

Implementación de una Red Neuronal Artificial para la predicción de la Demanda Eléctrica a corto plazo

J. Carrión

Universidad Nacional de Loja
E-mail: jorge.carrion.g@unl.edu.ec

Resumen

El pronóstico de la demanda eléctrica es un problema de gran importancia para el sector eléctrico, a partir de los resultados que se obtienen en un pronóstico los organismos reguladores toman decisiones adecuadas. Un buen pronóstico trae grandes beneficios tanto técnicos como financieros, por lo que en la actualidad se busca constantemente desarrollar modelos de predicción con el mínimo porcentaje de error, los resultados que se presentan en este trabajo corresponde al desarrollo de una red neuronal artificial para el pronóstico de la demanda eléctrica a corto plazo, utilizando las herramientas de Matlab. La base de datos que se utilizó corresponde a las mediciones registradas por el sistema SCADA en un alimentador primario de la ciudad de Loja-Ecuador. Se emplea una red neuronal con el mínimo de capas y neuronas, sin perder la precisión del pronóstico. Para entrenar la red neuronal se realizó una adecuada selección y clasificación de las variables de entrada.

Palabras clave— Alimentador primario, Pronóstico de la demanda eléctrica a corto plazo, Red neuronal, Precisión del pronóstico.

Abstract

The prognostication of electricity demand is a major problem for the electricity business, the regulators agencies can make appropriate decisions based on the results obtained in a demand prognostic. A good prediction produces great technical and financial benefits, It for this reason that nowadays is necessary to develop predictive models with minimal error rate.

The results presented have been obtained by using an artificial neural network for forecasting electricity demand in the short term developed using Matlab, the database used corresponds to those recorded by the SCADA system measurements on a feeder primary of of Loja-Ecuador city.

An artificial neural network was implemented with the minimum of layers and neurons, without losing forecast accuracy, to train the neural network an adequate selection and classification of input variables was performed.

Index terms— Primary feeder, demand electricity prognosis in the short term, neural network, forecast accuracy.

Recibido: 08-09-2016, Aprobado tras revisión: 16-12-2016

Forma sugerida de citación: Carrión, J. (2017). "Implementación de una red neuronal artificial para la predicción de la demanda eléctrica a corto plazo". Revista Técnica "energía". No. 13, Pp. 36-42
ISSN 1390-5074.

1. INTRODUCCIÓN

Pronosticar el consumo de energía eléctrica de carga diaria, genera ahorros de dinero considerables para las empresas suministradoras, por gastos de generación y operación. Por lo tanto, el costo de los errores de pronóstico pueden ser de tal magnitud que muchas investigaciones se han centrado en reducir al mínimo posible el error de pronóstico; convirtiéndose este tema en una parte integral de la planeación para las empresas de diversa índole y envergadura; que van desde la generación, transmisión y distribución hasta el consumo, requiriéndose de sistemas confiables de pronóstico.

El pronóstico de demanda de energía eléctrica se define básicamente como la ciencia o el arte de predecir la carga futura en un sistema dado, para un periodo de tiempo futuro específico. Esta predicción puede ser desde unos minutos con fines de operación, hasta años con fines de planeación.

Por la importancia que tiene la predicción de carga diaria se han desarrollado diferentes métodos de pronóstico, entre ellos los métodos basados en inteligencia artificial, en particular redes neuronales. Para el desarrollo de esta investigación se utilizó la información de las mediciones de demanda, medidas por el sistema SCADA de un alimentador de la ciudad de Loja, cada 15 minutos, con esta información se conformó la base de datos, para diseñar y crear una red neuronal artificial, para el pronóstico de demanda de energía a corto plazo haciendo uso de las herramientas que posee Matlab.

2. MÉTODO (DESCRIPCIÓN DE LAS REDES NEURONALES ARTIFICIALES)

2.1. Características de la Carga del Alimentador en Análisis

La carga del sistema eléctrico del alimentador en análisis posee un factor de carga de 0,86 aproximadamente, con fuerte presencia del tipo de consumidor residencial y comercial.

Estas características definen un perfil de la curva de carga con algunas variaciones características por las condiciones climáticas de la región. En la fig. 1, se muestra el perfil característico de la demanda del sistema eléctrico de este alimentador en análisis.




Figura 1: Curva de carga de demanda máxima del alimentador en análisis

3. APLICACIÓN (DESCRIPCIÓN DE LA APLICACIÓN AL ALIMENTADOR SELECCIONADO)

3.1. Pronóstico de la Demanda de Energía Eléctrica a Corto Plazo

El pronóstico a corto plazo es requerido por los encargados de planificar la operación diaria. Estos pronósticos consisten en proporcionar la demanda de energía eléctrica del sistema sobre un intervalo de horas, días e incluso semanas (Hinojosa Mateus, 2008) (Sarmiento Maldonado, 2008). El pronóstico desempeña un papel importante en la operación y despacho económico de unidades [1] [2] [3]. La demanda de energía eléctrica tiene variaciones naturales, ésta se ve afectada por varios factores tales como condiciones sociales, meteorológicas y económicas. Las condiciones climatológicas tienen un papel preponderante en el pronóstico de la demanda a corto plazo.

3.2. La Naturaleza de la Demanda de Energía Eléctrica

La curva de la demanda tiene un patrón que se repite sobre los años, en su gran mayoría es cíclica. La única diferencia es que el pico de la curva está aumentando constantemente cada año, señalando el crecimiento en la demanda (Sarmiento Maldonado, 2008).

Así, el pronóstico se reduce a un reconocimiento del patrón, para encontrar el crecimiento o tendencia subyacente de la demanda [2,3]. (Valencia C, 2013)

3.3. Redes Neuronales Artificiales

Una red neuronal artificial RNA puede ser definida como un sistema altamente conectado de procesadores elementales llamados neuronas, las cuales procesan informaciones a través de su estado dinámico en respuesta a señales externas (ALFONSO GALIPIENSO, 2003). Poseen este nombre porque son inspiradas en modelos biológicos, es decir, ellas están compuestas por elementos que reproducen algunas funciones elementales de la neurona biológica. La fig. 2 muestra una estructura genérica de una red frecuentemente usada [4].




Figura 2: Estructura de una Red Neuronal

Las neuronas están conectadas unas con otras, una neurona puede tener múltiples entradas pero una única salida. La entrada de una neurona puede provenir de una señal externa o la salida de otra neurona (Del Brio, 2001). Copias de la salida simple de una neurona puede ser la entrada de muchas otras neuronas en la red. A las diferentes conexiones, sinapsis, de las neuronas están asociados unos pesos, conforme se puede apreciar en la fig. 3a.

Cuando la suma de los pesos de entrada de una neurona excede un valor, la neurona es activada para producir una señal de salida. Las funciones de activación más utilizadas son la tangente sigmoidea y lineal unitaria, por su flexibilidad y amplio rango de resultados que ofrecen, conforme se puede apreciar en la fig. 3b y 3c, respectivamente.

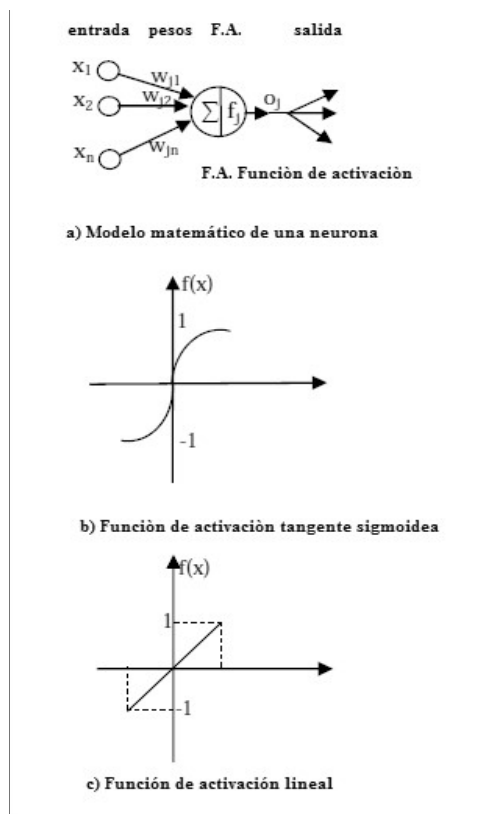


Figura 3: Esquema de una neurona artificial

4. DESARROLLO

4.1. Conjunto de Entrenamiento

Es el conjunto de datos que sirve para que la red neuronal pueda aprender los patrones presentes en los datos, que se define como la obtención de los pesos de la red.

En el desarrollo de la red, este conjunto de datos representará un total de 1128 mediciones de consumo de 1176 datos disponibles.

Los datos seleccionados corresponden a los 47 meses, del conjunto de meses analizados, que es 49, la base de datos corresponde a 5 años de mediciones.

4.2. Conjunto de Validación

Se utiliza para la comprobación final de la red, donde los datos empleados son los más recientes consecuentemente al último valor de la muestra. El conjunto de validación debe consistir en las más recientes y contiguas observaciones (Ojeda Sarmiento, 2010). Se debe procurar no usar el conjunto de validación como conjunto de testeo, tras ejecutar repetidamente pasos de series de entrenamiento-testeo-validación y adaptar las variables de entrada basadas en la actuación de la red en el conjunto de validación [5].

4.3. Conjunto de Prueba

El conjunto de prueba se selecciona de la base de datos, en este caso corresponde a los datos restantes, una vez seleccionados los patrones de entrenamiento. Este conjunto de datos seleccionado se utilizan para evaluar la precisión de la red, estos datos corresponden a los últimos 48 registros de consumo de la base de datos en estudio (últimos dos meses).

4.4. Selección de la Arquitectura de Redes Neuronales

Según la revisión bibliográfica desarrolla existen diversas formas para determinar la arquitectura a seguir para desarrollar una red neuronal de predicción, en la mayoría de los casos se utilizan las redes con algoritmo de entrenamiento Backpropagation [5] [6]. Para crear una red neuronal se debe seleccionar:

4.4.1 Número de Neuronas de Entrada

Corresponden a las mediciones registradas por el sistema SCADA a la salida del circuito analizado, en un intervalo de tiempo de un año, en la base de datos equivaldría a 12 meses, y el consumo de cada mes seleccionado equivaldría a 24 datos. En este caso la cantidad de neuronas de entrada son 24 datos.

4.4.2 Número de Capas Ocultas

Las capas ocultas dan a la red la habilidad de generalizar, y en la práctica las redes neuronales con una o dos capas ocultas son las más utilizadas y han tenido un buen desempeño [7]. El incremento en el número de capas también incrementa el tiempo de procesamiento y el peligro de sobre ajuste lo que conduce a un pobre desempeño en la predicción fuera de muestra. El sobre ajuste ocurre cuando un modelo de predicción tiene muy pocos grados de libertad (Santos Peña, 2005. En otras palabras, se tienen relativamente pocas observaciones en relación con sus parámetros y por lo tanto es capaz de memorizar datos individuales en lugar de aprender patrones generales. Es por eso que en casi todos los estudios se

recomienda que todas las redes neuronales comiencen de preferencia con una o a lo mucho con dos capas.

Para el desarrollo de esta investigación, se optó por una sola capa oculta, la cual es suficiente para asegurar la capacidad de generalización de la red, por lo que la red tendría un total de 3 capas, la capa de entrada, la capa oculta y la capa de salida.

El número de neuronas que conformaran la capa oculta será del 75% del total de entradas [8]. El número de entradas de la red es de 24, que equivalen al número de horas del día de mayor consumo de un mes, de los 49 meses de la base de datos, por lo que el número de neuronas que contendrá la capa oculta será de 18 neuronas.

Para decidir el número de neuronas que contendrá la salida de la red neuronal, se determinó emplear sólo una neurona de salida, debido a que las redes neuronales con múltiples salidas, especialmente si éstas salidas están ampliamente espaciadas, producirán resultados inferiores en comparación con una red con una única salida. Lo recomendable es tener una red especializada para cada una de las salidas deseadas en cada predicción.

En esta investigación el número de neuronas de la capa de salida de la red será una, porque solo se intenta predecir el valor de la variable seleccionada para el siguiente mes [6,7].

4.4.3 Función de Transferencia

Con esta función se busca prevenir a las salidas, de alcanzar valores muy elevados, los cuales pueden paralizar la red y detener el entrenamiento de la misma. Como función de transferencia se utilizó la función sigmoidea (cuyo rango de salida se encuentra entre -1 y +1) la cual es preferente para tareas de predicción según [7].

La fig. 4 muestra la arquitectura de la red neuronal implementada para la predicción de demanda eléctrica.

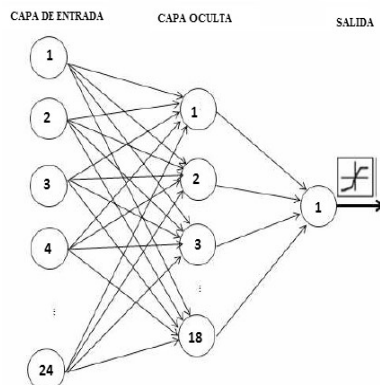


Figura 4: Arquitectura de la Red Neuronal

4.5. Criterios de Evaluación

Para el criterio de evaluación para medir la eficiencia de la red, se ha considerado utilizar el Error Cuadrático Medio (ECM). El Error Cuadrático Medio calculado se define como la diferencia entre la salida de la red y la respuesta deseada, el cual se usa como factor de culminación del entrenamiento. Para esta fase se fijó un parámetro de 300 iteraciones, y el factor de terminación empleado del ECM teniendo como umbral un valor de 0.5 [8].

4.6. Entrenamiento de la Red Neuronal

Entrenar una red neuronal para aprender patrones, involucra presentarle ejemplos de manera iterativa de las respuestas correctas. El objetivo fundamental del entrenamiento es encontrar un conjunto de pesos entre las neuronas que determinan el mínimo global de la función de error. A menos que el modelo esté sobreajustado, el conjunto de pesos debería proporcionar una buena generalización.

El entrenamiento de la red utiliza la técnica del gradiente descendente inmerso en el algoritmo de retro propagación (backpropagation). El entrenamiento de la red neuronal se detendrá cuando ocurra cualquiera de las siguientes variantes:

1. Se llegue al número de iteraciones programado.
2. Si la función de evaluación (ECM) cae por debajo de la meta establecida.
3. Si el error medido por la función de evaluación se incrementa para un número específico de iteraciones (este último caso requiere de la existencia del conjunto de validación). En cualquier caso los pesos y bias obtenidos son los encontrados en el mínimo error medido por la función de evaluación [5, 8].

4.7. Implementación del Modelo de Predicción con Redes Neuronales

Para hacer la implementación del modelo que se presentó en la fig. 4, se efectuó el procedimiento que se resume en la tabla 1 (Medina Hurtado, 2005). En la tabla se puede interpretar la estructura de la implementación y funcionamiento de la red neuronal desarrollada en MATLAB.

Tabla 1: Resumen de Datos de la Red Neuronal Desarrollada

Resumen de Datos de la Red Neuronal Desarrollada	
Base de datos pre procesada	1 176 mediciones
Variable	kW
Frecuencia de los datos	mensual
Número de iteraciones	300
Número de datos para el entrenamiento de la red neuronal	1 128
Número de datos para la prueba de la red neuronal	48
Número de neuronas de entrada	24
Número de capas ocultas	1
Número de neuronas ocultas en cada capa	18
Número de neuronas de salida	1
Función de transferencia	Función Sigmoidal
Función de error	Error Cuadrático Medio

En la fig. 5, se observa el entrenamiento de la red, una vez que se alcanzó la iteración 300, que era el número máximo de iteraciones permitido, condición de parada del entrenamiento. Es necesario guardar la red ya entrenada, para utilizarla en el cálculo del nivel de error, como dato final de la implementación del modelo de la red neuronal, se presentan los siguientes resultados gráficos que miden la eficiencia de la red:

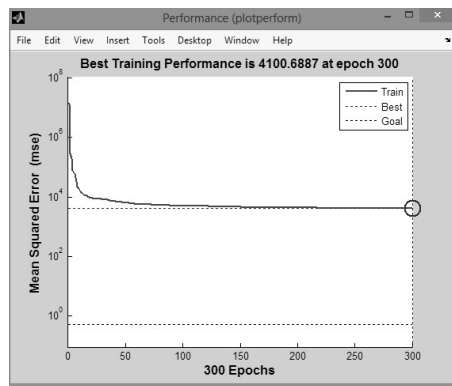


Figura 5: Performance del Entrenamiento

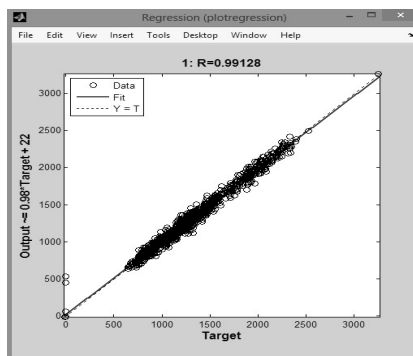


Figura 6: Correlación entre los valores reales y pronósticos de consumo

En la fig. 6, se puede observar, que el coeficiente de correlación es bastante elevado ($R=0,99128$) el cual está muy cercano a 1, por lo que se puede afirmar que existe una alta correlación entre los valores reales (abscisas) y los pronósticos (ordenadas). En la línea azul se indica los puntos en los que los valores reales son coincidentes o iguales a los pronosticados [5].

4.8. Cálculo del Error del Modelo Propuesto

Para el cálculo de error de la red neuronal se emplean los 48 registros de consumo eléctrico restantes de la base de datos, que corresponden a los últimos 2 meses de la misma (año 2014). Estos datos se utilizarán para determinar el nivel de error del pronóstico de la predicción de la demanda a mediano plazo (meses). La predicción de los próximos 2 meses (48 datos) de demanda, mediante la red neuronal seleccionada, se compara con los datos de demanda reales, para validar el modelo de red neuronal desarrollado. En la tabla 2 y tabla 3, se presentan los valores de la demanda de los dos últimos meses de la base de datos, y los valores obtenidos con la predicción que realiza la red neuronal implementada [5].

Con los resultados obtenidos que se presentan en la tabla 2, se evaluó y validó el comportamiento de la red neuronal implementada con un conjunto de datos de prueba, se hace la comparación entre los valores pronosticados y los consumos reales, se tomaron como referencia los dos últimos meses de la base de datos. Se presenta en la tabla 2 el error del pronóstico acumulado para cada caso, con un límite de 300 iteraciones en el entrenamiento de la red.

5. RESULTADOS

Con la validación de la red neuronal es posible tener un margen de certidumbre aceptable, para poder realizar la predicción de la posible demanda de energía del circuito en análisis, del siguiente mes, utilizando la red neuronal desarrollada. A continuación se describe el procedimiento a seguir.

Para poder pronosticar es necesario crear una nueva base de datos que comprende en crear una hoja de Excel, donde se encuentren el último mes de consumo, en este caso el día de mayor consumo del mes, que equivale a 24 datos anteriores a los que se quiere predecir.

Al ejecutar las líneas de código desarrolladas se obtiene el pronóstico de consumo del siguiente mes del circuito en análisis, en la tabla 3 se presentan los resultados obtenidos.

Tabla 2: Predicción de los últimos 48 datos de consumo eléctrico, Aplicando la RNA desarrollada

MES	HORA	CONSUMO REAL KW	PREDICCIÓN KW	NIVEL DE ERROR RELATIVO %
JUNIO	1	1 078	1 178,48	-9,32
	2	944	780,18	17,35
	3	882	769,67	12,74
	4	867	1 036,46	-19,55
	5	860	870,97	-1,28
	6	1091	976,07	10,53
	7	1 325	1 254,03	5,36
	8	1 245	1 185,49	4,78
	9	1 174	1 060,82	9,64
	10	1 235	1 382,46	-11,94
	11	1 294	1 263,10	2,39
	12	1 389	1 424,04	-2,52
	13	1 395	1 325,71	4,97
	14	1 433	1 367,76	4,55
	15	1 451	2 493,29	-71,83
	16	1 460	1 423,05	2,53
	17	1 414	1 450,28	-2,57
	18	1 388	1 580,86	-13,89
	19	2 103	2 036,84	3,15
	20	2 279	2 338,28	-2,60
	21	2 300	2 287,84	0,53
	22	2 157	2 197,63	-1,88
	23	1 858	1 799,58	3,14
	24	1 496	1 556,39	-4,04

Tabla 3: Predicción de la Red Neuronal del siguiente mes

HORA	DEMANDA DEL ALIEMNTADOR EN KW
1	1 177,82
2	820,28
3	692,81
4	780,72
5	902,03
6	996,34
7	1 352,92
8	1 249,17
9	1 057,55
10	1 395,75
11	1 135,18
12	1 329,46
13	1 447,91
14	1 381,48
15	1 461,75
16	1 376,61
17	1 441,24
18	1 508,40
19	2 098,38
20	2 325,53
21	2 254,30
22	2 202,63
23	1 743,73
24	1 562,07

Con los resultados obtenidos fue posible comprobar el comportamiento de la red neuronal desarrollada, los resultados obtenidos son aceptables.

6. CONCLUSIONES Y RECOMENDACIONES

Un pronóstico de consumo de carga diaria, genera ahorros de dinero considerables para las empresas suministradoras, por gastos de generación y operación. Para obtener un buen resultado es necesario reducir al mínimo posible el error de pronóstico.

Los resultados muestran el desempeño y precisión que tienen las redes neuronales para el pronóstico de la demanda a corto plazo, con mínimos errores de predicción.

En futuras investigaciones se debe evaluar el comportamiento de la demanda eléctrica considerando técnicas de agrupamiento de datos, en particular la técnica clúster, para conformar una base de datos más compacta y fiable al eliminar datos atípicos, y buscar una métrica de curvas de consumo características para conformar la base de datos de la red neuronal.

REFERENCIAS BIBLIOGRÁFICAS

Libros:

- [1] HINOJOSA M. Víctor Hugo. "Pronóstico de demanda de corto plazo en sistemas de suministro de energía eléctrica utilizando inteligencia artificial". 1a edición San Juan Argentina, 2008, ISBN 978-987-05-3838-7.
- [2] OJEDA SARMIENTO, Juan Manuel, "Demanda máxima de potencia eléctrica", Ingeniería Industrial 2010 Red de Revistas Científicas de América Latina, el Caribe, España y Portugal, n.28, ISSN 1025-9929, p 111-137.
- [3] ALFONSO GALIPIENSO, Ma Isabel, et al., "Inteligencia artificial". (2003). Ediciones Paraninfo, S.A. 384 páginas. ISBN -10: 8497321839, ISBN-13: 9788497321839
- [4] DEL BRIO, Bonifacio Martín, y SANZ MOLINA, Alfredo, "Redes neuronales y sistemas borrosos". RA-MA S.A. Editorial y Publicaciones 3A edición ,442 páginas. ISBN: 8478977430. ISBN-13: 9788478977437.
- [5] SANTOS PEÑAS, Matilde; PAJARES MARTINSANZ, Gonzalo), "Inteligencia artificial e ingeniería del conocimiento". Ra-Ma Editorial, S.A. 2005, Madrid, 384 páginas, ISBN: 8478976760. ISBN-13: 9788478976768.

Artículo de Revista:

[6] VALENCIA C. Marisol, CORREA M. Juan C., "Un modelo dinámico bayesiano para pronóstico de energía diaria", Universidad del Bío-Bío, revista Ingeniería Industrial. 2013, vol. 12, n.2, p.7-17, ISSN 0717-9103.

[7].SARMIENTO MALDONADO Henry O., VILLA ACEVEDO Walter M, "Inteligencia artificial en pronóstico de demanda de energía eléctrica, una aplicación en optimización de recursos energéticos". Revista colombiana de tecnologías de avanzada Año 2008, vol.2, n.12, ISSN 1692-7257.

Artículo de Revista Electrónica:

[8] MEDINA HURTADO, Santiago, GARCÍA AGUADO, Josefina, "Predicción de demanda de energía en Colombia mediante un sistema de inferencia difuso neuronal". Energética, n. 33, julio, 2005, p. 15-24, Universidad Nacional de Colombia, ISSN (Versión impresa): 0120-9833 [consultado en octubre2013] <http://www.revistas.unal.edu.co/index.php/energetica/article/view/24008/24676>



Jorge Enrique Carrión González.- Nació en Loja, Ecuador. Recibió su título de Ingeniera Electromecánica de la Universidad Nacional de Loja en 2008; de Máster en Ingeniería Eléctrica del Instituto Politécnico Superior "José Antonio Echeverría",

Cuba 2011. Sus campos de investigación se encuentran relacionados con la Evaluación y Proyección de las Redes Eléctricas de Distribución.