

ARTIFICIAL INTELLIGENCE IN FORECASTING DEMANDS FOR ELECTRICITY: AN APPLICATION IN OPTIMIZATION OF ENERGY RESOURCES**INTELIGENCIA ARTIFICIAL EN PRONOSTICO DE DEMANDA DE ENERGIA ELECTRICA: UNA APLICACION EN OPTIMIZACION DE RECURSOS ENERGETICOS****Ing. Henry Omar Sarmiento Maldonado***, **Ing. Walter Mauricio Villa Acevedo******* Docente Politécnico Colombiano Jaime Isaza Cadavid.**

Estudiante Maestría Universidad de Antioquia. Grupo en Manejo Eficiente de Energía.

E-mail: phosm984@jaibana.udea.edu.co

**** Universidad de Antioquia.** Grupo en Manejo Eficiente de Energía.

E-mail: retwal@gmail.com

Abstract: This paper presents a current application of neural networks in the task of forecasting electricity demands in Colombia. They are used networks of the Multi Layer Perceptron (MLP) type with backpropagation training algorithms, and Radial Basic Function (RBF). The information available with time and hourly values of demands in megawatts (MW) is organized in such a way that the task of forecasting raises a problem of classifying information where previous networks have shown good performance. The task of organizing information, training, validation and prognosis are developed with Matlab programming.

Resumen: En este artículo se presenta una aplicación actual de las redes neuronales en la tarea de pronóstico de demanda eléctrica en Colombia. Se utilizan redes del tipo Multi Layer Perceptron (MLP) con algoritmos de entrenamiento Backpropagation, y Radial Basic Function (RBF). La información disponible de tiempo y valor de demanda horaria en megavatios (MW) es organizada de tal forma que se plantea la tarea de pronóstico como un problema de clasificación de información donde las anteriores redes han evidenciado un buen desempeño. La tarea de organización de la información, entrenamiento, validación y pronóstico son desarrolladas con programación en Matlab.

Keywords: Neural networks, forecasts, feedforward networks, artificial intelligence, electric power systems.

1. INTRODUCCIÓN

El esquema actual de mercado del sector eléctrico colombiano está regido por principios de: eficiencia a partir de la competencia y libre acceso a las redes (demanda y generación), incentivo a la participación privada, expansión y operación del sistema con base en señales económicas, y la operación integrada de recursos del Sistema Interconectado Nacional. Teniendo como base estos principios y acorde con el Código de Redes, el Consejo Nacional de Operación – C.N.O., ha adoptado mecanismos para garantizar la operación

segura, confiable y económica del Sistema Interconectado Nacional. En el C.N.O. tienen representación las diferentes empresas de generación, transporte y distribución de energía eléctrica del país.

Dentro de la operación propia del sistema con las características expuestas, se realiza el denominado despacho económico. El despacho económico entendido como una tarea de asignación de quién, en que periodo de tiempo, cuanta potencia y a que precio, utiliza como variables para dicha determinación: la oferta y disponibilidad diaria de

los generadores con resolución horaria, la proyección de demanda, las tablas de seguridad y, la topología del sistema (Marín, 2005).

Así pues, la información de la demanda a consumirse en un periodo de tiempo (pronóstico de demanda), con resolución de día y hora para una semana (requerimiento propio de nuestro sistema) con una alta exactitud, es determinante en lo económico, es decir en los sobrecostos operativos por la desviación (exceso o defecto) en el pronóstico de la demanda.

Según Hippert (2001) la predicción es una tarea difícil ya que:

- La carga eléctrica depende no solo del valor de la carga en un periodo anterior (una hora), también de la carga a la misma hora pero en el día anterior, y además de esta en la semana anterior.
- También depende de variables como: el clima (temperatura), épocas de año, tipos de día, etc.

Los modelos predictores de carga trabajados se pueden clasificar en tres grupos: primero, modelos de series de tiempo (El-Sharkawi, 1996) donde los modelos de carga son función de los valores pasados; segundo, los modelos causales donde la carga es modelada como una función de algunos factores externos como el clima y las variables sociales; y tercero, los modelos obtenidos con inteligencia artificial donde las redes neuronales (años 80) del tipo perceptron multicapa han logrado exactitudes altas a nivel de sistemas de potencia (Bunn, 1995; Shanti, 2002).

Las técnicas que aplican redes neuronales tienen su limitación, ya que el entrenamiento y respuesta depende de la información disponible que le permita tener en cuenta las diferentes variables presentes que determinan el comportamiento de la demanda en el tiempo y las relaciones existentes entre ellas.

En este artículo se aborda el problema de predicción de demanda en sistemas eléctricos de potencia para corto plazo, específicamente para una semana con resolución de día y hora, y que cumpla con la reglamentación vigente en el país. Se obtiene un esquema que involucra redes neuronales artificiales (RNA) para realizar la tarea de predicción con base en la información disponible. Y finalmente, se evalúa el desempeño propuesto frente a los valores reales de demanda. Como medio para medir el desempeño de la red neuronal, se toma el error porcentual con respecto a la demanda real histórica, para cada uno de los 168 periodos que contiene una semana (24 por cada día) así como, el error real (MW en exceso o defecto).

2. MODELOS MODERNOS DE PRONÓSTICO DE LA DEMANDA ELECTRICA

Los modelos modernos son los obtenidos con base en las técnicas de inteligencia artificial tales como: sistemas expertos, lógica difusa, redes neuronales, algoritmos genéticos, y combinaciones entre ellas.

Ante la dificultad en el trabajo con modelos estadísticos y sus limitaciones asociadas, además de los altos requerimientos computacionales en tiempo de ejecución y grandes espacios de memoria, y la necesidad de disponer de relaciones explícitas entre las variables utilizadas, surgieron como una alternativa los modelos basados en inteligencia artificial, específicamente con las redes neuronales, utilizando básicamente datos de carga demandada y temperatura y en algunos incluyendo factores como son los días festivos y fines de semana (Shanti, 2002).

Algunos trabajos se han desarrollado redes neuronales para la predicción de carga para uno y cinco días (predicción en corto tiempo), utilizando predictores locales de redes neuronales en la clasificación de la información para entrenar la red (Mallo, 2002; Drezga, et al, 1999).

Las redes del tipo perceptron multicapa han sido las más utilizadas en las tareas de pronóstico de demanda, se ha buscado en la mayoría de estos trabajos evaluar el menor número de capas ocultas en la red con optimo funcionamiento (Bunn, 1995).

En forma general no existe una sistematización de cómo se implementan estas redes, en cuanto a entradas, número de capas ocultas en la red multicapa y la cantidad de datos para el entrenamiento y la validación, ya que esto es consecuencia de las características de cada problema en particular.

3. REDES NEURONALES ARTIFICIALES

Las Redes Neuronales Artificiales (RNAs) son una forma de emular el sistema nervioso biológico en una de las características propias de los seres vivos: la capacidad de memorizar y asociar hechos. Hoy en día, las redes neuronales están siendo aplicadas a muchos problemas del mundo real tales como: aproximación de funciones, clasificación, reconocimiento de patrones, modelamiento, entre otros. La habilidad de las redes neuronales para aprender y aproximar relaciones entre las variables de entrada y salida, es independiente del tamaño y la complejidad del problema.

La arquitectura de una red neuronal se define según las formas de interconectar las neuronas estándar creando redes de formas diferentes. En general en la literatura se encuentran algunas arquitecturas fundamentales y ampliamente reconocidas, tales como las MLP y RBF.

3.1 Perceptron multicapa (MPL)

El perceptron multicapa es una red con propagación hacia delante, compuesta de varias capas neuronas entre la entrada y la salida de la misma; en esta estructura cada salida de la neurona es conectada a cada neurona de la capa subsiguiente, sin conexión entre neuronas de la misma capa. Una importante característica de las redes MPL con una sola capa oculta es que pueden aproximar hasta el nivel deseado cualquier función continua en un intervalo, por lo tanto, las MLPs son aproximadores universales de funciones. Ver figura 1.

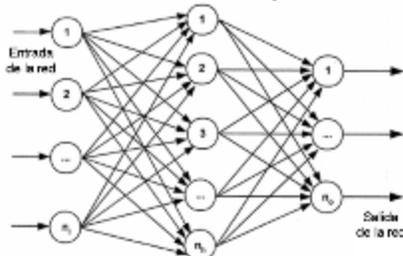


Fig. 1: RNA. MPL (Multi Layer Perceptron)

3.2 Red de Base Radial (Radial Basic Function, RBF)

Como puede observarse en la figura 2, la estructura de una red RBF es básicamente la misma de una MLP, la diferencia principal radica en que cada neurona es implementada como una función tipo Gaussiana. La habilidad de estas RBF es la capacidad de aproximar cualquier función continua con n funciones Gaussianas. La idea es centrar funciones de base radial alrededor de los datos a aproximar. La tarea para ajustar estas redes es encontrar el número funciones radiales necesarias, y los centros y anchos de estas. Al igual que las redes MLP tiene muchas aplicaciones en estudios de sistemas de potencia, y específicamente en pronóstico de demanda (El-Sharkawi, *et al*, 1996).

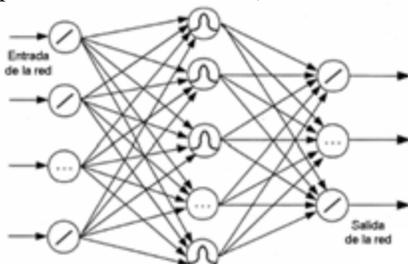


Fig. 2: RNA. RBF (Radial Basic Function)

3.3 Aplicación de redes neuronales en el pronóstico de demanda eléctrica

Existen diversas aplicaciones de redes neuronales en la predicción de demanda se encuentran en la literatura técnica (Hippert, 2001; El-Sharkawi, *et al.*, 1996). Aplicaciones relacionadas con los diferentes horizontes de predicción y teniendo muy en cuenta la selección de las variables de entrada. Características climáticas tiene principal importancia en países donde las estaciones son determinantes en el comportamiento de la demanda de la energía.

En el horizonte de 24 horas, se han realizado trabajos teniendo en cuenta no solo la predicción de demanda sino también la predicción de precios asociadas (Rocha, *et al.*, 2005; Radwan, 2004).

Utilizando redes MLP también para el horizonte de corto plazo (varios días), se ha seleccionado un amplio tipo de entradas, tales como: mes (variación estacional), día (festivos), temperaturas máximas y mínimas, humedades relativas máximas y mínimas, precipitación y nubosidad (García, *et al.*, 2003).

En el horizonte del muy corto plazo se han utilizado redes neuronales recurrentes con aprendizaje en línea, para evaluar su desempeño tratando de reducir tanto la estructura de la red como los tiempos de aprendizaje (Senjuy, *et al.*, 2002), aquí también es fuertemente dependiente de las condiciones climáticas estacionales.

Fidalgo, *et al.* (2005), presentan una aplicación donde consideran algunos comportamientos anormales que se encuentran en los datos históricos de la demanda de potencia, tales como días de fiesta, modificación en los hábitos de los consumidores tendientes a ahorrar energía, días atípicos, entre otros, los factores anteriores tiende a entorpecer el pronóstico de la demanda.

Adicionalmente, Ho Kim, *et al.* (2000), presentan combinación de técnicas de inteligencia artificial para la predicción de la demanda como son las redes neuronales y la lógica difusa, el propósito de esta aproximación es solucionar los problemas que causa los datos de demanda de días especiales.

Se han realizado también trabajos referentes a analizar la sensibilidad de los datos de entrenamiento en las bases de datos utilizadas para el entrenamiento de las redes en la predicción de demanda en sistemas de potencia (Ma, *et al.*, 1994), se enfatiza el tratamiento de datos y el efecto que producen los cambios abruptos en el clima y su efecto sobre las predicciones.

3.4 Pronóstico de demanda a realizar en relación con el código eléctrico.

De acuerdo con la reglamentación colombiana (C.R.E.G, Resolución 025, 1995), el pronóstico de demanda debe cumplir con un horizonte y una resolución, estos son: horizonte de una semana y resolución de día y periodo horario. También, según la misma reglamentación, se debe entregar el pronóstico a más tardar el día viernes a las 10 a.m., por lo cual los datos para entrenamiento no incluyen información desde el jueves al domingo anteriores a dicha semana como se muestra en la figura 3.

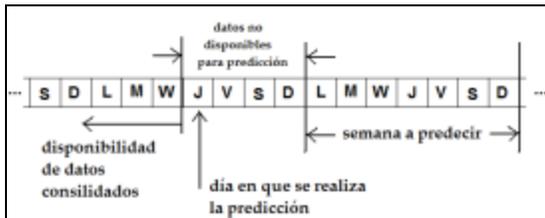


Fig. 3: Información disponible para pronóstico

4. APLICACIÓN DE LAS RNAs EN EL PRONÓSTICO: CASO COLOMBIANO

Para realizar el pronóstico de la demanda se organiza la información del comportamiento de la demanda real en Colombia, de forma tal que se pueda aproximar a un problema de clasificación de patrones. Actualmente se cuenta con una base de datos consolidados de demanda con resolución horaria. Esta base contiene datos de varios años anteriores (junio de 2004 hasta junio de 2007), datos suministrados por el Centro Nacional de Despacho-CND. Se asocia a esta base clasificación de días normales, días festivos, periodos de vacaciones de fin de año, periodo de semana santa. Podemos observar en la figura 4 el comportamiento de la demanda para una semana normal en la región, semana comprendida entre lunes 24 y domingo 30 enero de 2005.

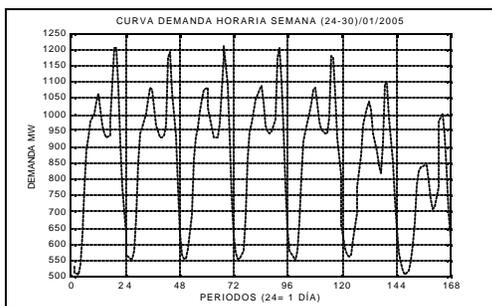


Fig. 4: Comportamiento de la demanda para una semana normal

La anterior es una curva típica de demanda de potencia en la región Antioquia-Choco.

4.1 Método propuesto para predicción de demanda con base en RNAs y clasificación de la demanda.

La demanda en la región Antioquia-Choco presenta comportamientos que han sido evidenciados y corroborados desde la información disponible, esto conlleva a que se clasifiquen básicamente en 5 grupos y que para cada grupo se proponga un predictor (P1, P2, P3, P4 y P5 son los predictores correspondientes a cada grupo), estos grupos son:

- Demanda en semanas normales. Este es el grueso de las semanas de predicción en el año.
- Demanda en semanas con lunes festivo: lunes y martes cambian su comportamiento por efecto del festivo. Los demás días siguen un comportamiento normal.
- Demanda en semanas dentro del periodo de vacaciones.
- Demanda en semana correspondiente a Semana Santa.
- Demanda en semanas con días festivos diferente de lunes.

La estructura del predictor de demanda presentada en la figura 5, se plantea teniendo en cuenta la clasificación anterior. De acuerdo con la figura 5, una base de datos general esta disponible para ser utilizada según el tipo de semana a predecir. Definido el tipo de semana, el predictor selecciona su base de datos. Esta base de datos es la información de entrada para el entrenamiento de la red neuronal. Se realiza el entrenamiento de la red neuronal y luego se le evalúa para una semana. Esta evaluación constituye el pronóstico de demanda.

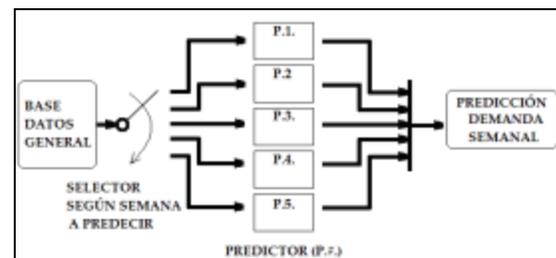


Fig. 5: Estructura del predictor propuesto

4.2 Implementación de la red neuronal.

Para la selección de la red neuronal a incluir en los predictores se llevo a cabo el siguiente procedimiento.

- Se tomó como base la predicción de una semana normal. El caso específico es el de la

semana que comienza el lunes 30 de enero de 2006.

- Se toman los datos reales históricos para la semana a predecir, que se utilizarán como medio de comparación para evaluar el desempeño del predictor.
- Se evalúan redes tipo MLP (“feedforward – backpropagation”) y RBF. La estructura de la red de acuerdo con los datos disponibles tiene dos entradas (periodo del día, y día de la semana) y una salida (la demanda).
- Se realizó la normalización de los datos que se ingresan al sistema neuronal entre -1 y 1. Las funciones de activación para la capa de entrada, la capa oculta y la capa de salida de la RNA, se escogieron entre las funciones logsig, tansig o purelin. El algoritmo de entrenamiento para el sistema es el “backpropagation”; este algoritmo presenta diferentes variantes del toolbox (Demuth, y Beale, 1998), que da la posibilidad de cambiar algunos parámetros que permiten entrenamientos más rápidos y con buenos resultados, como lo es el entrenamiento Levenberg-Marquardt (trainlm), el método del gradiente descendiente (traingd), con rata de aprendizaje adaptativa (traingdx) y con regulación Bayesiana (trainbr). El criterio de parada del entrenamiento son el número de epochs y el error objetivo (Haykin, 1994).
- Se realizan un grupo de entrenamientos y validaciones para definir las mejores configuraciones de RNA. Se tomaron redes de 2, 3 y 4 capas. Sobre estas se evaluaron varios números de neuronas en cada capa, diferentes funciones de activación, y diferentes algoritmos de entrenamiento. Y se comparo la respuesta de redes tipos MLP y RBF. Se evaluó también el desempeño de la una sola red para la predicción de toda la semana y dos redes, de estas dos una para predicción de lunes a viernes, y la otra para predicción de sábado y domingo. Algunos resultados de entrenamientos se observan en la tabla 1.

Tabla 1. Cuadro de resultados de entrenamientos para selección de red

No de capas	Mayor Error Validación (%)	Menor Error Validación (%)	Mayor error en MW	Menor error en MW
3	4,811	0,023	47,77	0,227
3	4,666	0,012	46,28	0,1
3	4,661	0,012	46,28	0,102
3	4,661	0,012	46,28	0,102

- Se decide con base en lo anterior la red o redes neuronales, el número de capas y número de neuronas asociadas, funciones de activación y algoritmo de entrenamiento. Esto teniendo en cuenta como medida de buen desempeño de la red: los errores absolutos y relativos en los resultados de la predicción con respecto a los datos históricos reales. Ver tabla 1.

Las redes de dos capas presentaron respuestas buenas y malas. Su buen desempeño no se puede generalizar, por esto son descartadas. Las redes implementadas con 3 capas, en conjunto presentaron en la mayoría de los casos, los menores errores en predicción, descartándose aquí las redes de 3 capas con un número reducido de neuronas por capa. También, en conjunto estas redes de 3 capas alcanzaron bajos errores de entrenamiento en el aprendizaje de la información. Las redes de 4 capas no presentaron ninguna ventaja frente a las de 3 capas, por lo cual también son descartadas.

4.3 Validación

En este proceso se tomó la configuración ya establecida de la RNA (MLP o RBF), que entrenada permite una respuesta adecuada para el pronóstico de la demanda. Esta validación tiene como referencia los datos reales de demanda con los cuales se puede comparar la información entregada por la red.

Se realizaron pronósticos para cada mes desde enero de 2006 a junio de 2007.

Se presentan en las figuras 6, 7 y 8 una muestra de resultados gráficos, que permite fácilmente ver las predicciones entregadas por la RNAs en comparación con los datos reales históricos. Como se puede observar en las graficas se presenta secciones en las curvas donde la aproximación realizada por la red presenta una diferencia a considerar, esta corresponde a los periodos de máxima demanda en el día. En la figura 7 la mayor diferencia se encuentra para el lunes dada su característica de festivo, y por esta misma característica se evidencia la dificultad de la RNA para obtener bajos errores en su pronóstico.

Para la temporada de vacaciones (ver figura 8) se presenta una mayor dificultad en el pronóstico debido a que este periodo presenta comportamientos muy atípicos en los datos de la demanda, por lo cual dificulta la respuesta de la RNA.

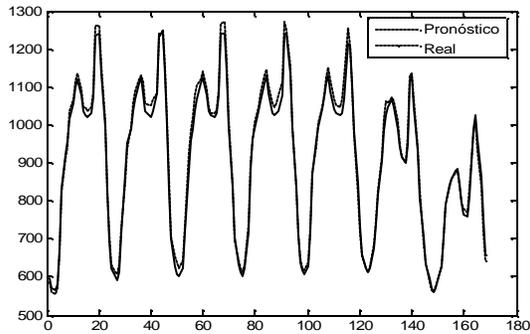


Fig. 6. Predicción vs. Comportamiento Real en Semana Normal. [14/05/2007]

Como se observa en la figura 6 la mayoría de los datos (95%) de predicción entregados por la RNA se encuentran por debajo de 4% y el total por debajo del 8 %, estos resultados son buenos comparados los resultados obtenidos por métodos tradicionales utilizados para el pronóstico en la región mencionada de los cuales se tiene referencia.

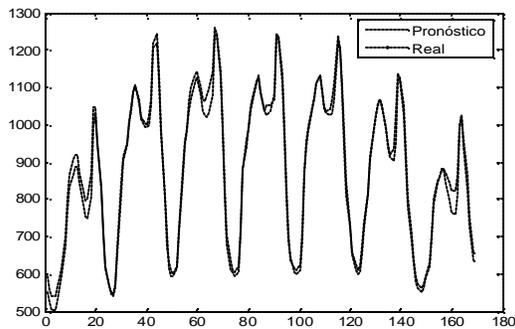


Fig. 7. Predicción vs Comportamiento Real en Semana con Lunes Festivo. [21/05 2007]

Para la semana con el lunes festivo (figura 7) se observó que los errores están por debajo del 14% pero esto corresponde en mayoría a los datos del día lunes y el grueso de los datos están por debajo del 6%.

Para el periodo de vacaciones (figura 8) el error máximo en un dato es del 19% y el grueso de los datos esta por debajo del 14%.

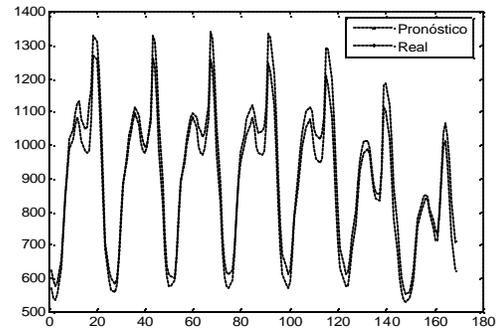


Fig. 8. Predicción vs. Comportamiento Real en Semana de Vacaciones. [18/12/2006]

5. CONCLUSIONES

La automatización del proceso de pronóstico para semanas normales utilizando inteligencia artificial, su buen desempeño, y teniendo en cuenta que es el mayor número de tipos de semana a predecir en el año, constituye una herramienta poderosa para la tarea del pronóstico.

El predictor que involucra redes neuronales para la predicción en semanas normales, es confiable y mejora los resultados obtenidos comparados con otros predictores.

El predictor que involucra redes neuronales para la predicción en semanas con lunes festivo, presenta resultados confiables. Teniendo en cuenta, que su mejor comportamiento se obtuvo cuando disponía de mayor amplitud en la base de datos con información coincidente para este tipo de semana.

Los predictores que involucra redes neuronales para la predicción en semanas con festivo diferente de lunes, semana santa y semana de vacaciones, presenta resultados deficientes. Teniendo en cuenta de que no se dispone de mayor una amplitud en la base de datos con información coincidente para este tipo de semanas.

Los pronósticos semanales, obtenidos por dos redes (una red para lunes a viernes, otra para sábado y domingo) presentaron mejores resultados que una sola red para la semana completa. Igualmente las RBF presentaron un desempeño aceptable, pero no igualaron ni mejoraron las MLP con la estructura propuesta.

REFERENCIAS

- Marín, G. (2005). Operación y Control de Sistemas Eléctricos de Potencia (Notas de Clase). Universidad de Antioquia. Medellín.
- Hippert, H.S. (2001) Neural Networks for short-term Load Forecasting. A review and Evaluation. En: *IEEE Trans. on Power Systems*, IEEE Vol. 16, No. 01. Piscataway, NJ.
- El-Sharkawi, M. (1996). *Artificial Neural Networks with Applications to Power Systems*. IEEE Power Eng. Society. Piscataway, New Jersey.
- Shanti, K. and Satish, B. (2002). Integrated ANN Approach to Forecast Load. En: *IEEE Computer Applications in Power*. pp. 46-51. IEEE, N.J.
- Bunn, D.W. (1995). *Comparative Models for Electrical Load Forecasting*. Wiley&Son, N.Y.
- Mallo, C. (2002). *Predicción de la demanda eléctrica horaria mediante redes neuronales artificiales*. Univ. De Oviedo. España.
- Drezga, I., et al. (1999). Short term load forecasting with local ANN predictors. En: *IEEE Trans. on Power Systems*. Vol 14, No 3. IEEE, N.J.
- El-Sharkawi, M. et al. (1996) System Load Forecasting: The U.S. Perspective. En: *Artificial Neural Networks with Applications to Power Systems*. Cap. 7, IEEE Power Eng. Soc., N.J.
- Rocha, A., et al. (2005). Feature Extraction via Multiresolution Analysis for Short Term Load Forecasting. En: *IEEE Trans. Power Systems*., Vol. 20, No.1, IEEE, N.J.
- Radwan, A. (2004). Short-Term Load Forecasting using Abductive Networks. En: *IEEE Trans. Power Systems*. Vol20, no1, IEEE, N.J.
- García, D. et al. (2003). Predicción de la demanda eléctrica de corto plazo mediante redes neuronales artificiales. En: *SIE.*, Habana, Cuba.
- Senjuy, T. et al. (2002). One Hour Ahead Load Forecasting Using Neural Networks, En: *IEEE Trans. Power Systems*., Vol. 17, no 1. IEEE, N.J.
- Fidalgo, J. N. et al. (2005). Load Forecasting Performance Enhancement when Facing Anomalous Events. En: *IEEE Trans. Power Systems*., Vol. 20, no 1, IEEE Piscataway, N.J.
- Ho Kim, K. et al. (2000). Short-Term Load Forecasting for Especial Days in The Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method. En: *IEEE Trans. Power Systems*., Vol. 2, no 15, IEEE, N.J.
- Ma, H. et al. (1994). Training Data Sensitivity Problem of Artificial Neural Network Based Power System Load Forecasting. En: *Proceedings 26th S. Symposium on System Theory*. pp. 650-652. IEEE Piscataway, N.J.
- C.R.E.G, Resolución 025. (1995). *Código de Operación del Sistema Eléctrico Colombiano*. Bogotá.
- Demuth, H. and Beale, M. (1998). *Neural Network Toolbox User's Guide for Matlab*, Mathworks, USA.
- Haykin, S. (1994). *Neural Networks a Comprehensive Foundation*. P-Hall Int., N.Y.