

**IDENTIFICATION OF A DYNAMIC MODEL STEAM GENERATOR FOR
BOILER PLANT TERMOTASAJERO COLGENER****IDENTIFICACIÓN DE UN MODELO DINÁMICO DEL GENERADOR DE
VAPOR DE LA CALDERA EN LA PLANTA TERMOTASAJERO COLGENER****MSc. Alejandro S. Guerrero Hernández, PhD. Oscar Gualdrón Guerrero
PhD. Ivaldo Torres Chávez**

Universidad de Pamplona, Facultad de Ingeniería y Arquitectura.
Ciudadela Universitaria. Pamplona. Tel.: +(57) (7) 568 5303, Ext. 164.
E-mail: {alejandrogue, oscar.gualdron, ivaldo.torres}@unipamplona.edu.co.

Abstract: In this paper, we identify the dynamic model of the dome of the boiler at the company Termotasajero Colgener, using the techniques NNARX, NNARMAX and ANFIS. The actual process data were collected through the SCADA system Daysy NETMATION. The selection, training and validation of the algorithm were performed in MATLAB®, worked various performance indices to see which of the models was the one who showed less error compared with the output of the plant. All in order to verify the advantages of working with black-box models in complex systems and nonlinear.

Keywords: Identification, NNARX, NNARMAX, ANFIS.

Resumen: En este artículo se realiza la identificación del modelo dinámico del domo de la caldera en la empresa Termotasajero Colgener, utilizando las técnicas NNARX, NNARMAX y ANFIS. Los datos reales del proceso fueron tomados a través del sistema SCADA DAYSY NETMATION. La selección, entrenamiento y validación de los algoritmos se realizaron en MATLAB®, se trabajaron diferentes índices de desempeño para verificar cual de los modelos presentaba menor error en comparación con la salida de la planta. Todo con el fin de verificar las ventajas de trabajar con modelos de caja negra en sistemas complejos y altamente no lineales.

Palabras clave: Identificación, NNARX, NNARMAX, ANFIS.

1. INTRODUCCIÓN

Los sistemas dinámicos abundan en nuestro ambiente y cada vez son más complejos conocer el comportamiento en cierta región de operación. Se puede recurrir a la experimentación sobre el proceso, sin embargo la experimentación es costosa y laboriosa por lo que es más conveniente contar con un modelo en que se puedan realizar las pruebas deseadas, sin dañar el sistema de estudio.

La obtención de modelos matemáticos es una técnica muy laboriosa que contempla los principios

y leyes naturales que rigen la dinámica del proceso.

Pero con el aumento de la complejidad de estos modelos matemáticos, se hace necesario la búsqueda de alternativas menos complicadas como es la identificación de sistemas.

La identificación de sistema es un procedimiento para la generación de modelos que reproduzca con exactitud la señal de salida de la planta y la dinámica del proceso a partir de sus datos reales entrada-salida.

El caso de estudio es el domo de una central termoeléctrica operada con combustible fósil (CTOF), de la empresa Termotasajero. Una CTOCF debe soportar el objetivo principal del sistema de potencia, el cual corresponde a cumplir con la demanda de potencia eléctrica todo el tiempo, a un voltaje y frecuencia constante. Por lo tanto optimizar estos sistemas es de múltiple importancia para minimizar el consumo de combustible fósil y rata de calor, maximizar la vida útil, minimizar las emisiones etc. [1] y [2].

La motivación de realizar este trabajo es de aplicar las técnicas de identificación NNARX, NNMARX y ANFIS como aproximaciones universales, se puede realizar una metodología de identificación alternativa a la teoría clásica de identificación. Por lo que debe ponerse un interés especial en la medición y al almacenamiento de las señales del proceso.

2. ESTRUCTURA DE IDENTIFICACIÓN

A través de la identificación de sistemas y, gracias al uso de datos de medición, se logra determinar los modelos que describe la dinámica del domo de la caldera de termotasajero.

El modelo obtenido puede utilizarse para predecir las señales de salida del sistema, también para diseñar sistemas de control, así como en diversas aplicaciones de ingeniería [10]. Existen varios tipos de modelos y distintas técnicas para conseguirlos. Como son las redes NNARX, NNARMAX y ANFIS.

2.1 Redes Neuronales

Las redes neuronales, a pesar de surgir a partir de motivaciones diferentes a de la identificación de sistemas dinámicos, representan un conjunto de modelos que encaja adecuadamente en la metodología de identificación. Son modelos paramétricos que, basándose en una medida del error y en un algoritmo para minimizarlo, aproximan una función no lineal con errores arbitrariamente pequeños.

La postura más habitual a la hora de escoger el conjunto de regresores para la red neuronal es reutilizar los regresores de modelos lineales, que resulta en las siguientes ventajas: es una extensión natural de estructuras de modelos ya conocidas; la arquitectura interna de la red puede expandirse gradualmente si se requiere más flexibilidad para modelar relaciones más complejas; las decisiones

que el usuario ha de tomar acerca de la estructura son razonablemente manejables; y, finalmente, resulta adecuado para el diseño de sistemas de control [3].

De esta manera, el modelo lineal más general es [3].

$$y(t) = G(q^{-1})u(t) + H(q^{-1})e(t) \quad (1)$$

En el que G y H son funciones de transferencia en el operador q^{-1} , $e(t)$ es una señal de ruido independiente de las entradas que puede caracterizarse mediante alguna función de densidad de probabilidad, $y(t)$ y $u(t)$ son la entrada y salida del modelo, respectivamente.

El objetivo de la identificación es obtener estimaciones adecuadas de las funciones de transferencia G y H . El criterio para decidir qué son y qué no son estimaciones adecuadas estará basado en la capacidad del modelo de producir predicciones a un paso con errores de varianza pequeña. Se puede verificar que, para el sistema lineal genérico de la ecuación (1), la predicción a un paso de menor varianza es.

$$\hat{y}(t|t-1) = H^{-1}G(q^{-1})u(t) + (1 + H^{-1}(q^{-1}))y(t) \quad (2)$$

Que es otra manera de representar un modelo. A partir de ahora se denotará la predicción a un paso de la ecuación (2) mediante $\hat{y}(t|q)$, en la que se ha hecho explícita la dependencia del modelo del conjunto de parámetros y se ha eliminado, por cuestiones de conveniencia notacional, el condicionamiento a $t-1$.

Conviene fijarse que en el caso lineal $\hat{y}(t|q)$ puede reescribirse de una forma más compacta.

$$\hat{y}(t|q) = \mathbf{j}^{-T}(t)\mathbf{q} \quad (3)$$

Donde \mathbf{j} es el vector de regresores (entradas anteriores, salidas anteriores y/o otras señales derivadas de ellas) y \mathbf{q} es el vector de parámetros del modelo, que es lo mismo que los pesos de la red neuronal.

Para una estructura de modelo NNARX en la que la predicción se calcula mediante:

$$\hat{y}(t|q) = q^{-d}B(q^{-1})u(t) + (1 - A(q^{-1}))y(t) \quad (4)$$

Y el vector de regresores incorpora ahora las salidas anteriores.

$$f(t) = \begin{bmatrix} u(t-1), \dots, u(t-n), \\ u(t-d), \dots, u(t-d-m) \end{bmatrix}^T \quad (5)$$

La extensión no lineal de este modelo convierte la predicción en.

$$\hat{y}(t | q) = g(\mathbf{j}^{-T}(t), \mathbf{q})$$

Si en la ecuación 1 se selecciona

$$G(q^{-1}, \mathbf{q}) = q^{-d} \frac{B(q^{-1})}{A(q^{-1})} u(t)$$

$$H(q^{-1}, \mathbf{q}) = \frac{C(q^{-1})}{A(q^{-1})}$$

El modelo resultante para la NNARMAX, en cuyo caso el predictor viene dado por:

$$\hat{y}(t | q) = q^{-d} \frac{B(q^{-1})}{A(q^{-1})} u(t) + \left(1 + \frac{C(q^{-1})}{A(q^{-1})} \right) y(t) \quad (6)$$

$$\hat{y}(t | q) = q^{-d} B(q^{-1}) u(t) + (1 + A(q^{-1})) y(t) + (C(q^{-1}) - 1) e(t, \mathbf{q})$$

Y el vector de regresor es:

$$\mathbf{j}(t) = \begin{bmatrix} y(t-1), \dots, y(t-n), \\ u(t-d), \dots, u(t-d-m), \mathbf{e}(t, \mathbf{q}), \\ \dots, \mathbf{e}(t-k, \mathbf{q}) \end{bmatrix}^T \quad (7)$$

Debido a la presencia del polinomio C el predictor ahora tiene polos y puede ser inestable. Para evitarlo conviene comprobar que todos los polos están dentro del círculo unitario. El hecho de que haya polos está ligado a que los regresores dependen de los parámetros del modelo, cosa que hace que el problema de estimación paramétrica sea más complicado.

Nuevamente, la extensión no lineal de este modelo convierte la predicción en:

$$\hat{y}(t | \mathbf{q}) = g(\mathbf{j}^{-T}(t), \mathbf{q}) \quad (8)$$

2.2 ANFIS

Si se combina los sistemas de inferencia difusa y las propiedades de aproximación de funciones de las redes neuronales, será posible conseguir estructura de modelado superior como la ANFIS [3], [4]. Este algoritmo difuso combina el método de gradiente descendiente y el método de mínimos cuadrados.

Una arquitectura ANFIS Es una red adaptiva que es equivalente a un sistema de inferencia difusa de tipo Takagi-Sugeno. La figura 1 muestra esta equivalencia.

La arquitectura ANFIS toma en consideración que:

- Se tienen dos entradas: x, y
- Se tiene una salida: z
- La base de reglas contiene dos reglas difusas del tipo de Takagi-Sugeno, esto es:

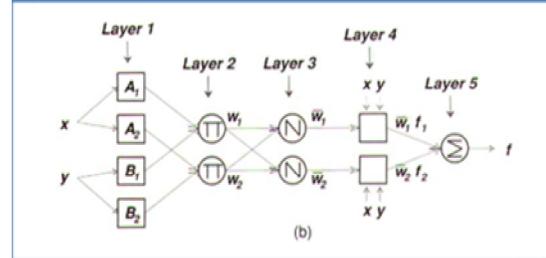


Fig. 1: Arquitectura ANFIS Generalizada [3].

Regla 1: si x es A₁ y y es B₁, entonces f₁=p₁x+q₁y+r₁

Regla 2: si x es A₂ y y es B₂, entonces f₂=p₂x+q₂y+r₂

Capa 1: Todo nodo i en esta capa es un nodo cuadrado con la función.

$$O_i^1 = m_{A_i}(x) \quad (9)$$

Siendo:

X=entrada al nodo i.

A_i= etiqueta lingüística asociada a la función de este nodo.

O_i¹=Función de membresía de A_i.

Donde la función m_{A_i}(x) es normalmente gaussiana, definida como:

$$m_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^{b_i} \right]} \quad (10)$$

Donde los valores a_i, b_i, c_i son conocidos como premisas, y están cambiando de manera continua y en consecuencia la forma de la función de campana.

Capa 2: Todo nodo en esta capa es un nodo circular etiquetado con ?, el cual multiplica las señales de entrada y salida del producto. Esto es,

$$w_i = m_{A_i}(x) * m_{B_i}(y), i = 1, 2, \dots \quad (11)$$

Cada nodo representa la fuerza de disparo de un regla, y distintos operadores de norma pueden ser empleados.

Capa 3: Cada nodo en esta capa es un nodo circular etiquetado con N. cada nodo calcula la relación entre la fuerza de disparo de la regla i y la suma de todas ellas. Esto expresa como:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2, \dots \quad (12)$$

Las salidas de esta capa son llamadas fuerza de disparo normalizadas.

Capa 4: cada nodo de esta capa es un nodo cuadrado con la función:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (13)$$

Los valores $p_i x + q_i y + r_i$ se llaman para metros consecuentes.

Capa 5: El nodo de esta capa es un nodo circular etiquetado con S, que calcula la salida total como la suma de todas las señales de entrada.

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{w_i} \quad (14)$$

La salida final para la arquitectura ANFIS sera entonces:

$$f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2$$

$$f = \bar{w}_1 f_1 + \bar{w}_2 f_2 \quad (15)$$

$$f = \bar{w}_1 (p_1 x + q_1 y + r_1) + \bar{w}_2 (p_2 x + q_2 y + r_2)$$

$$f = (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + \bar{w}_1 r_1 +$$

$$(\bar{w}_2 x) p_2 + q_2 (\bar{w}_2 y) + \bar{w}_2 r_2$$

3. CASO DE ESTUDIO

Termotasajero es una empresa termoeléctrica que genera 150MW de electricidad, que quema carbón (combustible fósil) como parte del procesos de generar vapor de agua sobrecalentado, suficiente para el funcionamiento de la turbina.

En la tabla 1 se muestran los datos de producción diaria de la planta [5], [6] y [7].

Tabla 1. Datos de producción 1 día en Termotasajero

PARAMETRO	VALOR	Rel.	UNIDAD
Generación	24		Horas
Generación neta	1817	91.4%	MW
Consumo auxiliares	171	8.6%	MW
Generación bruta	1988		MW
Factor de consumo de carbón	0.396		Ton/MW
Factor de consumo de energía	2457		Kcal/MW
Consumo de carbón	721		Ton
Poder calorífico	6413		Kcal/Kg
Porcentaje de ceniza	12.38%		
Cantidad de ceniza generada	89		Ton
Eficiencia de la planta	35.7%	257	Ton
Perdida en condensador	48%	346	Ton
Perdida en chimenea	15%	108	Ton
Perdida otras (purgas, tranfe)	1.3%	9	Ton

El circuito del flujo de agua y vapor es el que aparece en la parte izquierda de la figura 2 y su secuencia es la siguiente: El agua de alimentación es suministrada al tambor de vapor desde el cabezal de salida del economizador (eh-2). El tambor de vapor, a través de tubos bajantes, suministra agua a los cabezales inferiores del hogar (h-1y h-2) los cuales alimentan los tubos de las paredes frontal y trasera; los tubos de las paredes laterales y de las paredes laterales hogar extendido se alimentan de los cabezales (h-3 y h-4) respectivamente. La mezcla de agua vapor de las paredes del hogar llega, a través de los cabezales (h-5, h-6, h7 y h8), al tambor de vapor donde sucede su separación [5], [6] y [7].

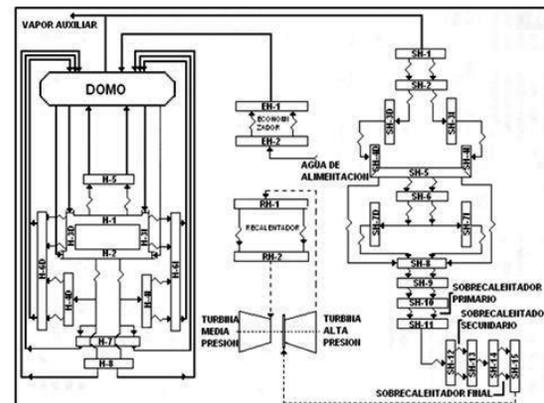


Fig. 2: Diagrama flujo agua vapor Termotasajero[5].

El vapor saturado pasa entonces al sobrecalentador a través de tubos conectores. El sobrecalentador del vapor saturado que sale del tambor se inicia en el techo del hogar y en el techo y paredes del paso posterior de la caldera, pasando luego por el sobrecalentador primario, formado por serpentines horizontales localizados en el paso posterior de la caldera. Del sobrecalentador primario el vapor pasa al sobrecalentador secundario localizado a la salida

del hogar y formado por serpentines colgantes y localizado entre la salida del hogar y el paso posterior de la caldera. La disposición de los sobrecalentadores en la figura 2 es el siguiente.

- Paredes de techo y paso posterior: entre los cabezales sh-1 y sh-9.
- Sobrecalentador primario: entre los cabezales sh-10 y sh-11.
- Sobrecalentador secundario: entre los cabezales sh-12 y sh-13.
- Sobrecalentador final: entre los cabezales sh-14 y sh-15.

Después que ha efectuado su trabajo en la etapa de alta presión de la turbina, el vapor pasa al recalentador fig. 2, formado por dos secciones de serpentines colgantes y localizados entre el sobrecalentador secundario y el sobrecalentador final. Allí se lleva a cabo el recalentamiento del vapor para ser enviado a la turbina de presión intermedia figura 3.

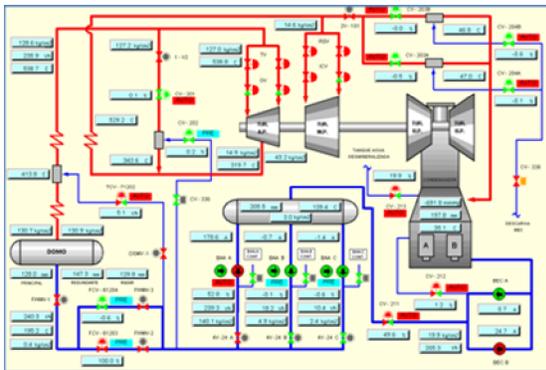


Fig. 3. Diagrama Flujo agua vapor sistema SCADA de Termotasajero.

4. IDENTIFICACIÓN DE LOS PARÁMETROS

El proceso de identificación consta de varios pasos para obtener el modelo adecuado que represente la dinámica del generador de vapor, como se muestra en la figura 4.

4.1 Recolección de datos

Para ello se debe excitar el sistema mediante la aplicación de señales de entrada y registrar, tanto las señales de entrada como las de salida durante un determinado intervalo de tiempo.

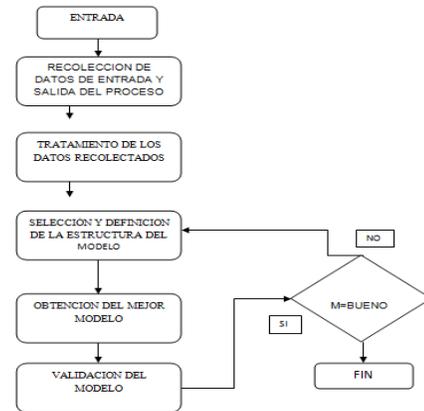


Fig. 4: Diagrama flujo utilizado para la identificación.

Para obtener datos con mayor cantidad de información posible se recurrió a la toma de muestras directas en tiempo real del SCADA DAISY NETMATION de la zona del generador de vapor. También se tuvo en cuenta el conocimiento de los expertos, jefe de la planta, operador del sistema SCADA para tener un conocimiento amplio de cómo funcionan las variables medidas.

Las variables tomadas del sistema SCADA (figura 5) y que influyen directamente sobre el domo del generador de vapor son las siguientes:

- Carga neta MW.
- Temperatura del agua de entrada al domo °C.
- Presión interno del Domo (Kg/cm²).
- Temperatura de salida del domo °C.
- Flujo de vapor principal en la salida del domo t/h.
- Flujo de agua de alimentación t/h.
- Nivel del Domo cm.
- Flujo total de combustible (carbón t/h).
- Porcentaje del flujo total de aire.

Después de conocer cada una de las variables y con la experiencia de los expertos de la planta, se llegó a la conclusión de tomar las siguientes variables: flujo de vapor principal (Ton/H), flujo de agua de alimentación (Ton/H) y de flujo total de combustible (Ton/H) para la identificación.

4.2 Tratamiento de los datos

Una vez que se tiene los datos de entrada-salida del sistema, se tomaron 3394 muestras, adjuntamos los datos en una sucesión de líneas rectas como se muestra en la figura 4.3 para luego ser llevadas a MATLAB para su identificación.

4.3 Elección de la estructura del modelo

Las estructuras a utilizar son ARX genéticos, NNARX, NNMARX y ANFIS cada una con características totalmente diferentes.

Es de recordar que también que se selecciono un número de retrasos con distintas combinación de entrada y salida por ejemplo: $y(k-1), y(k-2), u(k-4), u(k-5)$.

4.4 Obtención del mejor modelo

Ya elegida la estructura, el siguiente paso es el cálculo de sus parámetros. Estos parámetros son aquellos que hagan que las señales de salida del modelo y de la planta sean similares. Para la redes neuronales se trabajo con la metodología de *Train using Levenberg Marquardt backpropagation* (trainlm) y 25 neuronas en la primera capa, fue la que mejor se comportó. En el ANFIS se trabajo con 3 funciones de membresías tipo sigmooidal, con un entrenamiento hibrido y salida tipo lineal.

4.5 Validación

Consiste en determinar si los modelos obtenidos satisfacen los requerimientos para su aplicación. Si se llega a la conclusión de que el modelo no es válido, se deben revisar los siguientes aspectos como posibles causas:

- El conjunto de datos de entrada-salida no proporciona suficiente información Sobre la dinámica del sistema.
- La estructura escogida no es capaz de proporcionar una buena descripción del modelo.
- El criterio de ajuste de parámetros seleccionado no es el más adecuado.

En este trabajo se tomo una muestra de 3394 datos donde el 75% entrenamiento y el 25% restante para validación. Este tipo de validación consiste en observar la respuesta del modelo obtenido y la salida de proceso real.

Cuando se tienen varios modelos candidatos es difícil diferenciar cuál de ellos es el mejor, en este caso se utiliza los índices desempeño [3], los cuales son la cuantificación del error, por los que, entre menores sean, significa que las dos señales comparadas se parecen más.

Los índices de desempeño se calculan en base a la comparación de dos señales no importan la naturaleza de su origen, siempre y cuando se tenga el mismo número de muestras de cada una de ellas. A continuación se presentan los índices de desempeños empleados.

Integral del error cuadrático (ISE). Este índice penaliza en mayor medida los errores grandes, los cuales comúnmente se presentan al inicio de la señal y en menos medida los errores pequeños que generalmente se presentan al final de la señal. Donde n es el número de muestras y k son los instantes de muestreo.

$$ISE = \sum_{k=1}^N e^2(k) \quad (16)$$

Integral del error absoluto (IAE). Este índice penaliza de igual manera errores grandes y pequeños, ya que trata de la suma de los errores absolutos a lo largo de toda la señal.

$$IAE = \sum_{k=1}^N \|e(k)\| \quad (17)$$

Error cuadrático medio (MCE). Este índice calcula el error promedio a lo largo del total de muestras.

$$IAE = \sqrt{\frac{\sum_{k=1}^N e^2(k)}{N}} \quad (18)$$

Promedio. Este método estadístico se utiliza para organizar y analizar los datos obtenidos y de ese modo realizar comparaciones. Esta dada por la siguiente ecuación:

$$\bar{x} = \frac{\sum_{k=1}^N x(k)}{N} \quad (19)$$

Desviación estándar. La desviación es una medida de que tanto se alejan los datos de su media y está dada por:

$$S_x = \sqrt{\frac{\sum_{k=1}^N (x(k) - \bar{x})^2}{N}} \quad (20)$$

Varianza. Es el cuadrado de la desviación estándar.

Covarianza. Es la medición de la desviación estándar entre dos variables diferentes por:

$$S_{xy} = \frac{\sum_{k=1}^N (x(k) - \bar{x}) * (y(k) - \bar{y})}{N} \quad (21)$$

5. ANÁLISIS DE RESULTADOS

Una vez teniendo en claro las variables que se van a tomar para entrenamiento, validación y posterior análisis de los resultados, comencemos aplicar cada una de las técnicas de identificación propuestas.

Los modelos obtenidos se desarrollaron con los toolbox NNFTOL y ANFIS de MATLAB, en cambio el análisis del error y análisis estadísticos se desarrollaron en Excel.

Observando los resultados de la tabla 2 para la identificación del domo la validación en el dominio del tiempo para una entrada (flujo de agua de alimentación Ton/H) -salida (flujo de vapor principal Ton/H) donde comparamos los diferentes modelos nos damos cuenta que aquella en que la cuantificación del error ($e = y - \hat{y}$) sea menor, podemos sacar la conclusión que es la señal más idéntica a la salida del vapor principal de la planta es el modelo ANFIS.

Tabla 2. Resultados del análisis del error para cada uno de los modelos

VALIDACION TIEMPO	ARX GENT (Ton/H)	NNARX (Ton/H)	NNARMAX (Ton/H)	ANFIS (Ton/H)
INTEGRAL ERROR CUADRATICO MEDIO	274253073,2	497,9697977	7533,931046	175,7052138
INTEGRAL ERROR ABSOLUTO	983974,4888	64,08552816	218,9846089	0,344077358
ERROR CUADRATICO MEDIO	272,844963	0,367656028	1,4300493	0,218389882

En cuanto a la metodología estadística los tres modelos NNARX, NNMARX y ANFIS tienen una aproximación muy cercana a los valores de la salida real de la planta con excelente desempeño como la muestra la tabla 3.

Tabla 3. Resultados del análisis estadístico para cada uno de los modelos

VALIDACION ESTADISTICA	SALIDA REAL PLANTA (Ton/H)	ARN GENT (Ton/H)	NNARX (Ton/H)	NNARMAX (Ton/H)	ANFIS (Ton/H)
PROMEDIO	304,6622828	37,56823052	304,6448872	304,6028408	304,6621894
DESVIACION ESTANDAR	111,0970085	55,407164	110,9958899	111,0769128	111,0976185
VARIANZA	12342,54529	3069,953823	12320,07647	12338,08056	12340,45898
COVARIANZA		6151,587215	12327,89619	12335,94146	12336,12826

Observado los resultados de la tabla 4 validación en el dominio del tiempo para dos entradas (flujo de agua de alimentación, flujo de carbón)- una salida (flujo de vapor principal) donde comparamos los diferentes modelos nos damos cuenta que aquella en que la cuantificación del error sea menor podemos sacar la conclusión que es la que más se parece a la señal original.

Los demás modelos de identificación se comportan muy bien, pero podemos concluir que el modelo NNARX es el que tiene mayor similitud con la señal real de la planta. Debido a que integral error cuadrático medio, integral error absoluto y el error cuadrático medio son de menor valor que los otros modelos obtenidos como ARX Gent, NNARMAX y ANFIS.

Tabla 4. Resultados del análisis del error para cada uno de los modelos

VALIDACION TIEMPO	NNARX (Ton/H)	NNARMAX (Ton/H)	ANFIS (Ton/H)
INTEGRAL ERROR CUADRATICO MEDIO	179,5125127	7230,297416	8144,922585
INTEGRAL ERROR ABSOLUTO	22,91291716	0,21798586	0,120849754
ERROR CUADRATICO MEDIO	0,220743311	1,400935919	1,486906533

Para la metodología estadística si observamos la tabla 5 todos los sistemas de identificación utilizados tienen un comportamiento excelente con la señal real de la planta y no podemos decir que un método es mejor que el otro, solo que se ha logrado objetivos propuesto obtener varios modelos de identificación por diferentes algoritmo de entrenamiento con resultados satisfactorios para con cada uno de ellos.

Tabla 5. Resultados del análisis estadístico para cada uno de los modelos

VALIDACION ESTADISTICA	SALIDA REAL PLANTA (Ton/H)	NNARX (Ton/H)	NNARMAX (Ton/H)	ANFIS (Ton/H)
PROMEDIO	304,6622828	304,6685024	304,662342	304,562342
DESVIACION ESTANDAR	111,0970085	111,0105893	111,0985754	111,0870369
VARIANZA	12342,54529	12323,35094	12342,89346	12340,32976
COVARIANZA		12329,57606	12338,3877	12336,98207

6. CONCLUSIONES

El uso de sistemas basados en redes neuronales es particularmente adecuado para sistemas no lineales debido a la naturaleza paralela de la estructura interna de las redes neuronales artificiales. Adicionalmente, la combinación de las redes neuronales con sistemas difusos, permiten al sistema tratar con información vaga y por lo tanto presenta una mayor estabilidad ante la presencia de incertidumbres, al poder inferir el comportamiento del sistema basado en los datos de entrenamiento, proporcionando una salida adecuada.

Debido a que la identificación de sistemas se basa en datos de medición, es de vital importancia que estos tengan suficiente información acerca del sistema en estudio (domo de la caldera). Por lo que debe ponerse un interés especial en la medición y almacenamiento de las señales del sistema. El número de parámetros a estimar no debe ser una limitante, ya que, en la actualidad todo el procesamiento lo realiza el computador, aunque es indispensable tener una buena máquina para el procesamiento de los datos.

Se puede concluir con los resultados obtenidos con los modelos generados con NNARX, NNARMAX y ANFIS son confiables. Hay que recordar que esta identificación se hizo en un región de operación y todo sistema real es una entidad que no puede ser dimensionada totalmente a través de un modelo práctico.

Se abre la posibilidad de seguir investigando en la detección de fallas basada en modelo, es una aplicación muy interesante de los modelos matemáticos y también en modelo de caja negra. Por medio de los residuales generados se puede determinar si se están presentando fugas de masa o energía en el proceso. Esta herramienta contribuye a la optimización de recursos en la operación y el mantenimiento de una central termoeléctrica.

REFERENCIAS

- [1]. Garduno, R y Lee, K. Multiobjective Optimal Power Plant Operation Through Coordinate Control with Pressure Set Point Scheduling. IEEE Transactions on Energy Conversion. Vol. 16, No2. pp. 115 – 122. 2001.
- [2]. Garduno-Ramirez, Raúl. Overall Intelligent Hybrid Control System per a Fossil-Fuel Power Unit. A thesis in Electrical Engineering. The Pennsylvania State University, 2000.
- [3]. Avendaño Castellanos, Oscar Fabián. Identificación de sistema utilizando lógica difusa, 2008.
- [4]. Lee, C.; Lin, Y. and Lai, W. Systems Identification using type-2 fuzzy neural network. IEEE International Symposium on Computational Intelligence in Robotic and Automation, pp. 1264-1269, July, 2002.