

MODELOS DE PREDICCIÓN DE CAUDALES MENSUALES PARA EL SECTOR ELÉCTRICO COLOMBIANO

Ricardo A. Smith , Jaime Ignacio Vélez , Juan David Velásquez, Adrián Ceballos, Paula Lizet Correa, Catalina Góez, Olver Olfrey Hernández, Luis Fernando Salazar y Elizabeth Catalina Zapata
Escuela de Geociencias y Medio Ambiente, Facultad de Minas
Universidad Nacional de Colombia, Sede Medellín
rasmith@unalmed.edu.co

Recibido para evaluación: 07 de Julio de 2004 / Aceptación: 03 de Septiembre de 2004 / Recibida versión final: 22 de Septiembre de 2004

RESUMEN

Se hace una breve descripción de cinco metodologías utilizadas para la predicción de caudales medios mensuales en Colombia: Redes Neuronales Artificiales, Redes Adaptativas Neuro-Difusas, Análisis Espectral Singular, Modelo Estructural y Modelo Físico y la aplicación de estos modelos en diferentes estaciones de medición de caudal pertenecientes al Sistema de Generación de Energía Eléctrica de Colombia. Los modelos se aplicaron para ventanas de predicción de uno, tres, seis y doce meses. Además se presenta la descripción de una herramienta computacional construida para apoyar la predicción de caudales donde se incluye las metodologías anteriores, acompañada de algunos resultados que muestran las posibilidades del mismo. El software, permite incluir variables macroclimáticas predichas, en cuyo caso puede tomar esos valores de diferentes agencias internacionales.

PALABRAS CLAVES: Modelos de predicción, Sector Eléctrico Colombiano, Software para predicción

ABSTRACT

A brief description of five stream flow forecasting methodologies at a monthly level is presented. The methodologies are: Artificial Neural Networks, Artificial Neuro-Fuzzy Networks, Physical Models, Spectral Analysis and Structural Models. All methodologies are used for stream flows prediction in several rivers associated with the Colombian Electric Sector. Some results are presented with prediction windows of one, three, six and twelve months. A general description of a computational tool that has been built to support forecasting of monthly average stream flows for the main Colombian rivers is presented. Some results that illustrates the possibilities of the developed software are presented. This software allows to consider some forecasted macroclimatic variables.

KEY WORDS: Forecasting Methodologies, Monthly Average Stream Flows, Forecasting Software.

1. INTRODUCCIÓN

La variabilidad de los caudales en ríos colombianos ocurre en un amplio rango de escalas espacio-temporales. Los ciclos anuales y semi-anuales de caudales, responden a forzamientos atmosféricos de gran escala, entre otros, la migración latitudinal de la Zona de Convergencia Intertropical (ZCIT), la fluctuación e intensidad del transporte de humedad a cargo de los vientos alisios del este provenientes del mar Caribe, de la cuenca Amazónica y del Océano Pacífico (Poveda y Mesa, 2000); y de la interacción suelo-atmósfera. A escala interanual, el llamado fenómeno El Niño/Oscilación del Sur, a través de sus dos fases: El Niño (fase cálida) y La Niña (fase fría). Para el caso de predicción de caudales en Colombia, los efectos producidos por los eventos mencionados, no son despreciables y la capacidad de predicción cambia según las condiciones en las que se encuentra el año analizado.

La predicción de caudales medios mensuales ha sido un elemento importante en los procesos de toma de decisiones en el Mercado Mayorista de Energía en Colombia, por sus múltiples aplicaciones en generación de energía eléctrica. En particular, una de las aplicaciones se ha dirigido a valorar los beneficios económicos de involucrar tales predicciones hidrológicas en la operación del Sistema Eléctrico Nacional Colombiano, (Mesa et al., 2001; Poveda et al., 2002).

En el Sector Eléctrico Colombiano es común el uso de modelos de tipo ARIMA para la generación de series sintéticas. Estos modelos se han usado generalmente para la generación de series sintéticas y no para predicción de caudales. Ellos pretenden representar posibles comportamientos futuros de la hidrología que pueden ocurrir en periodos de tiempo indeterminados. Los módulos hidrológicos que usa el SUPEROLADE o el MPODE (modelo de operación muy difundido en el Sector Eléctrico Colombiano) son módulos que corresponden a este tipo de usos. (Velásquez, 2000).

Dada la alta componente de generación hidroeléctrica del Sector Eléctrico Colombiano es muy importante desarrollar una herramienta que faciliten el procesamiento de la información y realicen predicciones de caudales para tratar de inferir posibles precios futuros de la electricidad y apoyar las decisiones cuando se participa en el Mercado Eléctrico Colombiano.

Este artículo muestra la aplicación de algunos modelos de predicción de caudales de tipo matemático-estadístico, y da unos primeros pasos en la implementación de un modelo físico-matemático de la dinámica hidrológica y climática. Estos modelos fueron aplicados en varias series de caudales pertenecientes al Sistema de Generación de Energía Eléctrica del país, para hacer predicciones a uno, tres, seis y doce meses. Es con base en los errores de predicción para estos horizontes que se comparan los modelos.

Además se presenta el desarrollo de una plataforma de apoyo a la predicción de caudales en los principales ríos del Sector Eléctrico Colombiano, para que sus resultados sirvan de apoyo en la toma de decisiones tanto de los generadores como de los comercializadores del Sector.

2. MODELOS DE PREDICCIÓN

A continuación se describe brevemente cada uno de los modelos de predicción utilizados:

2.1. Redes Neuronales Artificiales (RNA)

Las RNA son modelos que pueden representar relaciones altamente no lineales entre las variables independientes y la variable dependiente. Se caracterizan por un paralelismo masivo de elementos computacionales conectados por pesos, llamados neuronas artificiales (Figura 1). Las neuronas se conectan con otras neuronas de manera que las salidas de una neurona sirven como entrada a otras neuronas que a su vez retornan una o varias señales (Masters, 1993; Eberhart y Dobbins, 1990). Los modelos de redes neuronales se caracterizan por la arquitectura de la red, la función de activación entre las capas y el algoritmo con el cual se define el procedimiento de aprendizaje.




FIGURA 1. Neurona básica que recibe n entradas y produce una salida.

Cada conexión entre las entradas y la neurona tiene asociado un valor de ponderación, de manera que la entrada neta a una neurona es la suma ponderada por los pesos de las conexiones de las señales que llegan de las neuronas de la capa anterior.

Las neuronas se pueden describir por un umbral interno y por un tipo de función de activación asociada, que cumple el papel de transformar las señales que llegan a una neurona. La función de activación empleada para la predicción de caudal en los ríos colombianos fue la función sigmoidea dada por:

$$a = s(u) = \frac{1}{1 + \exp(-u)} \quad (1)$$

El modelo de predicción desarrollado utilizando RNA, se basó en un perceptrón multicapa de propagación hacia adelante (Eppler, 1996; Ultsch et al., 1995), que está formado por tres capas de neuronas. La capa de entrada de la RNA está conformada por las neuronas que reciben la señal de entrada del exterior y que corresponden a las variables independientes del problema. En este caso se utilizaron como entradas los caudales rezagados y en algunos casos variables macroclimáticas como la Temperatura y las Anomalías de Temperatura en la región Niño 4 del Océano Pacífico, la Temperatura en el Atlántico Sur, entre otras. La capa oculta contiene neuronas que tratan de estimar la relación entre las capas de entrada y de salida por medio de la modificación iterada de los pesos de la red, proceso que realiza el algoritmo de entrenamiento. La capa de salida entrega la señal procesada por la RNA y corresponde al caudal predicho.

Como algoritmo de entrenamiento, se utilizó una técnica híbrida entre estrategias de evolución y mínimos cuadrados. Después de entrenar la red, ésta es capaz de estimar una salida para la variable a predecir, que en este caso específico son caudales a uno, tres, seis y doce meses.

2.2. Redes Adaptativas Neuro – Difusas (ANFIS)

Las redes adaptativas neuro-difusas aparecen en los 90's como sistemas capaces de combinar los sistemas de inferencia difusos (Mendel, 1995) y las redes neuronales, aprovechando las características sobresalientes de cada modelo. Por un lado, los sistemas de inferencia difusos proveen un mecanismo intuitivo y de alto nivel para representar el conocimiento mediante la utilización de reglas IF/THEN. Por otro lado, las redes neuronales

poseen un alto grado de adaptabilidad y capacidad de aprendizaje y generalización.

ANFIS es entonces un tipo de RNA que implementa un sistema de inferencia difuso para su razonamiento.

La red de ANFIS tiene una estructura de cinco capas como la mostrada en la Figura 2. (Jang, 1993). En la primera capa se calcula la función de pertenencia para las entradas de los antecedentes, en la segunda se generan los pesos de activación de cada regla definiendo la salida de esta capa como el producto de sus entradas, en la tercera se normalizan los pesos de la segunda, en la cuarta se calculan las salidas basadas en los parámetros del consecuente y al final se produce la salida del sistema como la sumatoria de los resultados de la capa cuatro. Los modelos en ANFIS pueden variar de acuerdo a las variables que se elijan en el antecedente y el número de conjuntos difusos en los que se dividan dichas entradas. Además de las variables que se elijan para los consecuentes, que pueden ser las mismas o distintas a las del antecedente.

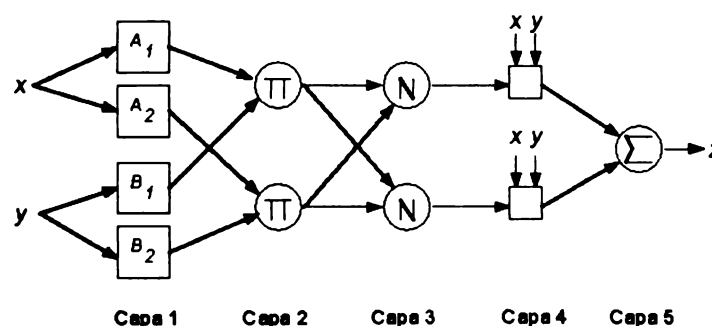


FIGURA 2. Neurona básica que recibe n entradas y produce una salida.

Para los modelos usados en Colombia se consideró una sola variable de entrada en el antecedente, dividida generalmente en dos o tres conjuntos difusos, en la mayoría de los casos esta entrada fue la serie de caudal rezaga en un mes. En las entradas del consecuente se consideraron en cambio varias variables, en algunos casos se utilizaba entre las variables de entrada la misma variable del antecedente. En los modelos seleccionados como mejores no aparecieron variables macroclimáticas como entradas del consecuente de manera que solo se usaron caudales rezagados para realizar los pronósticos.

2.3. Análisis Espectral Singular

La metodología se fundamenta en la aplicación de diferentes formas del Análisis de Componentes Principales (ACP) en el dominio del tiempo y del espacio (Preisendorfer, 1988). El AES se basa en el ACP en el espacio de los vectores conformados por versiones rezagadas de una serie de tiempo. En este contexto, la connotación del Análisis Espectral no se refiere al tradicional análisis en el dominio de la frecuencia, sino que se refiere a la expansión de la evolución de un campo espacio-temporal en diferentes modos ortogonales empíricos (obtenidos a partir de los datos). El AES es la expansión de un campo discreto, en sus componentes principales y Funciones Ortogonales Empíricas (FOE) considerando una longitud de ventana M .

La ortogonalidad en tiempo (covarianza cruzada igual a cero para dos CP en el rezago cero) y el espacio (ortogonalidad de las FOE), implica que el autovalor k de la matriz de Toeplitz representa la varianza de la k -ésima CP. La idea del método es reducir la información a p Componentes Principales, teniendo en cuenta la varianza explicada con respecto a la varianza total del proceso. Luego que se han seleccionado las p Componentes Principales, éstas se reconstruyen de forma óptima mediante un ajuste de mínimos cuadrados (Carvajal, 1994).

La descomposición anterior se realiza tanto para la serie de caudal que se quiere predecir, como para las series de variables macroclimáticas que servirán de apoyo al modelo. Luego que se tienen todas las series descompuestas se realiza un ajuste de regresión lineal múltiple entre componentes principales y se predice cada componente independiente de las otras. Finalmente se suman las componentes predichas y se obtiene el caudal total predicho.

2.4. Modelo Estructural

Los modelos estructurales de series de tiempo admiten la posibilidad de que cada uno de los componentes inobservables típicos de una serie temporal posea una naturaleza estocástica. Es decir, es razonable considerar que los componentes que describen el comportamiento de una serie de tiempo: tendencia, ciclo, estacionalidad y componente irregular, evolucionan aleatoriamente en el tiempo (Martín, 2002). Los modelos estructurales no son

más que modelos de regresión en los que las variables explicativas son función del tiempo y los parámetros varían en el tiempo (Harvey, 1989).

Un modelo de series de tiempo se puede definir como:

$$y_t = \mu_t + \psi_t + \gamma_t + \varepsilon_t \quad (2)$$

Donde μ_t representa la tendencia, ψ_t representa el ciclo, γ_t la componente estacional y ε_t representa la componente irregular. El modelo también puede incluir valores de la serie retardados y además variables explicativas adicionales.

Al aplicar el modelo a los ríos colombianos, se encontró que solo hay necesidad de usar las componentes de tendencia constante. La componente cíclica, de cada serie fue representada mediante armónicos, cuyas frecuencias fueron extraídas del análisis del espectro de Fourier de cada serie, y sus coeficientes fueron calculados con mínimos cuadrados. La componente estacional no fue tenida en cuenta debido a su poca influencia y a la incorporación de los armónicos en la componente cíclica. Por último la componente irregular fue modelada como un ruido blanco.

2.5. Modelo Físico

El modelo Físico propuesto busca representar por medio de un sistema de tanques interconectados entre sí los procesos determinantes de la producción de la escorrentía, los cuales se representan mediante las ecuaciones de conservación de masa y/o conservación de la cantidad de movimiento y algunas relaciones empíricas, que luego se acoplan para definir las cantidades de agua que cada elemento transfiere a sus vecinos (horizontal y verticalmente) en un intervalo de tiempo (Vélez, 2001). Se puede decir que los datos más importantes en la predicción de caudales, utilizando modelos físicos, son la información geomorfológica de la cuenca, y los datos hidrológicos de entrada (precipitación y temperatura). Las precipitaciones de precipitación son las variables de entrada al modelo para la simulación de la producción de caudal que se realiza en cada cuenca. De esta forma el modelo físico para la predicción de caudales está conformado por dos submodelos: uno de predicción de lluvia y otro para la predicción escorrentía, en el cual se transforma la lluvia predicha en caudal.

2.5.1. Predicción de lluvia

El modelo de precipitación desarrollado se compone de dos pasos: la predicción de la precipitación mensual y la desagregación a nivel diario de los datos mensuales predichos. Para la predicción de la precipitación mensual, se utilizó Análisis Espectral Singular, el cual ya fue descrito anteriormente.

Para la desagregación de la lluvia al nivel diario se emplea una versión de un modelo de simulación estocástico diario propuesto inicialmente por Richardson (1981) y refinado luego por diversos autores (Katz, 1996; Parlange y Katz, 2000). Se asume que la ocurrencia de precipitación sigue una cadena de Markov de primer orden con dos estados estables con probabilidades de transición P_{01} , la probabilidad de que a un día húmedo siga un día seco, y P_{11} , la probabilidad de que a un día húmedo siga un día húmedo. Para definir si un día es húmedo se determina un umbral de precipitación. Estas probabilidades de transición tienen un ciclo anual estacional. Para cada mes del año la probabilidad de un día húmedo es obtenida como (Katz, 1996):

$$P_w = \frac{P_{01}}{1 + P_{01} - P_{11}} \quad (3)$$

donde el llamado parámetro de persistencia está dado por $d = P_{11} - P_{01}$, que también es función del mes.

La cantidad de precipitación en un día húmedo se asume que tiene una distribución gamma como función de distribución de probabilidades de la siguiente forma:

$$f(r) = \frac{(r/b)^{a-1} \exp(-r/b)}{b\Gamma(a)} \quad (4)$$

donde a y b son parámetros de la función. Las probabilidades de transición P_{01} y P_{11} y los valores de a y b son estimados a partir de los datos diarios observados para cada mes, por lo que tienen un ciclo anual estacional.

2.5.2. Predicción de Caudal

En el modelo empleado para la predicción de los caudales, la producción de escorrentía se basa en balance hídrico en la cuenca, asumiendo que el agua proveniente de la precipitación se distribuye en cuatro tanques o niveles de almacenamiento conectados entre sí. (Ver Figura 3).

En cada intervalo de tiempo, la precipitación se distribuye a los distintos almacenamientos, donde en función del volumen almacenado en cada uno de ellos se determina su contribución a la escorrentía. El modelo realiza el balance de agua en cada tanque y actualiza los volúmenes almacenados en ellos.

La cantidad de agua que se deriva en cada nodo y la que continua hacia los niveles inferiores por el conducto distribuidor depende de la cantidad de agua disponible, el estado del almacenamiento del tanque y de la capacidad del conducto distribuidor aguas abajo del nodo, la cual se puede relacionar con la conductividad hidráulica en el subsuelo.

La descarga en cada uno de los tanques está en función del volumen almacenado y de las características de la cuenca que se pueden asociar con el tiempo de permanencia del agua en un elemento de almacenamiento temporal.

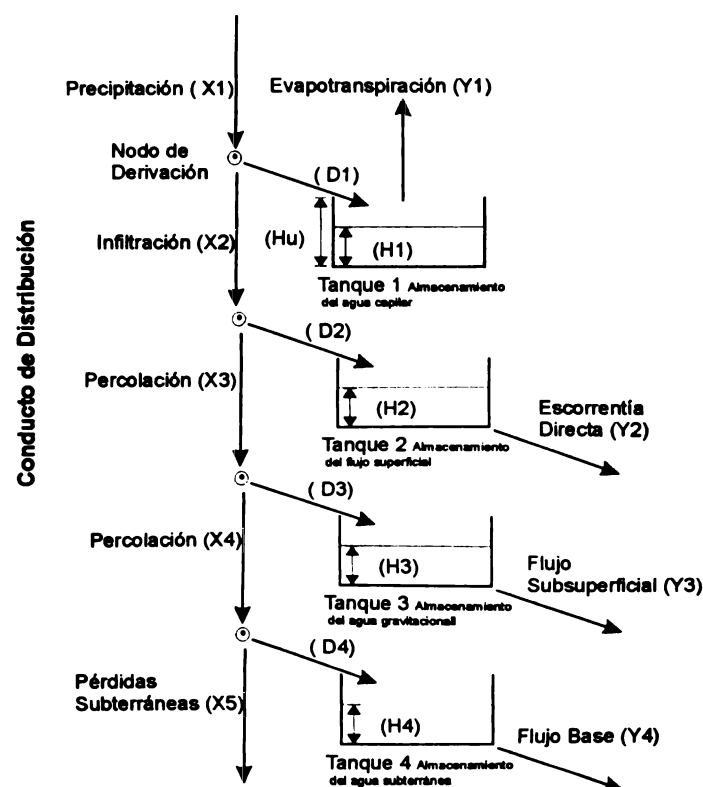


FIGURA 3. Modelo Físico de Tanques Utilizado.

Resultados

Para algunos de los ríos más importantes del Sector Eléctrico Colombiano, doce en total, se construyeron y se calibraron modelos de predicción, con cada una de las metodologías mencionadas anteriormente y utilizando ventanas de predicción de uno, tres, seis y doce meses. Se obtuvieron en general resultados que mejoran en promedio un 15% los modelos de predicción triviales como el uso de la media, o el mes anterior. Para la calibración o estimación de los modelos se utilizó el 80% de la serie histórica y el 20% restante para la validación de los mismos.

Las series analizadas fueron utilizadas para observar la validez de los diferentes modelos en dos esquemas de predicción. El primer esquema realiza predicción sin considerar predicciones de las variables macroclimáticas, lo que significa utilizar sólo los registros de caudal y el otro esquema utiliza predictores del macroclima. Estos esquemas fueron utilizados en todas las metodologías excepto en el modelo físico.

2.6. Resultados sin predicción de variables macroclimáticas

En este esquema de predicción solo se utilizan los registros de caudales. Por lo tanto, dependiendo del mes que se va a predecir, se rezagan los caudales una longitud de tiempo determinada y se realiza todo el proceso de modelación según sea el modelo seleccionado. Debido a que para cada mes en particular se ajustan varios modelos (dependiendo de la ventana de predicción), se presentan los resultados de la validación para las diferentes ventanas. También es importante anotar que este error se calcula solamente con la predicción en el mes n , que corresponde al valor de la ventana de predicción y no a los $n-1$ valores anteriores que también se predicen. De esta forma se habla de un error de predicción para las ventanas de 1, 3, 6 y 12 meses.

2.7. Resultados con predicción de variables macroclimáticas

En este caso se usan predicciones de variables macroclimáticas tomadas de diferentes agencias internacionales que las tienen disponibles. Estas variables se asumen que representan una predicción perfecta de los predictores. Al igual que en el caso anterior se realizó un proceso de validación bajo esas mismas consideraciones.

Por limitaciones de espacio solo se presentan los resultados de los mejores modelos obtenidos para cinco de las series analizadas, utilizando solo los dos esquemas de predicción: basados solo en los datos de caudal o utilizando también variables macroclimáticas. En la Figura 4 se presentan los resultados obtenidos con la aplicación de las diferentes metodologías de predicción para tres años del periodo de validación para una de las estaciones. En Tabla 1 se muestra el error cuadrático medio obtenido por cada uno de los modelos, de las cinco series para las diferentes ventanas de predicción.

3. SOFTWARE DESARROLLADO

En la siguiente sección se muestra la arquitectura del software, y algunos resultados obtenidos

3.1. Arquitectura del sistema

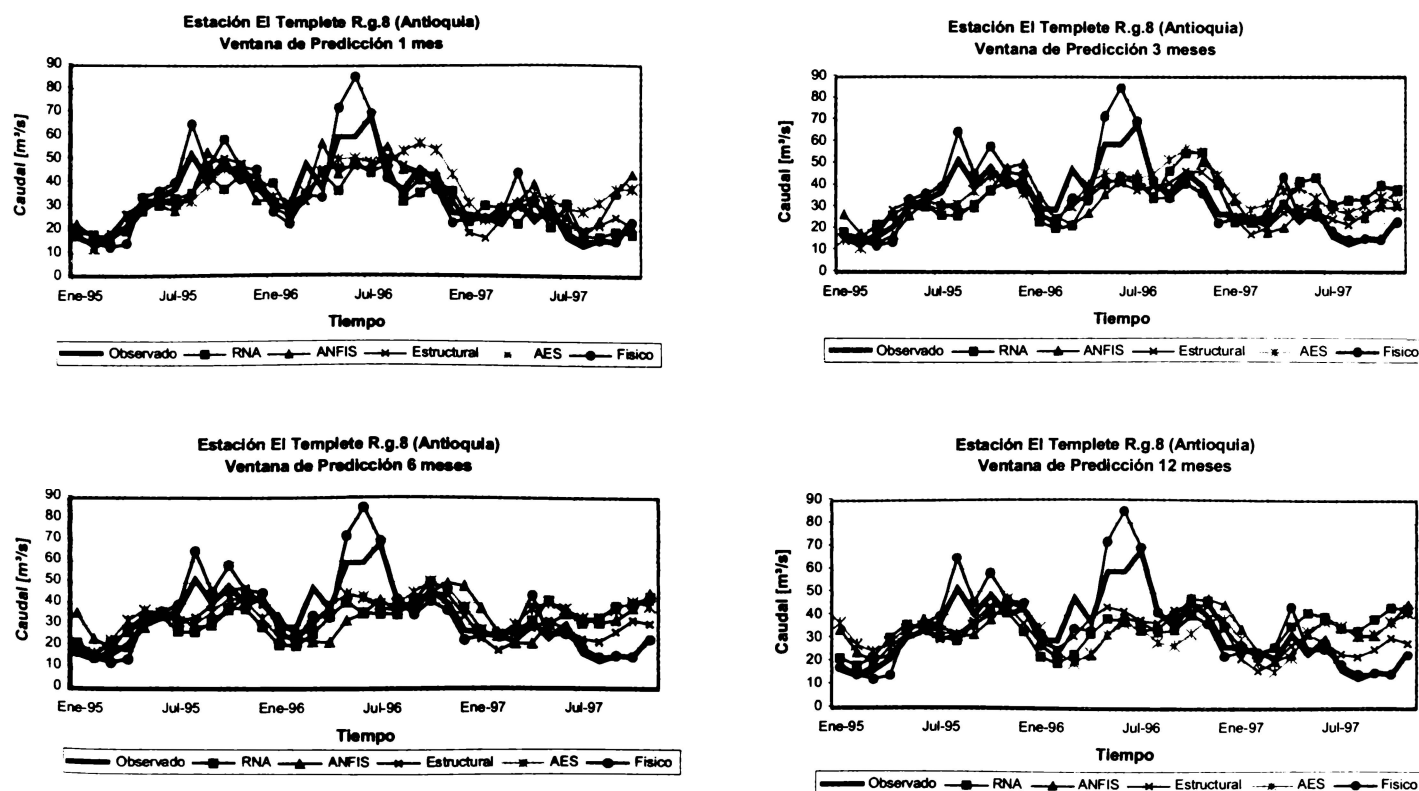
El software fue desarrollado con una metodología orientada a objetos y una arquitectura cliente servidor. Para la implementación de este se utilizó el lenguaje Java, ya que ofrece facilidades tales como la multiplataforma, gran cantidad de herramientas (librerías gráficas, matemáticas, estadísticas, entre otras) que facilitan el trabajo y conectividad con diferentes motores de bases de datos y sitios web. El almacenamiento de la información se llevó a cabo en el motor de base de datos MySQL (<http://www.mysql.org>), que además de ofrecer las posibilidades de consulta de un motor de base de datos relacional, ser robusto y manejar gran cantidad de datos. Ambas plataformas son de dominio público y gratuitas.

Después de analizar los requerimientos de almacenamiento de información se llegó a un primer modelo de la base de datos, presentado en la Figura 5.

TABLA 1. Errores totales para cinco series de caudal medio mensual, por los diferentes métodos empleados.

Serie	Modelo	Error Cuadrático medio (%)			
		1 mes	3 meses	6 meses	12 meses
El Templete Rg.8	RNA	24.6	28.4	29.8	30.1
	ANFIS	21.2	26.1	28.5	29.7
	AES	25.4	24.7	30.5	33.4
	Modelo Estructural	19.6	22.0	22.6	22.7
	Modelo Físico*	17.5	17.5	17.5	17.5
Puente Carretera	RNA	32.5	43.0	41.6	41.7
	ANFIS	25.4	30.8	32.4	33.0
	AES	35.8	40.4	-	40.2
	Modelo Estructural	24.3	28.4	30.3	29.7
	Modelo Físico*	29.6	29.6	29.6	29.6
Angostura de Urrá	RNA	22.6	26.4	27.2	27.4
	ANFIS	22.1	26.1	27.2	27.6
	AES	22.4	23.6	22.9	23.4
	Modelo Estructural	22.3	24.7	24.9	24.8
	Modelo Físico*	30.7	30.7	30.7	30.7
Chusneque	RNA	31.8	33.7	34.0	33.9
	ANFIS	31.8	41.5	41.5	42.2
	AES	34.8	33.2	49.9	-
	Modelo Estructural	30.0	32.8	33.0	33.1
	Modelo Físico*	18.3	18.3	18.3	18.3
Puente Fierro	RNA	28.1	32.2	32.0	31.7
	ANFIS	27.5	39.0	38.8	39.7
	AES	-	31.3	32.9	37.0
	Modelo Estructural	28.1	29.1	29.8	29.6
	Modelo Físico*	27.5	27.5	27.5	27.5

* Es importante tener en cuenta que este resultado es obtenido suponiendo predicción perfecta en la precipitación


FIGURA 4. Resultados Obtenidos con la aplicación de los modelos en la estación Templete R.g. 8 durante el periodo de validación.

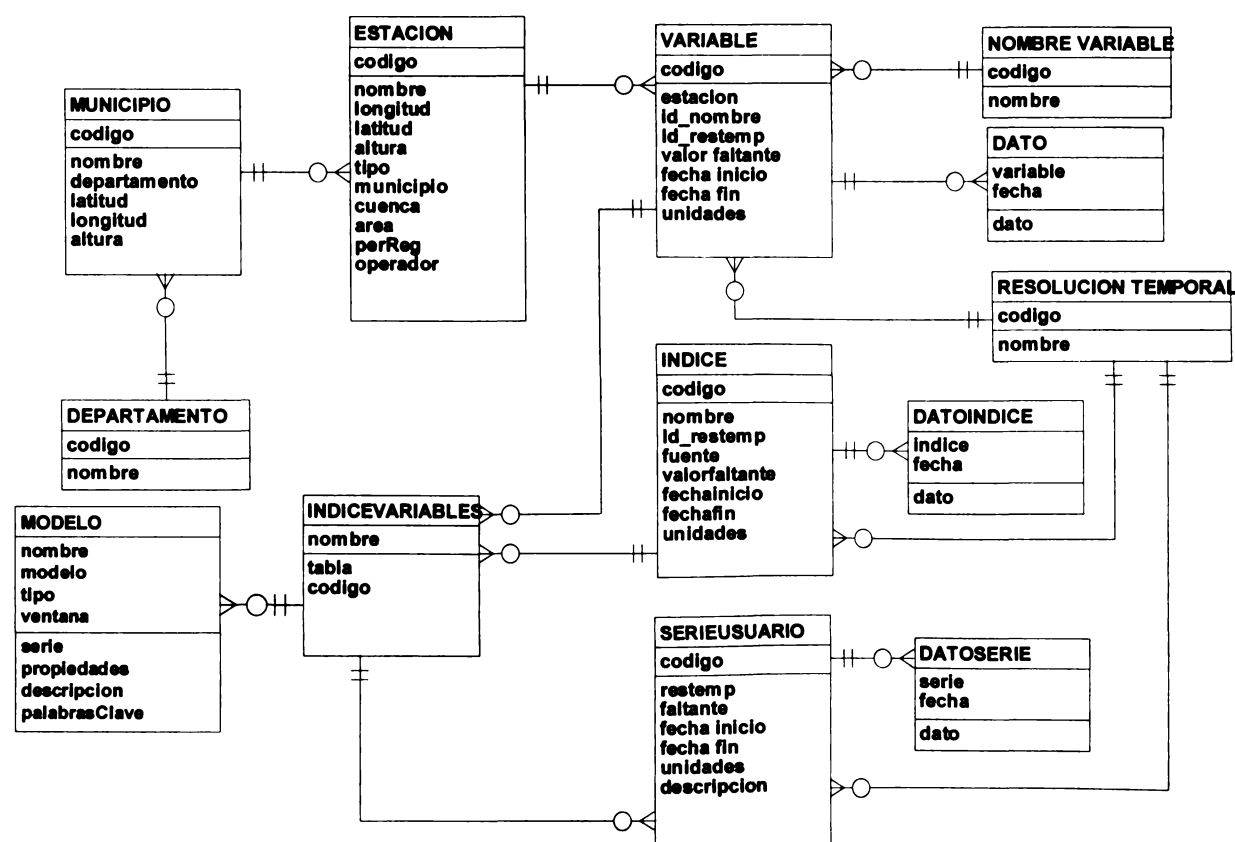


FIGURA 5. Modelo relacional de la base de datos del sistema.

El software fue desarrollado con una interfaz gráfica de múltiples ventanas, donde se podrá configurar y correr cada uno de los modelos descritos anteriormente.

Las herramientas del software son: un módulo para la construcción de nuevas series a partir de operaciones matemáticas y estadísticas de la información almacenada en la base de datos, las cuales también podrán ser almacenadas y consultadas después; un módulo para la visualización de la ubicación espacial de las estaciones hidrológicas que se están usando los sistemas de generación de energía involucrados y otros lugares de interés; un módulo para la visualización de series de tiempo para el cual se utilizaron las librerías de visualización jfreechart (<http://www.jfree.org/jfreechart>), esta interfaz permite la visualización de los datos en diferentes formas como la serie real, los datos estandarizados, el espectro de Fourier, el autocorrelograma y el ciclo anual; un módulo que permite la fácil actualización de las series de caudal y variables macroclimáticas que se encuentran almacenadas en la base de datos; por último y el módulo más importante el

de predicción, el cual permite al usuario del sistema el pronóstico de caudales y de precipitaciones, y visualizar medidas de error de dichas predicciones.

3.2. Funcionamiento

El sistema posee dos grandes herramientas para la predicción, el permite abrir un modelo individual o un grupo de modelos. Para la primera se selecciona un modelo, el cual se caracteriza por tener una serie a predecir, el algoritmo y la ventana de predicción, y el tipo de variables de entrada (si necesita o no predicciones macroclimáticas para realizar el pronóstico). (Ver Figura 6).

Cuando se tiene abierto un modelo, se pueden observar las características principales de éste, así como sus parámetros, cabe resaltar que esta interface cambia dependiendo del modelo de predicción, de sus características y de las variables predictoras, para esta opción se pide al usuario el ingreso de predicciones de variables macroclimáticas de ser necesario, e inmediatamente aparece una ventana mostrando la

predicción realizada, un resumen de los errores del método, y una gráfica que muestra la serie real y la serie que pronostica el modelo (ver Figura 7). Para el ingreso de los valores predichos de las variable macro climáticas,

el usuario tiene la posibilidad de acceder a varias agencias internacionales y tomar los valores de las páginas web de esas agencias.

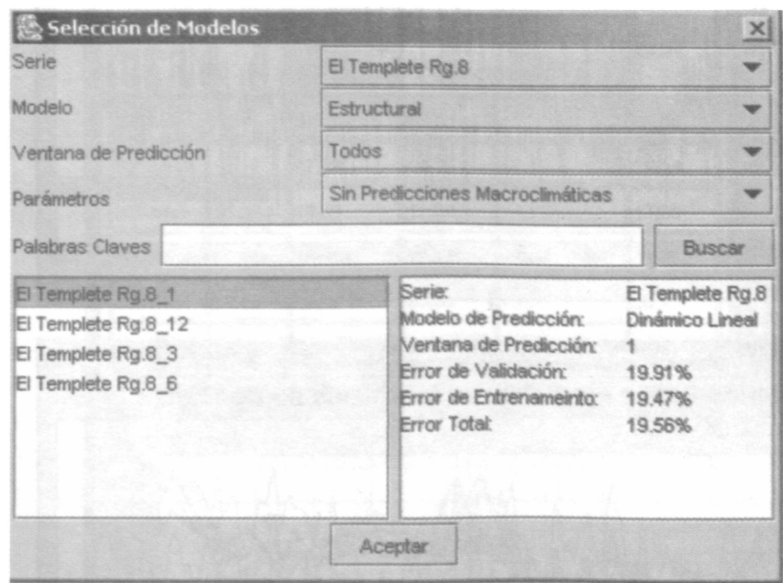


FIGURA 6. Interface para la selección de modelos individuales.

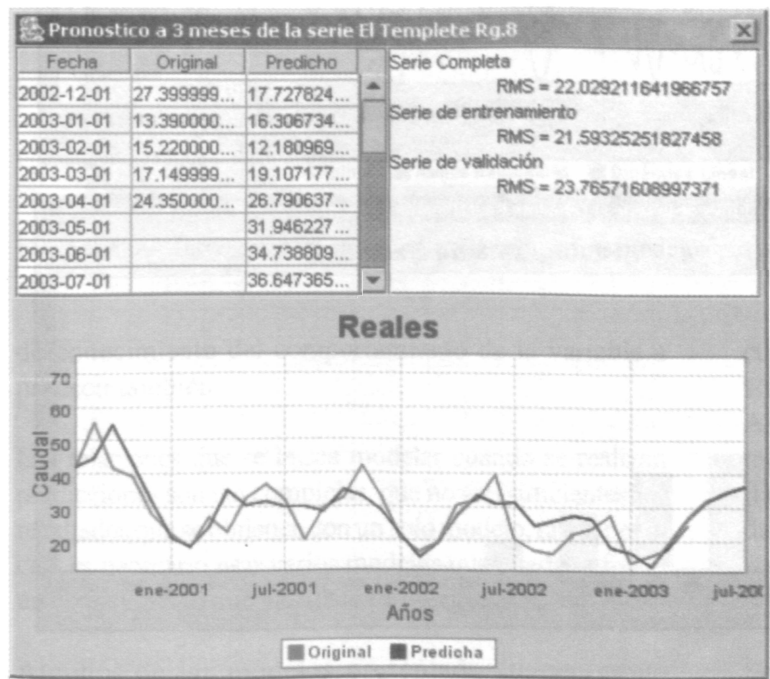


FIGURA 7. Ventana para la visualización de los pronósticos de un modelo para una serie.

El software a partir de la predicción permite observar indicadores de error que le dan al usuario criterios sólidos en cuanto a la credibilidad del modelo de predicción. En la Figura 8 se muestran algunos ejemplos.

Para abrir un grupo de modelos se selecciona una serie para una determinada ventana de predicción y el software despliega una ventana que muestra todos los posibles

modelos existentes, la base de datos para la serie y las ventanas seleccionadas. A medida que el usuario va seleccionando cada uno de estos modelos, el software muestra en una gráfica los resultados de los modelos, y dos tablas resumen. En la primera aparecen los últimos 24 meses de las series, incluyendo los resultados predichos y en otra el error cuadrático medio de cada uno de dichos modelos. Es importante mencionar que a

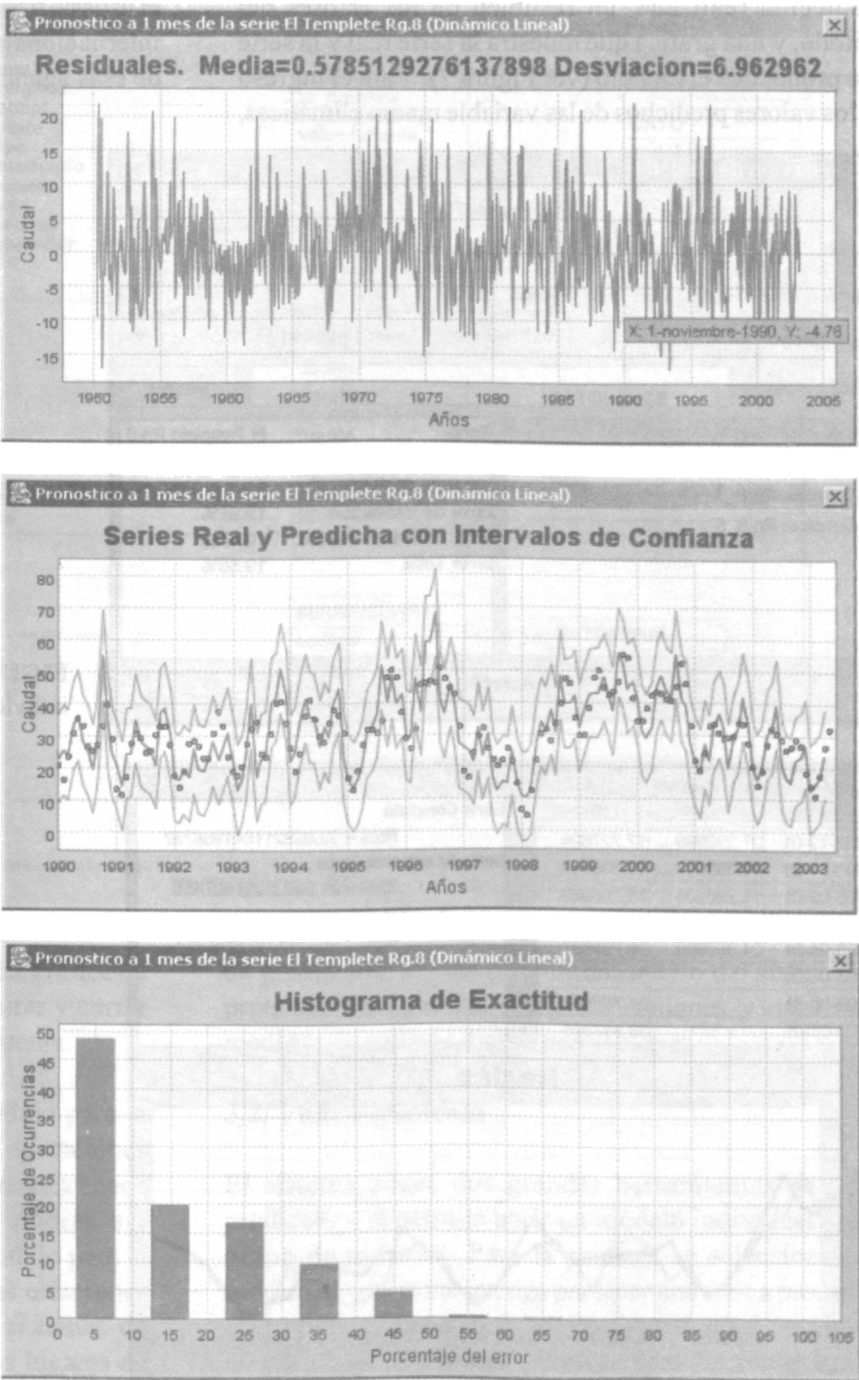


FIGURA 8. Evaluadores de la predicción.

medida que se seleccionan los modelos se va a desplegar la ventana que permite ingresar las predicciones de variables macroclimáticas si la estructura de cada modelo lo exige (ver Figura 9).

4. CONCLUSIONES

La hidrología en Colombia está altamente influenciada por fenómenos macroclimáticos de diferentes escalas,

como lo es el fenómeno de El Niño a nivel de macroescala; esto muestra la necesidad de incluir esas variables a la hora de predecir los caudales.

La predicción de caudales en Colombia es muy difícil y está sujeta a un alto grado de incertidumbre por la alta variabilidad climática. La ventana de predicción es un aspecto importante porque a medida que se amplía el horizonte de predicción, la incertidumbre es mayor y el

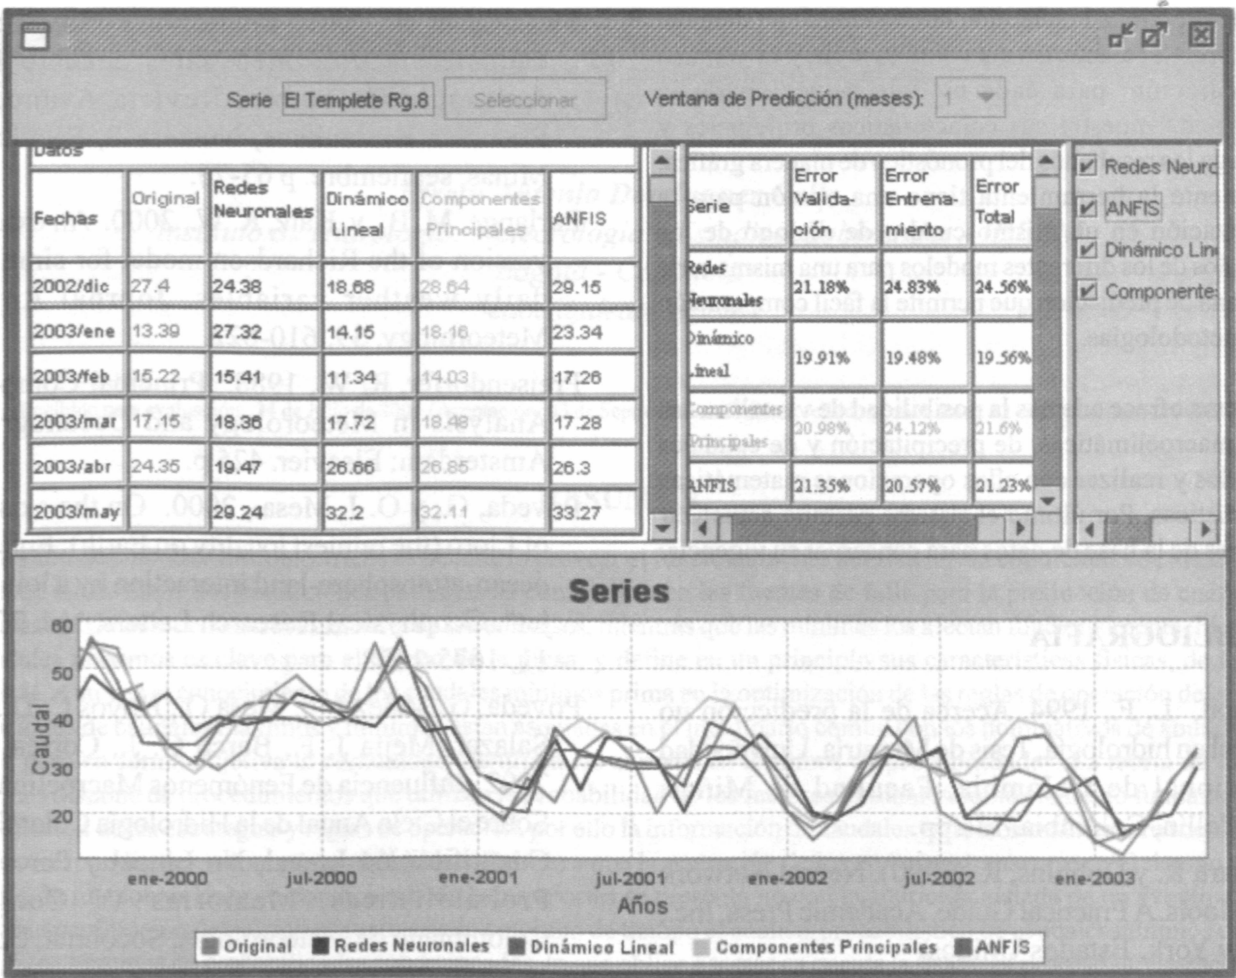


FIGURA 9. Interface para la visualización de varios modelos para la misma serie.

desconocimiento del comportamiento de la variable a predecir también.

Las relaciones que se busca modelar cuando se realizan predicciones son tan complejas, que no son suficientes los resultados que se obtienen con un solo modelo, razón por la cual es necesario usar varios modelos que puedan ofrecer un conocimiento más acertado de lo que está sucediendo.

Algunos de los modelos presentados tienen como fundamento básico la dinámica no lineal tratando de modelar el comportamiento de la naturaleza, la cual no obedece a leyes de tipo lineal; este es el caso de las redes neuronales y de las redes neuro-difusas (ANFIS).

En general los mejores resultados se obtuvieron con los modelos estructural y espectral. El modelo físico también presenta buenos resultados para algunas estaciones en las

cuales se contó con una muy buena información de lluvia.

A la hora de predecir caudales con el modelo físico es muy importante contar con una buena predicción de lluvia, esto lo confirma los resultados obtenidos en las diferentes estaciones, los cuales son aceptables donde se contó con una información suficiente para representar la precipitación en la cuenca.

Se desarrolló un sistema para la predicción de los caudales medios mensuales de los principales ríos del Sector Eléctrico Colombiano. Los modelos obtenidos para cada río con cada una de las metodologías propuestas anteriormente arrojaron resultados que mejoran en promedio un 15% los de los modelos triviales. Estos modelos fueron almacenados en una base de datos conectada con la herramienta desarrollada.

El sistema permite la selección de modelos de predicción, de acuerdo a características como la serie y la ventana de predicción; para cada modelo seleccionado la herramienta muestra sus características principales y despliega los resultados del pronóstico de manera gráfica. Igualmente la herramienta tiene una opción para la visualización en un mismo cuadro de dialogo de los resultados de los diferentes modelos para una misma serie y ventana de predicción que permite la fácil comparación entre metodologías.

El sistema ofrece además la posibilidad de visualizar las series macroclimáticas, de precipitación y de caudales asociados y realizar con ellas operaciones matemáticas y estadísticas. Por último el sistema permite actualizar las series de la base de datos para conservar su vigencia.

5. BIBLIOGRAFIA

- Carvajal, L. F., 1994. Acerca de la predicción no lineal en hidrología. Tesis de Maestría, Universidad Nacional de Colombia, Facultad de Minas, Medellín, Colombia. 136 pp.
- Eberhart, R. y Dobbins, R. (1990). Neural Network PC Tools. A Practical Guide. Academic Press, Inc., New York, Estados Unidos.
- Eppler, B., 1996. Interpretation of neural networks for classification tasks. <http://citeseer.nj.nec.com/903.html>.
- Harvey, A. C., 1989. Forecasting, Structural Time Series and the Kalman Filter, Cambridge University Press, U.K.
- Jang, R., 1993. ANFIS: Adaptive-Neural-Network-Based Fuzzy Inference System, IEEE Transactions on Systems, Man, and Cybernetics.
- Katz, R. W., 1996. Use of conditional stochastic models to generate climate change scenarios. *Climate Change*, 32, 237-255.
- Martín G., 2002. Modelos estructurales en el contexto de las series temporales económicas, Universidad de La Laguna. Tenerife, España.
- Masters, T., 1993. Practical Neural Network Recipes in C++. Academic Press, Inc. San Diego, Estados Unidos.
- Mendel J. M., 1995. Fuzzy Logic Systems for Engineering: A Tutorial, Proceedings of IEEE.
- Mesa O., et al., 2001. Predicción no lineal de los caudales medios mensuales del Río Nare, Antioquia-Colombia. *Revista Avances en Recursos Hidráulicos*, Número 8, Facultad de Minas, septiembre. p 65-76.
- Parlange, M. B., y Katz, R. W., 2000. An extended version of the Richardson model for simulating daily weather variables. *Journal Applied Meteorology*, 39, 610-622.
- Preisendorfer, R. W., 1988. Principal Component Analysis in Meteorology and Oceanography. Amsterdam: Elsevier. 425 p.
- Poveda, G., y O. J. Mesa., 2000. On the existence of Lloró (the rainiest locality on Earth): Enhanced ocean-atmosphere-land interaction by a low-level jet". *Geophysical Research Letters*. Vol. 27, No. 11, 1675-1678.
- Poveda, G., Vélez J. I., Mesa O., Hoyos C. D., L. F. Salazar, Mejía J. F., Barco O. J., Correa P. L., 2002. Influencia de Fenómenos Macroclimáticos Sobre el Ciclo Anual de la Hidrología Colombiana: Cuantificación Lineal, No Lineal y Percentiles Probabilísticas, Memorias VI Congreso Colombiano de Meteorología, Socolmet, Bogota.
- Richardson, C. W., 1981. Stochastic simulation of daily precipitation, temperature, and solar radiation. *Water Resources. Research*, 17, 182-190.
- Ultsch, A., Korus, D., y Wehrmann, A., 1995. Neural networks and their rules classification in marine geology. <http://citeseer.nj.nec.com/ultsch95neural.html>.
- Velásquez, J. M., 2000. El efecto de las tasas de descuento en la distribución óptima del recurso hídrico: casos de estudio: el modelo PD/AS y el MDPODE. *Revista Energética* N° 24. Universidad Nacional de Colombia, diciembre, Medellín, p 79-85.
- Vélez, J. I. 2001. Desarrollo de un Modelo Hidrológico Conceptual y Distribuido Orientado a la Simulación de Crecidas. Tesis Doctoral, Universidad Politécnica de Valencia, Valencia, España.