



TLATEMOANI
Revista Académica de Investigación
Universidad Autónoma de San Luís de Potosí
Editada por Eumed
No. 16 – Agosto 2014
ISSN: 1989-9300
revista.tlatemoani@uaslp.mx

Fecha de recepción: 28 de mayo de 2014
Fecha de aceptación: 16 de julio de 2014

PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES.

Anislei Santiesteban Velázquez
Universidad de Las Tunas. Cuba.
e-mail: anisleisv@ult.edu.cu

Julio Osvaldo Nápoles González
Universidad de Las Tunas. Cuba.
e-mail: jnapoles@ult.edu.cu

Daniel Rodríguez Peña
Universidad de Las Tunas. Cuba.
e-mail: daniel@ult.edu.cu

Delmar Jaime García
Universidad de Oriente. Cuba.
e-mail: delmar@ee.fie.uo.edu.cu

Resumen

En el trabajo, se propone el uso de las redes neuronales artificiales para el pronóstico de consumo de energía eléctrica. Se estudiaron los principales factores influyentes en el consumo de energía eléctrica en el sector público del país. Se determinan las principales variables influyentes en el consumo de energía eléctrica. Se analizaron los métodos de pronóstico de consumo de energía eléctrica más usados escogiéndose las redes neuronales artificiales por ser el más preciso. Se creó, simuló y validó una red neuronal para el pronóstico del consumo de energía eléctrica obteniéndose un error de aproximación de 5,87 %, debido a la existencia de pocos datos en el entrenamiento. Se comprobó la validez del método propuesto al comparar los resultados pronosticados, resultando una diferencia de 31,77 MWh. Con este valor obtenido se pudieron determinar las potencialidades técnicas de ahorro así como los beneficios económicos.

Palabras Claves: Pronostico de energía, redes neuronales, energía eléctrica.

Abstract

At work, we propose the use of artificial neural networks for forecasting electricity consumption. Key influencers in the consumption of electricity in the country's public sector factors were studied. Major influential variables are determined in the consumption of electricity. Forecasting methods consuming more electricity used artificial neural networks being chosen as the most accurate were analysed. Was created, simulated and validated a neural network for forecasting electricity consumption yielding an error of approximation of 5.87%, due to the existence of few training data. The validity of the proposed method comparing the predicted results was found, resulting in a difference of 31.77 MWh. This value could be obtained to determine the technical potential and economic benefits.

PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES

Keywords: *energy forecast, neural networks, electricity.*

INTRODUCCIÓN.

La disponibilidad de energía está fuertemente ligada al nivel de bienestar, a la salud y duración de vida de los seres humanos, actualmente en el mundo el 80% de la producción de energía se produce a través de los combustibles fósiles como el carbón, gas natural y el petróleo. La disponibilidad de energía eléctrica, uno de los más claros indicadores del desarrollo, se emplea como señal de crecimiento económico. La demanda mundial de electricidad está creciendo rápidamente en los últimos tiempos a un ritmo vertiginoso [1].

La posibilidad de pronosticar el consumo futuro de energía eléctrica es una premisa para el buen funcionamiento de los sistemas de gestión [2].

El siguiente trabajo se enmarca en la utilización de las redes neuronales artificiales para el pronóstico de consumo de energía eléctrica en la Universidad de Las Tunas. El siguiente trabajo se divide en cinco partes, en la primera de ellas se brinda una explicación sobre el pronóstico de consumo de energía y los métodos más usados, en la segunda parte se explica brevemente el uso de las redes neuronales, en la tercera parte se caracterizan las variables que influyen en el consumo de energía eléctrica, en la cuarta se aplica el método y se analizan los resultados, y en la quinta y última parte se dan las conclusiones finales del trabajo.

EL PRONÓSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA

La importancia del pronóstico de consumo de energía eléctrica radica no solo en su relación con la disponibilidad de combustibles primarios, sino también en los siguientes factores de carácter técnico económico [3]:

- Conocer con anticipación los futuros gastos financieros por concepto de adquisición de combustibles para la generación de energía eléctrica.
- Prever futuros cambios en las redes eléctricas, subestaciones, líneas de transmisión.
- Prever el aumento del parque de plantas productoras de energía eléctrica.
- Necesidad de aplicar nuevas medidas para el ahorro

En el plano eminentemente técnico el conocimiento del crecimiento o disminución del consumo posibilita realizar el contrato de la máxima demanda de potencia eléctrica en las mejores condiciones económicas posibles.

Métodos más usados para el pronóstico de consumo de energía eléctrica

La predicción del consumo de energía tiene vital importancia para la sociedad en general. Los métodos más usados en el pronóstico de consumo de energía son:

- Método de la tendencia histórica simple

El método de la tendencia histórica para el cálculo del consumo futuro de energía eléctrica se utilizó hasta finales de los años 70. En muchos países se consideraba un aumento de 7,5 % anual del consumo y su duplicación por cada década. Inicialmente este método se aplicó al análisis de las finanzas [4].

Este método solo es conveniente usarlo para predicciones a largo plazo que no requieran de gran exactitud; para análisis a corto y mediano plazo es inexacto, por lo que no es aconsejable su uso.

- Método de usuarios finales

El método de usuarios finales se basa en las ecuaciones clásicas que expresan el consumo de energía eléctrica para cualquier local, área administrativa, centro de trabajo, etc., donde existan consumidores eléctricos, en dependencia de su número, potencia y tiempo de utilización [5].

Este método se basa en ecuaciones definidas clásicas de la ingeniería eléctrica. Es fácilmente realizable en hojas de cálculo. El mismo presenta desventaja pues requiere de una contabilidad muy exacta del tipo de equipamiento, de su número y de la fecha de puesta en funcionamiento además el tiempo de uso promedio del equipamiento que influye significativamente en el consumo y su determinación presenta muchas inexactitudes. También es necesario conocer con anticipación la fecha de adquisición y montaje del nuevo equipamiento. Por lo antes expuesto no es aconsejable su uso.

- Métodos paramétricos

Los métodos paramétricos se ocupan de obtener, a partir del análisis estadístico y matemático de los valores reales de las variables, los valores que tendrían los parámetros de los modelos en los que esas variables actúan, así como de comprobar el grado de validez de esos modelos, y ver en qué medida estos modelos pueden usarse para la predicción del cambio futuro de las variables

PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES

definidas como independientes [6]. Este método no es aconsejable para su utilización en esta investigación pues su exactitud aumenta con el número de datos, lo que no siempre es posible obtener en la cantidad requerida además necesita de elevada correlación entre las variables independientes y la dependiente, exige baja autocorrelación entre las variables independientes.

- Métodos con aplicación de la inteligencia artificial

Las Redes Neuronales Artificiales (RNA) constituyen un potente instrumento para la aproximación de funciones no lineales. Su uso resulta especialmente útil en la modelización de aquellos fenómenos complejos donde la presencia de relaciones no lineales entre las variables es habitual [7]. Una de las aplicaciones de las RNA es la predicción de consumo de energía eléctrica. Por lo anterior expuesto es aconsejable la utilización en esta investigación.

ASPECTOS GENERALES DE LAS REDES NEURONALES ARTIFICIALES

Se puede considerar una Red Neuronal Artificial como un modelo matemático de las actividades mentales y cerebrales [8]. Estos sistemas explotan el procesamiento local en paralelo y las propiedades de la representación distribuida, aspectos que al parecer existen en el cerebro. En la comunicación diaria se utilizan habitualmente información imprecisa, que generalmente el cerebro procesa muy bien, generando incluso nuevo conocimiento [9].

Fundamentos de las Redes Neuronales Artificiales

Hay varias definiciones formales de una Red Neuronal Artificial (RNA). Una definición no tan formal se debe a Albuérne [8] que menciona: "... Una Red Neuronal Artificial es "Un grafo dirigido y no lineal con arcos ponderados, capaz de almacenar patrones cambiando los pesos de los arcos, y capaz de recordar patrones a partir de entradas incompletas y desconocidas"...

Las aplicaciones de las RNA han crecido sustancialmente incluso donde se conocen las relaciones entre las variables pero es difícil trabajar con ellas de una forma eficiente o donde se exija velocidad y precisión. Las RNA han sido entrenadas para efectuar funciones complejas en varios campos de aplicación entre los que se incluyen el análisis de comportamiento [10], el reconocimiento de tendencias [9], la optimización de procesos industriales [11, 12] y los sistemas de control [8, 13], entre muchos más.

En temas relacionados con procesos energéticos las RNA pueden utilizarse para controlar la operación y la eficiencia de un sistema de cogeneración [14], para evaluar las prestaciones de las unidades de generación distribuida [15, 16], para predecir demandas y gastos futuros de portadores en empresas, industrias y centros de servicios y para sugerir estrategias de ahorro [17, 18].

La arquitectura de redes neuronales más ampliamente utilizada es la que se conoce con el nombre de *perceptron* multicapas, la cual se caracteriza por el hecho de que sus neuronas se agrupan en capas por niveles. Cada una de estas capas está constituida por un conjunto de neuronas. Hay tres tipos de capas diferentes: la capa de entrada, las capas ocultas y la capa de salida, como se observa en la fig. 1.

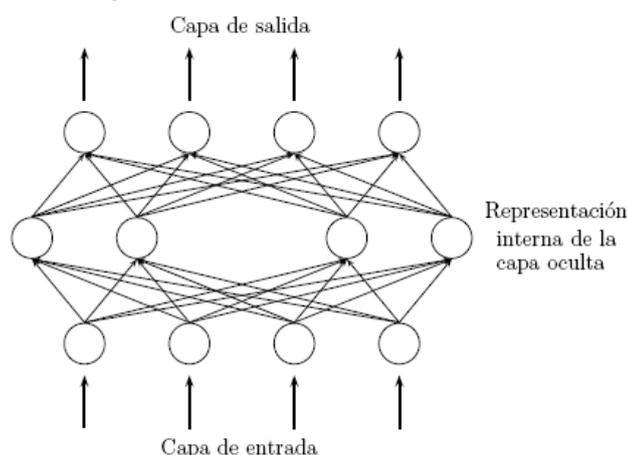


Fig. 1. Red neuronal *feedforward*.

Las neuronas de la capa de entrada se encargan únicamente de recibir señales o patrones que vienen del exterior y propagan tales señales a todas las neuronas de la capa siguiente. La última capa actúa como salida de la red, proporcionando al exterior la respuesta de la red para cada uno de los patrones de entrada. Las neuronas de las capas ocultas realizan un procesamiento no lineal

PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES

de los patrones recibidos. Como se observa en la fig. 1, las conexiones del perceptron multicapas están siempre dirigidas hacia delante, i. e., las neuronas de una capa se conectan con las neuronas de la capa siguiente; por tal motivo reciben el nombre de redes alimentadas hacia delante o redes *feedforward*. A las conexiones se les asocia un número real llamado peso de la conexión y a las neuronas de la red un umbral, que en el caso del perceptron multicapas es tratado como una conexión adicional a la neurona.

Para describir los resultados finales de un modelo basado en Redes Neuronales Artificiales existen formas de expresarlos esquemáticamente y otra a modo de ecuación. En la fig. 2 aparece la arquitectura de una RNA de tres capas según la ayuda del MATLAB.

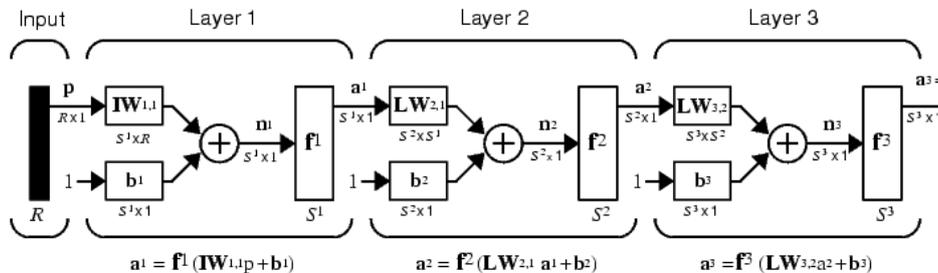


Fig. 2. Arquitectura de una red neuronal de tres capas.

El gráfico de la figura anterior se puede manifestar en forma de expresión matemática según la ecuación (1).

$$LW_{3,2}f^2(LW_{2,1}f^1(IW_{1,1}p + b_1) + b_2) + b_3 \quad (1)$$

En una neurona artificial las entradas X_i representan vectores o señales que provienen del exterior o son capturadas de otras neuronas. Los pesos W_i representan la intensidad de la sinapsis; tanto X_i como W_i son valores escalares. A esa señal ponderada se le adiciona el “*bias*” (b) y se obtiene una entrada total que actúa sobre el núcleo de la neurona para activarla; f es la función umbral o de transferencia que, evaluada para esa entrada total, produce la respuesta de la neurona al estímulo exterior recibido en forma similar a como ocurre en las células nerviosas biológicas.

En términos matemáticos este proceso se representa de forma sencilla como:

$$Salida = f(X_{neta} + b) \quad (2)$$

Tanto el vector de pesos W como el “*bias*” son parámetros escalares y ajustables de la neurona. La idea central de una red neuronal es que estos parámetros puedan ser ajustados de forma tal que la red reproduzca el comportamiento observado. El entrenamiento es precisamente eso; un proceso de ajuste de los parámetros en la red para que pueda realizar un trabajo en particular. Debe conocerse además, que existe la posibilidad de que la propia red los ajuste para cumplir sus obligaciones.

Las redes con “*bias*” pueden representar el sistema con mayor facilidad que las que no lo poseen ya que si la entrada neta de una red es cero y no posee “*bias*”, la salida será sólo la evaluación de la función de transferencia para el valor cero, pero al tenerlo, se puede aproximar más la respuesta al valor real del sistema cuando la entrada neta es cero.

SELECCIÓN DE LAS VARIABLES QUE INFLUYEN EN EL CONSUMO DE ENERGÍA ELÉCTRICA

Para realizar la predicción del consumo de energía eléctrica es necesario definir las variables explicativas (independientes) que se usarán, las que, directa o indirectamente, deben tener influencia en el consumo de electricidad.

Debido a que uno de los requerimientos de los análisis es evitar la autocorrelación entre variables, y que el número de estas no debe ser grande, con el objetivo de que no se produzca un coeficiente R^2 falso, se descarta el uso de la variable matrícula total, ya que esta incluye en un alto por ciento la matrícula diurna. Además, los alumnos externos que junto con los diurnos conforman la matrícula total prácticamente no inciden en el consumo de energía eléctrica debido a que su presencia en la Universidad es quincenal y no hacen uso de la beca, del comedor y el uso que

PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES

hacen de los laboratorios de computación es bajo. Se decide incluir la (variable diurnos + trabajadores), debido a que representan la totalidad de las personas que permanecen mayor tiempo en la Universidad, incidiendo en el consumo de energía eléctrica. Se incluye la variable becados, debido a que constituyen la categoría de estudiantes diurnos que más impacto tienen en el consumo de energía eléctrica por su pertenencia a la Residencia Estudiantil. Además se escogen como variables de entrada el número de computadoras (PC) y el número de aires acondicionados los cuales varían por cursos e inciden significativamente en el consumo de energía eléctrica de la universidad. La fig. 3 muestra un diagrama de Pareto donde se muestra el consumo de energía eléctrica por equipos claves.

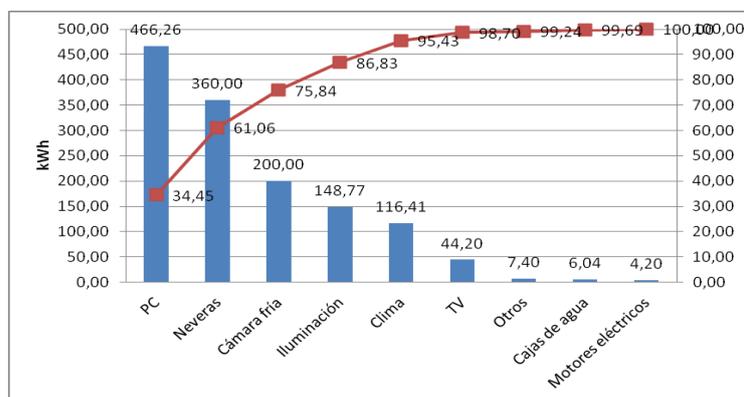


Fig. 3. Distribución del consumo de energía eléctrica por uso final.

En la tabla 1 se muestran las variables seleccionadas para realizar el pronóstico usando redes neuronales.

Tabla 1: Variables que inciden directamente en el consumo de energía eléctrica.				
MWh	BECADOS	PC	AIRES	MD+T
203,48	385	88	36	1341
194,86	376	96	38	1445
207,71	417	111	43	1645
238,90	571	123	50	1811
365,91	534	145	66	1922
390,55	508	162	79	1939
334,96	633	178	87	1810
315,68	603	268	97	1679
337,83	518	280	120	1809

ANALIZAN LOS RESULTADOS.

Para la predicción del consumo por cursos de energía eléctrica se modeló una red neuronal del tipo *Feed-forward backpropagation*, con una función de entrenamiento del tipo TRAINLM, formada por 2 capas. La primera capa está formada por 4 neuronas del tipo tangencial sigmoideal (*tansing*). La capa intermedia u oculta está formada por 10 neuronas del tipo *tansing*, estas se variaron en el entrenamiento. La tercera capa está formada por 1 neurona del tipo *pureline* o función de activación lineal. Para el entrenamiento se empleó el método del gradiente descendiente con retropropagación del error hacia atrás.

El entrenamiento supervisado se realizó con los datos de entrada de la tabla 1, se conformó una red neuronal que permitió pronosticar el consumo de energía eléctrica por cursos en función del total de becados, el total de diurnos y trabajadores, el número de PC por cursos y de aires acondicionados.

Como patrón de referencia de la exactitud se utilizó error medio cuadrático (EMC). Los valores de comparación fueron los pronosticados por la red y los reales de entrenamiento. No se utilizó la posibilidad de conformar vectores de validación debido a que el número de parámetros es bajo. Para modelar la red se varió el número de neuronas en la capa oculta y el total de épocas de la

PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES

red. Para el trabajo se utilizó el Neural Network Toolbox del MATLAB, usado en la creación, entrenamiento y simulación de la red neuronal. El mismo se puede llamar usando el comando *nntool*.

La determinación del número óptimo de neuronas de la capa oculta se llevó a cabo mediante un proceso de ensayo y error. En todo caso, el objetivo será dotar a la red de un número adecuado de neuronas en la capa oculta para que sea capaz de aprender las características de las posibles relaciones existentes entre los datos de la muestra. Demasiadas neuronas podrían llevar a un sobre-ajuste, la red memorizaría el conjunto de datos de entrenamiento y para valores pertenecientes al mismo su precisión sería casi absoluta. Sin embargo si le presentan valores desconocidos fallaría estrepitosamente, dado que como consecuencia del sobre-ajuste sería incapaz de generalizar. Por otra parte si el número de neuronas en la capa oculta es reducido podremos llegar a una situación de *sub-ajuste*, en la cual la red no sería capaz de aprender ciertas relaciones existentes entre las variables.

El aprendizaje de este modelo se estableció a las 30 interacciones. La capacidad de aprendizaje se estimó comparando el conjunto del entrenamiento y los datos en tiempo real para cantidades diferentes de neuronas en la capa oculta. Se eligió, por ultimo una cantidad de 10 neuronas en la capa oculta, ya que fue el valor que ofreció una mejor combinación entre estos datos. Luego de 100 interacciones, la red alcanzó un error cuadrático medio de 0.0001615369. El entrenamiento de la red se puede ver en el gráfico de la fig. 4.

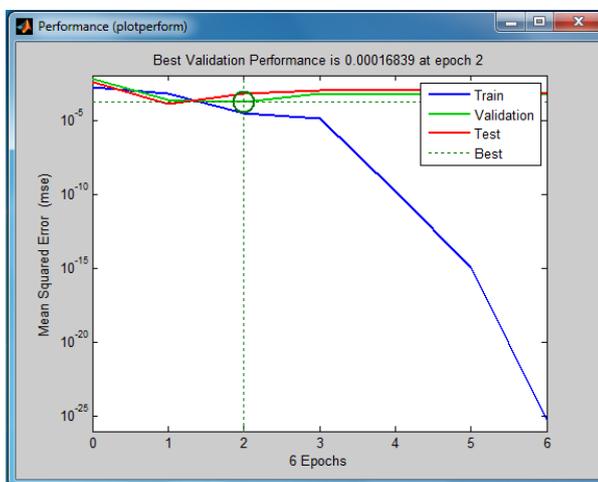


Fig. 4. Gráfico del aprendizaje de la red.

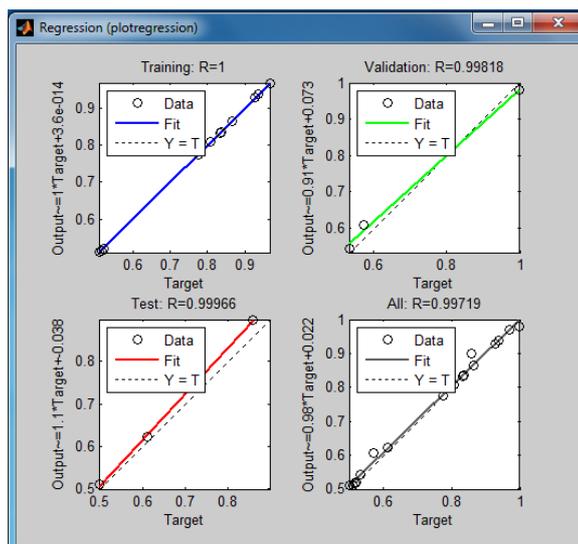


Fig. 5. Resultados del entrenamiento, las pruebas y la validación de los modelos en RNA.

El modelo basado en redes neuronales presentó un coeficiente de correlación, $R^2 = 0.99$. En la figura 5 se muestran los gráficos de dispersión entre los valores predichos por la red y los valores reales. Estos datos corresponden a los valores utilizados para el aprendizaje, los valores utilizados

PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES

para las pruebas y los utilizados en la validación. Finalmente aparecen todo el conjunto de datos reflejando que el modelo en RNA posee un ajuste de un 99%.

El modelo basado en RNA queda conformado con los siguientes pesos y polarizaciones en correspondencia con la cantidad de capa de neuronas:

IW{1,1}=			
0.53436	-1.177	-1.1564	1.3055
1.0683	0.042907	2.1661	0.58675
-1.6351	1.0448	-1.3928	0.27344
-0.78799	1.5413	1.7689	1.6865
-0.25229	2.2666	-0.49714	-0.25612
1.8738	0.17782	-1.2434	0.98435
-0.75665	-1.6949	-1.1679	1.184
0.47796	-1.833	1.0021	-0.63991
-1.832	-1.467	-0.047083	0.75042
0.69454	1.3915	-0.4981	-1.83

IW{2,1}=
[-0.028759 0.13705 0.0088941 0.74066 -0.38186 -0.070697 0.023666 -0.39638 -0.22705 -0.55138]

b{1}=
-2.5031
-1.9363
1.4636
0.649
-0.018299
0.17608
-0.82907
1.7898
-1.9938
2.6542

b{2}=
[0.55276]

En la tabla 2 se muestran los resultados de la simulación de la red neuronal de 10 neuronas (RN10), el error absoluto obtenido y el error medio cuadrático obtenido.

Tabla 2. Resultado de la simulación de la red RN10.	
MWh Real	RNA10 Pronosticado
203,480	203,509
194,860	194,901
207,710	217,414
238,900	247,598
365,910	360,066
390,550	390,550
334,960	339,741
315,680	324,806
337,830	337,828
EMC	5,870

Como se puede observar el error de aproximación obtenido de 5,87, provocado principalmente por la existencia de pocos datos de entrenamiento.

Observaciones:

- El hecho de que las RNA aceptan relaciones no lineales constituye una considerable ventaja ante la regresión múltiple.

Una manera de determinar el impacto económico de la utilización del método de pronóstico de consumo de energía eléctrica usando redes neuronales es realizando una comparación entre el

PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES

valor pronosticado por la red neuronal y el estimado por el departamento de contabilidad de la Universidad de Las Tunas.

Los datos de entrada utilizados para la simulación de la red neuronal fueron obtenidos en la oficina de estadística de la Universidad mostrándose de esta manera:

Becados	PC	Aires	MDT	MWh (Estimado por Estadística)
526	278	122	1830	330

Los MWh pronosticados por la red neuronal: 298.23 MWh año.

La diferencia de entre los MWh pronosticados y los estimados se realiza por cálculo aritmético.

$$Dif. Pronst_{MWh} = MWh_{est} - MWh_{pronst} \quad (3)$$

Donde:

MWh_{est} : MWh estimado por la oficina de Estadística en función del comportamiento del consumo de energía en los años y la suma de los consumos mensuales ajustados a los planes.

MWh_{pronst} : MWh pronosticado por la red neuronal.

$Dif. Pronst_{MWh}$: Diferencia entre pronósticos.

$$Dif. Pronst_{MWh} = 330 MWh - 298.2258 MWh$$

$$Dif. Pronst_{MWh} = 31,77 MWh$$

Este resultado muestra una información más allá del valor monetario que se pueda tener pues $Dif. Pronst_{MWh}$ es la diferencia de dos valores pronosticados, el alcance real de este valor está en las posibilidades que brinda al permitir de acuerdo con este valor la posibilidad de recontractar la demanda con la Empresa Eléctrica lo que si representaría un ahorro real. Además permitiría tener un valor de referencia para reprogramar los planes tanto anuales como mensuales. Aun así si el ahorro real fuese de 31,77 MWh eso representaría un ahorro en dinero de 31811.78 pesos al año, pues por factura se toman 0,166 \$/kWh que es la tarifa eléctrica promedio de la Universidad.

CONCLUSIONES

Se creó una red neuronal para el pronóstico del consumo de energía eléctrica obteniéndose un error de aproximación de 5,87 % debido a la existencia de pocos datos en el entrenamiento.

Se comprobó la validez del método propuesto al comparar los resultados pronosticados con los valores estimados por la oficina de estadística de la Universidad, resultando una diferencia de 31,77 MWh, mostrando lo fiable que resulta este método para el pronóstico de consumo de energía.

BIBLIOGRAFÍA

- [1] J. J. Cabello, *et al.*, "An approach to sustainable development: the case of Cuba.," *Environment, Development and Sustainability.*, vol. XIV, n. 4, pp. 573-591., 2012. ISSN: 0120-5609, Disponible: <http://dx.doi.org/10.1007/s10668-012-9338-8>.
- [2] V. M. Zavala, *et al.*, "On-line economic optimization of energy systems using weather forecast information," *Journal of Process Control*, vol. XXIX, n. 10, pp. 1725-1736., 2009. ISSN: 0959-1524, Disponible: <http://www.sciencedirect.com/science/article/pii/S0959152409001231>.
- [3] R. F. Pérez, "Proposición de indicadores de consumo de energía eléctrica para los CES del MES. Estudio de caso en la Universidad de Cienfuegos.," in *5to. Taller Internacional de Energía y Medio Ambiente*, Cienfuegos. Cuba. 23 al 25 de Abril, 2008. ISBN: 978-959-257-323-9,
- [4] D. V. Real, "Modelos para la predicción de la demanda de energía eléctrica," Tesis de Maestría, Universidad Autónoma de Andalucía., 2009. http://www.fondosdigitales.us.es/public_thesis/388/9081.pdf
- [5] G. F. Filho and R. A. Dias, "Estimativa de demanda em edificios residenciais: uma análise comparada," *Revista Eletricidade Moderna*, vol. X, n. 2, pp. 16 - 22, 2010. ISSN 1699-6569, Disponible: <http://www.labplan.ufsc.br/congressos/Induscon%202010/fscommand/web/docs/T0821.pdf>
- [6] D. Yu and S. Tao, "The Method of Classification for Financial Distress Prediction Indexes of Sinopec Corp. and Its Subsidiaries Based on Self-Organizing Map Neural Network.," in *Fourth International Conference on Computational and Information Sciences (ICCIS)*. , Chongqing. China., 2012, pp. 590 - 593., ISBN: 978-1-4673-2406-9., <http://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=6299182>.
- [7] J. C. Santana, "Predicción de series temporales con redes neuronales: una aplicación a la inflación colombiana.," *Revista Colombiana de Estadística*, vol. XXIX, n. 1, pp. 77 - 92, 2006. ISSN: 0120-1751, Disponible: <http://www.scielo.org.co/pdf/rce/v29n1/v29n1a05.pdf>.
- [8] Y. L. Albuérne, *et al.*, "Comparación De Las Fortalezas Y Debilidades De Los Esquemas De Control De Procesos Con Redes Neuronales.," *Tecnología Química*, vol. XXV, n. 3, pp. 65 - 73., 2005. ISSN: 2224-6185, Disponible: <http://ojs.uo.edu.cu/index.php/tq/article/view/2250/1791>.
- [9] M. C. Amorim Neto, *et al.*, "Improving financial time series prediction using exogenous series and neural networks committees," in *The 2010 International Joint Conference on Neural Networks (IJCNN)*, Barcelona. España., 2010, pp. 1 - 8 ISSN: 1098-7576 <http://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=5581822>.
- [10] S. M. Muyeen, *et al.*, "Reduction of frequency fluctuation for wind farm connected power systems by an adaptive artificial neural network controlled energy capacitor system.," *Renewable Power Generation, IET*, vol. VI, n. 4, pp. 226 - 235., 2012. ISSN: 1752-1424, Disponible: <http://digital-library.theiet.org/content/journals/10.1049/iet-rpg.2010.0126>.
- [11] J. C. Armas, *et al.*, "Evaluación termodinámica de sistemas de climatización centralizados por agua helada usando herramientas de inteligencia artificial.," *Ingeniería e Investigación.*, vol. XXXI, n. 2, pp. 134-142., 2011. ISSN: 2248-8723, Disponible: <http://www.revistas.unal.edu.co/index.php/ingenv/article/view/23472/24324>.
- [12] D. Aiordachioaie, *et al.*, "Pre-processing of acoustic signals by neural networks for fault detection and diagnosis of rolling mill," in *Fifth International Conference on Artificial Neural Networks*, Cambridge, UK, 1997, pp. 251 - 256. ISBN: 0-85296-690-3, http://digital-library.theiet.org/content/conferences/10.1049/cp_19970735.
- [13] O. Ozgonenel and T. Yalcin, "Principal Component Analysis (PCA) based neural network for motor protection," in *10th IET International Conference on Developments in Power System Protection (DPSP 2010). Managing the Change*, Manchester, UK, 2010, pp. 101-108. ISBN: 978-1-84919-212-5, <http://digital-library.theiet.org/content/conferences/10.1049/cp.2010.0252>.
- [14] H. Nikpey, *et al.*, "Development of an artificial neural network model for combined heat and power micro gas turbines.," in *International Symposium on Innovations in Intelligent Systems and Applications (INISTA)*. Trabzon. Turquía., 2012, pp. 1 - 5., ISBN: 978-1-4673-1446-6., <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&number=6247045>.
- [15] L. C. Barrios and A. R. Vázquez, "Clasificación de fallas con redes neuronales para grupos electrógenos.," *Ingeniería Energética*, vol. XXXIV, n. 2, pp. 137-150., 2013. ISSN 1815 - 5901, Disponible: <http://rie.cujae.edu.cu/index.php/RIE/article/view/364/366>.

PRONOSTICO DE CONSUMO DE ENERGÍA ELÉCTRICA USANDO REDES NEURONALES ARTIFICIALES

- [16] M. Dewadasa, *et al.*, "Fault isolation in distributed generation connected distribution networks," *IET Generation, Transmission & Distribution*, vol. V, n. 10, pp. 1053 – 1061, 2011. ISSN 1751-8695, Disponible: <http://digital-library.theiet.org/content/journals/10.1049/iet-gtd.2010.0735>.
- [17] F. P. Viego, *et al.*, "Programas nacionales de eficiencia energética en los edificios públicos," in *7mo. Taller Internacional de Energía y Medio Ambiente*, Cienfuegos. Cuba.. 2012. ISBN: 978-959-257-323-9,
- [18] R. M. Laurencio, *et al.*, "Predicción del consumo de electricidad y glp en un hotel mediante redes neuronales artificiales," *Energética*, vol. 42, n. 3, pp. 21-27., 2009. ISSN: 0120-9833 Disponible: <http://redalyc.uaemex.mx/src/inicio/ArtPdfRed.jsp?iCve=147012854002>.