

Predicción de demanda de energía en colombia mediante un sistema de inferencia difuso neuronal

Recibido para evaluación: 26 de Sep de 2004
Aceptación: 16 de Oct de 2004
Entrega de versión final: 15 de Abril de 2005

Santiago Medina Hurtado¹, Dra. Josefina García Aguado²

RESUMEN

En este trabajo se utilizan dos técnicas de inteligencia artificial para pronosticar la demanda mensual de energía eléctrica en Colombia con el objetivo es determinar el error de la predicción y puedan ser comparados posteriormente con otros modelos tradicionales pronóstico de series de tiempo. Una disminución importante en los errores de predicción, traería beneficios económicos para todos los agentes que operan en el sector eléctrico. Las redes neuronales Artificiales (RNA) y los Sistemas de Inferencia Borroso Adaptativo –ANFIS son actualmente ampliamente utilizados en problemas de pronóstico en muchos campos de la ciencia y la tecnología con buen desempeño, para nuestro caso estos modelos fueron alimentados con variables explicativas de la demanda. Se utilizó una RNA completamente interconectada con propagación hacia delante de tres capas y se probaron dos algoritmos de aprendizaje para la red encontrándose resultados significativamente diferentes en el error de predicción así como en el tiempo de entrenamiento. El modelo ANFIS utilizado fue de tipo Takawi-Sugeno de orden cero y fue alimentado con las componentes principales de las variables de entrada definidas. Los resultados fueron comparados mediante la función de error Raíz del Error Medio Cuadrático (RMSE) y el Porcentaje de Error Absoluto Medio (MAPE) encontrándose un mejor desempeño de la RNA.

PALABRAS CLAVES: Demanda de energía, redes neuronales, Redes neurodifusas, ANFIS.

ABSTRACT

This work two artificial intelligence techniques are used to forecast the monthly demand of electric power in Colombia, the objective is determinate the error of the prediction and they can be compared later with other traditional models of forecast time series. An important decrease in the prediction errors, would bring economic benefits for all the agents that operate in the electric market. The Artificial neural networks -RNA and Adaptative Neural Fuzzy Inference Systems -ANFIS are actually broadly used in forecast problems in many fields of the science and the technology with good performance, for our case these models were fed with explanatory variables of the demand.

We used a RNA totally interconnected with forward propagation and three hidden layer, two learning algorithms were proved for the net find significantly different results in the prediction error as well as in the time of training. The ANFIS model used was of type Takawi-Sugeno of order zero and it was fed with the main components of the defined entrance variables. The results were compared by means of the function of error Root of the Mean Square Error (RMSE) and the Percentage of Error Mean Absolute (MAPE). We find a better performance of the RNA.

KEYWORDS: Demand of electric power, Artificial Neural Network, Adaptative Fuzzy Inference System.

¹smedina@unalmed.edu.co
Universidad Nacional de
Colombia. Facultad de
Minas, EIO, Medellín,
²jgarciaa@ccee.ucm.es
Universidad Complutense
de Madrid. Departamento
de Estadística e
Investigación Operativa II.
Facultad de Ciencias
Económicas y
empresariales

1. INTRODUCCIÓN

En los últimos años un gran número de investigaciones han aplicado los modelos de redes neuronales Artificiales (RNA) y los sistemas de inferencia difusos (FIS) a muchos campos del conocimiento donde han demostrado tener una gran capacidad de adaptabilidad, aprendizaje y características de modelamiento libre. En el sector Eléctrico, estos modelos se han aplicado con éxito en problemas de detección de fallos y diagnóstico, modelamiento dinámico, control, despacho económico, predicción de potencia, predicción de energía, predicción de precios, entre otros. (Chanda, Bhattacharjee 1998; Abdelaziz 1999; Kalogirou 2000)

Específicamente en el tema del consumo de energía eléctrica, la predicción de la demanda de energía eléctrica es un insumo fundamental dentro de la información requerida por los agentes del sector eléctrico dentro de los diferentes procesos de decisión que llevan a cabo. Es así como los Generadores la usan para planificar su producción, decidir sobre sus inversiones, definir sus contratos y cubrir sus riesgos. Los Transportadores y los Distribuidores la usan para el diseño de sus instalaciones. Por otra parte, para los Comercializadores es un insumo básico y esencial en su función de compra y venta de energía. Para el caso del operador del mercado, el aumento de la precisión de los pronósticos de la demanda de energía eléctrica en el corto plazo, implica una programación más cercana al despacho real de los diferentes recursos de generación de electricidad; mientras que en el largo plazo, se constituye como un insumo fundamental para la generación de señales de inversión en nueva capacidad instalada. Por lo tanto, una buena predicción de la demanda trae beneficios tanto técnicos como financieros a todos los agentes que participan en el sector eléctrico.

Varias clases de modelos de predicción de demanda son usados actualmente y quizá la mayoría de los métodos tienen que ver con modelos de series temporales, entre los más usados están el modelo autoregresivo (AR), el modelo de promedio móvil autoregresivo (ARMA), el modelo de promedio móvil autorregresivo integrado (ARIMA) y los modelos de regresión múltiple. Todas estas técnicas son fiables pero tienen problemas cuando se presentan situaciones especiales tal como condiciones climáticas inusuales y días de fiesta o temporada (Tamami, Egbert, 2000). Por esta razón los eventos especiales son modelados a priori en los modelos econométricos mediante variables Dummy.

Durante los años 90 fueron propuestos modelos de predicción de demanda que usan técnicas de Redes Neuronales Artificiales (Al-Saba, El-Amin 1999; Lamedica, Prudenzi, Sforza, Caciotta 1996) y sistemas de Inferencia Borrosa (Mori, Kobayashi 1996) con resultados muy alentadores para resolver los problemas de la predicción de los modelos econométricos. En años más recientes se han propuesto sistemas híbridos que combina los sistemas RNA y FIS para reducir las limitaciones de cada una de estas técnicas individuales. En esta última categoría pueden encontrarse modelos neuronales con una o mas entradas que son tratadas previamente mediante un sistema borroso (Tamami, Egbert, 2000) o sistemas borrosos que modifican la salida de una red neuronal dependiendo de la presencia de factores especiales tales como cambios de clima, nivel de riesgo, etc. (Kwang-Ho, Park, Hwang, Kim 1995; Abraham, Nath, 2001)

Este trabajo describe la aplicación de los modelos ANFIS y RNA para predecir la demanda de energía eléctrica en Colombia a corto

plazo como una función de variables explicativas. Los modelos usados proporcionan un perfil de demanda mensual y son entrenados y validados con datos históricos mensuales a partir de 1995. El desempeño de cada modelo es medido mediante la función del error RMSE y MAPE de los valores de predicción.

2. CARACTERISTICAS DE LA DEMANDA DE ENERGIA ELECTRICA

En general existen varios factores reconocidos por los expertos que inciden en la evolución de la demanda de energía, con base en esta opinión, fue posteriormente construida la base de datos de los posibles factores explicativos de la demanda comercial. Estos pueden ser agrupados de la siguiente forma (UPME 2002):

- La temporada. Tal como los periodos de semana santa, vacaciones y navidad.
- Efectos climáticos tal como el fenómeno niño o niña.
- Factores económicos tal como el de crecimiento del PIB y los precios de la energía y los combustibles sustitutos.
- Consumos de sustitutos energéticos. Tal como el gas natural, el propano y el diesel y las tarifas o costos asociados.
- La Evolución del consumo de los grandes consumidores y el crecimiento de la población.

4.1 BASE DE DATOS Y SELECCIÓN DE ENTRADAS

La base de datos para realizar la predicción, tuvo como fuente las páginas web de las siguientes instituciones CREG, UPME, ECOPETROL, MEM, NOAA, ISA, Banco de la Republica y DANE. Las variables con que se cuenta para representar los factores mencionados, se presentan en la Tabla 1.

La selección de las variables para la predicción de la demanda mensual, se basó en el análisis de correlación (indicada en la Tabla 1), el análisis de correlación cruzada y la función de autocorrelación parcial.

Las variables de entrada se organizaron de tal modo que se pueda predecir la demanda de energía en (t+1) usando la serie de demanda y variables explicativas. Inicialmente se analizó la autocorrelación de la serie de demanda y la correlación cruzada para detectar el rezago significativo.

Para el caso de la serie de demanda, se encontró que esta presenta tendencia y un patrón estacional de periodo 12 (Figura 1). Lo cual se verifica en la función de autocorrelación parcial (PACF) que muestra una correlación significativa entre los valores en t con los valores en t-1, t-2, t-6 y t-12. Tabla 2.

La correlación cruzada entre demanda v.s. PIB y Demanda vs. Temperatura Superficial del Mar (TSM) se muestran en la Tabla 3 y Tabla 4 respectivamente.

Los resultados de la Tabla 3, indican la fuerza de la relación lineal entre la Demanda en el periodo "t" y el PIB al rezago "k" (con k entre -6 y +6), como se indica en la tabla existe una relación directa entre las variables. El comportamiento de la demanda está relacionada con el desempeño de la actividad económica en los meses pasados, especialmente con los rezagos k=-1.

La relación entre la Demanda en el periodo "t" y la TSM al rezago "k" (con k entre -6 y +6), indicada en la Tabla 4, muestra una relación directa entre las variables, además se considera que rezagos

Factor	Variable de Entrada	Correlación
Climáticos	Aporte de los Ríos m3/seg	-0.0352
	Índice de la oscilación del Sur (SOI index)	-0.4722
	Temperatura Superficial del Mar (TSM niño 3)	0.4815
	Nivel de los embalses Kwh	0.0977
Temporada	Mes aumento en la demanda	0.5384
	Mes disminución en la demanda	-0.2260
Población	Población	0.3433
Económicos	PIB Mill. de \$ ctes de 1994	0.6223
	Inversión Externa en Colombia Mill de USD	0.2718
	Importaciones Mill de USD	0.4842
	Exportaciones Mill de USD	0.4295
	TRM \$/USD	0.2953
Sustitutos energéticos	Consumo de gas natural Mbtu/día	0.4314
	Consumo de de ACPM BPDC	0.2788
	Consumo de Propano Barriles	0.3116
	Consumo de Fuel-Oil BPDC	0.2769
	Consumo de Cocinol BPDC	-0.2648
	Instalaciones domiciliarias de gas	0.3471
Índices sector eléctrico	Precio de la energía en bolsa \$/Kwh	0.3621
	Precio promedio de los contratos de energía \$/Kwh	0.3071
	Tarifa promedio de la energía \$/Kwh	0.3849
	Perdidas del STN Kwh	0.5745
	Demanda mensual de energía Gwh	1.0000

Tabla1. Lista de Variables y su correlación con la demanda

Estimated Partial Autocorrelations for Demanda			
Lag	Partial Autocorrelation	Lower 95.0% Prob. Limit	Upper 95.0% Prob. Limit
1	0.329565	-0.200038	0.200038
2	0.465991	-0.200038	0.200038
3	0.171796	-0.200038	0.200038
4	-0.0254352	-0.200038	0.200038
5	0.20717	-0.200038	0.200038
6	-0.385339	-0.200038	0.200038
7	0.155759	-0.200038	0.200038
8	0.119299	-0.200038	0.200038
9	-0.0879635	-0.200038	0.200038
10	0.0737275	-0.200038	0.200038
11	-0.0770083	-0.200038	0.200038
12	0.423517	-0.200038	0.200038
13	-0.414959	-0.200038	0.200038
14	-0.279785	-0.200038	0.200038
15	-0.150026	-0.200038	0.200038
16	-0.0804794	-0.200038	0.200038
17	-0.0117688	-0.200038	0.200038
18	0.0557938	-0.200038	0.200038
19	-0.0132122	-0.200038	0.200038
20	0.0988631	-0.200038	0.200038

Tabla 2. Función de Autocorrelación Parcial de la Demanda.

Demanda vs PIB	
Lag	Crosscorrelation
-6	0.156648
-5	0.271883
-4	0.400747
-3	0.523327
-2	0.612772
-1	0.680373
0	0.60734
1	0.42039
2	0.290569
3	0.206466
4	0.155832
5	0.0906065
6	0.10053

Tabla 3. Correlación cruzada entre demanda y PIB

positivos no tiene sentido ($k \geq 0$) pues no es lógico pensar que la temperatura superficial del mar depende del comportamiento de la demanda. Por tal motivo se tomaron valores de TSM rezagados -2 y -1 periodos.

Las variables finales seleccionadas se muestran en la Tabla 5 y considera al menos dos variables por factor con mayor correlación con la demanda:

Demanda vs. TSM	
Lag	Crosscorrelation
-6	0.245214
-5	0.284903
-4	0.341427
-3	0.379386
-2	0.394315
-1	0.413732
0	0.448671
1	0.457847
2	0.453267
3	0.435542
4	0.395234
5	0.374823
6	0.293515

Tabla 4. Correlación cruzada entre demanda y TSM

Variable de Entrada	
Factor de Cambio Demanda Acumulada FCDA	(t)
Mes aumento en la demanda	(t+1)
Mes disminución en la demanda	(t+1)
Tarifa promedio de la energía	(t)
Instalaciones domiciliarias de gas	(t)
Consumo de de ACPM	(t)
Consumo de gas natural	(t)
TSM niño 3	(t-1)
TSM niño 3	(t)
Importaciones	(t)
Exportaciones	(t)
PIB	(t-1)
PIB	(t)
Demanda mensual	(t-1)
Demanda mensual	(t)
Variable de Salida	
Demanda mensual	(t+1)

Tabla 5. Variables finales seleccionadas para el modelo

5.1 PREPARACION DE LA BASE DE DATOS

En esta etapa se llevan a cabo algunas o todas de las siguientes actividades sobre la base de datos:

- Detectar, corregir y completar datos incorrectos y faltantes.
- Normalizar los datos.
- Rezagar las variables explicativas.
- Generar nueva información a partir de las variables existentes.

- Reducir la dimensión (número de variables de entrada)
- Dividir la base de datos en un grupo de entrenamiento y otro de prueba del modelo.

Dentro del proceso de preparación de los datos es posible generar nuevos vectores de entrada, por ejemplo dos variables de entrada pueden ser reducidas a una, la cual tiene mayor valor que las dos variables originales. En este caso se generó un nuevo vector denominado Factor de Cambio en la Demanda Acumulada (FCDA = DA_t / DA_{t-1}) ya que este permite ingresar información de la tendencia de la serie. DA_t = Demanda Acumulada en el mes t , y DA_{t-1} = Demanda Acumulada en el mes $t-1$.

Algunas series de tiempo tienen una componente estacional muy marcada. Esta información puede ser comunicada al modelo incluyendo una o más variables de entrada en la base de datos que indiquen el periodo, por ejemplo, periodos de demanda baja pueden ser codificados con el valor “0” y periodos de demanda alta codificados con “1”. En general lo más utilizado es la generación de variables Dummy para capturar estacionalidades.

Como puede verse en la Figura 1, la demanda de energía tiene una componente estacional muy marcada y esta información debe ser incorporarse de manera a priori al modelo. Para tal efecto, se codificaron los meses de 1 a 12 respectivamente y se crearon dos vectores, el primero que contiene los meses donde ocurren aumentos en la demanda y el segundo donde ocurren disminuciones. Por ejemplo, para un año típico el vector que recoge los aumentos en la demanda será (0,0,3,0,5,0,7,8,0,10,0,12) y el vector que recoge las disminuciones será (1,2,0,4,0,6,0,9,0,11,0).

Antes del proceso de entrenamiento es frecuente normalizar las variables de entrada y salida ya que ellas provienen de diferentes fuentes y tienen diferente escala. Con el proceso de normalización se garantiza que los valores se mantengan dentro de cierto rango. El procedimiento más utilizado para normalizar los datos es hacer uso de la media y la desviación estándar de cada variable lo cual garantiza que cada variable tendrá media “0” y desviación típica “1”.

Por otra parte en algunas situaciones la cantidad variables explicativas es muy grande y están altamente correlacionados. El análisis de Componentes Principales (CP) permite crear variables nuevas no correlacionadas las cuales se ordena en función de la información que llevan incorporadas.




Figura 1. Comportamiento estacional de la Demanda

En la tabla 6, se muestra el análisis de CP para nuestros datos. Indica que con 5 componentes se explica el 82.56% de la varianza de los datos por lo que el espacio 15-dimensional puede ser reducido a un espacio 5-dimensional.

Para el trabajo con los modelos, se utilizó tanto los vectores de entrada originales previamente estandarizados (15 variables explicativas) así como los vectores de componentes principales obtenidos para reducir la dimensión (se corrieron modelos con 3, 5 y 7 componentes principales las cuales explican el 68.37%, 82.56% y 91.98% de la varianza de los datos de demanda como se indica en la Tabla 6). La ejecución de los modelos se comparó mediante la función de error RMSE y MAPE.

Una última etapa de la preparación es la relativa a dividir la base de datos en dos grupos. Un grupo de entrenamiento de 86 muestras consecutivas utilizadas para el entrenamiento o ajuste de los modelos y un grupo de 10 muestras consecutivas para la validación o verificación de los modelos.

5 MODELOS DE PREDICCIÓN

Nuestro trabajo se centra en la comparación de resultados obtenidos mediante la utilización de dos modelos seleccionados por la capacidad de capturar comportamientos no lineales, aprendizaje y tratar con la imprecisión, la incertidumbre y la mala definición, estos son:

Principal Components Analysis			
Component Number	Eigenvalue	Percent of Variance	Cumulative Percentage
1	5.24359	34.957	34.957
2	3.12396	20.826	55.784
3	1.88838	12.589	68.373
4	1.23521	8.235	76.608
5	0.893977	5.960	82.567
6	0.840379	5.603	88.170
7	0.571691	3.811	91.981
8	0.382276	2.549	94.530
9	0.251136	1.674	96.204
10	0.21078	1.405	97.609
11	0.167617	1.117	98.727
12	0.107278	0.715	99.442
13	0.0369783	0.247	99.688
14	0.0283479	0.189	99.877
15	0.0184043	0.123	100.000

Tabla 6. Análisis de Componentes principales

- Una Red Neuronal Artificial (RNA)
- Un Sistema de Inferencia Borroso Adaptativo - ANFIS.

1.1 RED NEURONAL ARTIFICIAL

Para nuestro análisis se seleccionó una arquitectura de red neuronal de tres capas completamente interconectada con propagación hacia adelante. Denotada por red K-H-J, donde:

- La primera capa contendrá las variables de entrada (K). Se probaron dos redes, la primera con el total de las variables

seleccionadas (15) previamente normalizadas y la segunda haciendo uso de las componentes principales.

- Capa de Neuronas Ocultas (H). Se inicia con un número de neuronas igual a la suma de las variables de entrada más la variable de salida. El número de neuronas en esta capa fue incrementándose y disminuyéndose para ver como evoluciona la función del error con el fin de seleccionar aquella estructura de red que minimice el error.
- La capa de salida contiene una neurona correspondiente a la predicción de demanda del próximo mes.

Para el entrenamiento de las redes se utiliza el Algoritmo BP (Back Propagation) con tasa de aprendizaje constante $a=0.001$ y momentum $b=0.90$ (traingdm). Con el fin de comparar los resultados, se usó un algoritmo de entrenamiento opcional que modifica la tasa de aprendizaje "a" durante el entrenamiento, esto con el fin de mejorar el tiempo de entrenamiento y el ajuste de la red. (traingdx). (Para mayor detalle del algoritmo de entrenamiento de las funciones traingdm y traingdx puede consultarse Matlab user guide o Simón 1994).

Se dividió la base de datos en un grupo de entrenamiento de 86 patrones y un grupo de validación de 10 patrones. La función de Ejecución utilizada en el modelo fue RMSE- Raíz de error cuadrado medio en Gwh dada por:

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (T_t - O_t)^2}$$

La función de transferencia utilizada para la capa oculta fue tangente hiperbólica y la función de transferencia utilizada para la capa de salida fue la función lineal. Para un mayor detalle teórico de las redes neuronales puede consultarse (Shing, Jang, Sun, Mizutani 1997; Simón 1994)

1.2 ARQUITECTURA ANFIS

Este modelo consiste en un sistema de inferencia borroso - FIS cuyos parámetros se determinan mediante el algoritmo de aprendizaje de una red neuronal con las siguientes características:

- La estructura ANFIS usada es del tipo Sugeno de orden cero con K-variables de entrada y una variable de salida correspondiente a la predicción de demanda del próximo mes.
- La capa de entrada corresponde a los vectores de Componentes Principales. Se probaron modelos ANFIS con 3, 5 y 7 entradas correspondientes a las componentes principales.
- El número de funciones de pertenencia asignadas inicialmente a cada variable de entrada fue de dos (2) y se aumenta dependiendo el comportamiento de la función de ejecución RMSE.
- La función de pertenencia utilizada se selecciona dependiendo el comportamiento de la función de ejecución.

Para el entrenamiento del modelo, se utilizó un algoritmo de aprendizaje híbrido que combina el Algoritmo BP (Back-propagation) y el estimador mínimo cuadrático. Para un mayor detalle teórico de los sistemas neuro-difusos consúltese (Shing, Jang, Sun, Mizutani 1997).

RESULTADOS

En esta sección se muestran los resultados obtenidos mediante la utilización de los modelos mencionados. Dichos modelos tienen la característica de permitir cambios en las condiciones de entrada como número de neuronas, funciones de activación, algoritmos de entrenamiento, tasa de aprendizaje, número de funciones de pertenencia, tipo de función de pertenencia, entre otros. Esto le da al proceso de obtención de resultados la característica de ser un proceso dinámico en el sentido que se cambian los parámetros y se observan los resultados hasta que se consigue un nivel de error deseado (modelamiento libre).

4.1 RESULTADOS DEL MODELO ANFIS

Se probó el modelo con 3, 5 y 7 componentes principales, los resultados se muestran en la Tabla 7.

MF	Modelo con 3 CP	RMSE-trn	RMSE-val	epoch
Bell	3-3-3	58.99	109.93	150
Bell	3-3-3	57.80	103.21	180
Triangular	3-4-3	56.43	164.42	100
Triangular	3-3-4	45.30	87.91	100
MF	Modelo con 5 CP	RMSE-trn	RMSE-val	epoch
Triangular	3-2-2-2-2	31.53	117.31	100
Triangular	2-3-2-2-2	43.68	88.87	100
Triangular	2-2-2-3-2	33.89	57.94	100
MF	Modelo con 7 CP	RMSE-trn	RMSE-val	epoch
Triangular	2-2-2-3-2-2-2	0.151	118.07	100
Triangular	2-2-2-2-3-2-2	0.169	241.11	100
Triangular	2-2-2-2-2-2-3	0.154	278.56	100

Tabla 7. Resultados del modelo ANFIS.

En la Tabla 7, la primera columna corresponde al tipo de función de pertenencia utilizada en el modelo, la segunda columna corresponde al número de conjuntos borrosos definidos para cada una de las componentes, la tercera y cuarta columna corresponden al error RMSE en el grupo de entrenamiento y validación respectivamente, la última columna representa el número de iteraciones realizadas para alcanzar el error reportado.

El mejor resultado obtenido fue el modelo de 5 componentes principales y estructura 2-2-2-3-2 modelo tipo Sugeno de orden Cero. El número de parámetros del modelo es:

- Número de Nodos: 126
- Número de parámetros lineales: 48
- Número de parámetros no lineales: 33
- Número total de parámetros: 81
- Número de patrones de entrenamiento: 86
- Número de patrones de validación: 10
- Número de reglas borrosas generadas: 48

La Figura 2 muestra la serie original y el pronóstico que realiza el Sistema de inferencia borroso para los datos de entrenamiento con RMSE = 33.89 Gwh.




Figura 2. Valores de Demanda vs salida del modelo ANFIS grupo de entrenamiento.

La Figura 3, muestra la serie de valores de demanda real de energía y el pronóstico del modelo ANFIS con intervalos de confianza al 95% para el grupo de validación con RMSE = 57.94 Gwh, MAPE = 1.163%




Figura 3. Valores de Demanda vs salida del modelo ANFIS grupo de validación.

4.2 RESULTADOS DE LA RED NEURONAL ARTIFICIAL

Para este caso se probaron dos modelos, el primero utilizó las 15 variables de entrada originales estandarizadas y el segundo uso como variables de entrada las componentes principales. En ambos casos se incrementaron y disminuyeron las neuronas en la capa oculta con el fin de medir el desempeño de la red mediante la función de error. Esta iteración permite realizar la selección de la estructura óptima de la red.

4.2.1 RNA CON VARIABLES ORIGINALES

Se utilizan dos algoritmos de entrenamiento y se predice la demanda del próximo mes. Los resultados obtenidos se muestran en la Tabla 8 y Tabla 9.

- Algoritmo de Entrenamiento: Gradiente Descendente con tasa de aprendizaje fija $a=0.001$ y momentum $b=0.90$ (traingdm).
- Algoritmo de Entrenamiento: Gradiente Descendente con tasa de aprendizaje variable y momentum (traingdx).

Red	RMSE-trn	RMSE-val	epoch
15-14-1	93.97	62.61	12870
15-16-1	19.63	63.38	30000
15-18-1	23.76	58.12	21000
15-20-1	29.31	92.66	21000

Tabla 8. Resultados de la RNA con entrenamiento traingdm.

Red	RMSE-trn	RMSE-val	epoch
15-14-1	10.22	45.74	132
15-16-1	14.26	44.86	96
15-18-1	0.058	34.30	112
15-20-1	6.9	44.29	153

Tabla 9. Resultados de la RNA con entrenamiento traingdx.

En general las estructuras de red utilizadas tienen un error RMSE-val muy similar para cada algoritmo de entrenamiento, sin embargo se obtienen mejores ajustes cuando se usa el algoritmo de Entrenamiento de Gradiente Descendente con tasa de aprendizaje (a) variable y momentum (traingdx), además de minimizar el tiempo de procesamiento.

La estructura de red con mejor ejecución es la red 15-18-1. La Figura 4, muestra la serie de demanda de energía y la salida de la red para los datos de entrenamiento con RMSE = 0.058 Gwh.

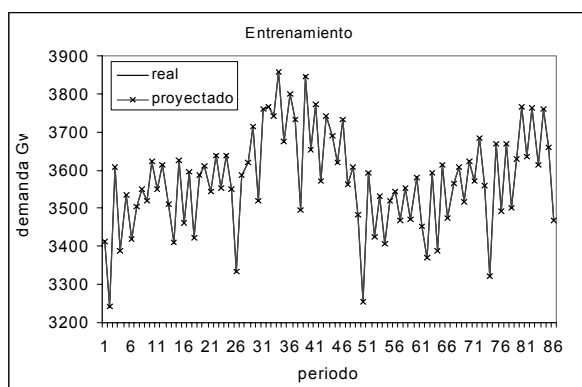


Figura 4. Valores de Demanda vs salida del modelo RNA grupo de entrenamiento

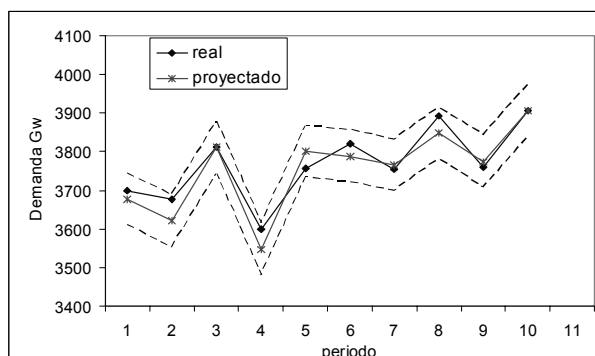


Figura 5. Valores de Demanda vs salida del modelo RNA grupo de validación

La Figura 5 muestra la serie de valores de demanda real de energía y el pronóstico de la red con intervalos de confianza al 95% para el grupo de Validación con RMSE = 34.30 Gwh. MAPE = 0.75%

4.2.1 RNA UTILIZANDO COMPONENTES PRINCIPALES

Para este caso las componentes principales se ingresan al modelo como variable de entrada. Se utilizan dos algoritmos de entrenamiento para predecir la demanda del próximo mes. Los resultados obtenidos con el algoritmo de Gradiente Descendente con tasa de aprendizaje fija $a=0.001$ y momentum $b=0.90$ (traingdm) se muestran en la Tabla 10.

Los resultados obtenidos con el algoritmo de entrenamiento basado en Gradiente Descendente con tasa de aprendizaje variable y momentum (traingdx) se muestran en la Tabla 11.

Los resultados indican que a medida se aumenta el número de componentes principales el ajuste mejora. Además ya no existe una diferencia tan marcada en el ajuste dependiendo del algoritmo de entrenamiento utilizado.

Red	RMSE-trn	RMSE-val	epoch
7-6-1	53.69	109.92	3000
7-8-1	54.44	66.28	3000
7-10-1	54.83	114.49	3000
7-12-1	50.29	94.335	3000
Red	RMSE-trn	RMSE-val	epoch
5-4-1	75.16	112.94	3000
5-6-1	68.61	126.06	3000
5-8-1	67.11	111.55	3000
Red	RMSE-trn	RMSE-val	epoch
3-2-1	75.8	156.91	538
3-4-1	128.33	203.64	195
3-6-1	78.52	156.54	457

Tabla 10. Resultados de la RNA con entrenamiento traingdm.

Red	RMSE-trn	RMSE-val	epoch
7-6-1	51.02	92.67	145
7-8-1	48.45	105.46	135
7-10-1	46.31	70.23	135
7-12-1	47.79	91.74	128
Red	RMSE-trn	RMSE-val	Epoch
5-4-1	62.78	113.28	145
5-6-1	59.89	61.73	97
5-8-1	39.33	50.29	182
Red	RMSE-trn	RMSE-val	Epoch
3-2-1	128.33	203.64	134
3-4-1	70.69	121.37	328
3-6-1	75.44	145.22	242

Tabla 11. Resultados de la RNA con entrenamiento traingdx.

La estructura de red con mejor ejecución es la red 5-8-1 entrenada con algoritmo de entrenamiento traingdx, la Figura 6 muestra la serie de demanda de energía y la salida de la red para los datos de entrenamiento con RMSE = 39.33 Gwh.




Figura 6. Valores de Demanda vs salida del modelo RNA grupo de entrenamiento

La figura 7 muestra la serie de valores de demanda real de energía y el pronóstico de la red neuronal con intervalos de confianza al 95% para el grupo de Validación con RMSE = 50.29 Gwh, MAPE=1.108%

4.2.3 ANALISIS DE LA CAPACIDAD PREDICTIVA.

En general la valoración de las predicciones se hace con base en el análisis de los errores y de que se cumpla el supuesto que el comportamiento pasado permanezca en el futuro. En términos generales un buen modelo genera unos errores cuyo comportamiento gráfico no presenta ninguna pauta regular, es decir deben presentar un comportamiento aleatorio y que su autocorrelación sea no significativa. En esta sección se presentarán los errores de los mejores modelos encontrados es decir la red neuronal artificial 15-18-1 y el modelo ANFIS (2-2-2-3-2).

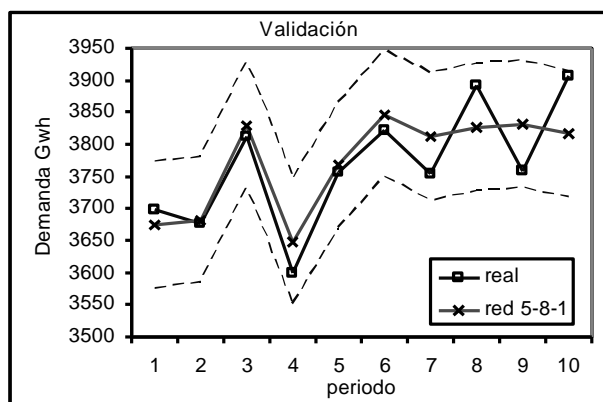


Figura 7. Valores de Demanda vs salida del modelo RNA grupo de validación.

El análisis de los errores para la red neuronal artificial 15-18-1 se muestra en la Figura 8, la cual indica un comportamiento aleatorio alrededor de la media.

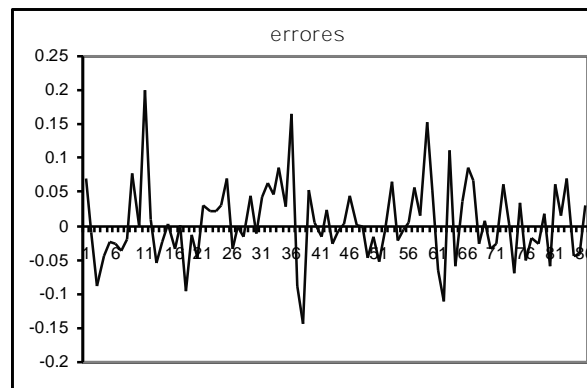


Figura 8. Comportamiento de los Residuales de la red neuronal

La Tabla 12 muestra la autocorrelación de los errores de la red neuronal, indicando que las correlaciones al rezago k son no significativas al 95% de nivel de confianza.

En forma similar el gráfico de dispersión de los errores del modelo ANFIS (2-2-2-3-2) se muestra en la Figura 9. Puede considerarse que se distribuyen de modo aleatorio alrededor del valor cero sin recoger restos de algún comportamiento sistemático.

Estimated Autocorrelations for demanda-prediccion				
Lag	Autocorr	Stnd. Error	Lower 95.0% Prob. Limit	Upper 95.0% Prob. Limit
1	0.016312	0.107833	-0.211349	0.211349
2	-0.0367929	0.107861	-0.211405	0.211405
3	-0.0366053	0.108007	-0.211691	0.211691
4	-0.036647	0.108151	-0.211973	0.211973
5	-0.210439	0.108296	-0.212256	0.212256
6	0.0483274	0.112951	-0.22138	0.22138
7	-0.072021	0.113191	-0.22185	0.22185
8	-0.0892433	0.113722	-0.222892	0.222892
9	-0.11379	0.114534	-0.224483	0.224483
10	0.144909	0.115841	-0.227045	0.227045
11	0.0143974	0.11793	-0.231139	0.231139
12	0.0678421	0.11795	-0.231179	0.231179

Tabla 12. Autocorrelación de los errores de la red neuronal artificial

La Tabla 13 muestra la autocorrelación de los errores del modelo ANFIS, indicando que las correlaciones al rezago k son no significativas al 95% de nivel de confianza.




Figura 9. Comportamiento de los Residuales del modelo Anfis

CONCLUSIONES

En este trabajo se predice la demanda de energía eléctrica Colombia basándose en dos modelos una Red Neuronal Artificial y un modelo ANFIS. Se comparó la ejecución de los modelos mediante la función de error RMSE. La Tabla 14 resume los resultados presentados en la sección anterior y además incluye una nueva medida de error MAPE. Como se indica en la Tabla 14, la Red Neuronal Artificial con 15 variables de entrada tiene una mejor ejecución que el modelo ANFIS. El error presentado es el obtenido sobre el grupo de Validación.

Estimated Autocorrelations for errores anfis				
Lag	Autocorr	Stnd.Error	Lower 95.0% Prob.Limit	Upper 95.0% Prob. Limit
1	-0.125999	0.107833	-0.211349	0.211349
2	-0.045145	0.109531	-0.214678	0.214678
3	0.243924	0.109747	-0.215102	0.215102
4	-0.020802	0.11588	-0.227121	0.227121
5	0.013140	0.115924	-0.227206	0.227206
6	0.031288	0.115941	-0.22724	0.22724
7	-0.170413	0.116039	-0.227433	0.227433
8	-0.091237	0.118913	-0.233067	0.233067
9	-0.082161	0.119725	-0.234657	0.234657
10	-0.080600	0.120379	-0.235938	0.235938
11	-0.254539	0.121004	-0.237165	0.237165
12	0.007036	0.127078	-0.249069	0.249069
13	0.003836	0.127083	-0.249078	0.249078
14	-0.014943	0.127084	-0.24908	0.24908
15	-0.164037	0.127104	-0.24912	0.24912
16	0.176248	0.129543	-0.253899	0.253899
17	0.134165	0.132301	-0.259307	0.259307
18	-0.045125	0.133874	-0.262389	0.262389

Tabla 13. Autocorrelación de los errores del modelo ANFIS

Modelo	Entrenamiento	RMSE-val	MAPE
Red 15-18-1 sin CP	traingdx	34.30 Gwh	0.75%
Red 5-8-1 con CP	traingdx	50.29 Gwh	1.108%
ANFIS 2-2-2-3-2	híbrido	57.94 Gwh	1.163%

Tabla 14. Resumen de resultados

El algoritmo de entrenamiento influye sobre el error alcanzado (precisión) en el entrenamiento de la red neuronal y en el tiempo de procesamiento. Mientras que el Algoritmo de Propagación hacia Atrás con momentum (función traingdm de Matlab) necesita más de 30000 iteraciones para obtener un error aceptable, el algoritmo de entrenamiento que permite modificar la tasa de aprendizaje a durante el entrenamiento (función traingdx de Matlab) necesita menos de 300 iteraciones. Por otra parte los resultados de la validación pueden variar si se seleccionan aleatoriamente los patrones en el grupo de entrenamiento y validación. Sería conveniente usar validación cruzada para verificar estos resultados.

Los modelos considerados son fáciles de implementar y producen una adecuada correspondencia entre las variables de entrada y salida a través del entrenamiento del modelo. Otra característica inherente a estos modelos es la flexibilidad con que el usuario construye las estructuras (seleccionando los parámetros y observa los resultados). Los modelos pueden captar la información de los

datos como llegan y se reduce el tiempo de análisis como ocurre con otros modelos econométricos.

ANFIS puede capturar variables lingüísticas propias de un sistema de Inferencia Borroso y además usa la capacidad de aprendizaje de las redes neuronales. Por lo tanto los sistemas Neuro-Borrosos están capacitados para modelar la incertidumbre, la imprecisión y el ruido subyacente en los datos así como incorporar la capacidad de aprendizaje de las redes neuronales.

En la bibliografía consultada se encontró que los modelos híbridos Neuro-Difusos ofrecen mejores resultados que las Redes Neuronales debido a su capacidad de razonamiento mediante las reglas Si-Entonces (sin embargo, esto depende del dominio del problema). Estos resultados no se verificaron, y en este estudio se encontró un mejor desempeño de las Redes Neuronales. Este resultado posiblemente sea consecuencia del número limitado de casos con que se cuenta para el entrenamiento y validación del modelo ANFIS. (El número de parámetros que debe calcular un modelo ANFIS es grande cuando se consideran más de 5 variables de entrada por lo que se requiere una base de datos suficientemente grande). No fue posible correr el modelo ANFIS con 15 variables de entrada, tampoco fue posible probar el modelo ANFIS tipo Sugeno de primer orden por la anterior razón.

Si se comparan los resultados de este estudio con los obtenidos en otro estudio de predicción de demanda mensual, puede observarse que se mejora en la predicción. Tamini y Egbert 2000, reportan un porcentaje de error absoluto medio (MAPE) de 2.924% usando una RNA y 2.277% usando un sistema híbrido FS-RNA para la predicción de la demanda mensual de energía en Wichita (EEUU). Lo que podría indicar que la inclusión en el modelo de otras variables explicativas ayuda a mejorar la predicción.

Las Redes Neuronal entrenadas con el vector de Componentes Principales mostraron la más pobre ejecución o ajuste. Además se requiere aumentar el número de componentes para mejorar la ejecución de la red. Parece que la combinación lineal de las variables originales para formar las componentes principales no es la adecuada, e indica la existencia de relaciones no lineales entre las variables. Podría aplicarse un método diferente de identificación de variables relacionadas de una manera no lineal, tal como el propuesto por Lin, Cunningham, Coggeshall 1996.

También se encontró que al aumentar el número de funciones de pertenencia de las variables de entradas para el modelo ANFIS, el modelo se ajusta muy bien (mínimo error) para el grupo de entrenamiento pero mal para el grupo de validación o pronóstico, indicando esto el sobre ajuste del modelo y la pobre capacidad de generalización.

El conjunto de reglas del modelo ANFIS generadas por el software puede ser analizado y reducido de tal forma que sólo existan las reglas que tengan sentido para el analista. Sin embargo este proceso se hace complicado cuando aumenta el número de variables de entrada al sistema, siendo el número máximo de reglas generadas igual a .

$$R = \prod_{i=1}^j N_i$$

Donde: N_i es el número de conjuntos borrosos definidos para la variable de entrada "i" y "j" es el número de variables de entrada.

Sería ventajoso eliminar (o mejor no crear) las reglas redundantes o contradictorias. Cordon, Herrera 1997 y Männle 1999 proponen métodos que pueden ayudar a reducir el número de reglas considerando las propiedades de integridad y consistencia.

Con respecto a otras técnicas de predicción de series temporales las cuales necesitan inicialmente ser desestacionalizadas, con modelos basados en redes neuronales o modelos neuro-difusas, este paso no es necesario; ya que la cualidad de aprendizaje que tienen estos modelos permite capturar la estacionalidad y la tendencia de los datos. Sin embargo, se deben incluir a priori variables de entrada que identifiquen el periodo que debe pronosticarse.

BIBLIOGRAFÍA.

- Aachen, Germany, September 1999; Verlag Mainz, Aachen.
http://maennle.org/manfred/index_en.html
- Abraham A, B. Nath A. Neuro-Fuzzy Approach for Modelling Electricity Demand in Victoria. *Applied Soft Computing*. 1 (2001) 127-138
- Ahmed R. Abdelaziz. A fuzzy-based power system reliability evaluation. *Electric Power Systems Research* 50 (1999) 1-5
- Al-Saba T, I. El-Amin. Artificial Neural Networks as applied to long term demand forecasting. *Artificial Intelligence in Engineering*. 13 (1999) 189-197
- Chanda R.S, P.K. Bhattacharjee. A reliability approach to transmission expansion planning using fuzzy fault-tree model. *Electric Power Systems Research* 45 (1998) 101-108
- Cordon O, F. Herrera. A tree stage evolutionary process for learning descriptive and approximate Fuzzy-Logic controller knowledge Bases from examples. *International Journal of Approximate Reasoning*. 1997-vol 17:369-407.
- De Falco I, A. Della Cioppa, E. Tarantino. Discovering interesting classification rules with genetic programming. *Applied Soft Computing* 1 2002-1: 257-269
- Haykin Simón. *Neural Networks*. A Comprehensive Foundation. IEEE PRESS. 1994
- Kwang-Ho Kim, J-K. Park, K-J Hwang, S-H. Kim. Implementation of Hibrid Short Term Load Forecasting System Using Artificial Neural Network and Fuzzy Expert Systems. *IEEE Transaction on Power Systems* 1995; 10(3): 1534-1539
- Lamedica R, A. Prudenzi, M. Sforna, M. Caciotta. A neural Network Based Technique For Short Term Forecasting of Anomalous Load Periods *IEEE Transaction on Power Systems* 1996; 11(4): 1749-1756
- Liu K, S. Subbarayan, R.R. Shoults, M.T. Manry, and other. Comparison of very Short term Load Forecasting Techniques. 1996; 11(2): 877-881
- Lin Y, G. Cunningham, S. Coggeshall. Input variable identification -Fuzzy curves and fuzzy surfaces. *Fuzzy Sets and Systems*, 1996 (82): 65-71
- Männle M. Identifying Rule-Based TSK Fuzzy Models. *Proceedings of EUFIT*, p. 286f,
- MATLAB. *Neural Network Toolbox User's Guide*. Release 12.
- Mori H, H. Kobayashi. Optimal Fuzzy Inference for Short Term Load Forecasting. *IEEE Transaction on Power Systems* 1996; 11(1): 390-396
- Shing J, R Jang, C-T. Sun, E. Mizutani. *Neuro Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall. 1997
- Soteris A. Kalogirou. Applications of artificial neural networks for energy systems. *Applied Energy* 67 (2000) 17-35
- Tamimi M, R.Egbert. Short term electric load forecasting via fuzzy neural collaboration. *Electric Power System Research*. 56 (2000) 243-248
- UPME, Unidad de Planeación Minero Energética. *Proyecciones de Demanda de energía Eléctrica y potencia máxima 2002-2011*. Nov. 2002.
- Paginas WEB:
www.greg.gov.co
www.upme.gov.co
www.isa.com.co
www.noaa.gov
www.ecopetrol.com.co
www.banrep.gov.co
www.dnp.gov.co
www.dane.gov.co