

PRONÓSTICO DE CARGA A CORTO PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES

RESUMEN

El presente artículo hace un recuento acerca de la carga eléctrica (energía eléctrica), su comportamiento y las variables que se involucran en la realización de un sistema que haga el pronóstico de esta. Posteriormente se plantea una técnica de pronóstico basada en redes neuronales artificiales, haciendo una corta descripción y proponiendo un modelo.

JAIRO A. MENDOZA VARGAS

Ingeniero Electricista
Profesor Asistente
Universidad Tecnológica de Pereira
jam@utp.edu.co

PALABRAS CLAVES: Pronóstico de carga, redes neuronales.

ABSTRACT

This paper review the concept of the electric load (electric energy), its behavior and its variables that concern on a system for short term load forecasting (STLF). Then is introduced a forecasting technique based on artificial neural networks with a short description and proposing a model of it.

KEYWORDS: Load forecasting, artificial neural networks.

1. INTRODUCCIÓN

En el entorno de la Ingeniería Eléctrica el término de carga es común a muchos significados; está el que se asocia a propiedades de las partículas como los electrones o protones (carga eléctrica), como también, la potencia eléctrica que se pone a disposición de un usuario o grupo de usuarios (carga instalada). En este trabajo se define carga como la demanda de energía eléctrica en el tiempo, dada en unidades de watts hora (Wh).

La predicción de carga a corto plazo es una de las funciones más importantes en la operación de sistemas de potencia, ya que es fundamental en la planeación de la cantidad de energía que se deben generar para alimentar eficientemente un país, región o ciudad. La inadecuada planeación conlleva desperdicio de recursos al generar significativamente más de lo que realmente se consume ó generando menos de lo que verdaderamente se necesita, ocasionando fallos operativos al sistema ó demanda no atendida para el peor de los casos. Lo anterior está al nivel de centrales generadoras; en el ámbito de empresas distribuidoras se compran paquetes de energía para un periodo determinado, el cual debe suplir la demanda del total de clientes que ellas posean; si la energía comprada no es suficiente, se ven obligadas a comprar lo faltante al precio que el generador o el mercado determine, ó dejar de atender la demanda. Esto último acarrea sanciones a la empresa. Si la energía adquirida es mayor a la demanda real, el sobrante se desperdicia o se negocia en condiciones propuestas por el mercado, en la mayoría de las veces desfavorables para ella. Igualmente el mal cálculo de las cantidades de energía puede acarrear sanciones de diversos tipos para la empresa prestadora del servicio.

El siguiente artículo es fruto del proyecto de grado: "Predicción de carga a corto plazo utilizando redes neuronales artificiales" [7], el cual fue asesorado por el ingeniero Harold Salazar Isaza. Este trata el problema del pronóstico de demanda a corto plazo, conocido en la literatura especializada como STLF que en inglés se reconoce con la sigla de Short Term Load Forecasting. El propósito central del trabajo es la implementación de un sistema de predicción de carga a corto plazo basado en redes neuronales artificiales, para una región como la ciudad de Pereira, la cual se adapte a las necesidades de la zona y utilizando datos de carga reales de la Empresa de Energía de Pereira.

2. CONTENIDO

2.1 Descripción general

Los métodos de predicción de carga se pueden dividir dentro de: muy corto, corto, mediano, y largo plazo. En muy corto plazo el periodo de tiempo abarca algunos minutos, mientras que a largo plazo el periodo es de algunos años o décadas. El periodo de interés de este trabajo es a corto plazo, y va desde unas horas hasta una semana.

El modelamiento de la demanda a corto plazo es muy complejo, involucra variables que influyen en los hábitos de consumo de las personas, tales como el clima, el tipo de día, la estación del año, variables sociales, etc. La predicción de carga a corto plazo, es uno de los problemas mas ampliamente atendidos en la literatura de sistemas de potencia, donde se han propuesto variadas metodologías que a lo largo del artículo se mencionarán.

Las técnicas inteligentes como redes neuronales artificiales se presentan como un valioso instrumento a la

hora de predecir demanda, por sus cualidades de aprendizaje que las hacen susceptibles a todas las variables que afectan los hábitos de consumo de personas y empresas.

2.1.1 Redes neuronales artificiales

“Redes neuronales artificiales son redes conectadas masivamente en paralelo de elementos simples (usualmente adaptivos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico”. [1].

En resumen, las redes neuronales artificiales son modelos inspirados en el sistema nervioso biológico. Son elementos simples trabajando en paralelo y altamente interconectados. Se puede entrenar una red neuronal artificial para que realice una función específica mediante el ajuste de los valores de interconexión entre las neuronas. Estos valores de interconexión se denominan pesos.

La neurona artificial es un modelo matemático inspirado en la neurona biológica. Las redes neuronales artificiales son modelos que intentan reproducir el comportamiento del cerebro. El modelamiento de la neurona biológica es relativamente sencillo. Se compone de una entrada p , un valor de peso w , un bias b (este valor tiene como justificación, el permitir que la neurona artificial mueva su frontera de decisión, que es una recta, de tal forma que no pase por el origen), una función de suma Σ , una función de activación f y una salida a (ver figura 1).

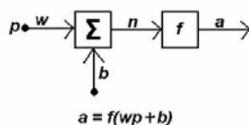


Figura 1. Esquema de la neurona artificial

La figura 1 muestra la representación de una neurona artificial, muchas de estas neuronas interconectadas forman una red neuronal. Se aprecia que la única entrada del exterior es p , el cual se multiplica con un valor específico de cada neurona w (peso); estos son llevados a una sumatoria con otro valor propio de la neurona denominado b . El valor resultante se lleva a través de f (función de activación o de transferencia), de donde sale el valor resultante que es transmitido a la siguiente neurona ó al exterior.

De acuerdo al número y a la distribución de las neuronas artificiales, ellas conforman capas o niveles (figura 2). Capa o nivel se conoce al conjunto de neuronas cuyas entradas provienen de la misma fuente (que puede ser otra capa de neuronas) y cuyas salidas se dirigen al mismo destino (que puede ser otra capa de neuronas).

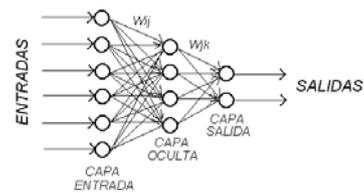


Figura 2. Red neuronal multicapa típica

Una red neuronal artificial es la interconexión de varias neuronas. La figura 2, muestra una red neuronal estructurada en capas; es una de las cuantas estructuras en la cual se pueden asociar las neuronas. En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el tipo y número de conexiones entre neuronas.

Luego de conformar el esquema de la red neuronal, se procede a la etapa de aprendizaje de la red. Por lo general las redes neuronales aprenden por medio de ejemplos, los cuales comúnmente se presentan a la red en patrones de entrada y salida.

En la etapa de aprendizaje o entrenamiento, se procura por que la red asimile todos los ejemplos, logrando que generalice los patrones, es decir, que a unas entradas determinadas, la red neuronal responda con valores lógicos esperados y no que solo memorice los ejemplos, dando respuestas aleatorias o erróneas.

Las redes multicapa son aquellas que disponen de conjuntos de neuronas agrupadas en varios niveles o capas. Normalmente todas las neuronas de una capa reciben señales de entrada de otra capa anterior, más cercana a la entrada de la red, y envían señales de salida a una capa posterior, más cercana a la salida de la red. A estas últimas se les denominan redes neuronales con conexiones hacia delante o feedforward. Este tipo de redes solo poseen conexiones hacia delante, no tienen conexiones laterales ni hacia atrás, y es la estructura que más comúnmente es utilizada en aplicaciones tales como, el pronóstico y el modelamiento de sistemas entre muchas otras.

2.1.2 Propiedades de la curva de carga

El comportamiento de la curva de carga es irregular y está dado por la relación de demanda contra tiempo. En este escrito el tiempo comúnmente se refiere en horas.

Cuando se toman datos de demanda de una población la cual incluye usuarios residenciales e industriales, los gráficos de carga contra tiempo presentan los picos en las horas de mayor consumo, que por lo general son las del medio día y las del anochecer; los valles en las de menor consumo, casi siempre en la madrugada (0 – 5 horas aprox.). Esto claramente se observa en la Figura 3. En la práctica, en la ciudad de Pereira, solo se considera un

pico, correspondiente a las horas 7 a 9 de la noche aproximadamente.



Figura 3. Curva típica de carga en un día para una ciudad

La Figura 3 muestra como es el perfil de carga típico para un día corriente en una ciudad pequeña como Pereira; se muestra como es la relación de carga con cada una de las horas del día; también esta curva puede relacionarse con los días de la semana y meses del año, presentando la misma irregularidad. Esta irregularidad se debe a horas, días o meses, en los que se consume más o menos, cantidades de energía. La figura 4 entrega el perfil de carga para una ciudad pequeña mes a mes. La figura 5 enseña el perfil de carga de los día a día durante un año.

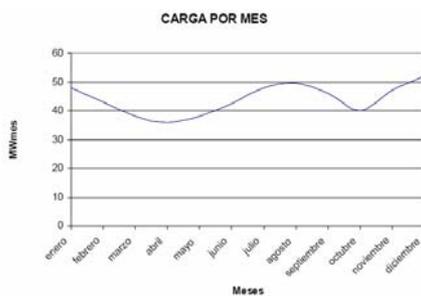


Figura 4. Perfil de carga típico para los doce meses del año.

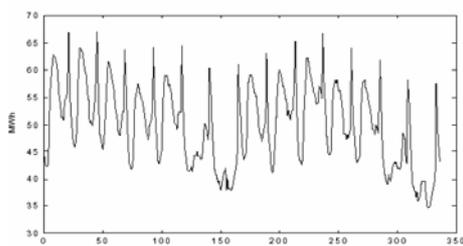


Figura 5. Perfil de carga día a día durante un año.

Las curvas de demanda muestran claramente un comportamiento cíclico o un ritmo diario de la demanda, o sea, las 12 horas de un día tiene una conducta similar a las 12 horas del día anterior; lo mismo con el lunes de una semana tiene características similares al lunes de la semana anterior. Estos comportamientos son directamente proporcionales a la conducta de las personas. La mayoría de las personas duermen en las horas de la noche, por ello la demanda de esas horas es la menor; las horas laborales, las de comida e inclusive las

horas de estar en casa y ver televisión, establecen ritmos cíclicos de consumo de energía eléctrica.

Los ritmos cíclicos son diferentes, dependiendo de la época del año ó la estación en que se encuentren; también se deben considerar diferentes tipos de día, tales como los fines de semana, días laborales, días festivos, fines de semana con festivo, etc. En Colombia se presentan muchas veces los fines de semana con lunes festivo, los cuales presentan un comportamiento especial desde el mismo viernes.

2.1.3 Métodos clásicos para pronóstico de carga a corto plazo

La predicción de carga obedece a un proceso aleatorio no estacionario conformado por miles de componentes individuales; además el rango de posibles soluciones al problema del pronóstico es amplio. Usualmente la única posibilidad de tener una vista del problema, es tratar de modelar el futuro como una reflexión de su comportamiento previo. Esto deja el campo abierto a muchas soluciones.

Algunos de los métodos clásicos más comunes para la determinación anticipada de la cargas referenciados en [2], [3] y [4] son los siguientes:

- Regresión lineal múltiple
- Series de tiempo estocásticas
- Frecuencia exponencial uniforme
- Método de estado – espacio

La mayoría de estas metodologías están relacionadas con procesos estadísticos.

2.2 Implementación de un sistema de pronóstico a corto plazo mediante redes neuronales artificiales

En la mayoría de la literatura científica, los autores proponen el uso de redes perceptron multicapa o backpropagation¹, para problemas relacionados con predicción, debido a que estas redes asimilan fácilmente el comportamiento no lineal de un sistema. Sin embargo hay otros diseños de redes neuronales que también han sido implementados con el mismo propósito; implementaciones de redes con conexiones laterales, recurrentes, etc.

¹ En [7] página 78 se presenta una tabla que relaciona artículos internacionales de revistas IEEE sobre autores que han tratado el tema del pronóstico a corto plazo mediante redes neuronales artificiales.

La mayoría de los autores, en la literatura especializada, toman sus criterios de diseño sobre las bases de pruebas empíricas y simulaciones; a continuación se presentan cuatro tareas que pueden generalizar el proceso de diseño de una red neuronal artificial [5]:

- Pre-procesamiento de los datos
- Diseño de la red neuronal
- Implementación
- Validación

2.2.1 Pre-procesamiento de datos

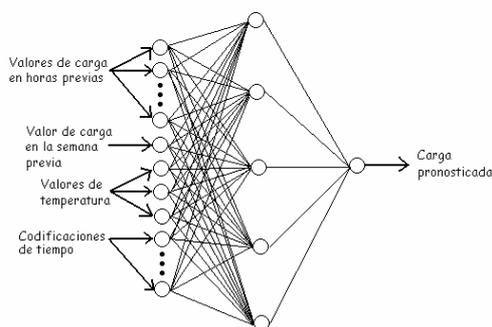
El pre-procesamiento de los datos es fundamental porque reduce el set de entrada, ya que la complejidad de la red tiene un comportamiento exponencial de acuerdo a la dimensión del vector de entrada. Adicionalmente el pre-procesamiento limpia el conjunto de datos de entrada de elementos anómalos, o sea, datos irregulares² cuya presencia puede afectar el correcto comportamiento de la red.

2.2.2 Diseño de la red neuronal

A la hora de escoger la arquitectura de red neuronal, la mayoría de los autores se han casado con la utilización de la red perceptron multicapa o backpropagation, tipo feed-forward³; la gran parte de ellas totalmente conectadas, es decir, cada neurona en una capa conecta cada neurona de la capa subsiguiente. Operacionalmente más de una capa intermedia no mejora los resultados en el pronóstico.

2.2.3 Implementación de la red neuronal artificial

Una red neuronal artificial puede tener una arquitectura muy variada, cada diseño es particular de la aplicación deseada; cada zona tiene sus condiciones especiales y en base a ellas se debe generar la implementación más adecuada.



² El sistema de pronóstico no prevé comportamientos anómalos en el consumo de carga de la población, ocasionados por eventos poco frecuentes tales como interrupciones del servicio.

³ En [8] se encuentra una buena descripción de las redes backpropagation.

Figura 6. Distribución de entradas de la red neuronal artificial

Como muestra la figura 6, una red neuronal artificial posee neuronas de entrada especializadas en un tipo de datos, donde en la figura estas son para valores de carga previos, condiciones de temperatura⁴ y las codificaciones de tiempo. El diseño de la red neuronal de la figura 6, consideró una sola neurona de salida (una hora a la vez), otros diseños pueden tener una capa de salida conformada por 24 neuronas con las cuales se pueden formar perfiles de carga de 24 horas.

Se debe entrenar la red neuronal utilizando datos reales del sistema al cual se quiera pronosticar, ya que la función de la red es la de asimilar y emular la demanda de energía de una región determinada.

2.2.4 Validación

La red neuronal se debe entrenar con un set de datos, pero se debe reservar un amplio conjunto de datos con los cuales se puedan realizar pruebas y validaciones de pronóstico. Las comparaciones entre los datos reales y los obtenidos con la red mostrarán el éxito o fracaso del entrenamiento de esta.

2.3 Modelo específico para pronóstico

En la aplicación específica se decidió generar perfiles de carga por día determinado ya que cada día tiene sus características particulares, es decir, el día lunes tiene un comportamiento típico diferente al día viernes y así todos los días entre si. Inclusive la carga del día depende de la semana del mes en la que esté ubicado.

En la figura 7 se aprecian cuatro perfiles de carga de un mismo día en diferentes semanas del mes. Resalta un perfil que es muy inferior a los otros tres. Este perfil mas pequeño correspondió al comportamiento de la carga un día festivo⁵. Los días festivos comúnmente la población consume menos energía eléctrica y las empresas por lo general no laboran.

⁴ Las condiciones de temperatura son en extremo influyentes en regiones o países que presentan estaciones. En la estación de verano se dispara el consumo de aire acondicionado y en invierno, lo hace la calefacción eléctrica.

⁵ Se omiten fechas y días específicos para cuidar la reserva de la información que suministró la Empresa de Energía de Pereira.

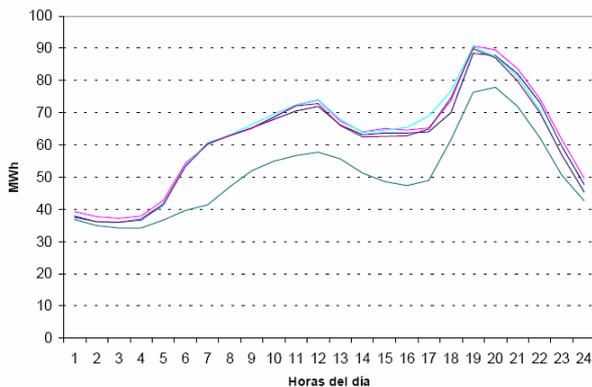


Figura 7. Perfil de carga típico para un día en el mes

2.3.1 Construcción

Se eligió utilizar una red neuronal por día de la semana, por ejemplo, el día lunes presenta una red de acuerdo a los patrones de entrenamiento que se escogieron para el determinado periodo del año y solo pronostica los lunes de ese periodo. También se hace lo mismo con los días restantes de la semana.

La estructura de la red neuronal mostrada en la figura 8 presenta unas neuronas de entrada, unas intermedias o ocultas, y unas neuronas de salida; el modelo que se escogió presentará siete neuronas en la capa de entrada, diecinueve neuronas en la capa intermedia, y una neurona en la capa de salida. Las siete neuronas de entrada se reparten en cinco, las cuales representan la hora en codificación binaria y las otras dos son valores de carga. No se tuvieron en cuenta entradas para temperatura, ya que en Pereira el clima es bastante parejo y no se presentan temperaturas muy bajas ni muy altas.

Al no existir delineamientos claros en la escogencia de los parámetros de la red como número de neuronas a la entrada, en la capa intermedia y a la salida; estas se obtienen de acuerdo a la necesidad y a la experiencia (en muchas ocasiones prueba y error). El modelo escogido necesitaba la especificación de la hora, por ello se pensó en utilizar codificación binaria (0's y 1's), que fuera desde 00001 representando la primer hora del día, hasta 11000 simbolizando la hora veinticuatro (figura 8 neuronas 1 a 5). Cada neurona comprende un bit del número binario. Las dos neuronas restantes reciben los valores de carga de ese mismo día y hora en las dos semanas anteriores a la que se busca pronosticar (figura 8 neuronas 6 y 7). El modelo se planteó con 19 neuronas ocultas, se observó un pequeño nivel de estabilidad en el algoritmo de entrenamiento con este número de neuronas en la capa oculta.

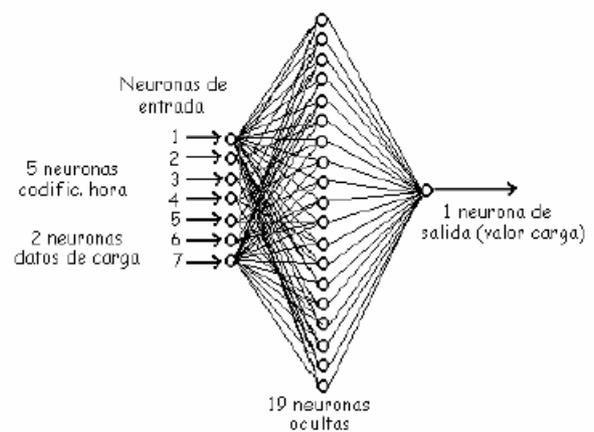


Figura 8. Diseño específico de la red neuronal artificial.

Respecto a la salida, solo fue necesario colocar una neurona, pues con ella se puede obtener los valores de demanda individuales de cada hora del día, para luego conformar el perfil de carga requerido del día a pronosticar.

2.3.2 Entrenamiento

El entrenamiento es la instancia en la cual se le presentan ejemplos a la red y ella los asimila reorganizando sus valores internos. La red neuronal utilizada es una tipo BACKPROPAGATION con algoritmo de entrenamiento LEVENBERG-MARQUARDT [9]. Para entrenar la red se utilizó la caja de aplicaciones de MATLAB “Neural Network Toolbox” [9].

Se debe tener en cuenta dos parámetros de entrenamiento los cuales son: iteraciones y tolerancia. Estos dos parámetros son muy importantes porque determinan la calidad de la red; si nos excedemos en las iteraciones o escogemos una tolerancia muy pequeña, se compromete el funcionamiento del sistema ya que puede causar un sobreentrenamiento que genere márgenes de error considerables.

2.3.3 Resultados

Para evaluar el comportamiento del sistema, se hicieron comparaciones de los perfiles obtenidos del sistema propuesto con los perfiles de los datos reales que no fueron tenidos en cuenta al hacer el entrenamiento de la red neuronal. Se manejaron dos indicadores de calidad de los resultados obtenidos, los cuales fueron: error medio (ecuación 1) y el error máximo⁶.

$$E_{medio} = \frac{1}{N} \sum_{i=1}^N \left[\frac{|\hat{C}_i - C_i|}{C_i} \right] \times 100\% \quad (1)$$

⁶ Diferencia máxima entre lo pronosticado y lo real, dada en porcentaje.

Donde,

N : Número de horas del día (24 horas)

\hat{C}_i : i -ésima carga pronosticada; es la salida que presenta la red frente a un set de datos de entrada.

C_i : i -ésima carga real; es el valor verdadero de carga.

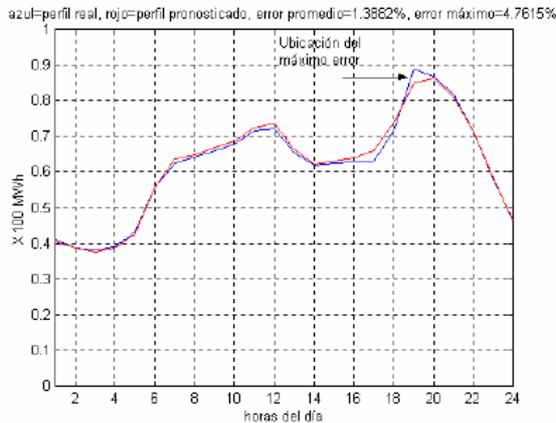


Figura 9. Verificación del comportamiento de la red neuronal entrenada.

La figura 9 muestra el resultado del pronóstico para un día de la semana; los errores máximo y medio se observan en la parte superior de la figura. Se aprecia que las líneas correspondientes a los perfiles de carga real y pronosticado se encuentran bastante cercanos, lo que prueba el excelente funcionamiento de la red neuronal en la predicción de la demanda de energía.

4. CONCLUSIONES

Las redes neuronales artificiales se muestran como una solución sencilla, eficaz y confiable a problemas tales como la predicción de demanda de energía eléctrica a corto plazo. Ellas han sido propuestas y estudiadas recientemente por muchos autores que han dado reportes favorables sobre su uso. En el mundo, la tendencia en el pronóstico de carga a corto plazo está dada en la utilización de técnicas que involucren inteligencia artificial, como es el empleo de redes neuronales artificiales e incluso modelos más complejos, híbridos con redes neuronales como son entre otros los neuro-difusos y neuro-estadísticos.

Existen diferentes modelos de redes neuronales artificiales, cada uno presenta características especiales para determinados problemas; para aplicaciones relacionadas con el pronóstico de demanda, la mayoría de los autores consultados en revistas IEEE coincidían en proponer la red Backpropagation. Esta red presentó excelentes resultados en cuanto a su aplicación en un modelo de pronóstico, como el expuesto en este artículo.

Cuando se efectúa la etapa de aprendizaje, se juega con el número de neuronas en la capa intermedia obteniendo resultados de rendimiento a través de pruebas,

concluyendo que el número de neuronas ocultas no es factor clave en el desempeño del pronóstico. Muy pocas neuronas compromete el éxito del sistema, muchas incrementa considerablemente los tiempos de entrenamiento con mejoras imperceptibles. En este proceso es definitiva la experiencia.

Respecto a los resultados en el pronóstico, este mostró evidencias interesantes en la asimilación del comportamiento de la carga, los errores fueron significativamente pequeños aunque no se hizo un contraste en los resultados de otra metodología.

5. BIBLIOGRAFÍA

- [1] KOHONEN, T. "An introduction to Neural Computing". Neural Networks, Vol.1, pags. 3-16, 1988.
- [2] MOGHAM, I. RAHMAN, S. "Analysis and evaluation of five short-term load forecasting techniques", IEEE Trans. Power Systems, vol. 4, no. 4, pp. 1484-1491, 1989.
- [3] PAPALEXOPOULOS, A. D. ESTERBERG, T. "A regression-based approach to short-term system load forecasting", IEEE Trans. Power Systems, vol. 5, no. 4, pp. 1535-1543, 1990.
- [4] HAGAN, M. T. BEHR, S. "The time series approach to short term load forecasting", IEEE Trans. Power Systems, vol. PWRS-2, no. 3, pp. 785-791, 1987.
- [5] STEINHERZ HIPPER, H. PEDREIRA, C. E. CASTRO SOUZA, R. "Neural Networks for Short-Term Load Forecasting: A Review and Evaluation". IEEE Transactions on Power System, Vol. 16, No 1, Febrero 2001.
- [6] MATHWORKS INC. *Matlab users guide*. Release 14. 2004.
- [7] MENDOZA VARGAS, J. "Predicción de carga a corto plazo utilizando redes neuronales artificiales". Trabajo de grado, Ingeniería Eléctrica, Universidad Tecnológica de Pereira. Pereira 2002.
- [8] RUMELHART, D. E., HINTON, G. E. WILLIAMS, R. J. "Learning internal representations by error propagation", in D. E. Rumelhart and J. L. McClelland, eds. *Parallel Data Processing*, vol.1, Cambridge, MA: The M.I.T. Press, pp. 318-362, 1986.
- [9] HAGAN, M. T., MENHAJ, M. "Training feedforward networks with the Marquardt algorithm," IEEE Transactions on Neural Networks, vol. 5, no. 6, pp. 989-993, 1994.
- [10] DEMUTH, H. BEALE, M. "Neural Networks Toolbox for use with MATLAB – User's guide Version 3.0" PDF, MATLAB 5.3, 1999.