

PREDICCIÓN DE CAUDALES DE RÍOS APLICANDO EL MODELO NEURODIFUSO ANFIS Y REDES NEURONALES.

Ernesto GOMEZ VARGAS

Facultad de Ingeniería, Universidad Distrital Francisco José de Caldas,
Bogotá, Cundinamarca, 057, Colombia

Lindsay ALVAREZ POMAR

Facultad de Ingeniería, Universidad Distrital Francisco José de Caldas,
Bogotá, Cundinamarca, 057, Colombia

Nelson OBREGON NEIRA

Facultad de Ingeniería, Pontificia Universidad Javeriana
Bogotá, Cundinamarca, 057, Colombia

RESUMEN

Este Artículo muestra los resultados obtenidos en la implementación del modelo neurodifuso ANFIS y de las redes neuronales para la predicción de caudales medios mensuales. Se desarrolla e Implementa el modelo ANFIS y se evalúa el comportamiento de 6 modelos al variar el número de entradas, el número y tipo de conjuntos difusos (funciones de pertenencia), que son los parámetros fundamentales del modelo ANFIS y se compara los resultados con los obtenidos con las redes neuronales perceptron multicapa.

Palabras claves: ANFIS, redes Neuronales, Pronósticos de caudales, Sistemas Neurodifusos, Inteligencia Artificial.

1. INTRODUCCION.

En hidrociencias, específicamente en el área de la hidrología, son de importancia el análisis y la predicción de series de tiempo, dichas series son registros históricos generalmente obtenidos de la medición de variables hidroclimáticas como la precipitación, la evaporación, el caudal en los ríos, etc.

El análisis y la predicción de series de tiempo permiten obtener información básica para la planeación, diseño y evaluación de hidrosistemas con base en la optimización en el manejo de los recursos hídricos en mejora del bienestar social. Los Procesos hidroclimáticos son de tipo no lineal, debido a la complejidad de los fenómenos que las generan, por lo cual se ha hecho necesario implementar herramientas de aproximación para estimar las variables involucradas en dichos procesos.

El reciente avance y desarrollo de modelos computacionales y su aplicación en diversas áreas de la ciencia, ha incrementado la implementación de herramientas para resolver problemas y aproximar magnitudes desconocidas. La hidrología no ha sido ajena a este proceso, y ha requerido de metodologías desarrolladas para otras disciplinas, una de ellas es la Inteligencia Artificial, en la que se encuentran los modelos basados en la Lógica Difusa (LD) y las Redes Neuronales (RN), las cuales tienen como ventajas el manejo del conocimiento experto y la facilidad de “razonamiento” para el caso de la LD y la capacidad de aprendizaje y adaptación de las RNA. La combinación de estas ventajas dan origen a los modelos neurodifusos. Para la presente investigación se seleccionó el modelo ANFIS propuesto por Jang en 1993, debido a la existencia de herramientas enfocadas a la implementación del modelo, específicamente un aplicativo computacional desarrollado en Matlab para la obtención y optimización de los parámetros de ANFIS. El comportamiento de este tipo de

modelo es incierto, de allí la necesidad de plantear la pregunta a resolver con el desarrollo de esta investigación “¿Cuál será la bondad de la aplicación del modelo neurodifuso ANFIS a la predicción de caudales medios mensuales?”, esto conlleva a determinar si es factible su implementación en hidrología y concretamente en nuestro medio. Para dar respuesta a esta pregunta, se implementará el modelo Neurodifuso ANFIS en la cuenca del río Bogotá en la Ciudad de Villapinzón, la cual en los últimos dos años ha causado inundaciones y serios problemas en la ciudad Bogotá.

En la primera parte del artículo se muestra la descripción general de los modelos utilizados para la predicción, posteriormente se analiza la estructura del modelo ANFIS y finalmente se muestran los resultados obtenidos y se comparan y analizan con los obtenidos con las redes neuronales.

2. MODELOS DE PREDICCIÓN.

Es importante mencionar que se decidió predecir caudales medios mensuales debido a que la información base obtenida tenía resolución mensual, para el caso de las series de caudal, valores promedio y para el caso de las series de precipitación, valores de precipitación acumulada mensual.

Para la predicción del caudal medio se utilizará la función f que depende de los valores de precipitación y caudal predecesores. De forma general para cualquier número de entradas será:

$$Q_t = f \left\{ P_{t-\tau}, P_{t-2\tau}, \dots, P_{t-m_p\tau}, Q_{t-\tau}, Q_{t-2\tau}, \dots, Q_{t-m_q\tau} \right\} \quad (1)$$

Donde:

τ : Tiempo de rezago

m_p : Dimensión de inmersión en P

m_q : Dimensión de inmersión en Q

Aunque existen muchos métodos para estimar el valor más adecuado de τ , m_p y m_q (correlación, entropía, vecino cercano,..etc) [1], el presente trabajo se centra en la exploración del Modelo ANFIS y las Redes neuronales bajo las mismas condiciones, para lo cual se tomaron 6 modelos, los cuales se sometieron a un sistema ANFIS y a las Redes neuronales perceptron multicapa para la correspondiente predicción de Caudales medios mensuales.

Modelo 1: Para este modelo se tiene en cuenta solamente el caudal del mes anterior, como se muestra a continuación.

$$Q_t = f\{Q_{t-\tau}, \tau = 1, m_q = 1\}$$

ENTRADA		SALIDA	
Q1		Q2	
Q2		Q3	
Q3		Q4	
Q4		Q5	
.....		

Figura 1. Modelo de predicción 1.

Modelo 2: Para este modelo se tiene en cuenta solamente la precipitación del mes anterior:

$$Q_t = f\{P_{t-\tau}, \tau = 1, m_p = 1\}$$

ENTRADA		SALIDA	
P1		Q2	
P2		Q3	
P3		Q4	
P4		Q5	
.....		

Figura 2. Modelo de predicción 2.

Modelo 3: Para este modelo se tiene en cuenta el caudal medio y la precipitación del mes anterior:

$$Q_t = f\{P_{t-\tau}, Q_{t-\tau}, \tau = 1, m_q = m_p = 1\}$$

ENTRADAS		SALIDA	
P1	Q1	Q2	
P2	Q3	Q3	
P3	Q3	Q4	
P4	Q4	Q5	
.....

Figura 3. Modelo de predicción 3.

Modelo 4: Para este modelo se tiene en cuenta el caudal medio del mes anterior y la precipitación de los dos meses anteriores:

$$Q_t = f\{P_{t-\tau}, P_{t-2\tau}, Q_{t-\tau}, \tau = 1, m_q = 1, m_p = 2\}$$

ENTRADAS				SALIDA	
P1	P2	Q2		Q3	
P2	P3	Q3		Q4	
P3	P4	Q4		Q5	
P4	P5	Q5		Q6	
.....	

Figura 4. Modelo de predicción 4.

Modelo 5: Para este modelo se tiene en cuenta la precipitación total del mes anterior y el caudal medio de los dos meses anteriores, como se muestra a continuación:

$$Q_t = f\{P_{t-\tau}, Q_{t-\tau}, Q_{t-2\tau}, \tau = 1, m_q = 2, m_p = 1\}$$

ENTRADAS			SALIDA
P1	Q1	Q2	Q3
P2	Q2	Q3	Q4
P3	Q3	Q4	Q5
P4	Q4	Q5	Q6
.....

Figura 5. Modelo de predicción 5.

Modelo 6: Para este modelo se tiene en cuenta la precipitación y el caudal medio de los dos meses anteriores, como se muestra a continuación:

$$Q_t = f\{P_{t-\tau}, P_{t-2\tau}, Q_{t-\tau}, Q_{t-2\tau}, \tau = 1, m_q = 2, m_p = 1\}$$

ENTRADAS				SALIDA
P1	P2	Q1	Q2	Q3
P2	P3	Q2	Q3	Q4
P3	P4	Q3	Q4	Q5
P4	P5	Q4	Q5	Q6
.....

Figura 6. Modelo de predicción 6

3. MODELOS ANFIS Y REDES NEURONALES.

El modelo ANFIS (Adaptive Network-based in Fuzzy Inference Systems) fue desarrollado por J.R. Jang en 1993 [2]. Las capacidades adaptativas de las redes ANFIS las hacen directamente aplicables a una gran cantidad de áreas como control adaptativo, procesamiento y filtrado de señales y series de tiempo, clasificación de datos y extracción de características a partir de ejemplos. Una propiedad interesante del modelo, es que el conjunto de parámetros se puede descomponer para utilizar una regla de aprendizaje.

Las reglas difusas del tipo Takagi-Sugeno utilizadas en el modelo ANFIS se representan de la siguiente forma [3]:

Regla n: Si X es An y Y es Bn, entonces fn = pnX + qnY + rn, Donde An y Bn son los conjuntos difusos de entrada y pn, qn y rn son constantes, para este caso pn y qn son cero obteniendo un modelo Takagi-Sugeno de orden cero. Las salidas individuales de cada regla son obtenidas como una combinación lineal entre los parámetros del antecedente de cada regla: fn = pnX + qnY + rn, n=1,2,....

La salida de control del modelo f se obtiene por la normalización de los grados de activación de las reglas por la salida individual de cada regla.

Estructura del modelo ANFIS:

La estructura del modelo ANFIS para el modelo 6 de predicción, se muestra en la Figura 7 y será descrita a continuación:

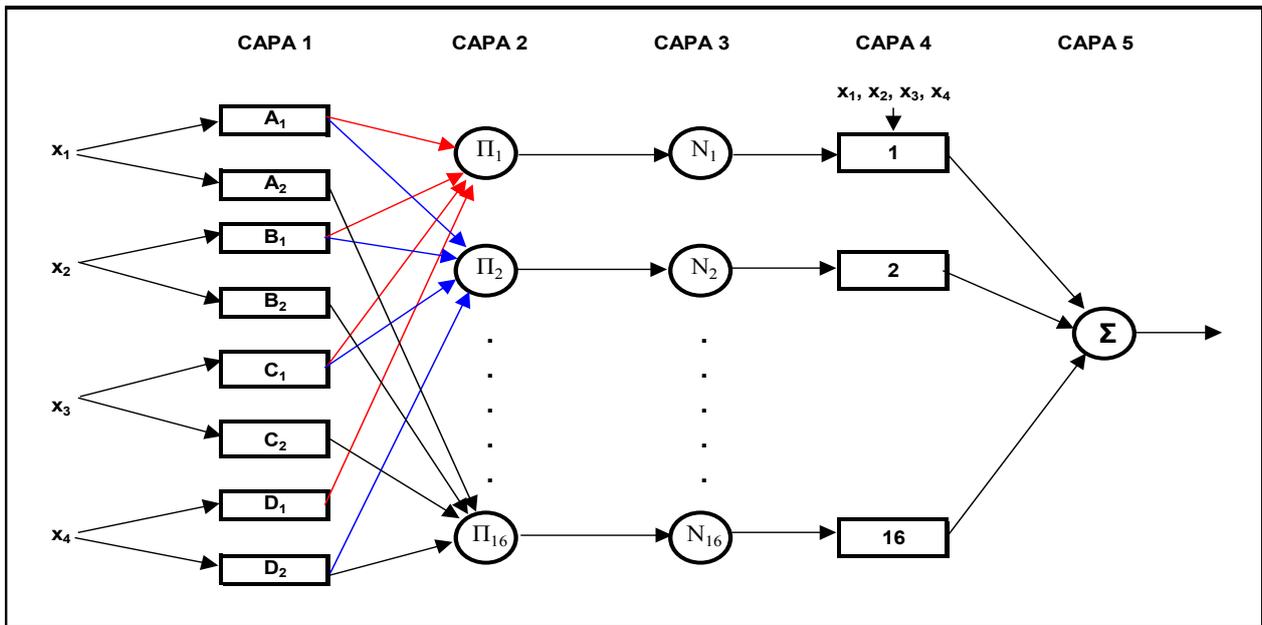


Figura 7. ANFIS para el modelo de predicción 6.

El sistema de inferencia difuso bajo consideración presenta 4 entradas x_1 , x_2 , x_3 y x_4 . Cada entrada tiene 2 términos lingüísticos (conjunto difuso), por ejemplo $\{A_1 = \text{bajo}, A_2 = \text{alto}\}$ para la variable de entrada x_1 . Por consiguiente, hay 16 reglas difusas tipo “if-then”, para el modelo 6 de predicción.

Para este ejemplo de cuatro entradas y para el caso del Modelo Difuso TSK de Primer Orden, una primer regla sería de la forma, *Regla 1: If x_1 es A_1 and x_2 es B_1 and x_3 es C_1 and x_4 es D_1 , then $f_1 = p_{11} * x_1 + p_{12} * x_2 + p_{13} * x_3 + p_{14} * x_4 + p_1$* , el superíndice en el coeficiente p denota el número de la regla, y los parámetros p_{11} , p_{21} , p_{13} , p_{14} y p_{11} son los parámetros consecuentes.

Se denota la salida del i -ésimo nodo en la capa k como O_{ki} . Cada nodo de la Capa 1 puede ser cualquier función de activación parametrizada $\mu_A(x)$, como por ejemplo la función “campana” generalizada, $\mu_A(x) = 1 / (1 + |(x-c)/a|)^{2b}$, donde las constantes a , b y c son referidos como los parámetros “de premisa” o “antecedentes”.

La función en cada nodo (regla) en la Capa 2 genera como salida el producto de todas las entradas, en términos de la evaluación de las funciones de membresía respectivas que estipule la regla. Así, para: $i=1,2,\dots,16$,

$$O_{2i} = w_i = \mu_{A_j}(x_1) * \mu_{B_j}(x_2) * \mu_{C_j}(x_3) * \mu_{D_j}(x_4), \quad j=1 \text{ ó } 2 \quad (2)$$

(según la regla).

En la Capa 3, la función de un nodo fijo se usa para normalizar las “fortalezas activadas de entrada”.

$$O_{3i} = \bar{w}_i = w_i / (\sum_{i=1}^{16} w_i), \quad \text{para } i=1,2,\dots,16. \quad (3)$$

Cada nodo en la Capa 4 es una función parametrizada dada por:

$$O_{4i} = w_i * f_i = w_i * (p_{i1} * x_1 + p_{i2} * x_2 + p_{i3} * x_3 + p_{i4} * x_4 + p_{i5}), \quad \text{para } i=1,2,\dots,16 \quad (4)$$

Para la Capa 5 sólo hay una salida, el cual es el valor aproximado determinado por el modelo (Salida calculada).

$$O_{51} = d = \sum_i (w_i * f_i) = \sum_i (O_{4i}). \quad (5)$$

En el proceso de calibración del modelo se obtienen los valores de los “pi” (parámetros consecuentes) de la regla TSK y los valores de a, b, c y d (parámetros de premisa) dependiendo del tipo de conjunto difuso con el que se esté trabajando; la red ANFIS permite a los sistemas difusos “aprender” los parámetros usando el algoritmo de aprendizaje.

Aprendizaje del modelo ANFIS:

El modelo ANFIS tiene dos tipos de parámetros que deben ser entrenados:

Los parámetros de los antecedentes los cuales corresponden a las constantes que caracterizan las funciones de activación de los conjuntos difusos, en la siguiente figura se observa tres tipos de funciones de activación usadas en el modelo ANFIS:

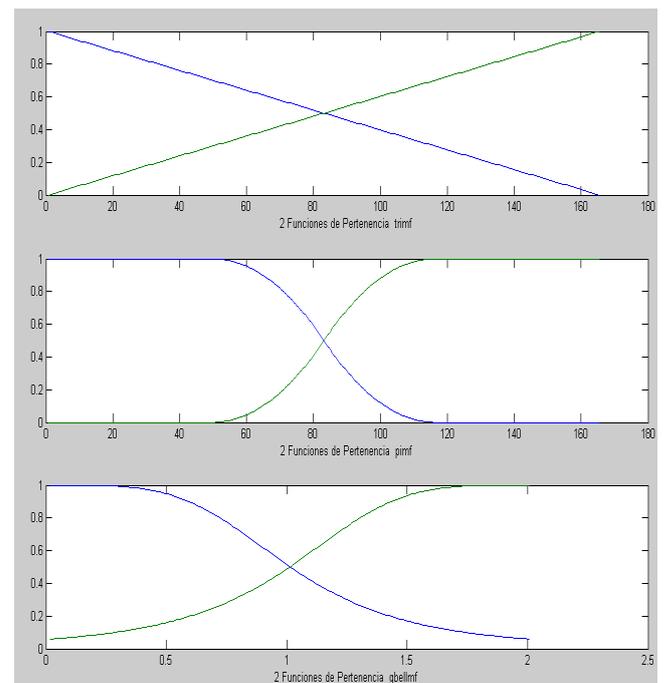


Figura 8. Funciones de Activación usadas en el modelo ANFIS

Los parámetros del consecuente (VT). Estos son parámetros lineales de la salida del modelo de inferencia. El paradigma de aprendizaje del modelo ANFIS emplea algoritmos de gradiente descendente para optimizar estos parámetros y el algoritmo de mínimos cuadrados para determinar los parámetros lineales del VT. A esta combinación se lo conoce como regla de aprendizaje híbrido, la cual es usada en el aprendizaje de este modelo [4].

Ahora se aplica lo descrito en [4] y [5], en donde para aplicar el aprendizaje híbrido en grupo, en cada periodo de entrenamiento debe ejecutarse un paso hacia adelante y un paso hacia atrás. En el paso hacia adelante, los parámetros de las funciones de los conjuntos son inicializados y se presenta un vector de entrada- salida, se calculan las salidas del nodo para cada capa de la red y entonces los parámetros de la VT son calculados usando el método de mínimos cuadrados. Una vez identificados los parámetros de la VT, el error es calculado como la diferencia entre la salida de la red y la salida deseada presentada en los pares de entrenamiento. En este caso se usa una de las medidas más empleadas para calcular el error de entrenamiento, el cual es la suma del error al cuadrado (SEC), definido como:

$$SEC = \sum_{k=1}^N (d_k - f_k)^2 \quad (6)$$

Los d_k corresponden a los patrones de entrenamiento proporcionados (salidas deseadas) y f_k es la correspondiente salida de la red. En el paso hacia atrás, las señales de error son propagadas desde la salida, en dirección de las entradas y el vector gradiente es acumulado para cada dato de entrenamiento. Al final del paso hacia atrás para todos los datos de entrenamiento, los parámetros en la capa 1 (parámetros de los conjuntos) son actualizados por el método descendente en una magnitud $\Delta\alpha$ igual a:

$$\Delta\alpha = -\eta \frac{\partial E}{\partial \alpha} \quad (7)$$

Donde E es el error de salida y η es la velocidad de aprendizaje, que puede ser expresada como:

$$\eta = \frac{\rho}{\sqrt{\sum_{\alpha} \left(\frac{\partial E}{\partial \alpha}\right)^2}} \quad (8)$$

Aquí ρ es el tamaño del paso, o sea la longitud de cada transición a lo largo de la dirección del gradiente en el espacio de parámetros. Generalmente, se puede cambiar el valor de ρ para variar la velocidad de convergencia de la siguiente manera: Se observa que si ρ es pequeño, el método del gradiente aproxima de cerca la trayectoria del gradiente, pero la convergencia será lenta puesto que el gradiente se debe calcular muchas veces. Por otra parte, si ρ es grande, la convergencia será inicialmente muy rápida, pero el algoritmo oscilará sobre el grado óptimo. De acuerdo con estas observaciones, se actualiza ρ según las siguientes reglas heurísticas:

- Si la medida del error experimenta cuatro reducciones consecutivas, se aumenta ρ en el 10%.
- Si la medida del error experimenta dos combinaciones consecutivas de un aumento y de una reducción, se disminuye ρ en un 10%. Sin embargo los valores de cuatro reducciones, dos combinaciones y el aumento o disminución de ρ en el 10%, son elegidos de manera un poco arbitraria, aunque como se observa más adelante, muestran un

buen resultado en la respuesta de la VT, lo importante es no escoger un valor inicial de ρ muy grande, para que este no sea crítico [6].

4. ESTRUCTURA DE LAS REDES NEURONALES SELECCIONADAS:

Para verificar los 6 modelos de predicción seleccionados, se utilizó también además del ANFIS, un perceptrón multicapa (PMC), la cual es una red neuronal artificial (RNA) formada por múltiples capas, esto le permite resolver problemas que no son linealmente separables, lo cual es la principal limitación del perceptrón (también llamado perceptrón simple). El perceptrón multicapa puede ser totalmente o localmente conectado. En el primer caso cada salida de una neurona de la capa "i" es entrada de todas las neuronas de la capa "i+1", mientras que en el segundo cada neurona de la capa "i" es entrada de una serie de neuronas (región) de la capa "i+1".

Las capas pueden clasificarse en tres tipos:

Capa de entrada: Constituida por aquellas neuronas que introducen los patrones de entrada en la red. En estas neuronas no se produce procesamiento.

Capas ocultas: Formada por aquellas neuronas cuyas entradas provienen de capas anteriores y cuyas salidas pasan a neuronas de capas posteriores.

Capa de salida: Neuronas cuyos valores de salida se corresponden con las salidas de toda la red.

En la siguiente figura se observa la estructura de la red para el modelo de predicción 6:

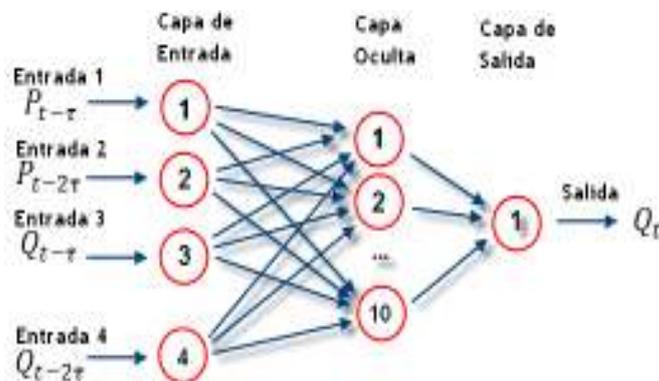


Figura 9. Red Neuronal para el modelo de predicción 6.

El algoritmo utilizado en el entrenamiento de estas redes es la propagación hacia atrás (también conocido como retropropagación del error o regla delta generalizada), por ello, el perceptrón multicapa también es conocido como red de retropropagación.

5. RESULTADOS:

Para el desarrollo del presente trabajo se utilizó el Software MATLAB, para el diseño y entrenamiento tanto del Sistema ANFIS como de las Redes Neuronales.

En las siguientes tablas se muestran los resultados de entrenamiento y de verificación de la correlación entre la salida deseada y la calculada para todos los modelos de predicción utilizados. Para la verificación del modelo se tomaron una serie de patrones diferentes a los utilizados en el entrenamiento.

Tabla 1. Correlación datos de Entrenamiento.

Modelo	ANFIS trimf	ANFIS pimf	ANFIS gbellmf	PMC 10 NCO	PMC 20 NCO
MOD-1	0.6361	0.6314	0.6348	0.6586	0.6917
MOD-2	0.3621	0.3653	0.3630	0.3574	0.2562
MOD-3	0.6466	0.6801	0.6863	0.6585	0.6313
MOD-4	0.7044	0.7434	0.7460	0.6931	0.6636
MOD- 5	0.6986	0.7494	0.7540	0.6050	0.6162
MOD-6	0.7738	0.8680	0.8633	0.5439	0.5955

Para el entrenamiento de los sistemas se tomaron un total 500 patrones, se puede apreciar que el mejor resultado con datos de entrenamiento se obtuvo con el modelo 6 y el sistema ANFIS usando la función de activación “primf” (campana), se obtuvo una correlación de 0.868.

Tabla 2. Correlación datos de Verificación.

Modelo	ANFIS trimf	ANFIS pimf	ANFIS gbellmf	PMC 10 NCO	PMC 20 NCO
MOD-1	0.5581	0.537	0.5314	0.1454	0.6540
MOD-2	0.5029	0.4873	0.4933	0.4243	0.1901
MOD-3	0.5119	0.2580	0.1853	0.3861	0.5370
MOD-4	0.1150	0.1822	0.0106	0.4265	0.3528
MOD- 5	0.6479	0.4176	0.4164	0.3919	0.4091
MOD-6	0.4044	0.4349	0.2093	0.3597	0.2875

El modelo 6 tiene en cuenta los dos meses anteriores tanto en precipitación como en caudal y la diferencia en la correlación es significativa con respecto a los otros modelos. En la siguiente Figura se puede apreciar la comparación de los datos de entrenamiento deseados y los calculados por el modelo ANFIS de mejor resultado.

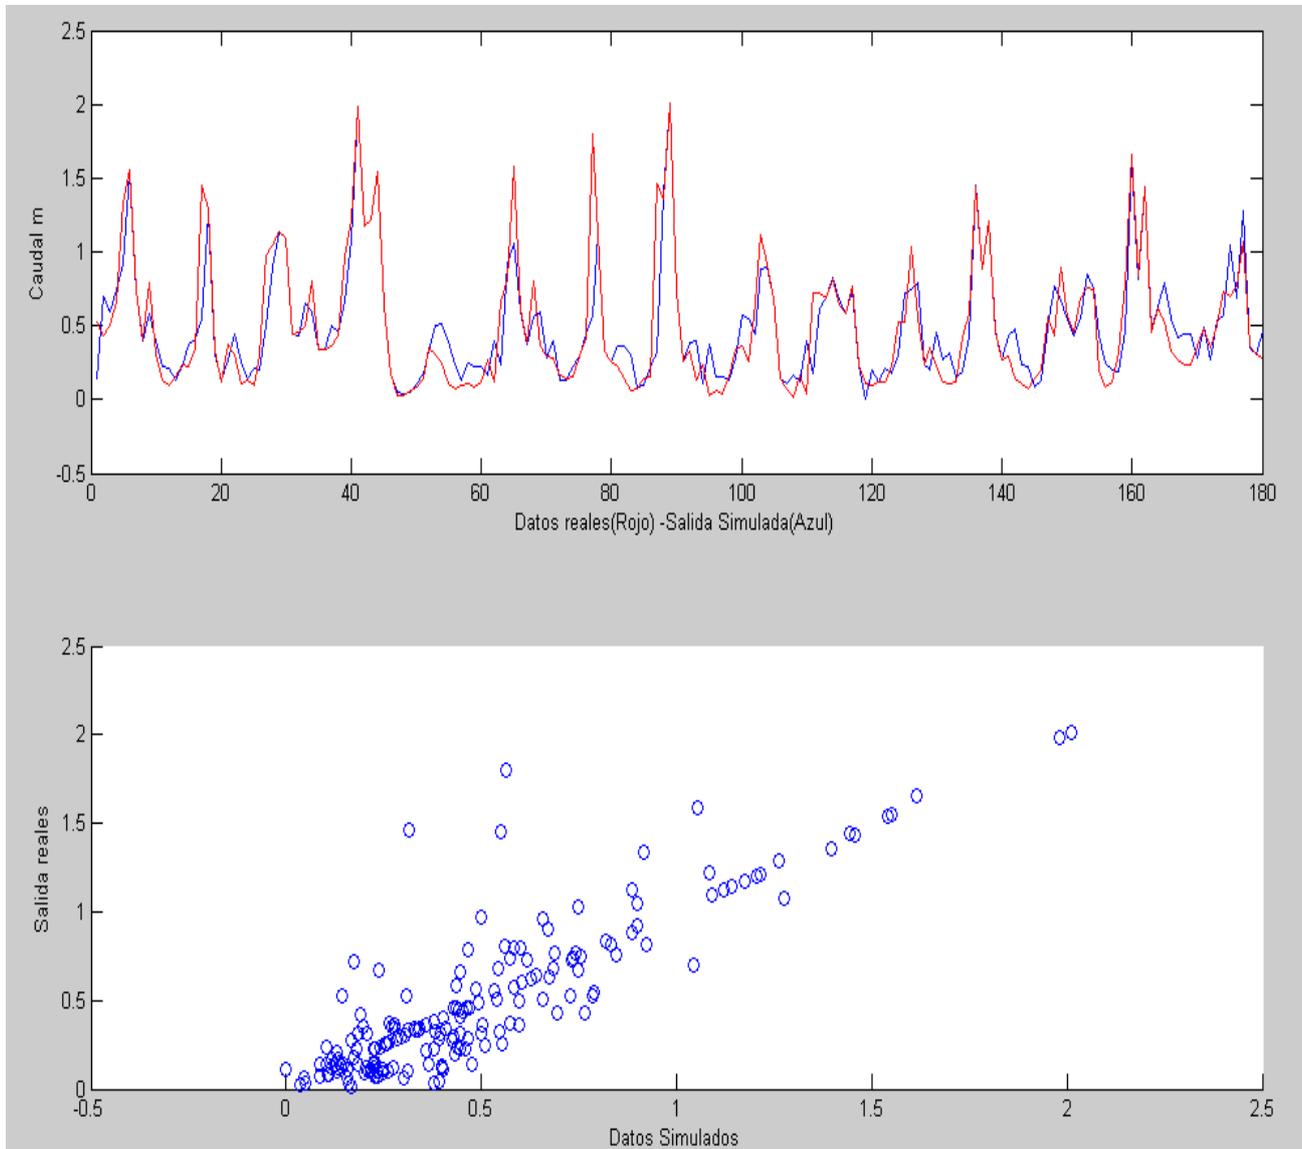


Figura 10. Entrenamiento Modelo 6-anfis pimf

El mejor resultado con los datos de verificación se obtuvo con el modelo 5 y el sistema ANFIS usando la función de activación "trim" (rampa). En la siguiente Figura se puede

apreciar la comparación de los datos de verificación deseados y los calculados por el modelo ANFIS de mejor resultado.

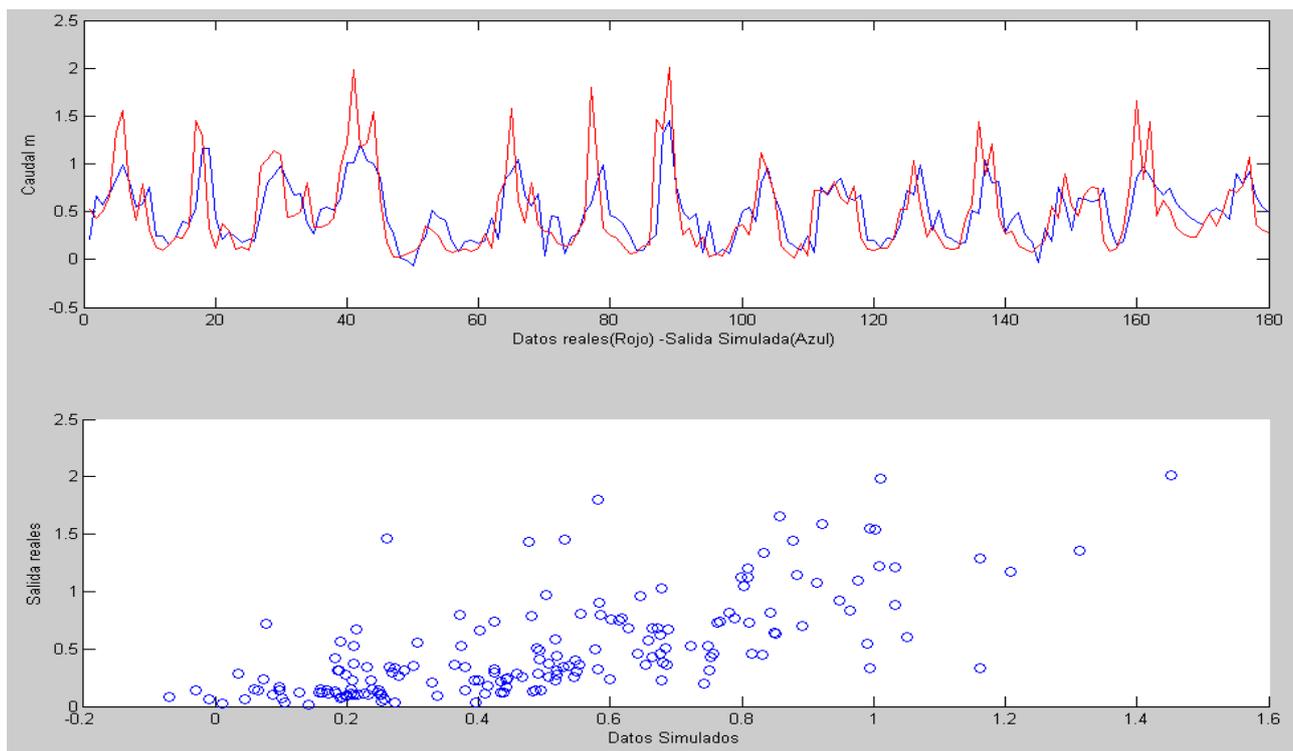


Figura 11. Verificación: Modelo 5-anfis trim

En el caso de los Sistemas PMC, se observa que el mejor resultado con datos de entrenamiento y verificación se encontró con el PMC de 20 neuronas en la capa oculta y el modelo 1, el cual tiene en cuenta solamente el caudal del mes

anterior. Los resultados gráficos de los datos deseados y calculados para esta red neuronal se pueden apreciar en la siguiente gráfica.

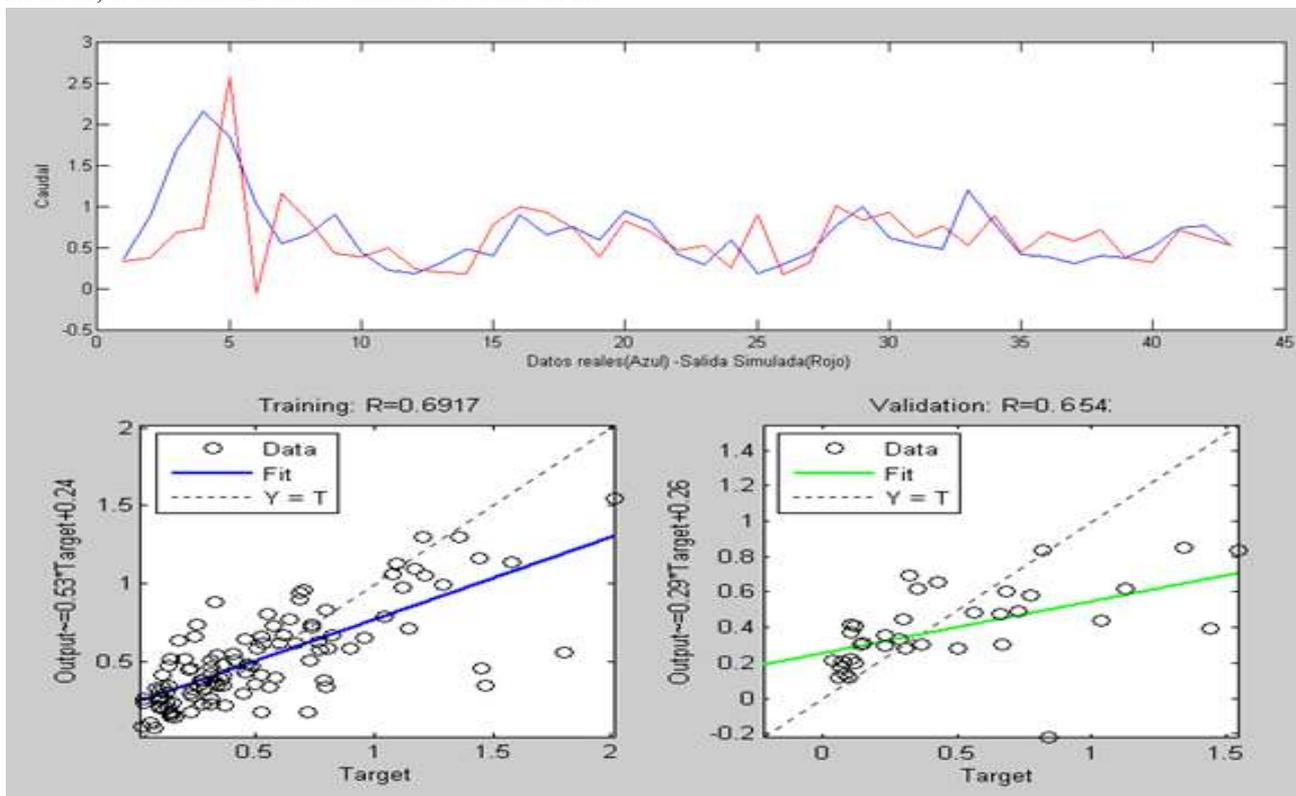


Figura 12. Entrenamiento y validación: Modelo 1-PMC (20 neuronas Capa Ocultas)

En términos generales se observa que en la mayoría de los modelos, el comportamiento del sistema ANFIS es mejor que el del PMC, esta situación se puede evidenciar en las

siguientes graficas en donde se muestra el desempeño de cada uno de los sistemas diseñados en cada uno de los modelos de predicción.

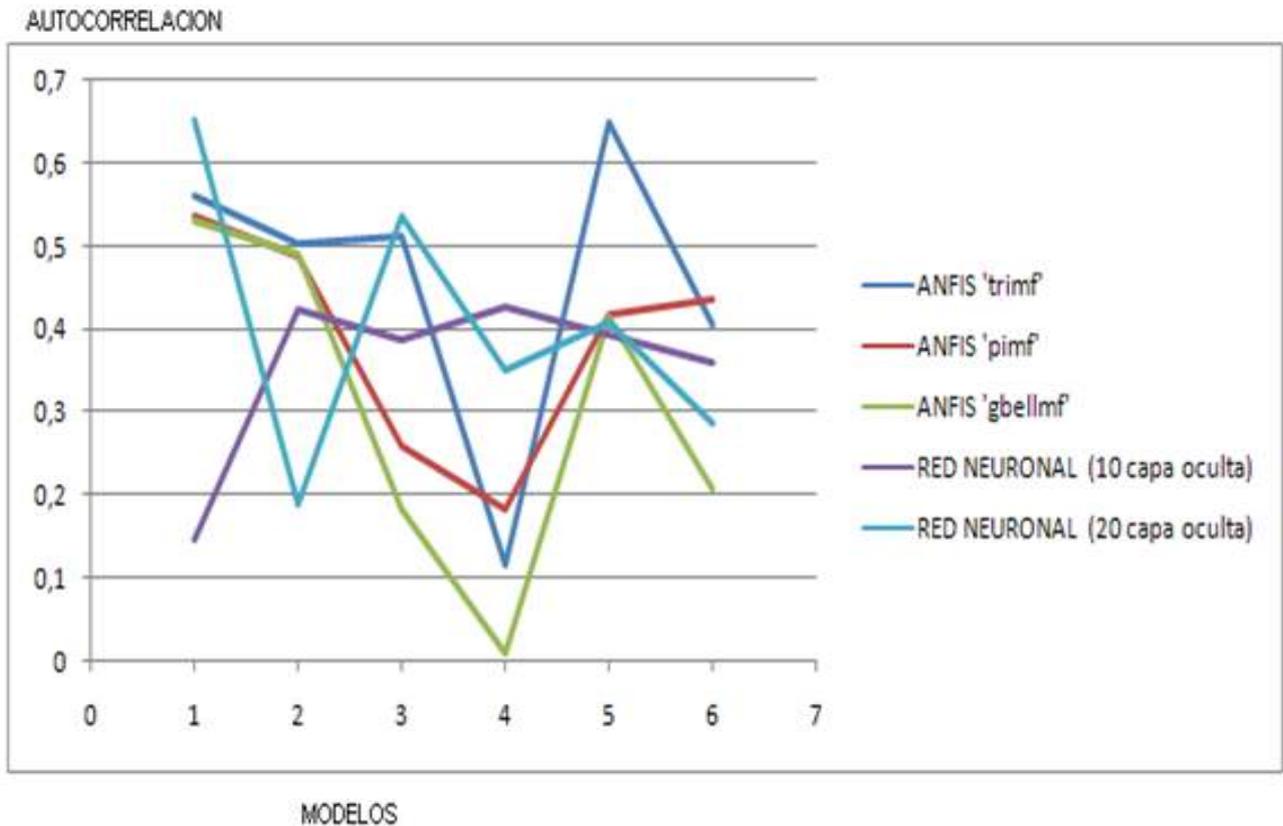


Figura 13. Comparación ANFIS Vs PMC (datos verificación).

AUTOCORRELACION

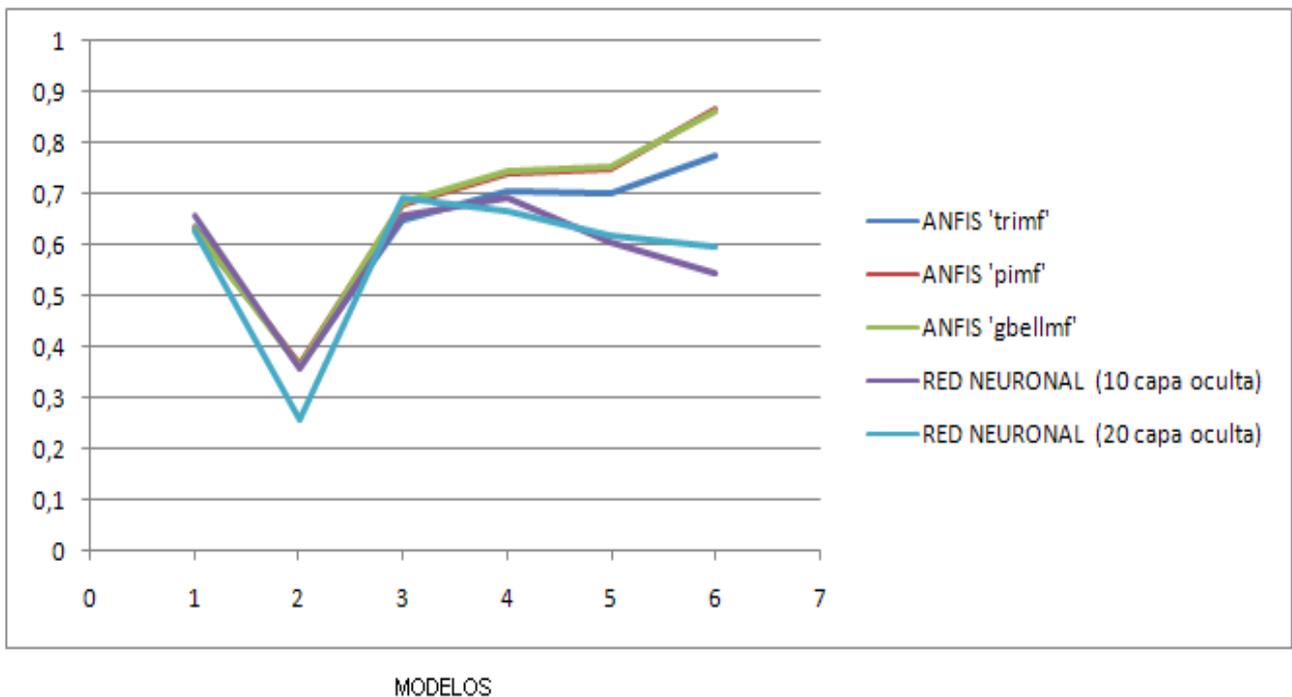


Figura 14.. Comparación ANFIS Vs PMC (datos entrenamiento.)

En las graficas anteriores se puede apreciar que con los datos de verificación en términos generales son más estables a través de los diferentes modelos los diseños PMC que los ANFIS. Con respecto a los datos de entrenamiento el comportamiento de todos los diseños fue en términos generales muy similar. De igual Forma es claro evidenciar que de los modelos de predicción seleccionados el modelo 2, fue el de peor resultado con los datos de entrenamiento, mientras que el modelo 4 fue el menos acertado con los datos de verificación.

Análisis de Parsimonia de los modelos.

En la siguiente tabla se muestra el resumen del factor de compresión (relación entre el número de patrones y el numero de parámetros) da cada uno de los modelos diseñados, para el caso del modelo ANFIS el numero de parámetros tiene en cuenta los parámetros antecedentes y los parámetros consecuentes. La siguiente expresión me permite el cálculo del número de parámetros en un sistema ANFIS [7]

$$nreq = nparantecedentes + nparconsecuentes \quad (9)$$

$$nreq = nvd \times ncd \times npp + ncd \times nvd \times (nvd + 1) \quad (10)$$

Donde: nvd es el número de variables difusas, ncd el número de conjuntos difusos y npp es el número de parámetros que definen la función de pertenencia del conjunto.

Tabla 3. Factor de Compresión de los Diferentes Sistemas .

Modelo	ANFIS trimf	ANFIS pimf	ANFIS gbellmf	PMC 10 NCO	PMC 20 NCO
MOD-1	50	50	50	25	12.5
MOD-2	50	50	50	25	12.5
MOD-3	20.8	20.8	20.8	16.6	8.3
MOD-4	10	10	10	12.5	6.25
MOD-5	10	10	10	12.5	6.25
MOD-6	4.8	4.8	4.8	10	5

De la tabla anterior, se puede concluir en términos generales que para las condiciones dadas en este trabajo, son necesarios un numero de parámetros similar en ambos sistemas (PMC y ANFIS), lo cual resalta aun más los resultados de correlación obtenidos en los sistema neurodifusos.

6. CONCLUSIONES.

En términos generales las mejores predicciones (asociadas al proceso de validación) realizadas con ANFIS y PMC a caudales medios mensuales presentan una correlación promedio de 0.64, valor que es moderadamente aceptable; los resultados de las mejores combinaciones de calibración presentan coeficientes de correlación superiores a 0.8 para el ANFIS y 0.7 para el PMC, demostrando de esta manera la facilidad que tienen este tipo de modelos para encapsular la información que le es presentada.

La ventaja de ANFIS frente a las PMC es su flexibilidad, ya que permite generar topologías sencillas para el caso de contar con un número de registros restringido y topologías más

complejas para el caso de tener bastante información. Para el caso de la validación se recomienda tener entre 1 y 3 variables difusas, de la misma manera 2 o 3 conjuntos difusos son suficientes; para el caso de la calibración se pueden incrementar el número de conjuntos difusos y el número de variables difusas.

Definir un tipo de conjunto difuso que describa de una manera generalizada el comportamiento de las serie de caudal es complicado, ya que este depende de los datos que se desea modelar.

Se recomienda, a la hora de implementar este modelo, diseñar estructuras o topologías sencillas, realmente la precisión no siempre aumenta al incluir mayor información, o al usar muchas variables de entrada. Lo fundamental es determinar previamente cuales serán las posibles mejores entradas.

REFERENCIAS.

- [1] S. Infante, J. Ortega , F. Cedeño, “Estimación de datos faltantes en estaciones meteorológicas de Venezuela vía un modelo de redes neuronales”, Revista de Climatología , Departamento de Matemáticas, Facyt, Universidad de Carabobo, 2008.
- [2] J-S. R.Jang “ANFIS: Adaptive-Network-based Fuzzy Inference Systems”, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 23, 1993.
- [3] M.Wiering, J. Vreeken, J. Van Veenen, y A. Koopman “Simulation and optimization of traffic in a city”. IEEE Intelligent Vehicles Symposium (IV’04). IEEE, 2004. A system level study. Technical Report 1991-09-01, California
- [4] T. Takagi y M. Sugeno “Derivation of fuzzy control rules from human operator’s control actions”, Proc. Of the IFAC Symp. on Fuzzy Information, Knowledge Representation and Decision Analysis, 1983.
- [5] S. Zak, *Systems and Control*, Oxford University Press, 2003.
- [6] Jang J-S. R. “Input Selection for ANFIS Learning”, Proceedings of the IEEE International Conference on Fuzzy Systems, New Orleans, 1996.
- [7] PLAZAS, Romero CRISTIAN, Aplicación de un modelo neurodifuso ANFIS al problema predictivo de caudales medios mensuales en la ciudad de Bogotá, Universidad Nacional De Colombia. 2006