

Perspectiva del uso de energía eléctrica mediante redes neuronales

José Rojas & Ricardo Luna

J. Rojas & R. Luna

Jrojas.utcorregidora@gmail.com

Universidad Tecnológica de Corregidora. Carretera a Coroneo km 11.2. Corregidora, Qro., México.

M. Ramos.,V.Aguilera.,(eds.). Ciencias de la Ingeniería y Tecnología, Handbook -©ECORFAN- Valle de Santiago, Guanajuato, 2013.

Abstract

Demand for electricity in industrial, commercial and residential sectors represents a current problem to predict ahead of time electricity consumption in these sectors in order to avoid penalties imposed by the respective companies supplying electricity, plans to develop a system perspective electricity demand for intelligent buildings using artificial neural networks (ANN) that allows us a prediction of power consumption ahead of time, and therefore better management of energy in buildings. The variables used as inputs to the neural prediction model were: temperature and humidity, as well as power consumption and time. The algorithm used for perspective was Levenberg-Marquardt. The model validation was performed by comparing the results with a non-linear regression model and actual data with analysis of variance (ANOVA). The results of the 4-4-1 model prediction were 95% reliability.

8 Introducción

Las actividades industriales, comerciales y habitacionales están creciendo rápidamente en todas las regiones, tratando de ganar mercados a sus competidores; estas actividades dependen del incremento de demanda de energía eléctrica, debido a que es la base de su desarrollo. A escala global, los edificios son responsables de aproximadamente un 40% del consumo de energía anual a nivel mundial (Omer, 2008), la mayor parte de ésta es empleada para proveer de iluminación, calefacción, enfriamiento y ventilación. Ante esta problemática, se ha buscado mejorar la eficiencia energética de dispositivos eléctricos y de control (Söderholm, 2008). El almacenamiento y generación, así como la distribución de energía eléctrica son los medios más significativos de optimización en los edificios (Wojciech et al. 2005).

La demanda de energía eléctrica en México, crecerá a un ritmo anual promedio de 5.7 % durante el periodo 2010 a 2012, mientras que la capacidad instalada de generación crecerá al 3.9 %, (SIE, 2009). De acuerdo con este escenario, la demanda eléctrica crecerá en mayor proporción que la capacidad instalada de generación, lo cual reducirá los márgenes operativo y de reserva. Creciendo con una tasa anual del 5.7 %, la demanda nacional de energía eléctrica pasaría de 195 Tera Watts hora (TWh) en el año 2007 a 264 TWh en el 2012.

La problemática anterior se puede enfrentar mediante modelos de perspectiva de la demanda de energía eléctrica, esto causó un gran interés desde el momento en que se instalaron las redes eléctricas como un sistema de transporte y distribución de energía, así como la proliferación del uso masivo de energía eléctrica en el entorno industrial, comercial y doméstico.

Por lo cual, la perspectiva es útil para diferentes usos, tales como aspectos económicos, planeación, mantenimiento, generación de recursos humanos y materiales, costos, operación, diseño e investigación, así como predecir el consumo de energía en invernaderos. Kalaitzakis, et al.(2002) realiza un análisis de perspectiva del consumo eléctrico en invernaderos, utilizando redes neuronales artificiales y muestra las ventajas de las redes neuronales a través de un enfoque de análisis de varianza obteniendo hasta un 95 % de nivel de confianza.

Actualmente, el uso de perspectiva de la demanda de energía eléctrica ha utilizado redes neuronales artificiales. Wong et al. (2009) desarrolla una red neuronal para el encendido de oficinas en los edificios, utilizando la temperatura y los días de la semana para estimar la demanda de consumo calorífico y de electricidad; las redes neuronales las emplea para obtener el proceso de información entre las entradas y salidas, conectadas por un gran número de eslabones, generalmente realizando un funcionamiento no lineal a través de un software llamado "neuroshell". Ruano et al. (2005) reporta la utilización de redes neuronales con información de temperatura interna, controlando el aire acondicionado para la perspectiva de la demanda de energía eléctrica. Senabre et al. (2004) propuso un mapa auto-organizado como modelo de red neuronal para la perspectiva a corto plazo de la demanda de energía eléctrica obteniendo una curva de demanda por medio de las horas del día siguiente. Lian et al. (2007) utiliza un modelo de perspectiva de cargas de energía eléctrica llamado red neuronal en combinación con la corrección del error (RBFNN) basado en la demanda de consumo de energía para aire acondicionado en edificios.

El propósito de este trabajo es desarrollar un sistema de perspectiva de la demanda de energía eléctrica para edificios inteligentes a través de modelos de redes neuronales que nos permita una perspectiva del consumo eléctrico con tiempo de anticipación, y en consecuencia una mejor administración de la energía en los edificios. Las variables utilizadas como entradas al modelo neuronal de perspectiva son: temperatura y humedad relativa, además del consumo de energía eléctrica y el tiempo. El modelo de validación se realiza comparando los resultados con un modelo de regresión no lineal y datos reales mediante el análisis de varianzas.

Este trabajo está estructurado de la siguiente manera, en la sección 2 se encuentran la metodología utilizada para el análisis y monitoreo de las variables de energía eléctrica; en la sección 3 se muestran los resultados obtenidos del sistema de monitoreo y su discusión; las conclusiones son mostradas en la sección 4, así como los trabajos futuros relacionados a este tema.

8.1 Método

Redes Neuronales: Hoy en día las redes neuronales son una excelente herramienta para realizar diversas tareas como son: reconocimiento de patrones (objetos en imágenes y dibujos), reconocimiento del habla, detección de explosivos, identificación de rostros humanos (en los aeropuertos para saber que personas entran y salen del mismo), realizar comprensión de datos, videojuegos, aprendizaje artificial y predicciones.

Éstas son aplicadas para resolver problemas ya que existen ciertos procesos para los que no existen algoritmos para resolverlos (como puede ser el reconocimiento de imágenes); esto ocurre porque los algoritmos son exactos, mientras que las redes neuronales tienen más flexibilidad (Ramazan et al., 2011).

Una red neuronal se compone de neuronas de entrada, neuronas ocultas y neuronas de salida. Cada una de éstas se agrupa en capas. La última capa de salida, suele tener una menor cantidad de neuronas que las capas de entrada. Los datos se propagan por toda la red partiendo desde las neuronas de entrada hasta llegar a las neuronas de salida.

A su paso van cargando los pesos de cada una de éstas. Lo que generalmente importa es solo el peso final de las neuronas de salida. Cuando las señales de salida se transmiten a las neuronas de entrada, el conjunto de señales se procesa nuevamente modificando los pesos neuronales. La discusión sobre si este proceso converge a estados específicos para cada neurona a través de las iteraciones es complejo, pero muchas veces es así. Es decir que las redes neuronales minimizan o maximizan los valores hasta encontrarlos óptimos.

Los nodos escondidos con las funciones de transferencia no lineales son usados para procesar la información recibida por los nodos de entrada. La red puede ser escrita como:

$$y_i = \alpha_0 + \sum_{j=1}^m \alpha_j f\left(\sum_{i=1}^m \beta_{ij} y_i + \beta_{0j}\right) + \varepsilon_i \quad (8)$$

Donde m es el número de nodos de entrada, n es el número de nodos escondidos, f es una función de transferencia sigmoidea, como la función logística:

$$f(x) = \frac{1}{1+\exp(-x)} \quad \{\alpha_{ij} = 0,1,\dots,n\} \quad (8.1)$$

También llamada como vector de pesos desde los nodos escondidos hasta los nodos de salida. α_0 y β_{0j} son los pesos de los arcos principales de los términos parciales, los cuales tiene valores siempre igual a 1 (White, 2000; Faraggi, 2005; Maier, 2001).

Se requieren varias iteraciones para entrenar una red pequeña, incluso para un problema simple. Reducir el número de iteraciones y agilizar el tiempo de aprendizaje de las RNAs, son temas de investigación reciente; algunas mejoras del algoritmo de retro propagación son la pendiente del gradiente (Zhou, 2007) y el algoritmo de Levenberg-Marquardt (Lavine et al., 2009; Marini et al., 2007) que es el que utilizaremos para probar nuestros modelos. La medida de funcionamiento más importante y decisiva de los modelos RNA es la exactitud de la perspectiva. Una medida de la exactitud se define a menudo en términos del error de perspectiva, que es la diferencia entre el valor medido y el estimado. Hay un número de medidas de exactitud en la literatura de la perspectiva, y cada uno tiene ventajas y limitaciones (In-Bong, 2003).

Entre los más frecuentemente usados están: el error medio cuadrático (MSE) (ecuación 8.2); el error medio cuadrático de la raíz (RMSE), (ecuación 8.3); y el error de porcentaje de la media absoluta (MAPE) (ecuación 8.4).

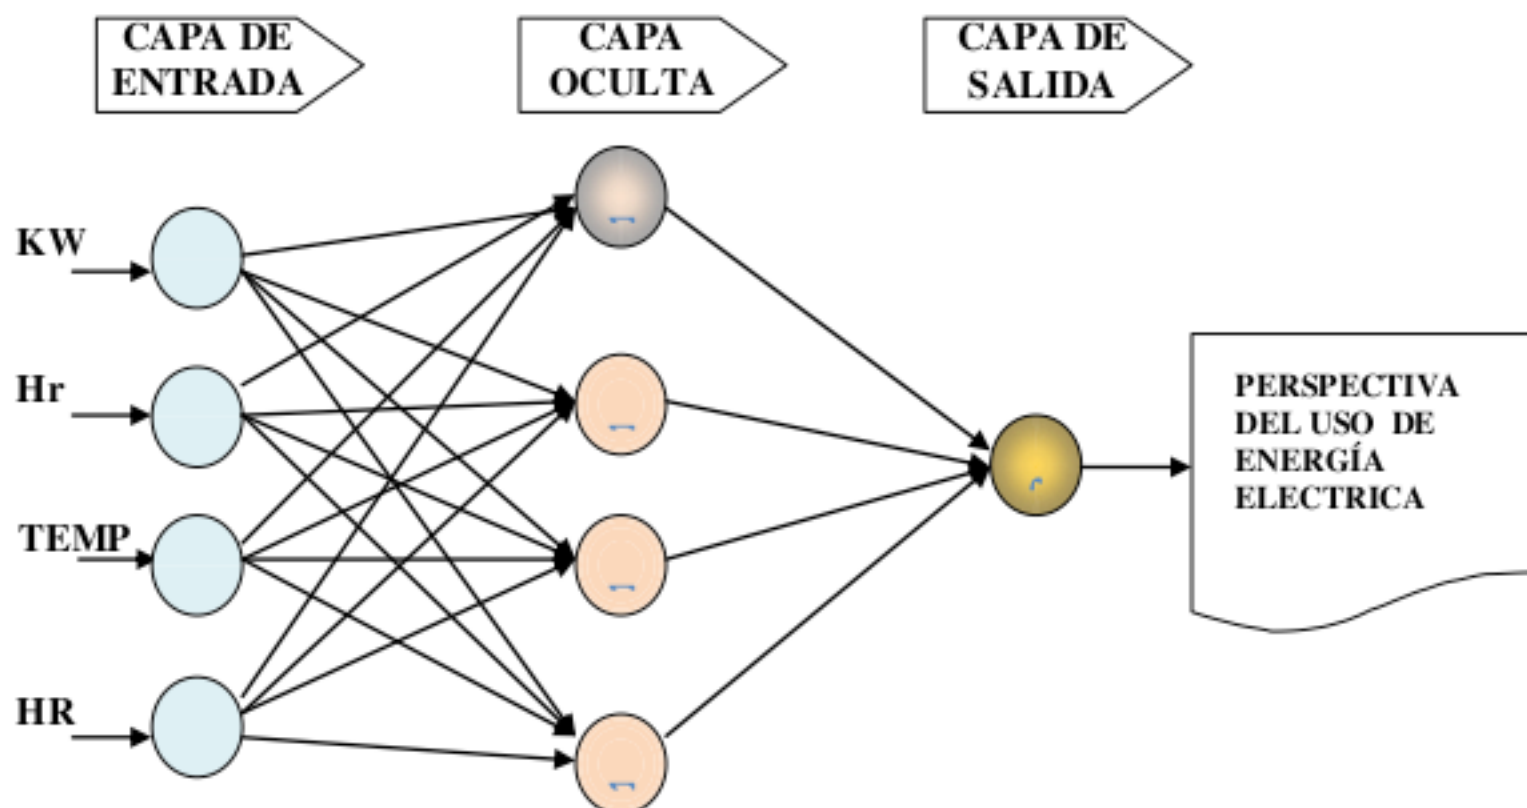
$$MSE = \frac{\sum (e_i)^2}{N} \quad (8.2)$$

$$RMSE = \sqrt{MSE} \quad (8.3)$$

$$MAPE = \frac{1}{N} \sum \left| \frac{e_i}{y_i} \right| (100) \quad (8.4)$$

Donde: e_i es el error de perspectiva individual; y_i es el valor actual; y N es el número de términos del error. La gama de usos de los modelos RNA está aumentando constantemente. Su uso en aplicaciones relacionadas con la administración y manejo de energía comienza a principios de los años 90. Kalogirou (2000) proporciona una exhaustiva descripción de las aplicaciones de las RNAs en sistemas de energía renovable y en edificios. El modelo RNA aplicado en este estudio, es una red con capas de entrada de 4 nodos y con una capa oculta con un número de variables de nodos ocultos, como son la temperatura (TEMP), humedad relativa (HR), tiempo (Hr) y el consumo de energía (KWh), con una capa de salida con un solo nodo, como se muestra en la figura 8.

Figura 8 Red neuronal artificial



Descripción del algoritmo: La propuesta para el modelo de perspectiva de la demanda de energía eléctrica en los edificios es un modelo de redes neuronales artificiales con el algoritmo Levenberg-Marquardt.

Con esta arquitectura de red se seleccionó el promedio de las diferencias absolutas entre los valores medidos y estimados, expresados como porcentaje de los valores medidos. Ya que es una medida más fácil de interpretar dado que su resultado en porcentaje no depende de aspectos como la magnitud de los datos de entrada. Comparando los mejores resultados con pruebas de igualdad de dos o más medias con técnicas de análisis de varianza para ser validados. Los datos del consumo de energía usados para la formación del modelo, se obtuvieron midiendo en la subestación principal del edificio de la Universidad con un sistema de monitoreo de energía eléctrica desarrollado en la propia facultad. Los datos de temperatura y humedad relativa fueron obtenidos con los sensores HOBO Pro V2 que permiten una rápida respuesta en la información y almacenamiento de los datos. El software HOBOWare fue requerido para transportar datos de campo para su análisis. También fue necesario el día y la hora en que los datos de energía temperatura y humedad relativa fueron obtenidos. Estos datos se dividieron en 2 grupos: en el primero se seleccionó un grupo de 192.5 hrs. para utilizarse en la formación de entrenamiento de la red neuronal, y en el segundo grupo se trabajó con el resto de los datos para probar el modelo de red neuronal.

8.2 Resultados y discusión

Fueron generados varios modelos y probados de acuerdo a su rendimiento y estructurados con 210 hrs. Los datos registrados se obtuvieron del consumo de energía eléctrica del día 7 de Enero al día 29 de Abril del 2013. El error de porcentaje de la media absoluta (MAPE) se utilizó para examinar la calidad de los modelos de perspectiva con la finalidad de determinar el mejor modelo de red neuronal. Se calcularon los valores MAPE para cada uno de los modelos obteniendo los resultados que se muestran en la tabla 8 donde se visualizan los mejores modelos, su confiabilidad y el mejor rendimiento. El modelo 4-4-1 es el que obtuvo el mejor resultado con un 0.0537 MAPE, 0.9310 R^2 y con 0.0849 SEP en comparación con los resultados de los modelos restantes de la tabla.

Tabla 8 Comparación del error estimado para diferentes modelos de redes neuronales

| Modelo | R^2 | MAPE | SEP |
|--------|--------|--------|--------|
| 4-2-1 | 0.9015 | 0.0628 | 0.0959 |
| 4-3-1 | 0.9270 | 0.0617 | 0.1788 |
| 4-4-1 | 0.9310 | 0.0537 | 0.0849 |
| 4-5-1 | 0.9264 | 0.0563 | 0.1094 |
| 4-6-1 | 0.9003 | 0.0662 | 0.1134 |
| 4-7-1 | 0.9153 | 0.0650 | 0.1073 |
| 4-8-1 | 0.9023 | 0.0631 | 0.1126 |
| 4-9-1 | 0.9010 | 0.0571 | 0.1094 |
| | | | |

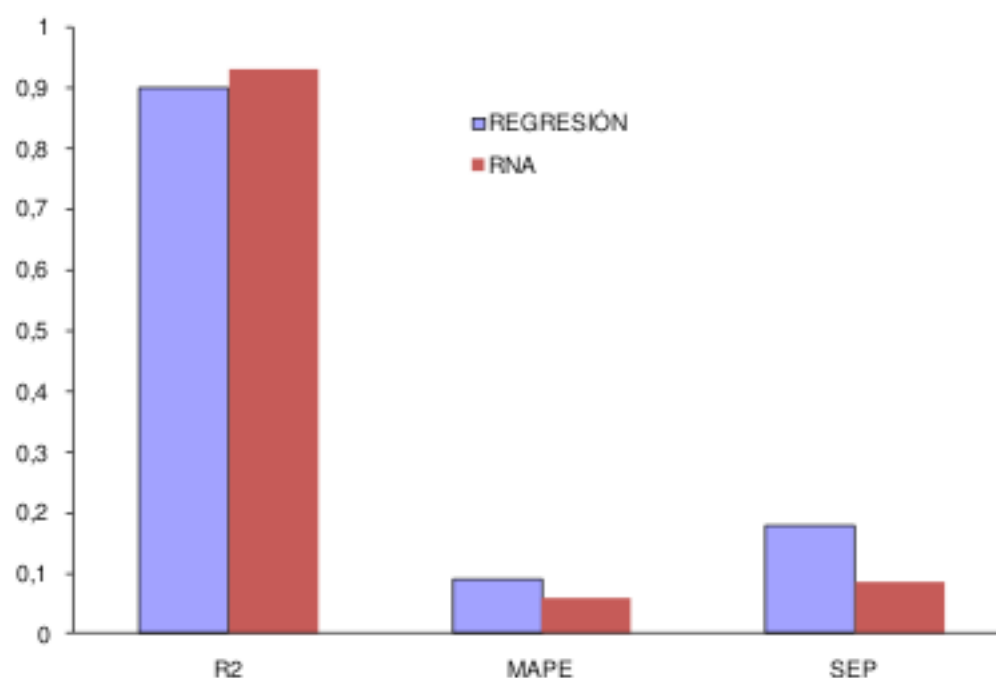
La tabla 8.1 muestra una comparación de resultados de los modelos de perspectiva y de regresión lineal respecto a los datos reales, donde se observa el error porcentual absoluto medio (MAPE) de cada modelo que nos indica la perspectiva más adecuada y con más posibilidad de ser una perspectiva acertada.

Tabla 8.1 Comparación de mediciones y valores estimados en modelos de Redes neuronales y regresión no lineal

| Horas | Medición | RNA | Regresión |
|------------|----------|---------|-----------|
| 109.0 | 4180,8 | 3859,18 | 3153,43 |
| 109.5 | 4023,5 | 4159,16 | 3460,33 |
| 110.0 | 4270,8 | 4339,19 | 3767,23 |
| 110.5 | 4450,6 | 4665,13 | 4074,13 |
| 111.0 | 4135,9 | 4319,69 | 4381,04 |
| 111.5 | 4315,7 | 4359,76 | 4287,94 |
| 112.0 | 4135,9 | 4459,27 | 4594,84 |
| 112.5 | 3461,6 | 3861,46 | 3501,74 |
| 113.0 | 5169,9 | 5270,13 | 5108,64 |
| 113.5 | 4900,1 | 5174,91 | 5015,54 |
| 114.0 | 5439,6 | 5493,37 | 5222,44 |
| 114.5 | 6451,1 | 6610,87 | 6529,35 |
| 115.0 | 7530,0 | 7772,6 | 6836,25 |
| 115.5 | 1497,1 | 1476,48 | 1343,15 |
| 116.0 | 6563,5 | 6645,61 | 6450,05 |
| MAPE error | | 0.0598 | 0.0893 |

El grafico 8 compara los modelos de red neuronal y de regresión, en cuanto al MAPE, MSE y R^2 . El modelo de perspectiva con la red neuronal artificial tiene un error menor en comparación con el modelo de regresión no lineal.

Grafico 8 Comparación de error de los modelos de red neuronal y regresión



Seleccionando los resultados de la red neuronal con los resultados de la regresión y los datos reales, fueron comparados mediante un análisis de varianza para una estimación de los componentes de variación por los diversos métodos de análisis, con el objetivo de comparar los errores sistemáticos con los aleatorios obtenidos al realizar los análisis con los diversos valores medios para determinar si alguno de ellos difiere significativamente del resto (Tabla 8.2).

Tabla 8.2 ANOVA comparación de datos entre la regresión no lineal y la red neuronal


| Abstract | | | | | |
|-----------------|------------|--------|-------------|-----|----------------|
| Groups | Count | | Sum (KW/h) | | Average (KM/h) |
| Meassured | 15 | | 70,526 | | 4,70 |
| Neural networks | 15 | | 72,466 | | 4,83 |
| Regression | 15 | | 67,726 | | 4,15 |
| Source | Sum square | Degree | Mean square | F | P (p-value) |
| Between groups | 0,4109 | 2 | 0,1853 | 4,5 | 0,0173 |
| Within groups | 1,4095 | 41 | 0,0409 | | |
| Total (corr.) | 1,8204 | 43 | | | |

Se realizaron proposiciones sobre los valores determinados en los modelos para tomar una decisión entre aceptarlos o rechazarlos mediante una herramienta de análisis de datos llamada prueba de hipótesis.

$$H_0: \mu = \mu_0 = \mu_1$$

$$H_1: \mu \neq \mu_0$$

Obteniendo un $P = 0.0173$, definiendo la hipótesis nula al comparar los dos modelos de perspectiva, con $\alpha = 0.05$ aceptando la hipótesis de la prueba con un 95% de confiabilidad de que el intervalo contiene el valor medido de la población; lo anterior indica que el consumo de energía estimado para los valores seleccionados del modelo de la red neuronal artificial y los datos reales son significativamente mejores que los valores obtenidos por el modelo de regresión no lineal (Grafico 8.1).

Grafico 8.1 Valores medidos y estimados Del consumo de energía eléctrica en edificios

8.3 Conclusiones

La construcción del modelo 4-4-1 en el algoritmo de la red neuronal artificial (RNA), fue capaz de producir los mejores resultados en la perspectiva del consumo de energía eléctrica, con una estimación de error de 0.0537 con los datos reales. Se utilizó el método estadístico ANOVA para estimación de la variación, comparando los resultados del modelo de la red neuronal artificial con los resultados del modelo de regresión no lineal, en comparación con datos reales, obteniendo un 95 % de confiabilidad en modelos de redes neuronales, encontrando éste modelo más cercano a los datos reales para la perspectiva del consumo de energía eléctrica en edificios inteligentes. El modelo de perspectiva de la demanda de energía eléctrica presentado en este trabajo será la base para diseñar un controlador de consumo de energía eléctrica basado en lógica difusa.

8.4 Agradecimientos

Los autores desean agradecer al L.C.C. Arturo Adolfo Vallejo Casanova, responsable de la Universidad Tecnológica de Corregidora. Corregidora Qro., México por su amable ayuda en la realización de este trabajo.

8.5 Referencias

Faraggi D., Simon R (2005). The maximum likelihood neural network as a statistical classification model. *Journal of statistical Planning and Inference* (46), pp93-104.

In-Bong B. (2003). Multi-period forecasting using different models for different horizon: an application to U.S. economic time series data. *International Journal Forecasting* (19), Pp387-400.

Kalaitzakis K., Stavrakakis G., Anagnostakis E. (2002). Short-term load forecasting based on artificial neural networks parallel implementation. *Electric Power System* (63), Pp185-196.

Kalogirou (2000). Applications of artificial neural networks for energy systems. *Applied Energy*, (67), pp 17-35.

Lavine B., Blank T. (2009). Feed-forward neural networks. *Comprehensive Chemometrics* (3), Pp 571-586.

Lian Z., Liu W., Yao Y. (2007). An innovate air-conditioning load forecasting model based don RBF neural network and combined residual error correction. *ELSEVIER*. pp 528-538.

Maier H., Dandy G. (2001). Neural network based modeling of environmental variables: A systematic approach. *Mathematical and Computer Modelling* (33), pp 669-682.

Marini F., Magri A., Bucci R. (2007). Multilayer feed-forward artificial neural networks for class modeling. *Chemometrics and Intelligent Laboratory Systems* (88), pp118-124.

Omer A.M. (2008). Energy, environment and sustainable development. *Renewable and Sustainable Energy Reviews*, 12 (9), pp 2265 - 2300.

Ramazan B., Irmak E., Colak I., Bektas A. (2011) Development of real time energy monitoring platform. *Electrical Power and Energy Systems* (33), pp 137-146.

Ruano A. E., E.M., Crispim, E.Z.E., Conceição b, M.M.J.R. (2005). Prediction of building's temperature using neural networks models. *Elsevier* (38), pp 682-695.

Senabre C., Valero V., Gabaldón A., Ortiz M., González M. (2004) Predicción de la Demanda Total de Energía Eléctrica Española Utilizando Mapas Auto-organizados como Modelo de Red Neuronal. *Transaction on neural networks*, pp 1-6.

SIE, 2009, Información estadística, balance de energía eléctrica, Secretaria de Energía México, <http://sie.energia.gob.mx>.

Söderholm P. (2008). The political economy of international green certificate markets. *Energy Policy*, 36 (6), pp 2051– 2062.

Wojciech G., Piotr B. (2005). Heating system control in commercial building with peak demand adjustment. AGH University of science and technology. Elsevier. pp 64- 70.

Wong, H. Li, S.W. Wang. (2009) Intelligent building research: review. *Automation in Construction*. (14), pp 143 – 159.

White H. (2000). Learning in artificial neural networks: A statistical perspective. *Neural Computation* (1). pp 425–464.

Zhou, G. and Si, J. (2007). Advanced neural network training algorithm with reduced complexity based on Jacobian deficiency. *IEEE Trans. Neural Networks* (9), pp 448-453.