

MAPEO CURVAS TÍPICAS, DEMANDA DE ENERGÍA ELÉCTRICA DEL SECTOR RESIDENCIAL, COMERCIAL E INDUSTRIAL DE LA CIUDAD DE MEDELLÍN, USANDO REDES NEURONALES ARTIFICIALES Y ALGORITMOS DE INTERPOLACIÓN.

Fecha de Recepción: Diciembre 10 de 2006
Fecha de Aceptación: Enero 11 de 2007

Héctor A. Tabares *
Jesús A. Hernández **

RESUMEN.

Uno de los principales problemas que se tienen para modelar el consumo de energía eléctrica en un lugar determinado, consiste en la extracción del conocimiento cuando éste se encuentra almacenado en grandes volúmenes de información como, por ejemplo, registros históricos. De acuerdo con esta representación, cada hecho ocurrido y registrado está compuesto por una pareja de componentes (t, P) en donde t representa el tiempo en el que se registró la muestra y P representa la potencia eléctrica consumida en ese instante. El registro diario cuenta con N casos que representa cada una de las parejas de estímulo-respuesta conocidas.

El objetivo que se busca con este trabajo, entonces, consiste en hallar una función que permita mapear el vector de variables de entrada t al vector de variables

* Departamento de Ingeniería Eléctrica, Facultad de Ingeniería. Universidad de Antioquia. Apartado Aéreo 1226 Medellín, Colombia. Correspondencia, Teléfono + 574 + 250 57 57 , fax + 574 263 82 82, correo electrónico htabares@udea.edu.co

** Profesor Facultad de Minas. Universidad Nacional de Colombia. Medellín, Colombia. jahernan@unalmed.edu.co

de salida P . F es una función cualquiera, en este caso el consumo de energía eléctrica. Su modelamiento con Redes Neuronales Artificiales (RNA) es un Perceptron Multi Capa (PMC). Otra forma de modelarlo es usando Algoritmos de Interpolación (AI).

Palabras claves:

REDES NEURONALES ARTIFICIALES, ALGORITMOS DE INTERPOLACIÓN, DEMANDA DE ENERGIA ELÉCTRICA.

TYPICAL CURVE OF DEMAND OF ELECTRIC POWER OF THE RESIDENTIAL, COMMERCIAL AND INDUSTRIAL SECTOR OF THE CITY OF MEDELLIN, USING ARTIFICIAL NEURAL NETWORKS AND ALGORHYTHMS OF INTERPOLATION

ABSTRACT

One of the main problems that arise to model the electric power consumption in a certain place, consists on the extraction of the knowledge when this is stored in big volumes of information like, for example, historical registrations. In accordance with this representation, each fact and registration is made up of two components (t , P). t represents the time and P represent the electric power consumed at that instant. The N cases are registered daily; these represent t , P couples.

The objective of this study is to map out the variable vector of t and P performance been F one of the functions. The model was made with Artificial Neural Network (ANN) which is a Multi Perceptron Layer (MPL). Another form of modeling is using Interpolation Algorithms(AI).

Keywords:

ARTIFICIAL NEURAL NETWORKS, INTERPOLATION ALGORITHMS.

1. INTRODUCCIÓN.

Este artículo resuelve el problema de determinar las funciones que modelan la serie histórica de datos "Consumo de Energía Eléctrica, sectores Residencial, Comercial e Industrial de la ciudad de Medellín para un periodo de 24 horas". La solución parte de la utilización de una RNA del tipo PMC como un aproximador universal de funciones y de la aplicación de los AI. Por lo tanto, este trabajo comienza haciendo una introducción a las RNA y a los AI. Seguidamente, se realiza el planteamiento del problema a resolver. Continúa el artículo estudian-

do las soluciones propuestas usando RNA y AI. Finaliza exponiendo conclusiones relevantes de este trabajo investigativo.

2. LAS REDES NEURONALES ARTIFICIALES.

La teoría y modelado de Redes Neuronales Artificiales está inspirada en la estructura y funcionamiento de los sistemas nerviosos, donde la neurona es el elemento fundamental. Existen neuronas de diferentes formas, tamaños y longitudes, atributos importantes para determinar su función y utilidad [1, 2, 3].

Aprendizaje de una RNA.

El aprendizaje es el proceso por el cual una Red Neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el proceso de aprendizaje se reducen a la destrucción, modificación y creación de conexiones entre las neuronas.

En el caso de las Redes Neuronales Artificiales, se puede considerar que el conocimiento se encuentra representado en los pesos de las conexiones. En realidad, puede decirse que se aprende modificando los valores de los pesos de la red.

Durante el proceso de aprendizaje, los pesos de las conexiones de la red sufren modificaciones, por tanto se puede afirmar que este proceso ha terminado (la red ha aprendido) cuando los valores de los pesos permanecen estables.

En forma general, se consideran dos tipos de aprendizaje: Supervisado y no supervisado.

La diferencia fundamental entre ambos tipos estriba en la existencia, o no, de un agente externo (supervisor) que controle el proceso de aprendizaje de la red. Particularmente, las supervisadas se caracterizan por tener arquitecturas en niveles y conexiones entre las neuronas estrictamente hacia delante. Frecuentemente son utilizadas para clasificar patrones.

Algoritmos de aprendizaje.

Existen dos categorías de algoritmos de aprendizaje: el Descenso por Gradiente, y técnicas de entrenamiento de segundo orden (Gradiente Conjugado, Levenberg-Marquardt -LM).

Todos los algoritmos parten de una condición inicial x_0 y luego se modifican por etapas de acuerdo con:

donde p_k representa una dirección de búsqueda y el escalar positivo α es la tasa de aprendizaje, que determina la longitud del paso.

El entrenamiento finaliza cuando una de las siguientes condiciones se presenta:

- Cuando se ha alcanzado la cantidad máxima de iteraciones.
- Cuando se ha alcanzado el error final deseado.
- La ejecución del gradiente alcanza un valor por debajo del mínimo gradiente.

Ventajas y limitaciones de las RNA.

El éxito de las RNA se debe a que pueden modelar datos que:

- Exhiben alta no linealidad impronosticable.
- Son caóticos en el sentido matemático.

Uno de los problemas que presenta el algoritmo de entrenamiento regla delta generalizada para redes multicapa es que busca minimizar la función de error, pudiendo caer en un mínimo local o en algún punto estacionario, con lo cual no se llega a encontrar el mínimo global de la función del error. Sin embargo, se debe tener en cuenta que no tiene por qué alcanzarse el mínimo global en todas las aplicaciones, sino que puede ser suficiente con un mínimo error preestablecido.

El algoritmo basado en LM es el más rápido para redes backpropagation cuando se trabaja con un moderado número de parámetros de la red. Por otra parte, requiere mayor costo computacional debido a que implica el cálculo de matrices inversas. Tiene la desventaja de requerir de unas tuplas de entrenamiento lo más estándar posible, pues de otra forma sólo aproximará correctamente valores que se encuentren dentro de los patrones de aprendizaje.

La utilización de modelos de aproximación con RNA, puede ocurrir el sobre ajuste (overfitting), que es un problema de los modelos estadísticos. *Esto es una mala situación porque en lugar de aprender a aproximar la función presente en los datos, la función simplemente los memoriza. El ruido en las series históricas se aprende entonces como parte de la función, a menudo destruyendo su habilidad para generalizar.*

Es útil mencionar que las comparaciones de velocidad entre diferentes algoritmos de entrenamiento no siempre son claras, ya que diversos autores han usado, para presentar sus resultados, diferentes problemas, criterios al considerar la red entrenada, medidas de velocidad computacional, y aproximaciones o concepciones, al promediar todos estos resultados.

3. ALGORITMOS DE INTERPOLACIÓN.

La interpolación se usa para obtener datos intermedios a partir de una

tabla en la cual los valores del conjunto de llegada (Y) son conocidos con gran precisión. Las funciones que suelen utilizarse para interpolar se seleccionan, principalmente, como funciones polinómicas [4, 5].

En caso de que la formulación analítica del problema sea conocida, se trata de obtener los coeficientes óptimos que permitan ajustar dicha formulación al conjunto de datos.

El polinomio de interpolación de grado n se podrá escribir en forma genérica como:

$$p_n(x) = a_0 + a_1x + a_2x^2 + \dots + a_nx^n = \sum_{i=0}^n a_i x^i$$

Ventajas y limitaciones de las AI.

Una dificultad práctica que ocurre con la interpolación consiste en que el término de error de la aproximación es difícil de aplicar. Generalmente, el grado del polinomio necesario para lograr la exactitud deseada no se conoce.

4. PLANTEAMIENTO DEL PROBLEMA: MAPEO, CURVAS TÍPICAS DE DEMANDA DE ENERGÍA ELÉCTRICA DE LA CIUDAD DE MEDELLÍN.

La calidad de servicio de un sistema eléctrico [6] puede cuantificarse a través de varios parámetros relacionados con: la continuidad del servicio, las fluctuaciones de voltajes, el contenido armónico de las formas de onda de voltaje y de corriente, variaciones de frecuencia, y la regulación.

El concepto de calidad del servicio como se puede apreciar es bastante amplio, de manera que no es posible sintetizarlo en un solo parámetro o índice.

Un parámetro comúnmente utilizado para evaluar la calidad del servicio, consiste en monitorear periódicamente los registros de consumo de

energía eléctrica. El estudio de su comportamiento sirve para tomar medidas que garanticen el rendimiento óptimo del sistema en su conjunto. Para el caso de la ciudad de Medellín las figuras 1, 2 y 3 muestran el consumo de energía eléctrica para los sectores residencial, comercial e industrial en un período de 24 horas.

Figura 1. Demanda diaria de energía eléctrica, sector residencial.

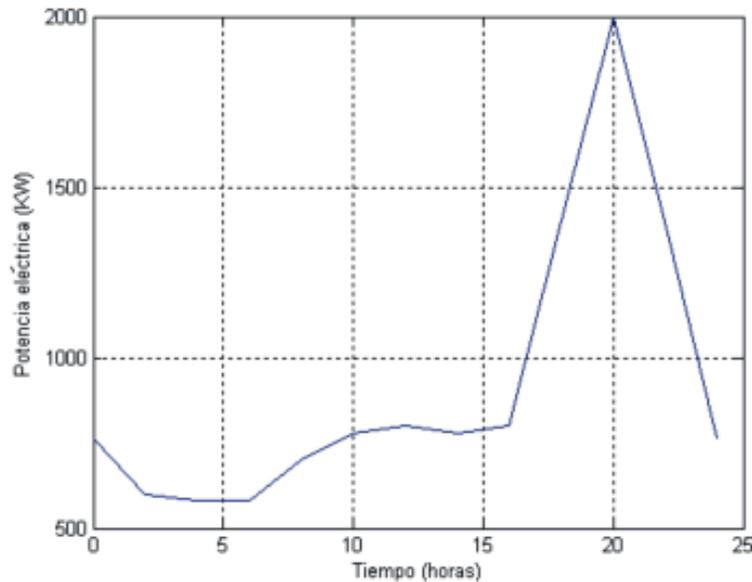


Figura 2. Demanda diaria de energía eléctrica, sector comercial.

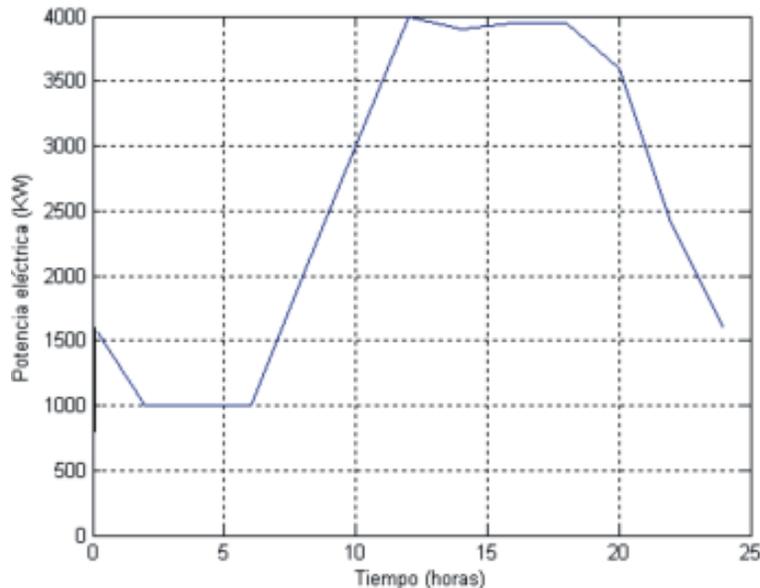
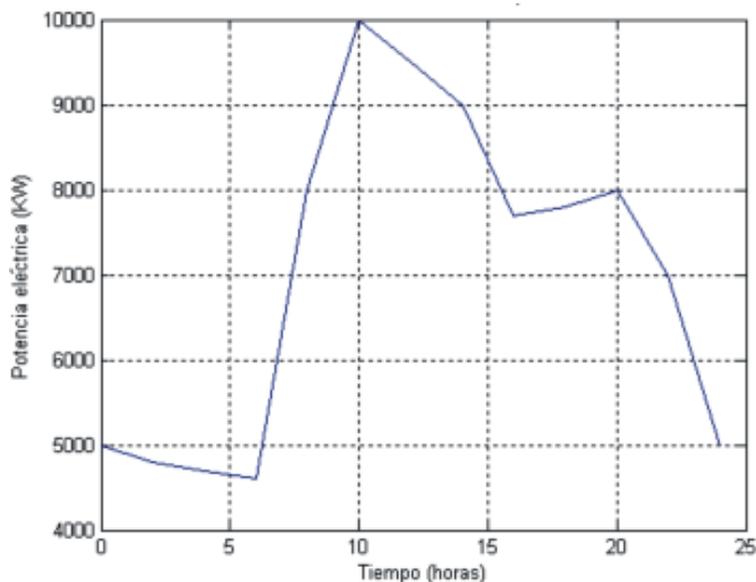


Figura 3. Demanda diaria de energía eléctrica, sector industrial.



Como se observa en las anteriores figuras, la dificultad radica en la extracción de la información pertinente cuando ésta se encuentra almacenada en grandes volúmenes, como por ejemplo, registros históricos gráficos o tabulados. La confiabilidad del análisis aumentaría si se tuviera una función con la cual modelar cada serie histórica.

5. APROXIMACIÓN A LAS SERIE HISTÓRICA SOBRE DATOS DE CONSUMO DE ENERGÍA ELÉCTRICA EN LA CIUDAD DE MEDELLÍN, USANDO REDES NEURONALES ARTIFICIALES Y ALGORITMOS DE INTERPOLACIÓN.

En este trabajo investigativo se encontró que la mejor solución para mapear series de datos son las RNA del tipo PMC y los AI. Su utilización significó aclarar las principales limitaciones que presentan ambos métodos. Con respecto a las RNA se tiene que:

- *A pesar de la investigación que se ha desarrollado en los últimos años sobre redes neuronales, que ha llevado al descubrimiento de varios resultados teóricos y empíricos significativos, el diseño de las arquitecturas o topologías de las RNA para aplicaciones específicas bajo un conjunto dado de restricciones de diseño, es un proceso de prueba y error, dependiendo principalmente de la experiencia previa con aplicaciones similares [7].*
- *Por otra parte, el desempeño de una red neuronal sobre problemas particulares es críticamente dependiente, entre otras cosas, del número de ejemplos de entrenamiento, la complejidad de la función a ser resuelta, el valor inicial de los pesos, el valor del coeficiente de aprendizaje y del algoritmo de aprendizaje utilizado.*

Pruebas de validación

Para realizar los experimentos numéricos de aproximación se utilizó

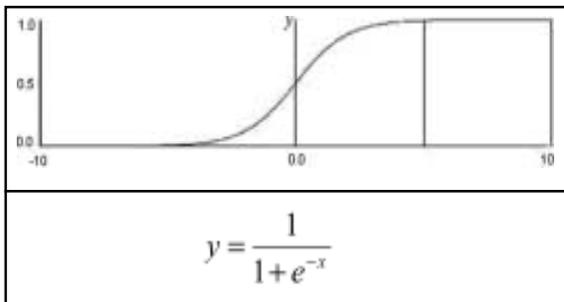
el paquete informático MATLAB. Éste es un conjunto de programas matemáticos e incluye la posibilidad de realizar programas usando lenguaje de alto nivel. Incluye una completa librería de funciones para trabajar con RNA (*Toolbox Neural Network, versión 6.5*), lo que lo convierte en una herramienta informática ideal para los requerimientos planteados en este trabajo investigativo.

Con base en lo anterior, se presentan a continuación las condiciones iniciales empleadas para aproximar las curvas típicas de demanda de energía con RNA.

Función de activación

La función de activación en cada neurona es la función sigmoide.

Figura 4. Función sigmoide



Por lo tanto, es necesario escalar las variables de entrada y de salida, como se ilustra a continuación.

Escalando vector de entradas y salidas.

$$x_e = \frac{2 * LS_EjeX(x - ValorMinVe\ ctorX)}{ValorMaxVe\ ctorX - ValorMinVe\ ctorX} + LI_EjeX$$

$$y_e = \frac{LS_EjeY(y - ValorMinVe\ ctorY)}{ValorMaxVe\ ctorY - ValorMinVe\ ctorY} + LI_EjeY$$

Definiendo

LS: Límite_Superior
LI: Límite_Inferior

Inicializando las variables:

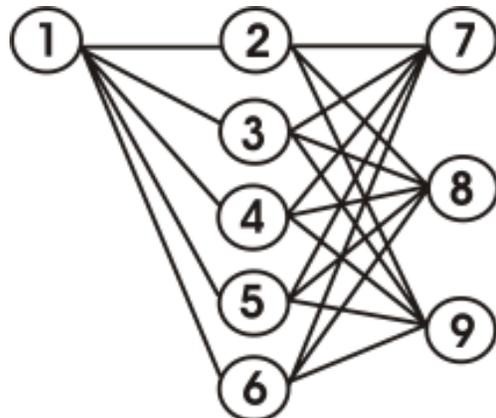
LS_EjeX= +0.95.
 LI_EjeX=-0.95.

LS_EjeY= 0.9.
 LI_EjeY=- 0.05

Topología y Algoritmos de entrenamiento.

Para resolver los problemas de aproximación expuestos en las figuras 1, 2 y 3, se utilizará un criterio heurístico, basado en la intuición y la experimentación, para seleccionar la topología de la RNA. Ésta tendrá una neurona de entrada (tiempo), tres de salida (Potencia en Kw del sector residencial, comercial e industrial) y una capa oculta con 5 neuronas. Las neuronas adaptativas son opcionales, por lo cual las simulaciones se harán sin estas conexiones, como se ilustra a continuación.

Figura 5. Topología RNA



En todas las pruebas de validación realizadas, los pesos del PMC se inicializarán aleatoriamente una sola vez. Se empleará el algoritmo de entrenamiento de segundo orden Trainlm por ser considerado el más rápido, con máximo 3000 iteraciones y un error final en la aproximación de 0.001.

Código fuente MATLAB.

El código fuente en MATLAB, para simular la aproximación a las curvas estudiadas en este artículo, usando RNA del tipo PMC es como se presenta a continuación.

```
%UNIVERSIDAD DE ANTIOQUIA
%FACULTAD DE INGENIERÍA
%Programa Ingeniería Eléctrica
%Asignatura : Control Inteligente
%-----
%-----
%Variable de entrada (tiempo) escalada
P=[-0.9 -0.7 -0.6 -0.4 -0.3 -0.1 0.0 0.1 0.3 0.4 0.6 0.7 0.9]

%Variables de salida escalada (Potencia consumida en KW sector Residencial,
Comercial e Industrial)
T= [ 0.1 0.2 0.0; 0.0 0.0 0.0; 0.0 0.0 0.0; 0.0 0.0 0.0; 0.1 0.3 0.6; 0.1 0.8 0.8;
    0.2 0.9 0.7; 0.2 0.9 0.6; 0.2 0.8 0.4; 0.5 0.9 0.5; 0.9 0.8 0.5; 0.7 0.4 0.3; 0.2 0.2
    0.0]';

plot(P,T,P,T,':')
PR=[min(P) max(P)];

%definir arquitectura de la red
net = newff(PR,[5 3],{'logsig' 'logsig'},'trainlm');

%para ver parametros de entrenamiento
net.trainParam.epochs = 3000;
net.trainParam.goal = 0.001;
net.trainParam.min_grad = 1e-9;
net.trainParam.show=50;

%Entrenando la red
net = init(net)
net = train(net,P,T);

%Datos de Generalizacion
ValorMin = 0; ValorMax = 24; Valor = 0; i = 1;

while Valor <=ValorMax
    %Escalando la entrada
    G(i) = ((1.9*(Valor - ValorMin))/(ValorMax - ValorMin))-0.95;
    i = i + 1; Valor = Valor + 0.01;
end

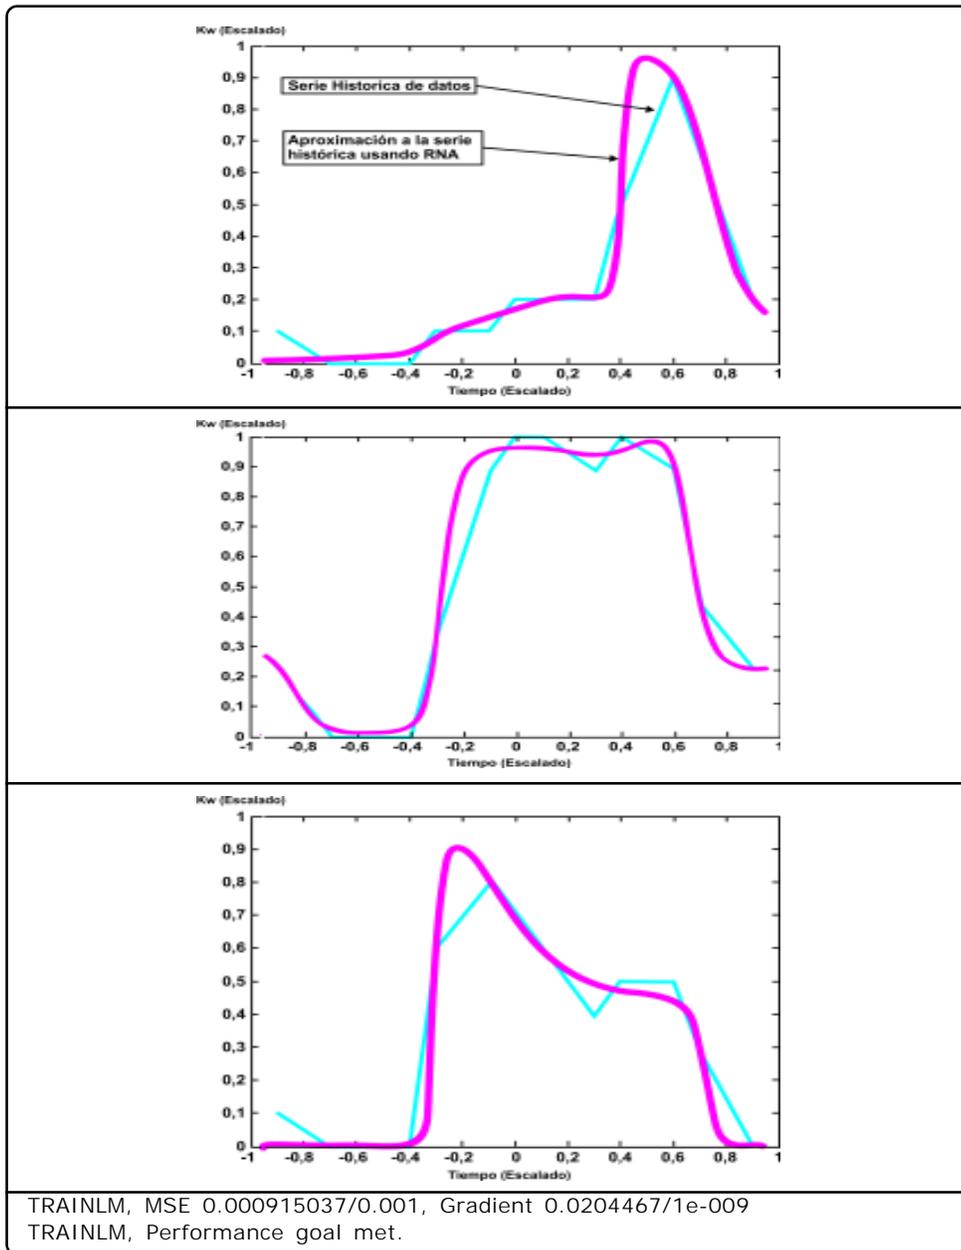
% definir patrones prueba de generalización
PG = G(1,:);

%Validando el entrenamiento
Y = sim(net,PG);
plot(P,T,PG,Y,':')
```

Gráficas de aproximación usando RNA

La figura 6 muestra las curvas de aproximación a las series históricas consumo de energía eléctrica de los sectores residencial, comercial e industrial de la ciudad de Medellín, modeladas con RNA del tipo PMC.

Figura 6. Salida de la RNA, sector Residencial, Comercial e Industrial.



Una de las características de las RNA es su capacidad de generalización, *es decir la facultad de la red para responder apropiadamente cuando se le presentan datos o situaciones a los que no había sido expuesta anteriormente*. El sistema puede generalizar la entrada para obtener una respuesta. Esta característica es muy importante cuando se tiene que solucionar problemas en los cuales la información de entrada es poco clara; además permite que el sistema de una solución incluso cuando la información de entrada esta especificada de forma incompleta.

Como se observa en la Figura 6, la RNA mapeo, generalizó correctamente el universo de datos de entrada.

Nótese que el error final en las aproximaciones fue de 0.01, lo cual es considerado como una buena medida.

Algoritmos de Interpolación

Con el objeto de validar las series de datos estudiadas en este artículo usando AI [6, 7], realizar experimentos numéricos y pruebas de ensayo, se desarrolló el simulador software sobre Métodos Numéricos MN_UdeA.exe. Éste incluye el módulo AI.

La implementación software se encuentra en la siguiente dirección electrónica de la Universidad de Antioquia:

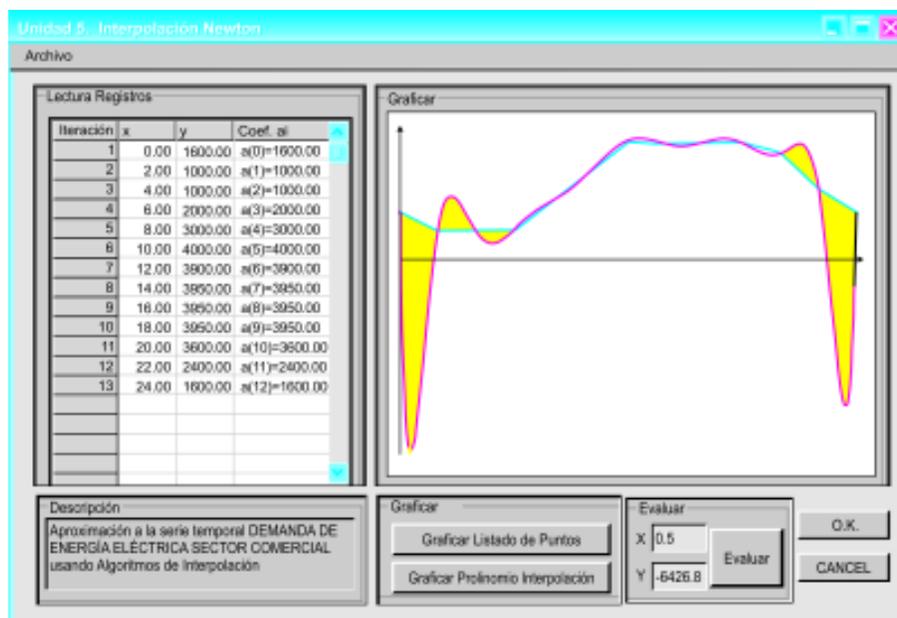
<http://ingenieria.udea.edu.co/inicial.html>
 Siga la siguiente ruta de acceso:

- Menú principal: Producciones.
- Menú Emergente: Páginas WEB Académicas.
- Opción: Temas de Apoyo a Cursos.

Héctor Tabares O.
 Métodos Numéricos

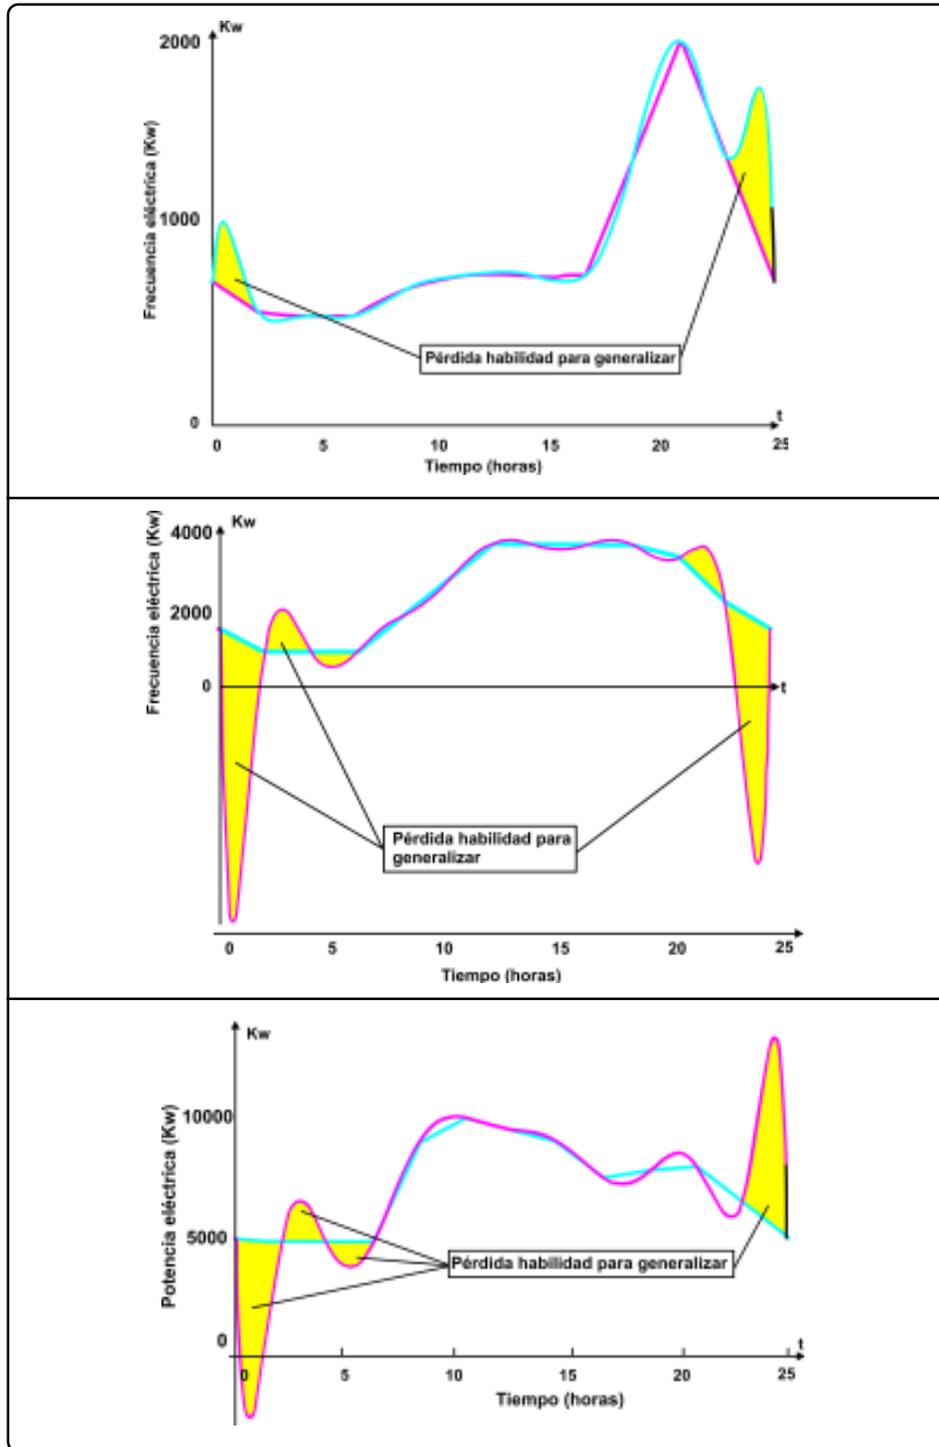
La interfaz del sistema es como se ilustra a continuación.

Figura 7. Interfaz programa MN_UdeA.



En la figura 8, se ilustra la aproximación a las curvas típicas de consumo de energía sector residencial, comercial e industrial de la ciudad de Medellín, usando AI.

Figura 8. Aproximación a las curvas sector residencial, comercial e industrial usando Algoritmos de Interpolación.



Como se observa en la Figura 8, las aproximaciones obtenidas usando Algoritmos de Interpolación, adolecen de la capacidad para generalizar correctamente el universo de datos.

Nótese que el error final en la aproximación no se pudo calcular, pues para lograr la misma exactitud de 0.01 obtenida con RNA, el grado del polinomio es desconocido. Por lo tanto, lo que se acostumbra es obtener los resultados de varios polinomios, hasta que se logre una correspondencia adecuada con el ejemplo a aproximar. Además, el trabajo realizado al calcular la aproximación mediante un segundo polinomio no reduce el que se requiere para calcular el tercero; tampoco es más fácil obtener la cuarta aproximación, una vez conocida la tercera y así sucesivamente.

5. CONCLUSIONES.

El concepto de calidad de servicio de un sistema eléctrico está adquiriendo especial importancia en la ciudad de Medellín, dada la presencia de una mayor cantidad de cargas sensibles tanto en las variaciones de voltaje y frecuencia como a los cortes de suministro. Existen diversos cuantificadores que dan cuenta de las fluctuaciones lentas o rápidas de voltaje e indican la necesidad de tomar medidas correctivas, dado que las fuentes de estos problemas son conocidas.

Por otra parte, los cortes de suministro de energía eléctrica en los sectores residencial, comercial y/o industrial afectan a los usuarios produciendo graves distorsiones en el desarrollo habitual de cualquier actividad. Éstas se cuantifican midiendo la frecuencia de aparición de cortes de suministro y su duración.

Con el objeto de evaluar el impacto de una falla en el sistema eléctrico, el operador del sistema estudia los registros históricos de consumo. El principal problema consiste en la extracción de la información pertinente cuando se encuentra almacenada en grandes volúmenes, siendo fuente de posibles errores en su lectura, que finalmente no se detectan.

Como una forma de contribuir a la confiabilidad del estudio sobre los registros de consumo eléctrico, se propone en este artículo mapear las curvas típicas de consumos de energía eléctrica en los sectores residencial, comercial e industrial en la ciudad de Medellín, usando RNA del tipo PMC. Su utilización, ayuda al analista del sistema eléctrico a evaluar, de manera más ágil, la variación de consumo de carga eléctrica de los diferentes sectores y el impacto que tendría en éstos una falla.

Como quedó demostrado en las pruebas de aproximación usando AI, éstos no se recomiendan, debido a que no se pudo calcular los errores al generalizar tendencias.

Finalmente, con respecto a las RNA es necesario comentar que son sistemas caóticos donde todo influye en todo y todo está interconectado con todo. Por tal razón, las investigaciones que se realizan a nivel mundial tendientes a mejorar su desempeño consisten en determinar el valor inicial óptimo de los pesos de la red, el valor inicial óptimo del valor del coeficiente de aprendizaje, el mejor conjunto de datos de entrenamiento de la red, los mejores algoritmos de entrenamiento, la habilidad que tiene la red para aprender y generalizar, la topología de una RNA con la cual resolver un problema particular.

REFERENCIAS

[1] J. Hilera. *Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones*. AlfaOmega, MADRID 2000. p. 132-153.

[2] B. Martín del Brio. *Redes Neuronales y Sistemas Difusos*. AlfaOmega, MADRID 2002, pp 64-66, 69.

[3] T. Masters. *Practical Neural Networks recipes in C++*. Ed. Academic Press, Inc. 1993. pp 173-180.

[4], R. Burden. y F. Duglas. *Análisis Numérico*. Editorial Thomson Learning. 2002. p.p 104-141

[5], J. Mathews & K. Fink. *Métodos Numéricos con Matlab*, 3^a Edición. Prentice Hall, Madrid 2000. p.p 203-250.

[6] S. Grainger, *Análisis de sistemas de potencia*, 1^a Edición Español. McGraw-Hill, 2002. p.p. 56-124.

[7] R. DOW, J. SIETSMAN. *Creating Artificial Networks that generalize* Neural Networks, vol. 4, no 1, pp198-209