irregularidades en el pico y en la bajante estacional; se produce un error severo en ene/04.

Se muestran (figuras 29 y 30) los residuos estandarizados en función del nivel hidrométrico predicho y el histograma de residuos para el modelo 3.




Figura 29.




Figura 30.

Aunque el histograma muestra una distribución aproximadamente gausseana de los residuos, el gráfico de la figura 29 podría estar indicando cierta estructura presente, aunque muy leve.

La figura 31 muestra el pronóstico a 14 meses con el modelo 3.




Figura 31.

A 14 meses se observa gran incremento del error más allá de may/03, y buen ajuste del patrón estacional.

Conclusión parcial

La modelación ARIMA de series de tiempo ofrece una alternativa bien conocida y siempre aplicable, su principal ventaja es que sólo necesita datos históricos de la propia serie a modelar y permite obtener muy buenos pronósticos a pocos meses.

Su desventaja es el crecimiento del error de pronóstico para una cantidad grande de meses, así como el crecimiento del intervalo de confianza (cuestión no analizada en este trabajo).

El pronóstico a un mes (figura 28) muestra un buen ajuste hasta may/03, a partir de jun/03 los pronósticos comienzan a hacerse más variables respecto a los datos observados aunque siempre se mantienen oscilante en torno a estos debido a que cada pronóstico se produce con datos observados.

En la construcción del pronóstico a 14 meses se ha utilizado cada pronóstico como entrada para elaborar el pronóstico del mes siguiente; como puede observarse el crecimiento del error más allá de may/03 es muy grande; aun así es interesante remarcar la buena conservación del patrón estacional del proceso, esto es debido a que dicho patrón fue debidamente modelado, y además en cada caso están interviniendo los correspondientes meses de años anteriores que sí son datos observados y no calculados.

Comparación entre modelos neuronales y modelos ARIMA estacionales

En esta última parte del trabajo se expone la comparación entre los pronósticos a 1 mes y a 14 meses para los 3 modelos analizados.

Se resumen en la tabla 2 (comparativa) los estadísticos para pronósticos a 1 mes:

Tabla 2

Estadístico	Modelo 1	Modelo 2	Modelo 3
Coef. de Corr.	0.989	0.991	0.981
RMSE	18.25	17.18	25.37
MAPE	6.28	6.15	8.48
Max. Residuo	29.89	24.97	43.16
Min. Residuo	-34.60	-32.85	-49.00

Esta tabla deja claro que los modelos de redes neuronales (RN) han dado resultados comparables o levemente mejores que la modelación ARIMA estacional univariada, debe tenerse en cuenta que los modelos 1y 2 (RN) usaron 60 datos de precipitación y 60 datos de nivel hidrométrico para el ajuste de pesos en entrenamiento; mientras en el modelo 3 (ARIMA) se usaron 348 datos de nivel hidrométrico para estimar los parámetros del modelo, los 3 modelos se han validado sobre la misma serie de 14 datos.

Para comparar pronósticos a 14 meses no se han elaborado estadísticos, sólo se mostrarán gráficos.

Dado que para pronosticar a 14 meses con red neuronal necesitamos 13 meses de pronóstico de precipitaciones; dispondremos de un pronóstico basado en los promedios de cada mes, es decir el pronóstico de precipitación acumulada mensual para el mes M se obtiene promediando todos los datos para ese mismo mes de todos los años anteriores disponibles, se trata entonces de un pronóstico de baja calidad.

Las series de precipitaciones observadas y pronosticadas para los 13 meses de validación se muestran en la figura 32.




Figura 32.

Se aplica ahora la red neuronal entrenada pero imponiendo la entrada de precipitaciones acumuladas mensuales a la serie promedio; los resultados se muestran en la figura 32.




Figura 33.

En la figura se observa como tomar un ciclo de precipitaciones promedio tiene un efecto similar a pronosticar con un modelo ARIMA estacional; las diferencias entre pp observadas y pronosticadas en los primeros meses del 2003 (ver figura 32) resultan determinantes para el output de la red neuronal (como se ve comparando las figuras 33 y 22).

Conclusiones del trabajo

- La modelación con redes neuronales resulta una metodología ágil para abordar el modelado de series temporales en donde se presenta más de una serie involucrada en el mismo fenómeno.
- Cuando se trate de modelar procesos en los que las variables causas y las variables efecto tienen relación no lineal (como en el presente trabajo) las redes neuronales manifiestan un desempeño igual o superior a los métodos ARIMA estacionales.
- Cualquier pronóstico de precipitación mensual que pudiera haber sido algo mejor que el que se usó (es decir más parecido a las precipitaciones reales) habría permitido un pronóstico a 14 meses de niveles hidrométricos con red neuronal (modelo 2) superior al que se mostró en este trabajo; notar que deliberadamente se adoptó aquí el pronóstico menos experto que consistió en tomar el promedio de meses pasados.
- La metodología de análisis y preparación de los datos para determinar el modelo neuronal es por lo menos tan importante como el modelo neuronal mismo. Sin esta fase previa y analítica del trabajo cualquier intento de uso de software para simulación de redes neuronales se torna “oracular” y tiene grandes posibilidades de fracaso.
- En este sentido se recomienda a los analistas interesados en la aplicación de redes neuronales a series de tiempo la profundización sistemática en herramientas estadísticas como las usadas en este trabajo y otras.

BIBLIOGRAFÍA

- Dolling, O** (2002) “*Utilización de Redes Neuronales Artificiales al Pronóstico de Caudales en Cuencas Nivales*”, Congreso Nacional del Agua 2002 Carlos Paz, Argentina.
- Dolling, O; Varas, E** (2002) “*Artificial Neural Networks for streamflow prediction*” Journal of Hydraulic Research Volume 40.
- Dolling, O** (2003) *Redes Neuronales Aplicadas a la Predicción* Editado por: Departamento de Postgrado Fac. de Ingeniería Universidad Nacional de San Juan San Juan , Argentina
- Hilera, J., Martínez, V.** (1995) *Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones* . Ra-ma Editorial. Madrid, España.
- Nilson, N.** (2001) *Inteligencia artificial una nueva síntesis* Cap. 3 Mc Graw Hill México DF, México.
- Ponce, V.** (1995) “*Hydrologic and environmental impact of the Paraná – Paraguay waterway on the Pantanal of Matto Grosso, Brazil*” San Diego State University San Diego, USA.
- Uriel, E.** (1992) *Análisis de Series Temporales Modelos ARIMA* Paraninfo Valencia, España.
- Wei, W.** (1994) *Time Series Analysis Univariate and Multivariate Methods* Addison-Wesley Publishing Wokingham, UK.
- Yu, Z.** (2000) “*Feed-Forward Neural Networks and their applications in forecasting*” Thesis presented to University of Houston Houston, USA.