

COMBINACIÓN DE PRONÓSTICOS DE CAUDALES MEDIOS
MENSUALES EN EL RÍO GUADALUPE-COLOMBIA

Julián D. Rojo H., Luis F. Carvajal S., Juan D. Velásquez
Universidad Nacional de Colombia, Sede Medellín, Colombia
jdrojoh@unal.edu.co, lfcarvaj@bt.unal.edu.co, jdvelasq@unal.edu.co

RESUMEN: (1^{era}. hoja)

El presente trabajo describe los métodos del promedio simple (MPS), el promedio ponderado (MPP), la red neuronal (MRN) y el sistema de inferencia difuso tipo Takagui-Sugeno (ANFIS), para combinar los pronósticos de cuatro modelos usados en la predicción de caudales medios mensuales. Las metodologías aquí presentadas son utilizadas en la predicción de los caudales medios mensuales del Río Guadalupe en Colombia. Una comparación entre los modelos de combinación demuestra que el ANFIS posee mayor eficiencia.

ABSTRACT: (1^{era}. hoja)

In this paper, the simple average method (SAM), the weighted average method (WAM), the neural network method (NNM) and the first order Takagui-Sugeno Fuzzy system are explained to combine together the simulation results of four different conceptual models to streamflow forecasting. The comparison of the forecast simulation efficiency of the Takagui-Sugeno method with the other three combination methods demonstrates that the first order Takagui-Sugeno method is the most efficient.

PALABRAS CLAVES: (1^{era}. hoja)

Predicción de caudales, Combinación de pronósticos, Hidrológica estocástica.

INTRODUCCIÓN

De todos los elementos del ciclo hidrológico los caudales de los ríos pueden ser los que mayores consecuencias tienen sobre la vida de los seres humanos. La seguridad alimentaría depende de hectáreas de tierras irrigadas con el agua proveniente de ríos y los embalses que regulan su flujo, en muchas zonas del planeta los diferentes cursos de agua representan la fuente primaria para consumo doméstico y generación de hidroelectricidad, gran parte de la industria y el comercio requiere del agua de los ríos para su abastecimiento, innumerables poblaciones desarrollan su vida cotidiana y hacen de los ríos su vía de comunicación, es por ello que los pronósticos de caudales constituye el objetivo principal de muchos tipos de estudios relacionados con el planeamiento y manejo de los recursos hídricos.

Los pronósticos derivados de tales estudios no son únicos dado que existen diferentes formas de obtenerlos, y aun cuando se halla seleccionado un procedimiento en particular, quedan todavía muchos problemas referentes a la selección de las variables de interés, el tipo de funcionamiento, la técnica de estimación de los parámetros del modelo usado y la incertidumbre del modelo. Como resultado, el investigador cuenta con varios pronósticos de caudales, generalmente diferentes, que lo llevan a formular la inquietud de si se debería escoger un sólo pronóstico o tomar de alguna forma un promedio de los resultados arrojados por los diferentes modelos. Ésta cuestión ha tenido mucha atención de la literatura académica en los años recientes, y en todas las investigaciones realizadas se concluye que es mejor usar una mezcla de los pronósticos en lugar de usar sólo uno de ellos (Castaño y Melo, 2006).

Los econométricos han sido los grandes precursores de los métodos de combinación de pronósticos. El primer trabajo que se conoce sobre el tema fue presentado por Bates y Granger (1969) y la revisión más completa sobre el asunto fue elaborada por Clemen (1989), sus estudios llegaron a la conclusión de que un pronóstico puede ser sustancialmente mejorado si se utiliza una combinación de pronósticos; si los resultados de diferentes modelos pueden ser tratados formalmente como pronósticos de diferentes expertos, entonces su combinación no debería generar ninguna controversia, pues equivaldría a combinar en la predicción distintos aspectos y fuentes de información, además, los fuertes resultados estadísticos obtenidos han permitido dejar atrás las críticas.

El concepto de combinación de pronósticos también hecho raíces en el modelamiento del clima, Vislocky y Fritsch (1995) demostraron que el promedio simple de los resultados por diferentes modelos (multi-model ensemble) posee una mayor capacidad de predicción que los diferentes modelos individuales, sin embargo se obtienen mejores resultados al ponderar las salidas de los modelos individuales (multi-model superensemble) y justamente éste postulado es empleado por Krishnamurti (1999,2000,2003) para previsiones del clima de largo plazo. En hidrología existen muy pocas aplicaciones en la combinación de pronósticos, muchas de ellas referidas a la combinación de diferentes modelos lluvia escorrentía. Shamseldin et al (1997) combina las salidas de cinco modelos lluvia escorrentía usando tres aproximaciones diferentes: un promedio simple, un promedio ponderado y una red neuronal; el caudal estimado a partir de la combinación fue más consecuente con la realidad que la mejor de las estimaciones individuales, especialmente para los métodos del promedio ponderado y la red neuronal.

Cuatro métodos son presentados en éste trabajo para la combinación pronósticos de caudales medios mensuales: el método del promedio simple (MPS), el método del promedio ponderado (MPP) el método de la red neuronal (MRN) y una combinación entre sistemas de inferencia difusa y redes neuronales conocida como ANFIS. Los primeros dos métodos han sido utilizados

extensivamente por muchos autores diferentes (Dickson (1975), Mkidraskis et al (1983), Vislocky y Fritsch (1995) y Krishnamurti et al. (1999)), quienes en gran medida sugieren la regresión lineal múltiple como método de combinación. Con el objetivo de explorar relaciones más complejas en la combinación de pronósticos Shamseldin et al (1997) incorporaron las redes neuronales dada su mayor versatilidad a la hora de modelar las relaciones complejas, no lineales entre las diferentes variables involucradas en el problema de la combinación de diferentes modelos lluvia escorrentía, previamente Donaldson and Kamstra (1996) habían usado las redes neuronales para la combinación de pronósticos en economía. Un método de combinación basado en inferencia difusa fue desarrollado por Xion et al (2001) quienes propusieron un sistema de primer orden basado en reglas del tipo Takagi-Sugeno cuya aplicación aumentó la eficiencia de la predicción combinada.

Se seleccionaron cuatro modelos utilizados en la predicción de caudales: los autoregresivos AR(2), ARIMA(2,1,1); un modelo basado redes neuronales artificiales (RNA) y un modelo periódico basado en la técnica del Análisis Espectral Singular (AESMP). Los modelos autoregresivos modelan los caudales como una variable aleatoria estocástica lineal según los postulados Box y Jenkins (1976). Las redes Neuronales han sido ampliamente utilizadas en los pronósticos hidrológicos dada su capacidad para reproducir la naturaleza altamente no lineal entre las variables de entrada y las variables de salida en un modelo de predicción, una extensiva revisión de la aplicación de las RNA en hidrología podrá ser consultada por el lector en los trabajos del ASCE Task Committee (2000b) y Maier & Dandy (2000). El modelo AESMP presentado por Rojo y Carvajal (2010) filtra las series de caudales usando el análisis multivariado de componentes principales de forma tal que se obtengan los mayores coeficientes de correlación entre la serie filtrada y las variables macro climáticos, las series filtradas son mucho mas predecibles y por tanto se utiliza un ajuste de la serie filtrada basado en regresiones lineales múltiples periódicas para predecir los valores futuros de los caudales, el modelo aplicado a diferentes ríos de Colombia muestra gran habilidad para pronosticar caudales con ventanas de 3 y 6 meses.

Las técnicas aquí descritas serán puestas a prueba sobre la serie de caudales del río Guadalupe ubicado al Nor-occidente de Colombia y para ello el presente trabajo muestra inicialmente los diferentes métodos utilizados para la combinación de pronósticos, luego se hace una breve descripción de los modelos y datos usados para el pronóstico de caudales, y por último se presentan los resultados con sus respectivos análisis.

COMBINACIÓN DE PRONÓSTICOS

Una estimación combinada del caudal \hat{Q}_{C_i} , obtenida a partir de N modelos para el i ésimo periodo, está formalmente definida como una función $F(\)$ de los N caudales estimados por los modelos individuales, de forma tal que:

$$\hat{Q}_{C_i} = F(\hat{Q}_{1,i}, \hat{Q}_{2,i}, \dots, \hat{Q}_{N-1,i}, \hat{Q}_{N,i}) \quad [1]$$

Donde $\hat{Q}_{j,i}$ es el caudal estimado por el j ésimo modelo para el i ésimo periodo (Shamseldin et al, 1997), cada método de combinación elabora su propia definición de la función $F(\)$. Un diagrama esquemático del proceso de combinación de pronósticos se presenta en la Figura 1.

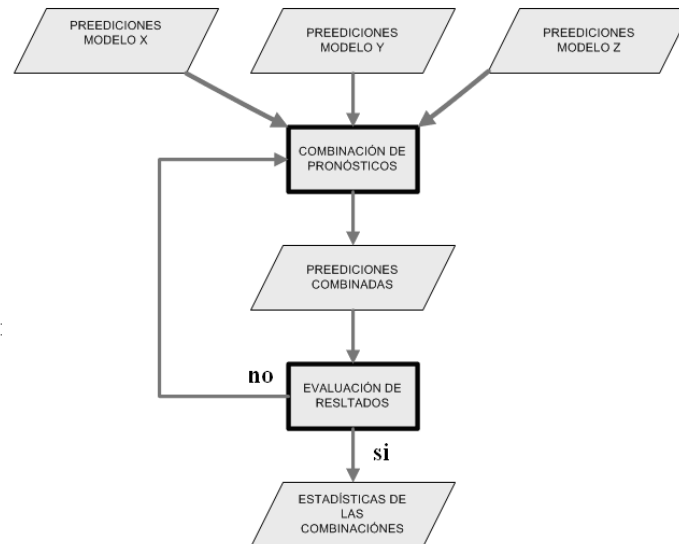


Figura 1.- Procedimiento general para la combinación de pronósticos

A continuación se describen algunas de las metodologías descritas en la literatura para la combinación de pronósticos

Método del promedio simple (MPS)

Dadas las predicciones de caudales $\hat{Q}_{j,i}$ de N modelos, una estimación combinada del caudal para el periodo i usando el método del promedio simple (MPS) está dada por:

$$\hat{Q}_i = \frac{1}{N} \sum_{j=1}^N \hat{Q}_{j,i} \quad [2]$$

Método del promedio ponderado (MPP)

Cuando algunos de los modelos individuales seleccionados para la combinación son mas precisos que otros, el método del promedio simple puede ser demasiado ineficiente (Armstrong, 1989), y es allí donde el uso de un promedio ponderado puede considerarse.

El método del promedio ponderado (MPP) para la combinación de pronósticos de caudales provistos por N diferentes modelos puede ser expresado como (Granger y Ramanathan,1984):

$$\hat{Q}_i = \sum_{j=1}^N a_j \hat{Q}_{j,i} + e_i \quad [3]$$

Donde a_j corresponde al peso asignado al caudal $\hat{Q}_{j,i}$ del j ésimo modelo y e_i es el error en el ajuste de la combinación. La ecuación [3] puede ser expresada en términos matriciales como

$$Q = PA + E \quad [4]$$

Donde P es la matriz que contiene los pronósticos de los diferentes modelos de predicción y está definida por:

$$P = \begin{bmatrix} \hat{Q}_{1,1} & \hat{Q}_{2,1} & K & K & \hat{Q}_{N-1,1} & \hat{Q}_{N,1} \\ \hat{Q}_{1,2} & \hat{Q}_{2,2} & K & K & \hat{Q}_{N-1,2} & \hat{Q}_{N,2} \\ \hat{Q}_{1,3} & \hat{Q}_{2,3} & K & K & \hat{Q}_{N-1,3} & \hat{Q}_{N,3} \\ M & M & M & M & M & M \\ M & M & M & M & M & M \\ \hat{Q}_{1,k-1} & \hat{Q}_{2,k-1} & K & K & \hat{Q}_{N-1,k-1} & \hat{Q}_{N,k-1} \\ \hat{Q}_{1,k} & \hat{Q}_{2,k} & K & K & \hat{Q}_{N-1,k} & \hat{Q}_{N,k} \end{bmatrix} \quad [5]$$

$Q = [Q_1, Q_2, Q_3, K, Q_{k-1}, Q_k]^T$ Corresponde al vector de salida del MPP, $A = [a_1, a_2, a_3, K, a_{N-1}, a_N]^T$ es el vector de ponderaciones y $E = [e_1, e_2, e_3, K, e_{k-1}, a_k]^T$ es el vector de errores en la combinación. T Denota el operador transpuesta y k corresponde al número de caudales predichos de manera individual por cada modelo. La ecuación anterior puede ser vista como un modelo de regresión lineal múltiple, donde el vector de pesos \hat{A} es estimado según el procedimiento de mínimos cuadrados:

$$\hat{A} = [(P^T P)]^{-1} P^T Q \quad [6]$$

Método de las Redes Neuronales (MRN)

Una típica red neuronal consiste en una estructura conformada por un número de elementos (nodos) y las líneas de conexiones entre éstos. Los nodos corresponden a los elementos computacionales de la red y usualmente son conocidos como neuronas, pues su diseño se basa en la forma de las neuronas que se encuentran en el cerebro humano. Las líneas de conexión transfieren información entre un par de neuronas y sobre cada conexión se designa un valor denominado peso de la conexión.

Una red neuronal usualmente posee una matriz de datos de entrada, tales datos constituyen lo que se denomina la capa de entrada, las neuronas en la red acumulan los datos de entrada y utiliza fórmulas de transformaciones matemáticas, conocidas como funciones de transferencia, para convertir esas entradas aculadas en las salidas de cada neurona. Dichas salidas son generalmente distribuidas (pero no divididas) según el número de conexiones a fin de proveer de entradas a otras neuronas que se encuentran en una nueva capa denominada capa oculta. Por último las salidas de la capa oculta son transformadas y llevadas por medio de conexiones a la neurona de salida.

A manera de ejemplo en la Figura 2 se propone una topología de red neuronal para combinar las predicciones usando como ejemplo tres modelos $(\hat{Q}_{1,k}, \hat{Q}_{2,k}, \hat{Q}_{3,k})$, la red presentada posee 6 neuronas representadas por los círculos en el esquema, cada par de neuronas se conecta con una línea y sobre cada conexión existe un peso $w_{m,n}$ siendo m la neurona de partida de la conexión y n la neurona de llegada. El número de neuronas de la capa de entrada es de tres (neuronas 1, 2 y 3), el número de neuronas en la capa oculta es de dos (neuronas 4 y 5) y existe una sola neurona de salida (neurona 6). Los valores que ingresan a la red (inputs) corresponden a los caudales predichos por los tres modelos, y la salida de red corresponde al caudal estimado mediante la combinación.




Figura 2.- Esquema de red Neuronal usada en la combinación de pronósticos

Existen varios tipos de redes neuronales pero la red que se utiliza en el presente trabajo se denomina: “ Perceptrón Multicapa de Retropropagación” , una red especialmente utilizada en la predicción hidrológica (Maier & Dandy, 2000). El perceptron multicapa es un tipo de red neuronal con una capa de entrada, una capa de salida y para éste caso una sola capa oculta. La capa de entrada tendrá un número de neuronas igual al número de entradas externas a la red, para el caso de la combinación de pronósticos las entradas externas a la red equivalen a los caudales predichos por los diferentes N modelos. Las entradas a cada neurona son transformadas utilizando una función de transferencia $f()$. Por ejemplo, en la capa de entrada, las variables externas X_i son transformadas por una función que las deja idénticas.

$$f(X_i) = X_i \quad [7]$$

En la capa oculta las neuronas reciben las salidas transformadas de la capa de entrada, y por ello tienen una función de transferencia de la forma:

$$y_{out,m} = f\left(\sum_{i=1}^n W_{m,i} X_{m,i}\right) \quad [8]$$

Donde $y_{out,m}$ corresponde a la salida de la neurona m , $X_{m,i}$ es la entrada a la neurona m proveniente de la neurona i y $f()$ es la función de transferencia que en este caso corresponde a la sigmoidea bipolar dada por la ecuación:

$$f(x) = \frac{2}{(1 + e^{-2x})} - 1 \quad [9]$$

Los pesos $W_{m,n}$ de la red neuronal deben ser ajustados mediante un entrenamiento, que consiste en comparar las salidas de la red con datos históricos de un periodo previamente elegido, el algoritmo de ajuste de los pesos se conoce como algoritmo de retropropagación y el lector podrá consultarlo en el trabajo de Hammerstrom (1993). La ecuación del perceptrón multicapa para la combinación de pronósticos esta dada por:

$$\hat{Q}_{C_i} = \sum_{h=1}^m W_m \cdot f\left(\sum_{i=1}^n W_{m,i} \cdot \hat{Q}_{m,i}\right) \quad [10]$$

Método ANFIS

Un sistema de inferencia difusa conformado por reglas de Takagi-Sugeno –véase a Sugeno y Kang (1988), Takagi y Sugeno (1983) y Takagi y Sugeno (1985)– puede ser interpretado como una red neurodifusa conocida como ANFIS (Jang, 1993). La Figura 3 presenta la arquitectura de ANFIS para un sistema de inferencia de dos variables difusas x y y donde:

$$\begin{aligned}
 \text{if } x \in A_1 \wedge y \in B_1 &\Rightarrow z = p_1x + q_1y + r_1 \\
 \text{if } x \in A_1 \wedge y \in B_2 &\Rightarrow z = p_1x + q_2y + r_2 \\
 \text{if } x \in A_2 \wedge y \in B_1 &\Rightarrow z = p_2x + q_1y + r_3 \\
 \text{if } x \in A_2 \wedge y \in B_2 &\Rightarrow z = p_2x + q_2y + r_4
 \end{aligned}
 \tag{11}$$

El dominio de x está cubierto por los conjuntos borrosos A_1 y A_2 , y el dominio de y por B_1 y B_2 . La función de pertenencia $\mu(u)$ para dichos conjuntos borrosos se define, comúnmente, como la función de campana generalizada:

$$\mu(u) = \Phi(u; \alpha, \gamma) = \frac{1}{1 + \left| \frac{u - \gamma}{\alpha} \right|^2}
 \tag{12}$$

El proceso de inferencia para una entrada (x, y) implica:

- Calcular $\mu_{A_1}(x)$, $\mu_{A_2}(x)$, $\mu_{B_1}(y)$ y $\mu_{B_2}(y)$ usando [12].
- Estimar la inferencia producto para cada regla $w = \mu_{A_i}(x) \times \mu_{B_j}(y)$
- Establecer el porcentaje que cada regla aporta a la solución final.
- Estimar la salida del conjunto borroso.

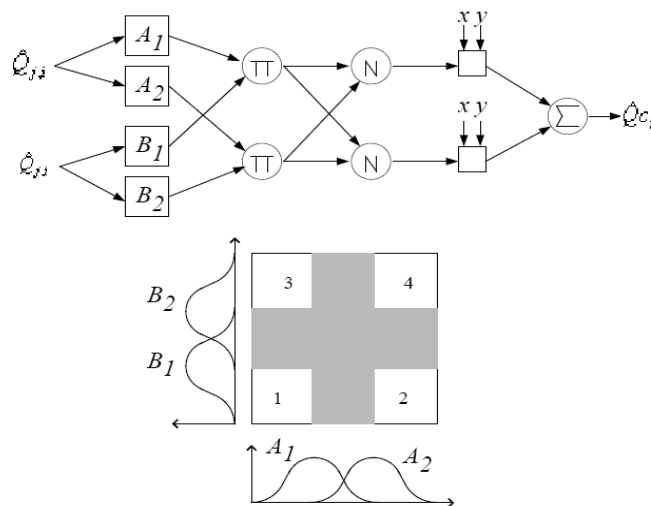


Figura 3.- Modelo ANFIS para la combinación de pronósticos

Nótese que en [11] las variables que conforman los antecedentes de las reglas son las mismas que conforman sus consecuentes; y que el dominio de cada variable está cubierto por al menos dos conjuntos borrosos, de acuerdo con la definición de reglas de Takagi–Sugeno. Usualmente, la función especificada para el consecuente de las reglas es la combinación lineal de las entradas, pero en el caso general es posible usar funciones más complejas. La ecuación de la campana

$$z_t = \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad [15]$$

Donde los parámetros $\phi_1, \phi_2, \dots, \phi_p$ y $\theta_1, \theta_2, \dots, \theta_q$ tienen el mismo significado que para los modelos AR(p) y MA(q).

Una manera eficiente de garantizar la estacionalidad de una serie consiste en diferenciarla la cantidad (d) de veces que sea necesaria, En general, la diferenciación de orden d es de la forma:

$$a_t = z_t - z_{t-d} \quad [16]$$

Los modelos autorregresivos integrados de media móvil (ARIMA), equivalen a aplicar un modelo ARMA sobre la serie de caudales no estacionaria diferenciada. Y de forma general esta expresado como:

$$\phi(B)\nabla^d z_t = \theta(B)a_t \quad [17]$$

z_t Corresponde a la serie estandarizada de caudales, $\phi(B)$ son los coeficientes de la parte autorregresiva, $\theta(B)$ los coeficientes de media móvil del modelo y ∇^d el diferenciador de orden d .

Redes Neuronales Artificiales (RNA)

En la sección anterior del presente trabajo se había expuesto el perceptron multicapa de retropropagación para la combinación de pronósticos, la misma arquitectura mostrada con antelación puede ser utilizada como modelo individual para pronosticar caudales cambio las entradas del modelo y el número de neuronas en la capa de salida, así por ejemplo, podrán ser entradas del modelo, datos rezagados de caudales, variables macroclimáticas de períodos anteriores, datos de lluvia, etc. y el número de neuronas en la capa de salida depende de la ventana de predicción. Un ejemplo de red neuronal para predicción de caudales a un horizonte de un mes se presenta en la Figura 4.

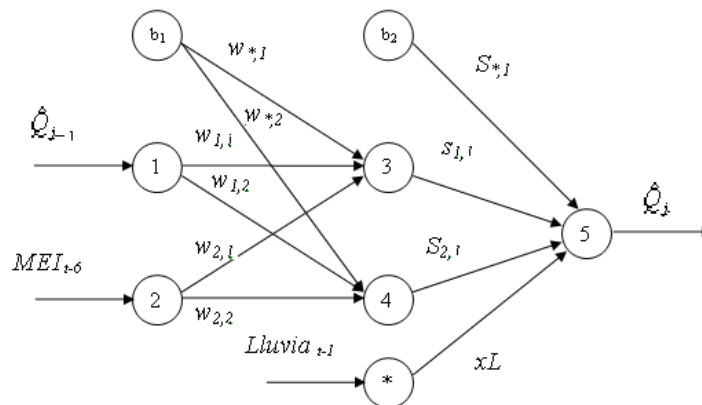


Figura 4.- Ejemplo de red neuronal usada para predicción de caudales

Modelo periódico basado en el Análisis Espectral Singular (AESMP)

El Análisis Espectral Singular (AES) es usado en estudios climáticos para referirse a la aplicación univariada del Análisis de Componentes Principales (ACP) en el tiempo, y es equivalente a aplicar las Funciones Ortogonales Empíricas a series de tiempo univariadas. El AES trata de capturar la evolución del sistema en el espacio de fases y la implementación del método procede de manera análoga a la reconstrucción artificial de la evolución de las trayectorias en un sistema no lineal sensible a condiciones iniciales (Ghil et al 2002). El análisis clásico de ACP se consiste en

proyectar una serie de tiempo sobre una base ortogonal de vectores M-dimensionales ($E^k, 1 \leq k \leq M$) conocidos como funciones ortogonales empíricas y para la implementación del análisis espectral se plantea una expansión es de la forma:

$$X_{i+j} = \sum_{k=1}^M a_i^k E_j^k \quad 1 \leq i \leq n; 0 \leq j \leq M-1 \quad [18]$$

Donde los a_i son las componentes principales de la serie de tiempo. Las funciones ortogonales empíricas corresponden a los vectores propios de la matriz de covarianzas de la serie. Las diferentes componentes obtenidas a partir del análisis espectral pueden ser analizadas en el dominio del tiempo y la frecuencia para determinar modos dominantes de oscilación a fin de asociarlas con diversos eventos macro-climáticos. Se trata entonces de utilizar dicha información filtrar la series truncando la cantidad de componentes usadas para reconstruir los datos. Dado que la serie filtrada es más predecible que la serie histórica, sobre la primera se ajusta un modelo auto-regresivo periódico de orden ρ basado una regresión lineal múltiple que permite definir los parámetros necesarios para predecir cada mes en función de sus antecesores. Así por ejemplo, una regresión lineal múltiple auto-regresiva de orden n usada predecir el mes t requiere los datos filtrados en los meses en $t-1, t-2 \dots t-n$, Por tanto:

$$Q_{ft} = C_1 Q_{ft-1} + C_2 Q_{ft-2} + K + C_n Q_{ft-n} \quad [19]$$

Donde Q_{ft} corresponde al caudal filtrado mediante análisis espectral para el mes t . La metodología descrita en detalle puede ser consultada en los trabajos de Rojo y Carvajal (2010).

DATOS Y RESULTADOS

Los datos utilizados para el desarrollo del presente trabajo corresponden a las serie de caudales medios mensuales del río Guadalupe, cuya estación de aforo se encuentra ubicada en inmediaciones de la población de Carolina del Príncipe al nor-occidente de Colombia. El río Guadalupe constituye el eje central de la cadena de generación eléctrica conocida como GUATRON que actualmente genera el 7% de la hidroelectricidad del país; se cuenta con un periodo de registro de la serie de caudales que inicia en enero de 1938 y finaliza en diciembre de 2008 (71 años). La serie de caudales del río Guadalupe y su ubicación se presentan en la Figura 5. Para efectos de aplicar los modelos de predicción de caudales y los modelos de combinación de pronósticos a la serie del río Guadalupe se han definido los siguientes periodos:

1938-1980: Para la calibración de los modelos de predicción.

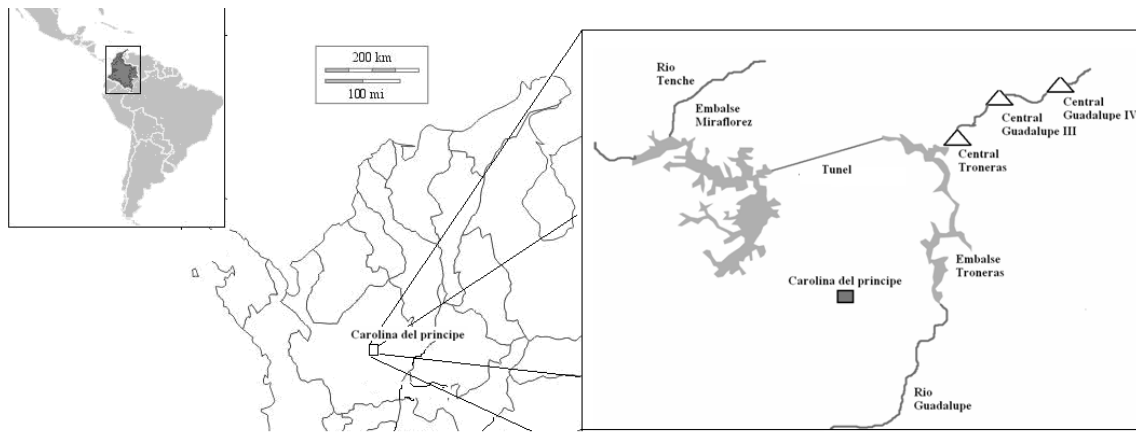
1981-2008: Para predecir caudales con los modelos calibrados.

1981-1995: Calibración de los modelos de combinación con base en las predicciones

1996-2008: Validación de los modelos de combinación de pronósticos.

Se cuantifica la capacidad de predicción que tienen los modelos y sus combinaciones mediante la comparación de los caudales observados o históricos con los caudales pronosticados durante el período 1996-2008, dicha evaluación se hace mediante la siguiente expresión:

$$RMSE(\%) = \frac{\sqrt{\frac{1}{n} \sum (Q_{real} - Q_{predicho})^2}}{\overline{Q_{real}}} \times 100 \quad [20]$$



Serie de Caudales medios mensuales del río Guadalupe

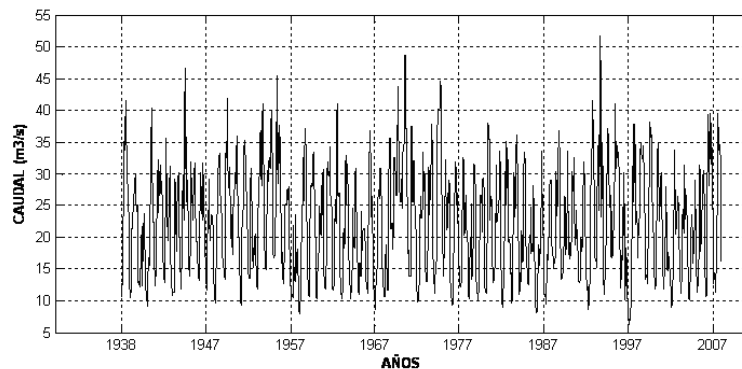


Figura 5.- Esquema de ubicación y serie de caudales del río Guadalupe-Colombia

Con los modelos AR(2), ARIMA(2,1,1), RNA y AESMP, se obtuvieron predicciones de caudales para el Río Guadalupe con horizontes de 1, 3 y 6 meses para el periodo comprendido entre 1981 y 1995, en la Figura 6 se presentan las predicciones para la ventana de pronóstico de un mes. Los pronósticos obtenidos durante dicho periodo fueron utilizados para calibrar los modelos de combinación MPS, MPP, MRN y ANFIS. Luego se hicieron predicciones con los modelos individuales y los modelos de combinación para el periodo comprendido entre los años 1996 y 2008,.

Caudales del río Guadalupe predichos entre 1981 y 1995 Horizonte de predicción: 1 mes




Figura 6.- Pronósticos de los modelos AR(2), ARIMA(2,1,1), RNA y AESMP para el río Guadalupe

En la Tabla 1 se presenta una relación entre los caudales predichos por los modelos de pronóstico y los caudales históricos para horizontes de predicción de 1,3 y 6 meses con su respectivo coeficiente de determinación para el periodo 1996-2008. Los resultados indican que el modelos AESMP es el de mayor eficiencia, seguido por la red neuronal (RNA), el modelo ARIMA(2,1,1) y el modelo AR(2), según lo muestran los coeficientes de determinación para cada caso.

Tabla 1.- Pronósticos de los caudales usando los modelos AR(2) ARIMA(2,1,1) RNA y AESMP

Modelo	Horizonte de pronóstico		
	1 mes	3 meses	6 meses
AR(2)			
ARIMA (2,1,1)			
RNA			
AESMP			

En las Tablas 2 y 3 se presentan los resultados de la combinación de pronósticos para el río Guadalupe durante el periodo 1996-2008. Según la Tabla 3 el método MPS es mas eficiente que RNA, ARIMA(2,1,1) y AR(2), sin embargo no supera en precisión a el AESMP. La combinación por ponderación (MPP) arroja predicciones más precisas que cualquiera de los modelos individuales, dado que presenta un %RMS mas bajo y un r^2 mas alto que cualquier modelo utilizados en el presente trabajo para pronostico. Alguna ganancia presenta la aplicación de combinación con redes neuronales (MRN) frente a la combinación ponderada (MPP), sin embargo ANFIS se postula como el método de combinación más exitoso con los valores más altos del coeficiente de determinación, los menores %RMS y la menor dispersión en los gráficos de caudales históricos vs. Caudales Predichos por combinación.

Tabla 2.- Pronósticos de los caudales usando los modelos AR(2) ARIMA(2,1,1) RNA y AESMP

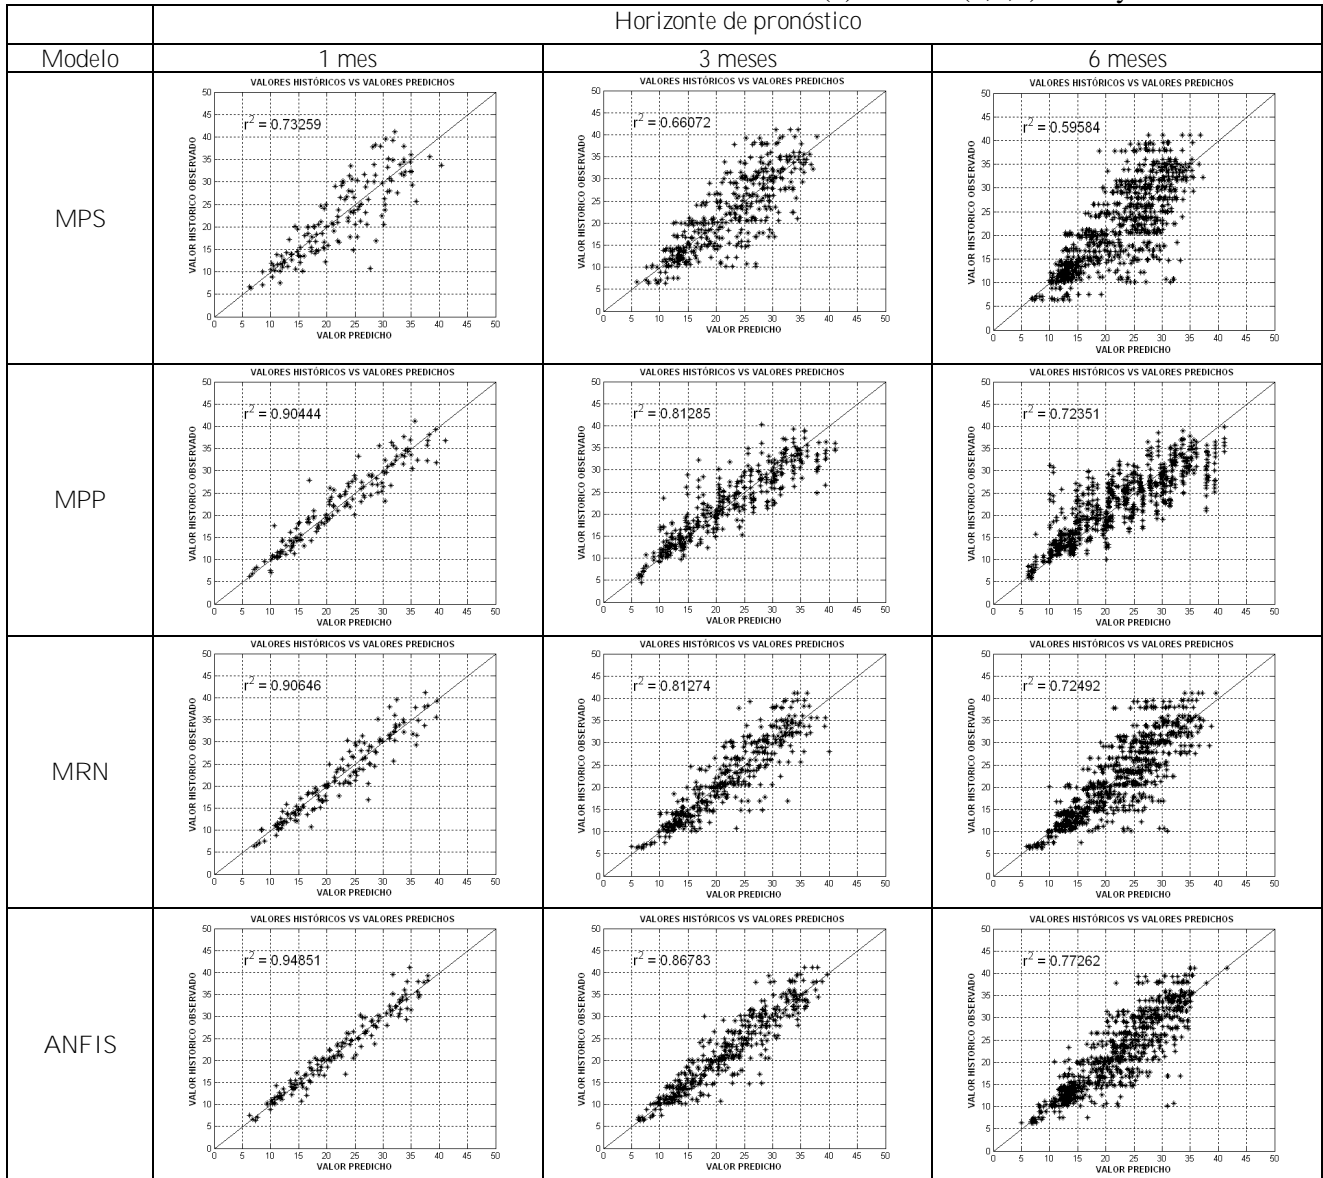


Tabla 3.- Valores del RMSE (%) para los diferentes modelos

MODELO	Horizonte de pronóstico (meses)		
	1	3	6
AR(2)	26.36	30.96	33.77
ARIMA(2,1,1)	22.76	28.14	28.59
RNA	19.7	21.98	23.71
AESMP	11.76	15.3	18.6
MPS	17.85	20.57	22.55
MPP	11.01	14.71	18.51
MRN	10.85	13.5	17.2
ANFIS	8.43	12.53	16.78

CONCLUSIONES

Los cuatro métodos de combinación, llamados método del promedio simple (MPS), método del promedio ponderado (MPP), método de redes neuronales (MRN) y el método neuro-difuso (ANFIS) han sido evaluados usando la serie de caudales del río Guadalupe y los resultados de dicha evaluación demuestran que por lo menos tres de las estimaciones combinadas (MPP, MRN y ANFIS) son más eficientes que el mejor de los modelos de pronóstico, con lo que se justifica el uso de la metodología de combinación en el contexto de la predicción de caudales medios mensuales.

Las estimaciones de los diferentes modelos para el coeficiente de determinación y el RMSE muestran que el mejor de los modelos de combinación es el ANFIS.

Los resultados del proceso de combinación dependen de las capacidades y habilidades de los diferentes modelos para capturar distintos rasgos de la serie de tiempo a modelar, por ello el uso eficiente del método de combinación depende de un análisis exhaustivo de los datos de entrada y los parámetros de calibración de los modelos conceptuales que predicen los caudales.

Agradecimientos

Al Departamento Administrativo de Ciencia, Tecnología e Innovación de Colombia (COLCIENCIAS) por considerar el proyecto: “DESARROLLO DE UN SISTEMA EXPERTO PARA LA PREDICCIÓN DE CAUDALES EN COLOMBIA” como una propuesta de investigación pertinente y ajustada a las necesidades del país. Los resultados presentados en este documento corresponden a los primeros avances del proyecto.

Referencias Bibliográficas

- Armstrong J.S. (1989). “Combining forecasts: the end of the beginning or the beginning of the end”. *Int. J. Forecast.*;5:585-588.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000): “Artificial neural networks in hydrology II: hydrologic applications”, *J. Hydrol. Eng.*, 5, 124–137, 2000b.
- Bates J.M. and Granger C.W (1969). “The combination of forecasts”. *Oper. Res. Quart.*;20:451±468.
- Box, G.E.P., Jenkins, G.C. (1970). “Time Series Analysis: Forecasting and Control”. Holden-day Inc., Calif, US.
- Bunn, D. (1985) ‘ Statistical Efficiency in the Linear Combination of Forecast’, *International Journal of Forecasting*, 151-163.
- Castaño E. & Melo L. (2000). “Métodos de combinación de pronósticos: una aplicación a la inflación”, *Lecturas de Economía*, Universidad de Antioquia, Departamento de Economía, issue 52, pages 113-165, Enero-Jun.
- Clemen R.T. (1989). “Combining forecasts: a review and annotated bibliography”. *Int. J. Forecast.* 5:559-583.
- Dan W. Hammerstrom, Steven Rehfus. (1993). “Neurocomputing hardware: present and future”. *Artif. Intell. Rev.* 7(5): 285-300.
- Dickinson, J. P. (1973). “Some Statistical Results on the Combination of Forecasts”. *Operations Research Quarterly*, 24,253-260.
- Donaldson, R.G., Kamstra, M. (1996). “Forecast combining with neural networks”. *J. Forecast.* 15, 49–61.
- Granger C.W., Ramanathan, R. (1984). “Improved methods of combining forecasts”. *J. Forecast.* 3:197-204.
- Jang, J. (1993), “Anfis: Adaptive-network-based fuzzy inference system”, *IEEE Transactions on Systems, Man, and Cybernetics* 23, 665–684.

- Krishnamurti, T.N., Kishtawal, C.M., Larow, T.E., Bachiochi, D.R., Zhang, Z., Williford, C.E., Gadgil, S., Surendran, S. (1999). "Improved weather and seasonal climate forecasts from multimodel superensemble". *Science* 285, 1548–1550.
- Krishnamurti TN, Kishtawal CM, Larow TE, et al. (200). "Multi-model ensemble forecasts for weather and season climate". *J. Climate*. 13:4196-4216.
- Krishnamurti, T.N., Surendran, S., Rajendran, K., Kumar, T.S.V.V., Lord, S., Toth, Z., Zou, X., Cocke, S., Ahlquist, J.E., Navon, I.M. (2003). "Improved skill for the anomaly correlation of geopotential heights at 500 hPa". *Mon. Weather Rev.* 131, 1082–1102.
- Maier, H. and Dandy, G. (2000). "Neural networks for the prediction and forecasting of water resources variables: A review of modeling issues and applications". *Environ. Modell. Softw.*, 15(1), 101– 104.
- Makridakis, S. Winkler, R. (1983). "Averages of forecasts: Some empirical results". *Manage. Sci.* 29:987-996.
- Rojo, J.D., Carvajal L.F. (2010); "Predicción no lineal de caudales Utilizando variables macroclimáticas y análisis espectral singular", *Tecnología y Ciencia del Agua -antes Ingeniería Hidráulica en México-*, vol 1, No 4, oct-dic.
- Shamseldin, A.Y., Oconnor K.M., Liang G.C. (1997). "Methods for combining the outputs of different rainfall-runoff models. *J. Hydrol*". 1997;197:203-229.
- Sugeno, M. y Kang, G. T. (1988). "Structure identification of fuzzy model", *Fuzzy Sets and Systems* 28, 15–33.
- Takagi, T. y Sugeno, M. (1983). "Derivation of fuzzy control rules from human operator's control actions", in *Proceedings of the IFAC Symposium on Fuzzy Information, Knowledge Representation and Decision Analysis*, pp. 55–60.
- Takagi, T. y Sugeno, M. (1985), "Fuzzy identification of systems and its applications to modelling and control", *IEEE Transactions on Systems, Man, and Cybernetics* 15, 116–132.
- Vislocky, R., Fritsch, J.M. (1995). "Improved model-output-statistics forecasts through model consensus". *Bull. Am. Meteorol. Soc.* 76, 1157–1164.
- Velasquez, J.D. (2008). "Construcción de Escenarios de Pronóstico del Precio de Electricidad en Mercados de Corto Plazo". *Programa de Doctorado en Ingeniería – Área Sistemas Energéticos*. Universidad Nacional de Colombia.
- Xiong, L. Shamseldin, A, & Connor, K. (2001). "A non-linear combination of the forecasts of rainfall-runoff models by the first-order Takagi -Sugeno fuzzy system" *J. Hydrol.* 245:196-217.