

# PRONÓSTICO DE CAUDALES DE MEDIANO Y CORTO PLAZO UTILIZANDO RAZONAMIENTO INDUCTIVO FUZZY Y ALGORITMOS EVOLUTIVOS – APLICACIÓN PARA LAS CENTRALES DE EMBALSE Y CENTRALES DE PASADA

**Freddy Anchaluisa**  
**TRANSELECTRIC S.A.**

**Víctor Hugo Hinojosa**  
**Investigación y Desarrollo**

## RESUMEN

Los pronósticos de caudales son de vital importancia cuando se realiza la Planificación de la Operación con horizontes semanal, diario y horario.

En el presente artículo se propone analizar la aplicación de un método de modelación y simulación cualitativa – cuantitativa no lineal (Razonamiento Inductivo Fuzzy) al pronóstico de caudales de mediano y de corto plazo, considerando los factores principales que afectan al pronóstico (incertidumbres) y minimizando los errores de predicción.

Se realiza un análisis con otros métodos de pronóstico para poder determinar con que método se obtienen predicciones más precisas.

**PALABRAS CLAVE:** Pronóstico, Series de Tiempo, Correlación, Razonamiento Inductivo Fuzzy, Algoritmos Evolutivos.

## 1. INTRODUCCIÓN

El 55% de la energía consumida en el año 2006 fue suministrada por centrales hidroeléctricas. Dada la disponibilidad de estos recursos, el sistema eléctrico ecuatoriano debe aprovechar la generación hidroeléctrica para sustituir al máximo la generación termoeléctrica, cuyo costo operativo es muy alto.

La operación de una central hidroeléctrica depende de dos variables principales: el volumen almacenado en el embalse y el caudal afluente a dicho embalse, que es una variable estocástica. Debido a la incertidumbre asociada a los caudales afluentes, es necesaria la adopción de modelos de previsión que simulen de una manera eficiente el comportamiento de la hidrología del sistema.

Las series de caudales tienen un comportamiento estocástico, reflejado en parámetros como la media, desviación estándar, asimetría y estructura de autocorrelación. Dada la importancia de su previsión, gran variedad de modelos han sido propuestos durante las últimas décadas, entre los que se cuentan

los modelos de alisamiento exponencial, modelos de regresión lineal y no lineal, y modelos de series de tiempo (AR, ARIMA, SARIMA, PAR). Estas técnicas se basan en métodos estadísticos y extrapolan el comportamiento de los caudales en el pasado, mientras consideran el efecto de otros factores como el clima y la correlación espacial entre caudales de diferentes centrales; sin embargo, estos modelos emplean un gran número de relaciones complejas y no lineales entre la serie de caudales y dichos factores.

En los últimos años se han desarrollado con resultados satisfactorios, modelos de pronóstico basados en Inteligencia Artificial (Redes Neuronales, Lógica Fuzzy, Algoritmos Genéticos, Razonamiento Inductivo Fuzzy, etc.) y recientemente se ha desarrollado una metodología de pronóstico de demanda (Razonamiento Inductivo Fuzzy y Algoritmos Evolutivos), obteniéndose resultados muy satisfactorios [3].

## 2. PLANIFICACIÓN DE LA OPERACIÓN

El objetivo de la Planificación Operativa Energética es establecer una política óptima de la operación de los embalses y uso eficiente de los recursos disponibles de generación, previa la coordinación de mantenimientos efectuada por el CENACE con los generadores y el transmisor, y minimizando los riesgos de falla en el abastecimiento de energía y de los posibles vertimientos en los embalses; teniendo en cuenta además, la previsión de las demandas y la aleatoriedad de la oferta y los caudales.

En el artículo 24 literal i, de la Ley de Régimen del Sector Eléctrico (LRSE), se define entre las funciones específicas del CENACE el “preparar los programas de operación para los siguientes doce meses, con un detalle de la estrategia de operación de los embalses y de la generación esperada mensualmente de cada central”.

El CENACE elabora la Planificación Operativa Energética de conformidad a lo establecido en la LRSE y en base al artículo 6, capítulo II, del Reglamento de Despacho y Operación del Sistema Nacional Interconectado elaborado por el CONELEC.

Para elaborar esta Planificación se debe seguir la metodología que se establece en los procedimientos de Despacho y Operación.

### 3. DESCRIPCIÓN DEL PROBLEMA

Como sistema de prueba se utilizan las series históricas de caudales del embalse Amaluzá con resolución horaria, diaria y semanal y para el embalse de la Central Hidroeléctrica de Agoyán se utiliza la resolución horaria.

La Base de datos que se utiliza para el embalse Amaluzá esta comprendida en el período desde el 01 de enero de 1984 hasta el 22 de enero de 2007 y para el embalse de la central Agoyán se utiliza el período desde el 01 de enero de 2000 hasta el 31 de diciembre de 2006.

#### 3.1. Estructura del Sistema Multivariable

En la Tabla 1 se indica la estructura del sistema multivariable del problema a plantear para el pronóstico de caudal.

TABLA 1: Sistema Multivariable para el Pronóstico

[A]	[F]
mes (t-n)	Caudal (t-n)
...	...
mes (t-1)	Caudal (t-1)
mes (t)	Caudal (t)

Donde:

- A = Variable tipo de mes (enero, diciembre).
- F = Variable caudal.

### 4. ESTADO DEL ARTE [3]

El razonamiento humano ha sido entendido como un proceso mental de simulación debido a que los humanos somos capaces de tomar decisiones aún sin tener el conocimiento total del fenómeno, sólo reconociendo los patrones pudiendo así analizar el comportamiento del sistema.

#### 4.1. Razonamiento Inductivo Fuzzy

La metodología Fuzzy Inference Reasoning (FIR) es una implementación de la metodología de análisis general de sistemas "General System Problem Solver (GSPS)", que posibilita estudiar los modos conceptuales de comportamiento de sistemas dinámicos.

Fue reimplementada por F. Cellier de la Universidad de Arizona. Mediciones Fuzzy fueron añadidas

a la metodología de modelación para tratar las incertidumbres de los límites, donde también se incluye el tratamiento de valores perdidos y las mediciones para estimar la predicción del error.

En la Figura 1 se muestran las cuatro etapas de la metodología:

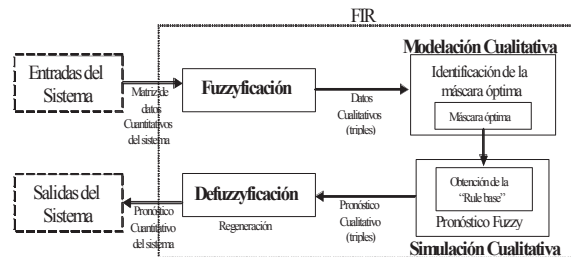


FIGURA 1: Razonamiento Inductivo Fuzzy

Es importante notar que el razonamiento propiamente dicho no involucra las etapas de fuzzyficación y defuzzyficación, pero son esenciales para que la metodología FIR opere en un entorno mixto (cualitativo/cuantitativo) de modelación y simulación.

#### Fuzzyficación (Fuzzy Recoding)

El objetivo es aumentar drásticamente la velocidad de optimización. Si tenemos una relación entre  $n$  entradas y una salida, en lugar de realizar la búsqueda en el espacio continuo  $n$ -dimensional para encontrar el óptimo patrón de entrada/salida, la búsqueda es limitada al espacio discreto  $c$ -dimensional de los valores clase.

Este proceso convierte los datos cuantitativos que describen el comportamiento del sistema a una trayectoria triple cualitativa.

El primer elemento de la variable triple se llama class value (discretización gruesa de los valores originales de la variable), el segundo elemento se llama fuzzy membership value y denota el nivel de confianza expresado en el valor clase elegido para representar un particular valor cualitativo y el tercer elemento se llama side value, el cual indica si el valor cuantitativo está a la derecha o a la izquierda del valor pico de la función de membresía fuzzy asociada.

El valor del flanco que es particular de la metodología FIR (no es comúnmente utilizado en la lógica fuzzy), es responsable de preservar el completo conocimiento del valor original cuantitativo.

## i) Tipo de Mes

Esta variable se la fuzzyfica en tres clases (enero a marzo, abril a agosto, y septiembre a diciembre). La fuzzyficación se indica en la Tabla 2 [2].

TABLA 2: Fuzzyficación de la Variable Tipo de Mes

[A]	CODIFICACIÓN	MEMBRESÍA	FLANCO
Enero	1	1	0
Febrero	1	1	0
Marzo	1	1	0
Abril	2	1	0
Mayo	2	1	0
Junio	2	1	0
Julio	2	1	0
Agosto	2	1	0
Septiembre	3	1	0
Octubre	3	1	0
Noviembre	3	1	0
Diciembre	3	1	0

## ii) Caudal

Para modelar, por ejemplo, el caudal semanal del embalse Amaluzá se realiza una división de clases utilizando el algoritmo de Clustering Fuzzy c-means [1].

El cálculo de los límites de cada clase se muestra en la Figura 2.

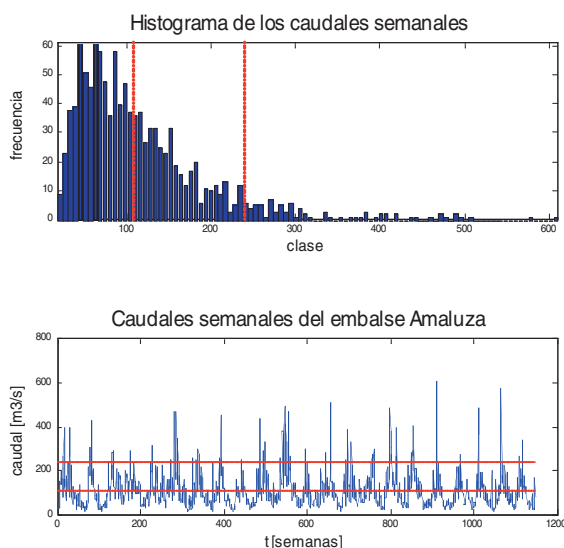


FIGURA 2: Cálculo de los Límites de Cada Clase Utilizando el Algoritmo Fuzzy c-Means

## Modelación Cualitativa (Qualitative Modeling)

La modelación cualitativa tiene como objetivo identificar los patrones (espaciales y temporales) en el tiempo, mediante la determinación del grupo de variables de entrada (máscara de correlación) que mejor explican el comportamiento entrada – salida. El número de filas de la máscara es conocida como la profundidad y está directamente relacionada con la observación histórica del sistema.

Una relación cualitativa para el pronóstico horario de caudal que incluya las variables “tipo de mes”, y “caudal”, podría estar dada por la ecuación (1), que relaciona el pronóstico del caudal en  $(t)$  con el tipo de mes en  $(t-4)$ , y el caudal histórico en 1, 2, 3, 8, 13 y 15 horas anteriores a  $(t)$ .

$$F_{(t)} = \tilde{f}(A_{(t-4)}, F_{(t-15)}, F_{(t-13)}, F_{(t-8)}, F_{(t-3)}, F_{(t-2)}, F_{(t-1)}) \quad (1)$$

Donde:

$\tilde{f}$  = Es un funcional que denota una relación cualitativa genérica (patrón de entrada-salida) de las variables de entrada.

Esta relación es conocida como máscara de correlación. La función de la máscara es seleccionar las  $m$ -entradas y la salida en cada matriz de clase, membresía y flanco, y transformar dichos valores en patrones estáticos de entrada – salida (estados del sistema). Desplazando la máscara de correlación sobre las matrices de clase, membresía y flanco, se obtienen distintos estados del sistema explicativos del comportamiento del mismo en el tiempo. El conjunto de estados del sistema es conocido como “Matriz de Comportamiento” o “Rule Base” (base de conocimiento).

## Búsqueda de la Máscara Óptima

- En la metodología FIR definida por Cellier, las matrices candidatas a máscara óptima son un conjunto de máscaras posibles, de las cuales la mejor es elegida por un mecanismo de búsqueda exhaustiva (Problema Combinatorial). La Entropía de Shannon, se utiliza para determinar la incertidumbre asociada al patrón de entrada – salida.
- En investigaciones anteriores se resolvió con total éxito un problema de optimización para encontrar la máscara de correlación que tienen un mejor comportamiento comparadas con las máscaras encontradas por la metodología FIR tradicional, utilizando Algoritmos Evolutivos (Simulated

Rebounding Algorithm) para determinar las entradas de la máscara de correlación como se explica más adelante.

### **Simulación Cualitativa (Qualitative Simulation)**

El objetivo de esta etapa es analizar y aprender patrones observados en la máscara de correlación con el fin de predecir el comportamiento futuro en base a los datos históricos.

El pronóstico opera en dos etapas:

- 1) Etapa determinística: el patrón de entrada para el pronóstico es extraído de la matriz de valores clase por medio de la máscara y es comparado con todos los patrones análogos de la matriz de comportamiento del sistema (datos históricos). Para todos aquellos patrones que coinciden con el patrón de entrada, se observan los valores clase de salida.
- 2) Etapa estadística: se realiza la predicción del valor más probable de salida, a partir de las observaciones anteriores, mediante un promedio ponderado de los valores más próximos en la base de datos de entrenamiento. En esta etapa se utiliza la regla 4-NN (4 más cercanos vecinos).

### **Defuzzyficación (Regeneration)**

Las predicciones de los valores de membresía, flanco y código de clase de la salida pronosticada son convertidas a predicciones cuantitativas usando la operación inversa a la fuzzyficación.

#### **4.2. Algoritmos Evolutivos – SRA**

Para encontrar las entradas al modelo de pronóstico se consideró la aplicación del algoritmo Simulated Rebounding Algorithm (SRA), que pertenece a la clase de algoritmos estocásticos (randomization algorithms) basados en búsqueda local aleatoria controlada (como lo es, entre otros, el Simulated Annealing).

El SRA ha sido contrastado en Investigaciones anteriores con el Simulated Annealing y algunas implementaciones de Algoritmos Genéticos en problemas de optimización con similares características y debido a la alta performance del mismo es que se eligió como motor de optimización del desarrollo aquí planteado.

### **La Simulación del Proceso Físico de Rebotes Simulados**

Suponiendo que se lanza una pelota con coeficiente de elasticidad cercano a 1 sobre una superficie  $S$ , la pelota caerá sobre la superficie debido a la acción del campo gravitatorio en el cual esta inmersa. El choque producido por la caída podrá afectar a la energía cinética de la pelota si parte de esta energía es disipada en deformaciones permanentes (choque inelástico). Estas deformaciones serán proporcionales a la energía cinética del choque, siendo esta la equivalente a la diferencia de energía potencial desde el punto de choque hasta la altura desde la cual cae la pelota. Si el proceso no es detenido, los rebotes se detendrán cuando la energía cinética de la pelota sea cero.

En este proceso de rebotes inelásticos, la pelota choca con distintos puntos de la superficie, desviada por los mismos rebotes sobre una superficie no plana. Si la superficie posee “valles” y “lomas”, los puntos pertenecientes a un valle tendrán menor energía potencial que las lomas. Por la acción de la gravedad, la pelota buscará detenerse sobre algún valle, y dependiendo de la energía cinética que posea, será capaz de saltar montes para explorar nuevos valles.

La analogía con un problema de optimización combinatorial se realiza haciendo una equivalencia entre la superficie de rebotes y el espacio de soluciones, y entre la altura de cada punto de la superficie y el valor de la función de costo correspondiente a esa solución. El SRA resulta así una extrapolación multidimensional del proceso físico de rebotes.

Debido a la acción de la gravedad y a la pérdida gradual de energía cinética y potencial debido a las colisiones, al final del proceso de rebotes simulados, la pelota se detiene sobre el mínimo global (punto de menor altura de la superficie) o sobre algún mínimo local cercano al global.

La Figura 3 muestra por simplicidad un ejemplo unidimensional: como se muestra con las líneas de trayectoria, la pelota puede alcanzar el mínimo global (escalón 11) si es lanzada desde el punto A o C; sin embargo, es atrapada en el mínimo local del escalón 14 si la pelota es lanzada desde el punto B. Es decir, el mínimo global es alcanzado si la energía potencial inicial ( $E_0$ ), y el porcentaje de pérdida de energía debido a colisiones inelásticas ( $\alpha$ ) permiten saltar todos los mínimos locales durante el proceso de rebotes.




FIGURA 3: Ejemplo Unidimensional de Rebotes Simulados

En el SRA las deformaciones producidas por las colisiones pueden ser de tres tipos:

- Deformación transitoria**, es decir, que la pelota no pierde energía cinética por ser la altura de la caída pequeña.
- Deformación leve**, cuando la pelota rebota sobre las paredes de un valle por ser su energía potencial menor que la altura del punto de destino, disminuyendo su energía potencial en un valor pequeño.
- Deformación permanente**, cuando la pelota pierde energía cinética debido a una colisión provocada por una altura considerable de caída.

Estos tipos de deformación actúan en el proceso de optimización de diferente manera. La deformación transitoria es la que permite explorar el espacio de búsqueda. Si sólo existiera este tipo de deformaciones, el proceso no se detendría nunca, si no fuera por la pérdida de energía provocada por fricción y rozamiento. La deformación leve disminuye la energía de la pelota cuando es atrapada en un valle, y provoca la detención del proceso si no existe ninguna solución con energía potencial menor que la de la pelota (valle profundo). La deformación permanente acelera la convergencia hacia el óptimo, ya que disminuye la energía potencial de la pelota cuando ésta es muy superior a la de la superficie en el entorno de rebotes.

#### Aplicación del SRA al Pronóstico de Caudal

La profundidad de la máscara de correlación óptima encontrada para el pronóstico de caudal con horizonte semanal fue de 9 (se realizaron pruebas, considerando profundidades de 5, 13, 17 y 53). De los 18 elementos de esta matriz (mes y caudal), 17 son datos factibles ( $m\_inputs$ ) y el elemento (9,2) que es el valor de

caudal a pronosticar en el instante  $t$  – es el resultado (output).

Si se analiza la configuración de entradas de dimensión 7 correspondiente a 1 variable para tipo de mes y 6 entradas para la variable caudal, el problema de optimización debe formularse de la siguiente manera:

$$\text{Minimizar} = \text{Error\_Pronóstico} (a_1, f_1, f_2, f_3, f_4, f_5, f_6)$$

$$\text{T.q.} = 1 \leq a_1 \leq 9, 1 \leq f_1, f_2, f_3, f_4, f_5, f_6 \leq 8 \ \& \ f_m \neq f_j; \\ m=1, \dots, 6 \ \& \ j \neq m$$

Donde:

$a_1$  = Elemento de la variable tipo de mes.

$f_1, \dots, f_6$  = Variable caudal.

#### Función Objetivo o de Evaluación

El método de entrenamiento que se propone aplicar en este trabajo es el "Aprendizaje Supervisado".

Si se analiza por ejemplo el pronóstico de caudal semanal se ha utilizado como valor de referencia los datos semanales de caudal de las últimas 8<sup>1</sup> semanas de entrenamiento según lo expresa la ecuación (2).

Para encontrar la configuración  $v^*$ , tal que esta configuración minimice la sumatoria de los errores obtenidos en las últimas 8 semanas de entrenamiento, se utiliza -para el cálculo del error- el pronóstico de caudal para 1 semana en adelante y el caudal real histórico para dicha semana.

$$E_{(t)} = \frac{\sum_{i=1}^8 \left( \frac{|\hat{Q}_{t-i} - Q_{real,t-i}|}{Q_{real,t-i}} \right)}{8} * 100 \quad (2)$$

Donde:

$\hat{Q}_{t-i}$  = Es el PQCP para la semana  $t$ .

$Q_{real,t}$  = Es el caudal histórico real en la semana  $t$ .

Para el caso del pronóstico de caudal semanal se utiliza la ecuación (2), para encontrar las entradas del modelo de pronóstico.

<sup>1</sup> Se encontró como óptimo utilizar 8 semanas como período de entrenamiento. Se probaron 4, 12, 14 y 52 semanas.

## 5. RESULTADOS DE LAS SIMULACIONES

Una vez que se realiza la Planificación semanal de la Operación en base al pronóstico de caudal semanal (PQMP), se podría tomar medidas correctivas a esta Planificación considerando que se puede realizar una actualización del caudal a través del pronóstico de caudal a corto plazo (PQCP, su horizonte es de uno a varios días en adelante).

Finalmente, con el pronóstico de caudal de muy corto plazo (PQMCP), su horizonte es de una a varias horas en adelante, se tendría la posibilidad de reajustar la programación de la central hidroeléctrica, esto debido al aumento/disminución del caudal considerado en la programación de la operación.

### 5.1. Pronóstico de Caudal para el Embalse Amaluz

#### PQMCP Utilizando Resolución Horaria

**Número de evaluaciones a ser evaluadas por el SRA:** en la Tabla 3, se detalla el espacio de soluciones totales de la máscara de correlación planteada, variando la cantidad de entradas para la variable caudal entre 1 y 8 y se ha supuesto que existe una entrada para la variable tipo de mes. Para el análisis se ha considerado profundidades de máscaras de 25, 49 y 73.

TABLA 3: Espacio de Soluciones para Diferentes Profundidades

v	depth=25	depth=49	depth=73
v <sub>2</sub>	600	2 352	5 256
v <sub>3</sub>	6 900	55 272	18 6588
v <sub>4</sub>	50 600	847 504	4 353 720
v <sub>5</sub>	265 650	9 534 420	75 101 670
v <sub>6</sub>	1 062 600	83 902 896	1 021 382 712
v <sub>7</sub>	3 364 900	601 304 088	11 405 440 284
v <sub>8</sub>	8 652 600	3 607 824 528	107 537 008 392
v <sub>9</sub>	18 386 775	18 490 100 706	873 738 193 185

Para este caso se va a utilizar las series temporales de caudal horario del embalse Amaluz y se elige el período de test desde las 11:00 del 01 de diciembre hasta las 24:00 del 02 de diciembre de 2006. En la Figura 4 se indica las series de caudal real y pronosticado y se incluye, para la configuración óptima, el error relativo horario (error relativo promedio para las 38 horas = 5,75%).




FIGURA 4: PQMCP del Embalse Amaluz

#### PQCP Utilizando Resolución Diaria

Se procede a evaluar el performance de la Metodología FIR & SRA utilizando las series temporales de caudal diario del embalse Amaluz y se elige el período de test desde el 01 abril hasta el 07 de abril de 2006. En la Figura 5 se indica las series de caudal real y pronosticado y se incluye el error relativo diario (error promedio de los 7 días 16,08%).




FIGURA 5: PQCP del Embalse Amaluz

Se puede observar en la gráfica como la Metodología FIR & SRA trata de adaptarse a los cambios del caudal. En algunos puntos el error es mínimo acercándose al valor real.

#### PQMP Utilizando Resolución Semanal

Para analizar la performance de la Metodología FIR & SRA y compararla con los Modelos Económicos de Box – Jenkins, se analiza el período comprendido desde la semana del 07 de diciembre hasta la semana del 28 de diciembre de 2006 – 4 semanas. En la Dirección de Planeamiento del CENACE el error relativo promedio para el PQMP del período de test analizado, utilizando Modelos ARIMA, fue de 34,29%, mientras que el error obtenido con la metodología FIR & SRA fue del 10,66%, obteniéndose una reducción de 68,92%.

Se procede a simular otros períodos de tiempo para determinar la eficiencia de la Metodología de pronóstico. El segundo período de test utilizado está comprendido desde la semana del 06 de julio hasta el 27 de julio de 2006 y como tercer período de test, se toma los datos desde la semana del 06 de abril hasta la semana del 27 de abril de 2006. En la Tabla 4 se detalla los errores relativos de cada una de las Metodologías, para los 3 períodos de test analizados.

TABLA 4: Resultados del PQMP del Embalse Amaluza

Período	Real	ARIMA	FIR & SRA	E.ARIMA	E.FIR & SRA
Diciembre	85,5	65,1	78,1	34,2	8,7
	59,6	85,1	72,7	42,9	22,1
	91,0	60,5	91,3	33,5	0,3
	90,0	66,1	100,4	26,6	11,5
Julio	82,4	172,9	105,8	109,8	28,4
	132,6	121,3	206,7	8,5	55,9
	65,7	158,8	76,5	141,7	16,4
	77,4	93,8	142,1	21,2	83,6
Abril	192,0	107,6	95,1	44,0	50,5
	79,4	162,6	71,7	104,8	9,7
	101,6	141,3	96,6	39,1	4,9
	205,1	136,4	127,5	33,5	37,8

El error relativo promedio de las 12 semanas de test, utilizando los pronósticos realizados por la Dirección de Planeamiento, fue de 53,31%, mientras que si el pronóstico se hubiera realizado con la Metodología FIR & SRA, el error relativo promedio sería de 27,49%. La nueva Metodología de Inteligencia Artificial logra una reducción del error del 48,43%. En la Figura 6 se indica los caudales semanales reales y pronosticados para las 12 semanas de test simuladas.

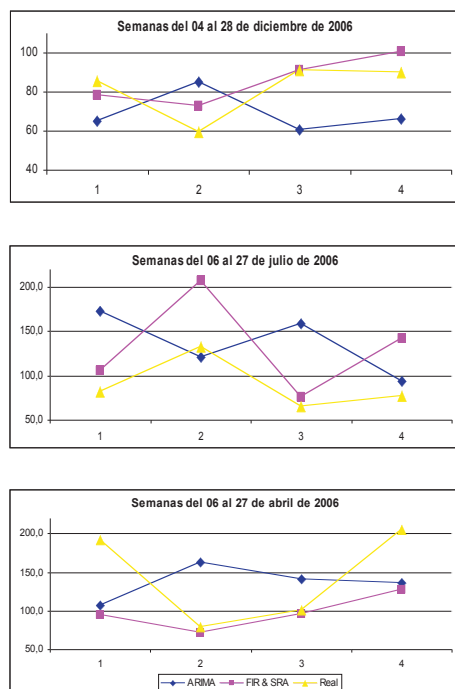


FIGURA 6: PQMP del Embalse Amaluza

## 5.2. Pronóstico de Caudal para el Embalse de la Central Agoyán

### PQMCP Utilizando Resolución Horaria

En forma similar, al del embalse Amaluza de la Central Paute, se procede a evaluar el performance de la Metodología FIR & SRA utilizando las series temporales de caudal horario del embalse de la Central Agoyán. Se elige como período de test, el período comprendido desde las 11:00 del 30 de diciembre hasta las 24:00 del 31 de diciembre de 2005. En la Figura 7 se indica las series de caudal real y pronosticado y se incluye el error relativo horario para la configuración óptima (error relativo promedio para las 38 horas = 5,34%).

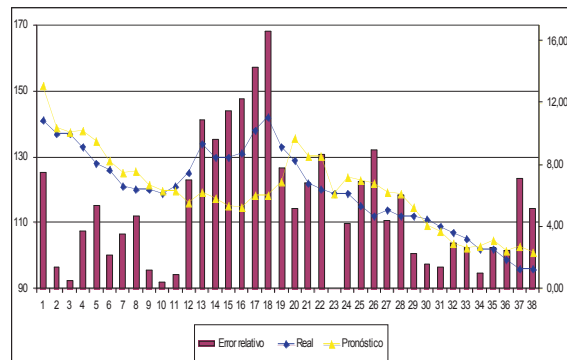


FIGURA 7: PQMCP del Embalse de la Central Agoyán

## 6. CONCLUSIONES

- CENACE utiliza un Modelo Econométrico (ARIMA) para el pronóstico de caudales de Paute, el cual es un método de pronóstico lineal. El pronóstico de caudales se considera como una función no lineal, por lo que se necesita de una modelación no lineal como la utilizada en este desarrollo. Además, con el Modelo ARIMA se tiene una modelación univariable y no se considera variables exógenas que pueden ayudar a explicar la varianza del pronóstico.
- Esta modelación Cualitativa – Cuantitativa tiene la ventaja de poder incluir n variables explicativas sin ninguna modelación compleja, debido a las ventajas multivariables que presenta el Razonamiento Inductivo Fuzzy (FIR).
- Esta Metodología de Pronóstico con resolución horaria podrá ser utilizado por los Agentes Hidráulicos del Mercado Eléctrico Mayorista que se encuentren interesados

en realizar la Programación de la Operación del Mercado ecuatoriano, y poder prever con algunos períodos de tiempo de antelación (38 horas) la evolución del caudal de ingreso a sus centrales. Esta metodología tiene como principal ventaja, la de poder utilizar información real de los últimos períodos de la serie histórica y poder así estimar el comportamiento del caudal en base de las últimas observaciones, disminuyendo así las desviaciones del caudal pronosticado con respecto al caudal real.

- Se ha demostrado que para encontrar las entradas del modelo de pronóstico no basta utilizar las metodologías tradicionales para selección de entradas y que están basadas en series temporales (función de autocorrelación y función de autocorrelación parcial) o la Entropía de Shannon utilizada por la Metodología FIR propuesta por Cellier. La selección tradicional de entradas, basada en series temporales, se basa en la correlación lineal clásica y debido a que el pronóstico de caudal es un problema no lineal no es suficiente esta selección autoregresiva de entradas para decidir que variables influyen sobre el caudal, por lo tanto, es necesario utilizar alguna herramienta de correlación no lineal o simplemente como se ha hecho en este trabajo no presuponer ninguna correlación.
- Tanto los modelos como los algoritmos desarrollados han sido validados exhaustivamente, con datos provenientes de caudales de 2 Centrales Hidroeléctricas (Paute y Agoyán) del SSEE del Ecuador.

## 7. BIBLIOGRAFÍA

- [1] BEZDEK J. C.; Fuzzy Mathematics in Pattern Classification, Tesis doctoral, Centro de Matemáticas Aplicadas, Universidad de Cornell, 1973.
- [2] HINOJOSA V.; Pronóstico de Caudales de Muy Corto Plazo del Embalse Amaluza de la Central Hidroeléctrica Paute Utilizando Inteligencia Artificial, XXII Seminario del Sector Eléctrico ecuatoriano - ECUACIER, Quito 2007.

- [3] HINOJOSA V.; Pronóstico de Demanda de Corto Plazo en Sistemas de Suministro de Energía Eléctrica Utilizando Inteligencia Artificial, Tesis de doctorado, Instituto de Energía Eléctrica de la Universidad Nacional de San Juan, Argentina, 2007.



**Freddy Anchaluiza Limaico.-**  
Nació en Quito, Ecuador en 1977. Recibió su título de Ingeniero en Electrónica y Control en la Escuela Politécnica Nacional en el 2004.

Desde febrero 2005 hasta julio 2006 se desempeñó como Supervisor en el Departamento de Mantenimiento Eléctrico en la Central Hidroeléctrica de Agoyán.

En el período de febrero 2005 hasta febrero 2007 realizó estudios de Maestría de Ingeniería Eléctrica en la Escuela Politécnica Nacional. Actualmente, se desempeña como Ingeniero de diseño en la División de Subestaciones en el Área de Ingeniería y Construcción de TRANSELECTRIC.



**Víctor Hinojosa Mateus.-**  
Nació en Quito, Ecuador en 1975. Recibió su título de Ingeniero Eléctrico en la Escuela Politécnica Nacional en el 2000. Desde enero del 2000 hasta julio del 2001 se desempeñó como Ingeniero de Operación y Transmisión en el CENACE.

En el período agosto 2001 a julio 2005 realizó estudios de doctorado en el Instituto de Energía Eléctrica de la Universidad Nacional de San Juan en la República Argentina, a través de una beca otorgada por el Servicio Alemán de Intercambio Académico (DAAD). Actualmente, se desempeña como Investigador en el Área de Investigación y Desarrollo del CENACE y es profesor en la EPN. Sus principales áreas de interés están enmarcadas en la Operación y Planificación de Sistemas Eléctricos de Potencia utilizando Técnicas de Inteligencia Artificial.