

Pronóstico de Caudales Afluentes para la Planificación de la Operación de Sistemas Hidrotérmicos de Potencia aplicando el modelo ANFIS

Andrés A. Zúñiga ⁽¹⁾ Douglas M. Aguirre ⁽²⁾
Facultad de Ingeniería en Electricidad y Computación
Escuela Superior Politécnica del Litoral (ESPOL)
Campus Gustavo Galindo, Km 30.5 vía Perimetral
Apartado 09-01-5863. Guayaquil-Ecuador
azuniga@espol.edu.ec ⁽¹⁾, daguirr@espol.edu.ec ⁽²⁾

Resumen

Este trabajo presenta el pronóstico de caudales medios mensuales afluentes a dos centrales hidroeléctricas en el Ecuador (Daule – Peripa y Paute – Molino), utilizando uno de los más populares modelos de Redes Neuro-Fuzzy denominado ANFIS (Adaptive-Network-Based Fuzzy Inference System). El desempeño de ANFIS fue comparado con el pronóstico obtenido mediante la aplicación de un modelo de series de tiempo Periódico Autoregresivo de Medias Móviles PARMA y con caudales reales de un período de 5 años (2009 – 2013), mediante la aplicación de métricas de error usadas frecuentemente en pronósticos con técnicas de redes neurofuzzy. Los resultados obtenidos con el modelo ANFIS fueron superiores en todas las métricas de error consideradas; este tipo de resultados es de gran importancia para el sector eléctrico pues un buen pronóstico de caudales afluentes mensuales garantiza que la planificación de la operación de las centrales hidroeléctricas se haga de manera óptima.

Adicionalmente se presenta la aplicación de ambos modelos de pronóstico para evaluar su influencia en los modelos de planificación de la operación de un sistema hidrotérmico de prueba.

Palabras Claves: *Pronóstico de caudales, sistemas hidrotérmicos de potencia, sistemas neuro-fuzzy, ANFIS, soft computing.*

Abstract

This work presents an average mean streamflow forecasting of two important Ecuador's hydroelectric power plants: Daule-Peripa and Paute-Molino, using a popular neuro-fuzzy system called as ANFIS (Adaptive-Network-Based Fuzzy Inference System). The ANFIS's performance was compared with forecasts applying a stochastic time series model called PARMA (Periodic Auto-regressive Mean Average) and compared with real streamflow data from 5 years (2009 – 2013), by application of frequently used error metrics. Results obtained with ANFIS presents better performance than other method considering the error metrics applied; this kind of results is very important for the electricity authority because a good streamflow forecast grants that the hydrothermal operation planning be made as optimal results.

To evaluate the streamflow forecasting influence in the operation planning of hydrothermal power system, ANFIS results was applied in a hydroelectric test system.

Keywords: *Streamflow forecasting, ANFIS, hydrothermal power systems, neuro-fuzzy systems, soft computing.*

1. Introducción

El Ecuador es un país con una considerable capacidad de generación hidroeléctrica (el 53.16% de la energía bruta disponible en el año 2012 fue suministrada por centrales hidroeléctricas [3]) y existe un gran potencial hidroeléctrico aprovechable aún no explotado y que se encuentra en pleno desarrollo.

Dada la disponibilidad de estos recursos, el sistema eléctrico ecuatoriano debe planificarse considerando un óptimo aprovechamiento de la generación hidroeléctrica para sustituir al máximo la generación termoeléctrica, cuyo costo operativo es muy alto. En

la planificación de la operación de un sistema hidroeléctrico, el principal fenómeno hidrológico a considerarse corresponde al ingreso de caudales de los ríos afluentes al embalse de las centrales hidroeléctricas. Siendo la hidrología un proceso estacional, las series mensuales de caudales se pueden representar por modelos estocásticos capaces de generar series sintéticas de dichos caudales, considerando los parámetros característicos extraídos a partir de los datos de la serie histórica.

Los modelos de series de tiempo y de regresión lineal son ampliamente utilizados en el sector eléctrico ecuatoriano [8, 13], aplicándose

específicamente un modelo econométrico ARIMA que “considera una modelación univariable y no contempla el uso de variables exógenas que pueden ayudar a explicar la varianza del pronóstico” [13]; las limitaciones de estos modelos motivan el desarrollo y aplicación de nuevas metodologías para la previsión que representen, de manera más exacta, las variaciones estacionales de la serie de caudales afluentes. Frente a estas limitaciones, los modelos basados en técnicas del soft computing han tomado gran acogida en las últimas décadas en la solución de problemas como el pronóstico de series de tiempo.

Para el desarrollo de este proyecto se utilizó la metodología propuesta por Jyh-Shing Roger Jang, denominada ANFIS (Adaptive-Neuro-Based Fuzzy Inference System) [14, 17, 18, 20, 21, 23], y que corresponde a la representación de las reglas de un sistema de inferencia Fuzzy (modelo tipo Takagi-Sugeno) a través de una estructura de red adaptable, la cual es entrenada mediante un algoritmo de aprendizaje híbrido.

En las siguientes secciones se presentará un resumen de las redes neuro-fuzzy (sección 2), la arquitectura del modelo ANFIS (sección 3), el algoritmo de aprendizaje ANFIS (sección 4), la aplicación del modelo ANFIS (sección 5), y la aplicación del modelo en .

2. Descripción general del modelo ANFIS

La teoría de los conjuntos difusos nació como una alternativa para representar computacionalmente información con un alto grado de incertidumbre, intentando emular el proceso del pensamiento humano donde su razonamiento no se basa en valores numéricos sino en etiquetas lingüísticas; por ello se indica que la lógica fuzzy intenta captar el conocimiento y los mecanismos de razonamiento humanos [35]; dentro de este contexto fue creada la teoría de la lógica fuzzy.

La lógica fuzzy permite construir mecanismos de inferencia (razonamiento) basados en la teoría de conjuntos fuzzy, similar a la inferencia considerando lógica booleana. Un sistema de inferencia fuzzy está constituido por un conjunto de reglas de tipo (SI x_1 es F_1^l Y x_2 es F_2^l Y \dots x_n es F_n^l) ENTONCES (y es g^l), donde F_i^l corresponde a un conjunto fuzzy. Existen diferentes mecanismos de inferencia, entre los cuales se destacan el tipo TSUKAMOTO, MAMDANI y el TAKAGI-SUGENO [14].

El modelo ANFIS se constituye en la representación de un sistema de inferencia TAKAGI-SUGENO [39] empleando la arquitectura paralela de una red adaptable, que es un tipo especial de red neuronal [14]; este tipo de sistemas se conoce como *sistemas híbridos neuro-fuzzy*. El objetivo de esta representación es emplear los paradigmas de aprendizaje empleados por las redes neuronales

artificiales para el ajuste de sus parámetros. Los modelos híbridos neuro-fuzzy han sido empleados con mucho éxito en problemas de identificación de sistemas, clasificación, aproximación de funciones y pronóstico,

3. Arquitectura del modelo ANFIS

Supóngase que se tiene un sistema de inferencia tipo Takagi-Sugeno con 2 variables de entrada (x e y) y dos reglas fuzzy (ver figura 1) [14]:

$$\begin{cases} R^1 : \text{SI } x \text{ es } A_1 \text{ Y } x \text{ es } B_1 \text{ ENTONCES } f_1 = p_1x + q_1y + r_1 \\ R^2 : \text{SI } x \text{ es } A_2 \text{ Y } x \text{ es } B_2 \text{ ENTONCES } f_2 = p_2x + q_2y + r_2 \end{cases}$$




Figura 1. Sistema de inferencia Takagi-Sugeno [14].

El sistema de inferencia mostrado en la figura 1 puede ser representado como una red adaptable, definiéndose entonces la arquitectura del modelo ANFIS como una red interconectada de 5 capas (ver figura 2). La estructura de la red ANFIS es similar a la de una red neuronal.




Figura 2. Representación del sistema T-S como una red adaptable [14].

Las funciones de los nodos en cada capa son descritas a continuación [14]:

Capa 1: Las entradas en esta capa corresponden a las entradas x e y , y la salida del nodo es el grado de pertenencia para el cual la variable de entrada satisface el término lingüístico asociado a este nodo. Debido a que la función de pertenencia posee parámetros que serán actualizados por el proceso de aprendizaje, los nodos de la primera capa están representados como nodos cuadrados.

$$O_i^1 = \mu_{A_i}(x), \quad i = 1, 2. \quad (3.1)$$

Capa 2: Cada nodo calcula el grado de activación de la regla asociada a dicho nodo. Ambos nodos están representados con una en la figura 3.8-b, por el hecho de que estos nodos multiplican las señales de entrada. Los nodos de esta capa son conocidos como nodos de reglas y no poseen parámetros asociados, por ello se representan por un círculo.

$$O_i^2 = \alpha_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2. \quad (3.2)$$

Capa 3: Cada nodo en esta capa está representado por una N en la figura 3.8-b, para indicar la normalización de los grados de activación, no poseen parámetros asociados, por ello son representados por un círculo. La salida del nodo es el grado de activación normalizado (con respecto a la suma de los grados de activación) de la regla i.

$$O_i^3 = \bar{\alpha}_i = \frac{\alpha_i}{\alpha_1 + \alpha_2}, \quad i = 1, 2. \quad (3.3)$$

Capa 4: La salida de los nodos corresponde al producto entre el grado de activación normalizado por la salida individual de cada regla y al no poseer parámetros asociados, por ello son representados por un círculo.

$$O_i^4 = \bar{\alpha}_i f_i = \bar{\alpha}_i (p_i x + q_i y + r_i), \quad i = 1, 2. \quad (3.4)$$

Capa 5: El único nodo de esta capa es representado por una en la figura 3.8 para indicar la suma, calcula la salida total del sistema (agregación) como la suma de todas las entradas individuales de este nodo

$$O^5 = f = \bar{\alpha}_1 f_1 + \bar{\alpha}_2 f_2 \quad (3.5)$$

La arquitectura completa de un modelo ANFIS quedará determinada por:

- Cantidad de funciones de pertenencia que representan cada variable de entrada al modelo.
- Tipo de funciones de pertenencia para cada entrada.
- La cantidad de capas de la red es fija e igual a 5 capas.

4. Algoritmo de aprendizaje en el modelo ANFIS

En el modelo ANFIS se tienen dos conjuntos de parámetros que deben ser entrenados: los parámetros del antecedente (constantes que caracterizan las funciones de pertenencia de las variables de entrada) y los parámetros del consecuente (parámetros lineales de la salida del modelo de inferencia).

El algoritmo de aprendizaje del modelo ANFIS es de tipo *entrenamiento supervisado* y se lleva a cabo en dos fases: una fase forward (hacia adelante) en la que se calculan los parámetros del consecuente del sistema de inferencia (p , q y r en la ecuación 3.4), y

una fase backward (hacia atrás) en la que se actualizan los parámetros del antecedente que corresponden a los parámetros de las funciones de pertenencia que representan las entradas. A esta combinación se lo conoce como regla de aprendizaje híbrido [14].

5. Aplicación del modelo ANFIS en el pronóstico de caudales de las centrales Daule Peripa y Paute Molino

Para determinar la arquitectura de los modelos ANFIS que representan los caudales mensuales se siguió un procedimiento heurístico propuesto por Jang en [13] y representado por el siguiente algoritmo:

```

for mes = 1:12 %Número de meses del modelo estacional
  for nfpert = 2:numFP %nFP para cada entrada
    for tipoFP = 1:8 %tFP para cada entrada
      for epocas = 1:1 %Épocas de entrenamiento
        %Realiza el entrenamiento de los modelos ANFIS
        ANFIS(histor, años, nprev, nfpert, epoc, tipoFP);
      end
    end
  end
end

```

Donde *mes* representa al número de meses del modelo (12 meses), *nfpert* representa el número de funciones de pertenencia por cada entrada (1 hasta 6 funciones para Paute y 9 funciones para Daule-Peripa) y *tipoFP* representa los 8 tipos de funciones de pertenencia considerados en el entrenamiento [14]. Estos modelos (*mes* x *nfpert* x *tipoFP*) fueron entrenados por una sola época y se seleccionaron solo aquellos modelos mensuales que alcanzaron el menor error de entrenamiento.

Los modelos ANFIS seleccionados fueron entrenados por un máximo de 300 épocas. Finalmente se determinó la arquitectura de 12 modelos ANFIS, uno para cada mes, En las tablas 1 y 2 se presenta la arquitectura de los 12 modelos ANFIS.

Tabla 1. Arquitectura final de los modelos ANFIS mensuales para la serie de caudales de la central Paute-Molino [14].

Mes	nFP	tFP	Épocas
Enero	5	Gauss tipo 2	119
Febrero	2	Triangular	47
Marzo	4	Triangular	99
Abril	6	D-sigmoide	44
Mayo	5	Gauss tipo 2	4
Junio	5	Triangular	102
Julio	4	Gauss	201
Agosto	5	Gauss	191
Septiembre	4	Triangular	34
Octubre	4	Triangular	147
Noviembre	3	Gauss tipo 2	158
Diciembre	5	Gbellmf	106

Tabla 2. Arquitectura final de los modelos ANFIS mensuales para la serie de caudales de la central Daule-Peripa [14].

Mes	nFP	tFP	Épocas
Enero	3	Triangular	69
Febrero	6	D-sigmoide	10
Marzo	6	Gauss	223
Abril	2	Triangular	221
Mayo	6	Gbell	3
Junio	7	Pi	223
Julio	7	Pi	258
Agosto	3	Triangular	117
Septiembre	8	Pi	173
Octubre	7	Pi	195
Noviembre	8	Pi	199
Diciembre	5	Pi	124

Los modelos ANFIS obtenidos fueron comparados con un modelo de previsión de series de tiempo estocásticas de tipo Periódico Autoregresivo de Medias Móviles PARMA, y a su vez ambos comparados caudales reales presentes en el período de 2009 a 2103. Más información sobre el modelo PARMA puede ser encontrada en [14].

Para medir y comparar el desempeño de los modelos ANFIS y PARMA se han considerado 3 métricas de error comúnmente utilizadas en trabajos con redes neuronales [5, 7, 9], estas métricas son la Raíz del Error Cuadrático Medio (RECM), el Error Porcentual Medio (EPM) y el Error Absoluto Medio (EAM), definidos como:

$$RECM = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5.1)$$

$$EPM = \frac{100}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (5.2)$$

$$EAM = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5.3)$$

En las figuras 3 y 4 se presentan los resultados de manera gráfica y en las tablas 3 y 4 se presentan los errores obtenidas para los modelos PAR y ANFIS.

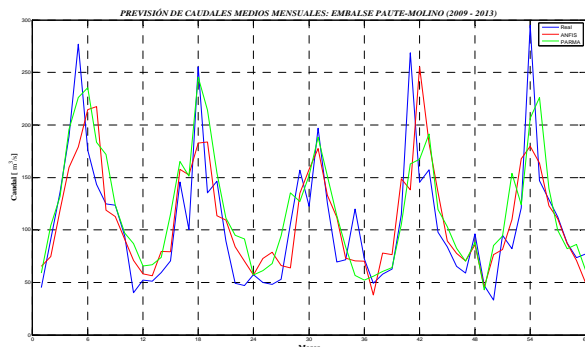


Figura 3. Comparación de caudales pronosticados para el período 2009-2013, entre el modelo ANFIS (línea roja), el modelo PARMA (verde) y caudales reales (azul) central Paute-Molino.




Figura 4. Comparación de caudales pronosticados para el período 2009-2013, entre el modelo ANFIS, PARMA y caudales reales, central Daule-Peripa.

Los errores obtenidos con el modelo ANFIS fueron menores que los errores del modelo PARMA en todas las métricas consideradas, siendo este comportamiento coherente con los resultados publicados en trabajos similares (ver [5, 7, 9]). Sin embargo, analizando los errores porcentuales se puede apreciar valores muy altos, especialmente los errores obtenidos para el pronóstico de caudales de la central Daule-Peripa, superiores al 40% (tablas 3 y 4).

Tabla 3. Métricas de error determinados para el pronóstico de caudales con horizonte de 5 años de la central Paute-Molino.

Modelo	RECM	EAM [m ³ /s]	EPM [%]
ANFIS	27.07	25.27	27.59
PARMA	36.11	26.75	29.79

Tabla 4. Métricas de error determinados para el pronóstico de caudales con horizonte de 5 años de la central Daule-Peripa.

Modelo	RECM	EAM [m ³ /s]	EPM [%]
ANFIS	83.21	61.169	41.544
PARMA	150.52	88.575	60.227

Estos valores altos del error de pronóstico podrían dar la impresión de que el modelo ANFIS presenta serias deficiencias en esta aplicación, sin embargo, dichos errores también podrían ser resultado de la calidad de la información proporcionada por el histórico de caudales o por el efecto de fenómenos atmosféricos que alteran la parsimonia de la serie y provocan valores extremos que contribuyen al aumento de la varianza de los caudales. En el caso de los caudales de la central Daule-Peripa, cuya desviación estándar supera al valor promedio en varios meses [14], este error de pronóstico podría

explicarse por la presencia del fenómeno del niño, que podría introducir eventos extremos y por consiguiente aumenta la varianza provocando errores fuera de contexto como los indicados en la tabla 4.

Para comprobar la eficiencia del modelo ANFIS frente a un conjunto de datos confiables y bien estructurados, se realizó un pronóstico para la central hidroeléctrica FURNAS de Brasil, que es utilizada ampliamente para probar modelos de pronóstico desarrollados en dicho país. Los caudales de la central Furnas corresponden al período de 1931 a 2003 y ha sido utilizados por Marinho et al. en [5]. La arquitectura de las redes mensuales ANFIS se muestra en la tabla 5 y los resultados del pronóstico se presentan en la tabla 6 y figura 5.

Tabla 5. Arquitectura final de los modelos ANFIS mensuales para la serie de caudales de la central Furnas [14].

Mes	nFP	tFP	Épocas
Enero	8	Gauss tipo 2	101
Febrero	3	P-sigmoide	25
Marzo	9	Gbell	182
Abril	3	P-sigmoide	85
Mayo	2	Gbell	15
Junio	7	P-sigmoide	224
Julio	10	Gbell	281
Agosto	2	P-sigmoide	134
Septiembre	2	Gauss	182
Octubre	2	Gauss	202
Noviembre	8	Gbell	199
Diciembre	8	Gauss	142

Tabla 6. Métricas de error determinados para el pronóstico de caudales con horizonte de 5 años de la central Furnas [14].

Modelo	RECM	EAM [m ³ /s]	EPM [%]
ANFIS	53.92	146.247	14.52
PARMA	251.70	173.117	21.1

Al comparar los errores porcentuales, se puede apreciar que el modelo ANFIS presenta mejores resultados que el modelo PARMA y estos errores porcentuales se sitúan entre el 14 y 21%, valores muy coherentes para el pronóstico de caudales, lo que ratifica que el modelo ANFIS presenta excelentes resultados en este tipo de problemas.

En la figura 5 se presenta la trayectoria de caudales pronosticados y reales para la central Furnas; se puede notar que la curva de caudales pronosticados con el modelo ANFIS es muy cercana a la curva de caudales reales, incluyendo los caudales del mes 25 que fueron los más altos en el periodo analizado, en el año 13 se presenta otro pico pero ninguno de los dos modelos (ANFIS y PARMA) fueron capaces de reproducir este pico.




Figura 5. Comparación de caudales pronosticados con horizonte de 5 años para la central FURNAS [14].

6. Desempeño de los modelos de pronóstico de caudales en la simulación de la operación de sistemas hidrotérmicos de potencia

Para determinar la influencia del modelo de pronóstico en la operación de un sistema hidrotérmico, se han realizado simulaciones considerando dos años del período de pronóstico 2009-2013, correspondientes a años secos (caudales bajos) y húmedos (caudales altos). Las figuras 6 y 7 presentan la trayectoria del almacenamiento del embalse de la central Daule-Peripa para un año seco (2011) y húmedo (2012).

Para el año seco el almacenamiento obtenido al utilizar los caudales pronosticados con el modelo PARMA presentaron una trayectoria más cercana a la obtenida considerando los caudales reales. Para el año húmedo la trayectoria obtenida con los caudales pronosticados con ANFIS es la más cercana a la operación simulada con caudales reales. La trayectoria de los embalses permite identificar si las políticas de operación determinadas por el algoritmo optimizador corresponden a las reglas de operación óptimas de un sistema hidrotérmico [14].




Figura 6. Trayectoria del almacenamiento en el embalse de la central Daule-Peripa para el escenario año 2011 (año seco).




Figura 7. Trayectoria del almacenamiento en el embalse de la central Daule-Peripa para el escenario año 2012 (año húmedo).

En las figuras 8 y 9 se presentan las trayectorias del embalse de la central Paute-Molino considerando los dos modelos de pronóstico analizados.

La trayectoria obtenida presenta un comportamiento errático y muy diferente al comportamiento esperado, que sería que el embalse inicia lleno al inicio de cada etapa, se vacía anticipándose al período anual de afluencias altas y luego se recupera paulatinamente (ver [14]).




Figura 8. Trayectoria del almacenamiento en el embalse de la central Paute-Molino para el escenario año 2010 (año seco).




Figura 9. Trayectoria del almacenamiento en el embalse de la central Paute-Molino para el escenario año 2011 (año húmedo).

El comportamiento del almacenamiento también es producto de la falta de regulación mensual de la central Paute-Molino, ya que la capacidad de su embalse es pequeña comparada con el volumen de los caudales afluentes laterales y las contribuciones de la

central Paute-Mazar que se encuentra en la cabecera del río (ver [14]).

Para verificar cual debería ser la forma óptima del almacenamiento, se ha considerado una simulación consistente en las dos centrales que se encuentran actualmente en operación: Paute Molino y Paute Mazar. En la figura 10 se presenta la trayectoria de los embalses de ambas centrales operando en cascada con la central Mazar en la cabecera.




Figura 10. Trayectoria de los embalses Mazar y Amaluza funcionando como cascada.

Como se puede apreciar en la figura 10, el almacenamiento de la central Molino presenta un comportamiento casi constante durante el año, y es el embalse de la central Mazar el que realiza la regulación de los caudales generando más energía en presencia de los caudales futuros abundantes. Este es el comportamiento óptimo de los embalses de un sistema hidrotérmico que considera reglas de operación optimizadas y no considera reglas paralelas para el vaciamiento de los embalses [14].

7. Conclusiones

En este trabajo se ajustaron dos modelos ANFIS para realizar el pronóstico de los caudales medios mensuales afluentes a las centrales hidroeléctricas Paute-Molino y Daule-Peripa; para determinar la eficacia del modelo propuesto, fue comparado con los caudales reales del período de prueba y con un pronóstico basado en el modelo de series de tiempo estocásticas PARMA. La comparación se realizó utilizando métricas de error comúnmente utilizadas en aplicaciones de redes neuronales artificiales.

Los resultados obtenidos muestran que el modelo ANFIS presenta mejor eficiencia en el pronóstico frente al modelo PARMA, cuando son comparados con los caudales reales ocurridos en el período de prueba utilizando las métricas de error definidas para la comparación.

Los resultados obtenidos son coherentes con las referencias consultadas y se pudo establecer que el modelo ANFIS permite obtener un mejor pronóstico de caudales para las dos centrales hidroeléctricas estudiadas. También pudo demostrarse que para el proceso de entrenamiento, el modelo ANFIS requiere

un número de épocas muchísimo menor que las redes neuronales artificiales.

Para evaluar la influencia que tiene el modelo de pronóstico de caudales en los costos de operación de un sistema hidrotérmico y en las políticas de operación. Para tal efecto se seleccionaron dos años del período pronosticado, un año de afluencias altas y un año de afluencias bajas. Los resultados en cuanto a la trayectoria del almacenamiento del embalse nuevamente fueron favorables para el modelo ANFIS, pues al optimizar la operación del sistema con los caudales pronosticados con esta herramienta se obtuvieron trayectorias de almacenamiento más cercanas a la operación considerando caudales reales..

Una de las limitaciones que se tuvieron en la aplicación del modelo de optimización fue la falta de información detallada de las centrales, especialmente en lo que se refiere a las ecuaciones que relacionan los volúmenes del embalse y canal de desagüe con la altura y el turbinamiento, respectivamente.

8. Trabajos futuros

Se sugiere la continuación de estos estudios considerando el aumento del orden de autoregresión ya que es importante analizar el rendimiento del pronóstico bajo estas consideraciones.

Otro aspecto importante es el uso de técnicas afines como algoritmos genéticos para el ajuste de las funciones de pertenencia, ya que el procedimiento heurístico utilizado constituye un ensayo tipo “prueba y error”.

Un desarrollo importante y necesario es el establecimiento de un *Sistema de Información para las Centrales Eléctricas del Ecuador*, dicho sistema debería contar con una base de datos detallada con las características principales de cada una de las centrales hidroeléctricas y termoeléctricas, de tal forma que los investigadores cuenten con información completa para aplicar diferentes modelos de optimización.

14. Referencias

- [1] CONELEC, “Estadística del Sector Eléctrico Ecuatoriano 2012”, Quito, Ecuador, 2014, accesado en 2015-02-10 desde http://www.conelec.gob.ec/archivos_articulo/doc_10371_Estadistica2012.zip.
- [2] Ruilova, J. C., “Estudio del Año Hidrológico 2001, Embalse Amaluza”, Centro Nacional de Control de Energía, Quito, Ecuador, mayo de 2001.
- [3] Hinojosa, V. H., 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, Revista Técnica Energía, CENACE, Quito, Enero 2008, pp. 149 – 154.
- [4] Jang, J-S. R., “ANFIS: Adaptive-Network-Based Fuzzy Inference System”, IEEE Transactions on Systems, Man and Cybernetics, Vol. 23 No. 3, may/june 1993.
- [5] Manoel Henrique da Nóbrega Marinho, Thyago Carvalho Marques, Rosangela Ballini, Secundino Soares, “Comparative Study of Seasonal Streamflow Forecasting models”, 5th Latin American Congress: Electricity Generation and Transmission, November 16- 20 2003, Sao Pedro, Brazil.
- [6] Velásquez, J. D., Dyner I., Souza, R.C., “Modelación de Series Temporales usando ANFIS”, Inteligencia artificial: Revista Iberoamericana de Inteligencia Artificial, Vol. 8, N°. 23, 2004, págs. 47-64.
- [7] Zúñiga, A., Jordán, C., “Redes Adaptables y Sistemas de Inferencia Fuzzy: Una aplicación al problema de la previsión de caudales”, I Congreso Nacional de Investigación, Tecnología e Innovación, Escuela Politécnica del Ejército, Quito, Octubre de 2005.
- [8] Firat, M., Güngör, M., “Sugeno fuzzy inference system for river flow estimation”, International Congress on River Basin Management, Antalya, Türkiye, pp. 583-598, 2007.
- [9] Jordán, C., Zúñiga, A., Medina, D., “Ajuste de un Modelo Lluvia-Caudal para la Cuenca Media del Río Paute Aplicando el Modelo Neuro-Difuso ANFIS”, V CONGRESO SOBRE INGENIERIA E INVESTIGACION CIENTIFICA- V CONIIC 2009, Universidad Tecnológica del Perú, Lima, Perú, 16 a 19 de Octubre de 2009.
- [10] Zadeh, L., “Fuzzy sets”, Information and Control 8, 338-353, 1965.
- [11] Takagi, T., Sugeno, M., “Fuzzy Identification of Systems and its Applications to Modelling and Control”, IEEE Transactions on Systems, Man and Cybernetics, 15:116-132, 1985.
- [12] Dirección de Planeamiento CENACE, Plan de Operación del Sistema Nacional Interconectado Julio 2014 – Junio 2015, Centro Nacional de Control de Energía CENACE, julio de 2014, accesible desde www.cenace.org.ec (acceso en 2014-11-09).
- [13] Jang, J-S. R., “Input Selection for ANFIS Learning”, Proceedings of the IEEE International Conference on Fuzzy Systems, New Orleans, 1996.
- [14] Zúñiga, A., “Pronóstico de Caudales Afluentes para la Planificación de la Operación de Sistemas Hidrotérmicos de Potencia aplicando el modelo ANFIS”, Informe de Proyecto de Graduación FIEC-ESPOL, Marzo 2015.