



ESCUELA SUPERIOR POLITECNICA DEL LITORAL
Facultad de Ingeniería en Electricidad y Computación



**“PROYECCIÓN DE LA DEMANDA DE ENERGÍA
ELÉCTRICA A CORTO PLAZO, MEDIANTE REDES
NEURONALES ARTIFICIALES”**

Examen Complexivo, Componente Práctico

INFORME PROFESIONAL

Previa a la obtención del título de:

MAGISTER EN AUTOMATIZACION Y CONTROL INDUSTRIAL

Autor : Ing. Luis Fernando González Peña

Guayaquil, Ecuador

Año 2016

AGRADECIMIENTO

A mi familia, familiares y a las personas que con su colaboración y ayuda hicieron posible la culminación de la presente.

DEDICATORIA

- A mis padres
- A mi esposa
- A mis hijos

TRIBUNAL DE SUSTENTACIÓN

M. Sc. Sara Ríos
Presidente

Ph.D. Wilton Agila
Vocal

M.Sc.Holger Cevallos
Vocal

M.Sc. Efrén Herrera
Vocal

DECLARACIÓN EXPRESA

“La responsabilidad del contenido de este informe, me corresponden exclusivamente; y el patrimonio intelectual de la misma, a la ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL”

(Reglamento de Exámenes y Títulos Profesionales de la ESPOL).

Luis Fernando González Peña

RESUMEN

El crecimiento poblacional en cualquier lugar, define parcialmente el requerimiento de servicios para desarrollarse, por tal motivo, es necesario abastecerlos de energía eléctrica ininterrumpidamente.

Con el fin de estar preparados para entregar esta energía ininterrumpidamente en el área de concesión, se hace indispensable realizar su mejor predicción.

Para llegar con dicha energía a los clientes, se debe expandir y mejorar las instalaciones eléctricas de distribución de energía eléctrica, requiriéndose dinero, que se debe invertir en dichas instalaciones.

El conocimiento de la magnitud de energía requerida, trae como consecuencia, el uso de los recursos de manera adecuada, para evitar:

- Inversiones prematuras, en expandir las instalaciones que no tendrán un aprovechamiento inmediato (sobre equipamiento),
- Inversiones por debajo de la necesidad del sistema eléctrico a futuro, sobreutilizando las existentes, generando deterioro en ellas y en la calidad del suministro (sub equipamiento).

Por tal motivo, es necesario establecer el mejor método de pronóstico de la demanda, que se ajuste al comportamiento de la población dentro de esa área de concesión, donde la CNEL EP Santa Elena presta sus servicios.

La aplicación actual del pronóstico de la demanda se fundamenta en la aplicación de la serie de tiempo desarrollado inicialmente mediante herramientas de hoja de cálculo, y uso de software de estadística.

Por lo tanto, para mejorar y obtener en el periodo adecuado, la predicción del consumo requerido por los clientes, y por tanto, requerido por el sistema eléctrico de distribución, se procedió a realizar comparaciones con los métodos que se utilizaban (las funciones de Excel, uso de software estadístico Centurion XV), con las simulaciones generadas por el uso de Matlab (la función de red neuronal de retropropagación y retropropagación con retardo de tiempo)

Los resultados obtenidos con este último método son relativamente mejor, sin embargo, no se utiliza en la CNEL EP Santa Elena, debido al poco conocimiento del uso de la herramienta MATLAB.

INDICE GENERAL

	Página
Agradecimiento.....	i
Dedicatoria.....	ii
Tribunal.....	iii
Declaratoria.....	iv
Resumen.....	v
Índice General.....	vii
Índice de Figuras.....	viii
Índice de Tablas.....	ix
Introducción.....	x
Capítulo I.....	1
Capítulo II.....	12
Conclusiones y Recomendaciones.....	21
Bibliografía.....	24
Glosario de términos.....	25
Anexos.....	27

INDICE DE FIGURAS

	Página
Figura No.01. Clasificación de los métodos de predicción.....	1
Figura No.02. Clasificación de las redes neuronales por aprendizaje y arquitectura	3
Figura No.03. Estructura de una red neuronal artificial de retropropagación	8
Figura No.04. Estructura de una red neuronal con retardo de tiempo	9
Figura No.05. Resultado de la TDNN a datos mensuales de potencia.....	15
Figura No.06. Resultado de la TDNN. Curva de potencia.	16
Figura No.07. Resultado de la TDNN. Estructura.	16
Figura No.08. Resultado de la TDNN. Curva de energía.	17

INDICE DE TABLAS

	Página
Tabla No.01. Datos anuales del sistema de distribución.....	4
Tabla No.02. Datos mensuales del sistema de distribución.....	5
Tabla No.03. Relaciones entre técnicas neuronales u estadísticas.....	6
Tabla No.04. Elementos del modelo neuronal.....	10
Tabla No.05. Elementos de algunos modelos neuronales.....	11
Tabla No.06. Predicción de potencia para el año 2008-2019.....	12
Tabla No.07. Predicción de energía para el año 2008-2019.....	13
Tabla No.08. Comparación de la predicción anual.....	14
Tabla No.09. Configuración de la red neural retropropagación....	14
Tabla No.10. Resultado predicción mensual de la demanda.....	18
Tabla No.11. Resumen de los métodos predictivos utilizados....	19
Tabla No.12. Configuración de la red neural retardo de tiempo....	19

INTRODUCCIÓN

La empresa eléctrica EMEPE, Empresa Eléctrica Península de Santa Elena C.A., fue reestructurada varias veces, siendo su última denominación CNEL EP Unidad de Negocio Santa Elena.

La ESPOL, mediante la carrera de Automatización y Control Industrial, difundía el uso de herramientas mejoradas para el tratamiento de las series de tiempo, mediante la aplicación de inteligencia artificial.

La CNEL EP Santa Elena, realizaba la predicción de la demanda, con hojas electrónicas, y en breve con utilitarios de tipo estadístico.

Con el fin de mejorar y facilitar el trabajo de planificación del sistema eléctrico de distribución, se incentiva el uso de las redes neuronales artificiales para predecir la demanda. Siendo necesario el desarrollo de programas aplicados al pronóstico de la potencia y energía comprada a CELEC EP Transelectric.

Las empresas eléctricas anualmente, presentan un plan de expansión de sus instalaciones con un horizonte de 10 años, con el fin de ir mejorando y expandiendo sus instalaciones, para servir a la comunidad.

Para elaborar esos planes, es requerido establecer el crecimiento de energía y potencia, lo cual se traduce en ampliación de las redes del sistema eléctrico de la distribuidora; es decir, el uso futuro del dinero para mantener el suministro de energía de calidad a la comunidad.

Declarar valores por debajo de la realidad, desemboca en sobreutilización de las instalaciones, debido a que tendría que soportar más carga de los nuevos clientes, debido al poco recurso monetario justificado. Mientras que valores por encima de la realidad, resulta en una subutilización de las instalaciones nuevas construidas, dejando de utilizar el recurso adquirido de manera eficiente. Es decir, la empresa se beneficia al utilizar adecuadamente el recurso monetario y los clientes de servirse con instalaciones que brinden calidad y continuidad.

Para realizar la proyección de la demanda, se requiere establecer contacto con la comunidad, sus necesidades. Se hace indispensable tabular datos relevantes del sistema, conocer el comportamiento de la energía y potencia comprada por la empresa eléctrica, para luego proceder con el análisis de datos, para la elaboración del plan de expansión del sistema eléctrico de distribución en CNEL EP Santa Elena.

Conocer y utilizar una mejor herramienta para realizar la predicción de la demanda del sistema eléctrico de distribución de CNEL EP Santa Elena, es importante para la planeación, siendo la inteligencia artificial mediante las redes neuronales artificiales de la herramienta MATLAB, recomendada para esta tarea.

En el Capítulo I, se describe la metodología y programación utilizada para y obtener la predicción de la demanda de energía y potencia total del sistema eléctrico de la CNEL EP Santa Elena.

En el Capítulo II, se establece la comparación de los datos registrados, resultados del uso de la programación realizada en la herramienta Matlab y las existentes.

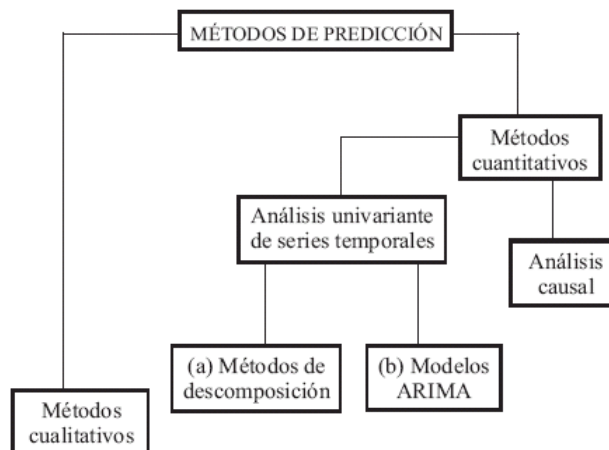
En el apartado de Conclusiones y Recomendaciones, se presenta las consideraciones y comentarios a los resultados obtenidos con esta comparación, proponiendo la acogida de este método de predicción o su mejora en la línea de investigación a periodos semanales y horarios.

CAPITULO I

Metodología o Solución Tecnológica Implementada

Los métodos de predicción pueden ser agrupados en dos categorías; métodos cualitativos y métodos cuantitativos. (Jimenez, Gázquez, & Sánchez, 2006)

Figura No.01 Clasificación de los métodos predicción



Fuente: (Jimenez, Gázquez, & Sánchez, 2006)

Cuantitativos, extraen información contenida en los datos y en base al patrón ocurrido en el pasado realizar estimaciones en el futuro. Mientras los cualitativos, no tienen referencia del pasado.

Como se aprecia en la figura No.01, tenemos que el análisis de series temporales corresponde a los métodos de predicción cuantitativos.

Cuando se pretende analizar un conjunto de datos con relaciones complejas y condiciones adicionales, es recomendable utilizar redes neuronales artificiales.


El uso de esta herramienta se fundamenta (Muñoz, 2000), cuando comparamos la incapacidad del procesamiento actual de los sistemas clásicos de computo, al no poder entender el significado de las formas visuales, o distinguir entre distintas clases de objetos, haciendo que un gran número de investigadores centre su atención en el desarrollo de nuevos sistemas de tratamiento de información, que permitan resolver problemas cotidianos tal como lo hace el cerebro humano, al contar con características deseables para cualquier sistema de procesamiento digital, tales como:

- ✓ Es robusto y tolerante a fallas, todos los días mueren neuronas sin afectar su desempeño.
- ✓ Es flexible, se ajusta a nuevos ambientes por medio de un proceso de aprendizaje, no hay que reprogramarlo.
- ✓ Puede manejar información difusa, con ruido o inconsistente.
- ✓ Es altamente paralelo.
- ✓ Es pequeño, compacto y consume poca energía.

El diseño de la presente investigación es experimental cuantitativa; siendo el modelo utilizado para el pronóstico, de las redes neurales artificiales, de retro

propagación y retropropagación con retardo. En la figura No.02 se presenta la clasificación de estos modelos.

Figura No.02 Clasificación de las redes neuronales por aprendizaje y arquitectura



Fuente: (Martín del Brío & Sanz Molina, 2007)

La red neuronal artificial de retropropagación, posee aprendizaje supervisado y su arquitectura es unidireccional. Se consideran estáticos ya que su arquitectura está diseñada para encontrar relaciones entre patrones de entrada y salida independientes de la variable de tiempo. Para aplicarlo al problema de predicción, debe obtenerse el patrón de la entrada y cierta historia de ese patrón, la cual se representa utilizando una secuencia finita temporal en el pasado. (Isasi Viñuela & Galván León, 2004)

De los registros de las bitácoras de las subestaciones eléctricas, tabuladas en el área de planificación, se obtuvieron los datos anuales de potencia y energía desde el año 1990 hasta el año 2008, ver la tabla No.01, siguiente:

Tabla No.01
 Datos anuales del sistema eléctrico de distribución

Tiempo	DMX8	Fac9	SIS9
Año	Mw	Gwh	Gwh
1.990,00	27,10	73,75	98,48
1.991,00	29,10	87,03	112,47
1.992,00	31,40	106,20	122,49
1.993,00	33,50	101,52	134,70
1.994,00	37,60	124,65	154,16
1.995,00	41,00	147,09	171,35
1.996,00	45,90	164,00	190,59
1.997,00	50,10	186,78	213,56
1.998,00	48,30	183,92	212,43
1.999,00	54,10	188,12	229,78
2.000,00	54,90	189,65	244,28
2.001,00	56,17	184,96	249,36
2.002,00	56,98	191,21	256,37
2.003,00	60,87	186,41	284,78
2.004,00	64,25	191,02	300,29
2.005,00	66,59	210,35	328,39
2.006,00	71,70	238,47	345,10
2.007,00	73,58	253,42	362,15
2.008,00	76,28	276,57	380,20

Fuente: CNEL EP Santa Elena
 Autor: Luis F. González Peña

La tabla refleja el comportamiento de la potencia (DMX8) en MW, y la energía (SIS9) en GWh, se aprecia los datos anuales a utilizarse desde el año 1990 hasta el año 2007, y se procederá a realizar la predicción para el año 2008 mediante técnicas estadísticas (clásicas) y modelos de red neuronales artificiales (Retropropagación). Para compararlo con el dato real tabulado en ese año.

De igual manera para el comportamiento mensual, se consideraron los datos tabulados de la demanda desde el año 2003 hasta el año 2007, y se pronosticaron los datos del año 2008. Tabla No.02.

Tabla No.02
Datos mensuales del sistema eléctrico de distribución

tiempo (año)	tiempo (mes)	dmx (mw)	enr (mwh)	tiempo (año)	tiempo (mes)	dmx (mw)	enr (mwh)
2003	01	52,93	24.148,14	2006	01	61,77	30.263,48
2003	02	57,24	23.399,93	2006	02	66,98	29.614,34
2003	03	59,03	27.312,43	2006	03	63,54	32.560,03
2003	04	56,38	25.315,02	2006	04	65,36	31.365,89
2003	05	50,42	25.144,09	2006	05	55,18	29.402,08
2003	06	46,62	21.977,49	2006	06	54,43	28.032,97
2003	07	38,45	22.111,57	2006	07	51,91	26.362,71
2003	08	47,39	22.893,52	2006	08	55,10	27.075,65
2003	09	46,92	21.887,45	2006	09	52,20	25.970,24
2003	10	46,92	23.116,29	2006	10	52,65	26.935,13
2003	11	48,35	22.413,08	2006	11	54,71	27.192,70
2003	12	60,87	25.064,19	2006	12	71,70	30.336,86
2004	01	59,39	27.298,37	2007	01	67,20	34.379,00
2004	02	62,41	27.644,07	2007	02	73,58	32.522,92
2004	03	57,57	29.539,63	2007	03	68,58	34.690,91
2004	04	60,80	27.644,07	2007	04	68,28	32.067,16
2004	05	51,52	25.097,03	2007	05	63,16	31.369,00
2004	06	47,78	23.450,15	2007	06	59,97	27.758,49
2004	07	46,25	22.087,05	2007	07	58,08	27.936,06
2004	08	51,46	23.211,45	2007	08	58,33	27.694,70
2004	09	46,58	22.367,69	2007	09	54,99	25.856,43
2004	10	52,98	23.112,03	2007	10	58,33	28.880,44
2004	11	54,90	23.023,71	2007	11	54,99	28.062,44
2004	12	64,25	25.813,00	2007	12	70,87	30.931,85
2005	01	58,62	28.767,79	2008	01	69,09	32.705,80
2005	02	66,59	29.184,38	2008	02	76,28	33.400,40
2005	03	62,67	30.962,72	2008	03	72,21	35.379,33
2005	04	61,26	30.086,80	2008	04	64,61	32.742,64
2005	05	53,01	27.052,42	2008	05	67,77	31.476,32
2005	06	53,30	25.215,54	2008	06	61,14	29.150,64
2005	07	51,87	25.906,63	2008	07	62,14	31.537,19
2005	08	56,31	27.190,83	2008	08	61,61	31.285,08
2005	09	52,10	24.917,92	2008	09	59,73	29.158,88
2005	10	51,43	25.538,97	2008	10	60,20	30.525,80
2005	11	52,26	25.369,28	2008	11	61,31	29.901,22
2005	12	65,48	27.928,71	2008	12	71,70	32.940,12

Fuente: CNEL EP Santa Elena
Autor: Luis F. González Peña

Utilizando técnicas estadísticas (ARIMA) y redes neuronales artificiales (Retropropagación con retardo)

Las técnicas estadísticas y neuronales están muy relacionadas que ningún campo es a priori mejor que el otro (en algunos casos ambos son indistinguibles incluso), y que lo razonable es aplicar en cada caso la solución más idónea. (Martín del Brío & Sanz Molina, 2007)

Se presenta en la tabla No.03, algunas de las relaciones entre las técnicas neuronales y estadísticas.

Tabla No.03
Relaciones entre técnicas neuronales y estadísticas

Modelo Neuronal	Técnica estadística
Perceptrón simple (nodo tipo umbral)	Análisis discriminante
Perceptrón simple (nodo tipo sigmodeo)	Regresión logística
Adalina	Regresión lineal
Perceptrón multicapa	Regresión no lineal simple Regresión no lineal multivariada
Aprendizaje hebbiano no supervisado	Análisis de componentes principales
Red simple de Kohonen (competitiva)	Análisis cluster mínimos cuadrados
Cuantificación de vectores LVQ	Análisis discriminante (vecindad)
Funciones de base radial (RBF)	Métodos de kernel regression
Mapa de Kohonen	Escalas multidimensionales

Redes neuronales sin paralelismo claro
Contrapropagación
Redes ART
Modelo de Hopfield

Fuente: (Martín del Brío & Sanz Molina, 2007)

Es decir, las predicciones pueden ser realizadas mediante técnicas estadísticas o modelos neuronales, siendo importante, el conocimiento de la

herramienta y la complejidad de los datos e información obtenida para realizarlas.

Diseñar una red neuronal artificial (Sánchez Campero & Alanís García, 2006), consiste en:


- ✓ Definir tipo de red y su estructura
- ✓ Dimensión de la entrada y la salida (proceso heurístico)
- ✓ Entrenamiento de la red
- ✓ Presentación de los ejemplos
- ✓ Aplicación (generalización)

Se conoce a la red neuronal artificial de retropropagación, al perceptrón multicapa cuyo aprendizaje supervisado es el algoritmo de retropropagación. (Martín del Brío & Sanz Molina, 2007). Por la potencialidad para aproximar funciones se aplica en diversas disciplinas.

Es decir, La Backpropagation (BP), es un tipo de red de aprendizaje supervisado, que emplea un ciclo de propagación- adaptación de dos fases. Una vez aplicado un patrón de entrada como estímulo, éste se propaga por la primera capa hasta las capas superiores de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error por cada una de las salidas. (Muñoz, 2000)

Se presenta la estructura de la Red Neuronal Artificial Retropropagación ó Backpropagation (BP), en la figura No.03. (Muñoz, 2000). Donde se aprecia su conformación en este caso de tres capas, con tres redes perceptrón en cascada, una por capa. Adicionalmente, es importante observar, la salida de la red, se encuentra embebida en la última capa.


Figura No.03 Estructura de una red neuronal artificial retropropagación



Esta configuración BP, es apropiada para encontrar relaciones entre patrones de entrada y salida independientes de la variable tiempo, esto no impide su uso en problemas de predicción de series temporales. En los datos anuales, se considera utilizar la predicción en un solo paso de tiempo. (Isasi Viñuela & Galván León, 2004)

En los datos mensuales a ser analizados, se considera utilizar la predicción en múltiples pasos de tiempo, donde se considera una ventana deslizante entre los datos de entrada y salida, con el fin de predecir el comportamiento de la serie, no únicamente en el instante inmediato sino en un futuro más lejano.

(Isasi Viñuela & Galván León, 2004). Siendo la configuración utilizada la Red Neuronal Artificial de Retropropagación con retardo de tiempo (TDNN), tal como se presenta en la figura No.04.



Para este tipo de red neuronal artificial, se establece el retardo entre la entrada y la primera capa de la red. (Ventana deslizante).

Para analizar los datos anuales y mensuales, se ha realizado el siguiente procedimiento para realizar la predicción:

1. Captura de datos de Excel.
2. Mostrar gráfico y/o tabla de datos de la demanda
3. Cambio de escala y Conversión de formato
4. Creación de la red neurona artificial
5. Parámetros de entrenamiento
6. Simulación de la red
7. Cambio de escala y conversión de formato
8. Mostrar gráfico y/o tabla de resultados.

En resumen, podemos determinar la red neuronal artificial, conociendo los elementos enumerados en la tabla No.04 Elementos del modelo neuronal.

Tabla No.04 Elementos del modelo neuronal

Modelo Neuronal	Elementos
Entrada	Analogicas, Digitales
Regla de propagación	Suma Ponderada, Distancia Euclidea
Función de activación	Puede depender del estado anterior y potencial postsinaptico. $a_i(t) = f_i[a_i(t - 1), h_i(t)]$
	O solo postsinaptico. $a_i(t) = f_i[h_i(t)]$, donde las funciones más utilizadas son: Identidad, Escalón, Linea, Lineal por intervalo, sigmoidad, tansig, gaussiana.
Función de salida	Pueden ser las funciones identidad, escalón, estocástica, pero normalmente se utiliza la función identidad.
Pesos sinápticos	Exitadoras, Inhibidoras
Algoritmo de aprendizaje (Criterio de optimización)	Pueden ser mediante: Corrección de error, Boltzman, Ley Efectos de Thorndike, Regla de Hebb (Delta), Competitivo.
Métodos de solución al problema de optimización	Del Gradiente descendiente, De newton, De Gauss Seidel, De Mínimos Cuadrados, Levenberg-Marquard.
Paradigma de aprendizaje	Supervisado, Por reforzamiento, No supervisado, Hibrido

Autor: Luis Fernando González Peña

Las combinaciones de los elementos mostrados, son utilizadas en la mayoría de las redes neuronales artificiales, de tal manera que para cada clase de RNA, se tienen la combinación de estos parámetros.

Por lo tanto, se muestra para algunos tipos de redes neuronales, estas características de acuerdo a la tabla No.05, siguiente:

Tabla No.05 Elementos de algunos modelos neuronales

Característica	Red Neural Artificial				
	Preceptrón	Adaline	Perceptron multicapa (MLP)	Backpropagation	Time Delay NN
Entrada:	Binaria	Binaria	Binaria	Real	Real
Regla de propagación:	Suma Ponderada	Suma Ponderada	Suma Ponderada	Suma Ponderada	Suma Ponderada
Función activación:	Escalón	Escalón	Continua	Continua	Continua
Función salida:	Identidad	Identidad	Identidad	Identidad	Identidad
Salida:	Binaria	Real	Real	Real	Real
Algoritmo aprendizaje:	Corrección de error	Regla Delta (LMS)	Regla Delta Generalizada	Regla Delta Generalizada	Regla Delta Generalizada
Método solución:	Regla de Hebb (perceptron)	Gradiente descendente	Gradiente descendente	Gradiente descendente	Gradiente descendente
Paradigma de aprendizaje:	Por refuerzo	Supervisado	Supervisado	Supervisado	Supervisado
Numero de capas:	Monocapa	Monocapa	Multicapa	Multicapa	Multicapa
Flujo de datos:	Unidireccional	Unidireccional	Unidireccional	Unidireccional	Unidireccional
Actualización estado:	Sincrona	Sincrona	Sincrona	Sincrona	Sincrona
Tipo:	Estatica	Estatica	Estatica	Estatica	Dinámica

Autor: Luis Fernando González Peña

En el Anexo No.01, se adjuntan las tablas de datos y resultados utilizados en el presente informe. En el Anexo No.02, se presentan los programas en lenguaje .m utilizados en MATLAB e información de referencia.

CAPITULO II

Resultados Obtenidos

En base a los datos mostrados en el capítulo anterior, se registran los resultados de la predicción anual para la potencia y energía en la tabla No.05

Tabla No.06
Predicción de potencia para el año 2008-2019

Demanda Potencia (MW)			
Año	Mtdo-01	Mtdo-02	Mtdo-03
2008	78,3466	75,8400	76,2909
2009	81,4864	78,5400	79,0005
2010	87,6826	81,2400	81,6833
2011	94,3579	83,9400	84,2285
2012	101,9873	86,6400	86,9189
2013	107,3352	89,3400	89,5860
2014	111,1801	92,0500	92,2697
2015	113,5470	94,7500	94,9376
2016	115,5500	97,4500	97,6155
2017	117,7309	100,1500	100,2622
2018	120,4097	102,8500	102,9311
2019	122,8011	105,5500	105,6059

Método 01 (Mtdo-01): Modelo: Global Sectorial sin Carga Especial
 Método 01 (Mtdo-02): Modelo: Tendencia Lineal= -5348,58+2,7014t
 Método 01 (Mtdo-03): Modelo: Backpropagation

Año 2008	Mtdo-01	Mtdo-02	Mtdo-03
76,2807	78,3466	75,8400	76,2909
	2,71%	-0,58%	0,01%

Fuente: CNEL EP Santa Elena
Autor: Luis González

E tabla mostrada, se aprecia la mejora de la predicción de la demanda, para el año 2008, los datos de series temporales con la RNA, aumenta ligeramente

la precisión al modelo estadístico clásico, sin embargo las tendencias son similares para el año horizonte de la planeación.

De igual manera, se presenta la tabla comparativa de los datos para la predicción de la demanda de energía eléctrica en los puntos de compra CELEC Transelectric.

Tabla No.07
Predicción de energía para el año 2008-2019

Demanda Energía (GWh)			
Año	Mtdo-01	Mtdo-02	Mtdo-03
2008	391,42	377,6590	377,6639
2009	408,53	393,1690	393,1987
2010	454,04	408,6790	408,7107
2011	505,35	424,1890	424,3114
2012	567,46	439,6980	439,8724
2013	608,73	455,2080	455,3912
2014	635,51	470,7180	470,9021
2015	646,92	486,2280	486,4567
2016	653,72	501,7370	502,0719
2017	661,49	517,2470	517,7002
2018	673,88	532,7570	533,4031
2019	682,07	548,2670	548,9715

Método 01 (Mtdo-01):

Método 01 (Mtdo-02):

Método 01 (Mtdo-03):

Modelo: Global Sectorial sin Carga Especial

Modelo: Random walk with drift = 15.5098

Modelo: Backpropagation

Año 2008	Mtdo-01	Mtdo-02	Mtdo-03
380,2034	391,4201	377,6590	377,6639
	2,95%	-0,67%	-0,67%

Fuente: CNEL EP Santa Elena
Autor: Luis González

Se muestra concordancia con los métodos estadísticos clásicos y la red neuronal artificial.

Estos resultados se resumen en la tabla No.08.

Tabla No. 08 Comparación de la predicción anual

Metodo	Utilitario	MW	GWh	%Error MW	%Error GWh
Modelo: Global Sectorial sin Carga Especial	Hoja electrónica EXCEL	78,3466	391,4201	2,7083%	2,9502%
Modelo: Random walk with drift = 15.5098	Software Centurion XV	75,8400	377,6590	-0,5777%	-0,6692%
Modelo: Backpropagation	Software Matlab	76,2909	377,6639	0,0133%	-0,6679%
VALOR REAL AÑO 2008		76,2807	380,2034		

Fuente: CNEL EP Santa Elena
Autor: Luis F. González Peña

La estructura de la red neuronal artificial de retropropagación utilizadas en esta predicción se establece en la siguiente tabla No.09

Tabla No. 09 Configuración de la red neuronal retropropagación (neurodinámica)

Parámetros de la red neuronal artificial utilizada en la predicción anual

RNA BP


Características	Configuración	
	POTENCIA	ENERGIA
Número de entradas:	1	1
Número de capas:	3	3
Función en capa:	tansig-tansig-purelin	tansig-tansig-purelin
Número de neuronas en capa:	1-3-1	1-1-1
Número de salidas:	1	1
Número de bias:	1-1-1	1-1-1
IW{1,1}	0,14	1,59
LW{2,1}	-4,8	-1,09
	2,98	
	-4,07	
LW{3,2}	-1,68 2,30 -0,82	-0,62
b{1,1}	0,49	0,96
b{2,1}	3,22	-0,77
	-0,94	
	-4,56	
b{3,1}	-0,4	-1,08

Fuente: CNEL EP Santa Elena
Autor: Luis F. González Peña

Los soportes de los resultados del uso de las redes antes indicadas se encuentran en el Anexo No.01.

Los resultados de la aplicación de la red neuronal artificial de retropropagación con retardo, se presentan en la siguiente figura No.05:


Figura No.05 Resultado de la TDNN a datos mensuales de potencia



En la figura vemos, la primera curva los datos originales, luego en la segunda curva vemos esos datos normalizados entre -1 y 1, en la tercera curva vemos los datos normalizados con el resultado del entrenamiento de la TDNN utilizada y en la cuarta curva, vemos el resultado de la predicción con un retardo de tiempo de 9 meses (0 – 8).


El resultado se aprecia mejor en la figura No.06.

Figura No.06 Resultado de la TDNN. Curva de potencia



La red generada se muestra en la siguiente figura No.07.

Figura No.07 Resultado de la TDNN. Estructura.



RED NEURONAL TDNN - POTENCIA

iw $\begin{matrix} IW(1,1) \\ IW(2,1) \end{matrix}$ $d(1,1)$ LW $\begin{matrix} LW(1,1) LW(1,2) \\ LW(2,1) LW(2,2) \end{matrix}$ b $\begin{matrix} b(1,1) \\ b(2,1) \end{matrix}$

$IW(1,1)$	-1.22	0.38	-1.16	-0.48	-1.28	0.53	-0.16	0.97	0.68
$IW(2,1)$	0.32	-0.09	-0.09	0.00	-0.01	-0.09	0.09	0.00	-0.09
$d(1,1)$	-0.12	0.38	1.06	-0.01	1.22	-0.28	0.22	-0.52	0.12
	0.79	-0.53	-0.01	0.52	-0.31	-0.14	0.90	0.15	-0.86

$LW(2,1)$	0.01	3.18	0.02	-0.14
-----------	------	------	------	-------


$b(2,1)$	0.36
----------	------

$d(1,1)$	0	1	2	3	4	5	6	7	8
$b(1,1)$	1.16	-0.07	-0.41	2.00					

En este modelo tenemos dos capas, con 4 y 1 neuronas respectivamente, con un retardo de 9 periodos de tiempo o pasos.

El resultado obtenido para la energía, se presenta en la figura No.08, siguiente:

Figura No.08 Resultado de la TDNN. Curva de energía.



La tabla de resultados comparativos de la energía y potencia en periodos mensuales se presentan a continuación:

Tabla No. 10 Resultado predicción mensual de la demanda

Demanda Potencia (MW)					
Año	Mes	Mtdo-01	Mtdo-02	Dato	
2008	01	69,8530	69,8969	69,0873	
2008	02	76,7479	75,8985	76,2807	
2008	03	71,4810	71,1696	72,2146	
2008	04	71,3193	70,7225	64,6135	
2008	05	66,1276	65,6085	67,7678	
2008	06	62,9748	62,2997	61,1356	
2008	07	61,0655	60,4990	62,1447	
2008	08	61,3255	60,9273	61,6122	
2008	09	57,9804	57,3868	59,7254	
2008	10	61,3230	60,9405	60,2024	
2008	11	57,9816	57,3242	61,3145	
2008	12	73,8624	73,3916	71,6966	

Método 01 (Mtdo-01): Model: ARIMA(1,0,1)x(0,1,0)12 with constant

Método 02 (Mtdo-02): Modelo: TDNN 4-1 Delay 9

Año 2008	Mtdo-01	Mtdo-02	
76,2807	76,7479	75,8985	
Error	0,61%	-0,50%	
MaxVar	6,7058	6,1090	MW
MinVar	0,2867	0,3822	MW

Demanda Energía (MWh)					
Año	Mes	Mtdo-01	Mtdo-02	Dato	
2008	01	34.004,90	34.678,39	32.705,80	
2008	02	33.710,70	33.385,25	33.400,40	
2008	03	36.018,00	34.886,39	35.379,33	
2008	04	34.708,50	33.111,58	32.742,64	
2008	05	32.715,40	32.646,89	31.476,32	
2008	06	30.153,10	28.751,99	29.150,64	
2008	07	31.034,20	29.067,07	31.537,19	
2008	08	31.923,30	28.303,07	31.285,08	
2008	09	29.748,40	26.530,65	29.158,88	
2008	10	30.985,00	29.742,69	30.525,80	
2008	11	30.531,40	28.864,67	29.901,22	
2008	12	33.122,40	32.056,50	32.940,12	
		388.655,30	372.025,16	380.203,43	

Método 01 (Mtdo-01): Model: ARIMA(0,0,0)x(2,1,2)12 with constant

Método 02 (Mtdo-02): Modelo: TDNN 2-1 Delay 9

Año 2008	Mtdo-01	Mtdo-02	
380.203,43	388.655,30	372.025,16	
Error	2,22%	-2,15%	
MaxVar	1.965,86	2.982,02	Mwh
MinVar	182,28	15,15	Mwh

Fuente: CNEL EP Santa Elena
Autor: Luis F. González Peña

Tabla No. 11 Resumen de los métodos predictivos utilizados.

Metodo	Utilitario	MW	MWh	%Error MW	%Error MWh
Model: ARIMA(1,0,1)x(0,1,0) 12 with constant	Software Centurion XV	76,7479	388.655,30	0,6125%	2,2230%
Modelo: TDNN Delay 9	Software Matlab	75,8985	372.025,16	-0,5011%	-2,1510%
<i>VALOR REAL AÑO 2008</i>		<i>76,2807</i>	<i>380.203,43</i>		

Fuente: CNEL EP Santa Elena
Autor: Luis F. González Peña

En la tabla No.11, se muestra la comparación de la proyección del método estadístico y de la red neuronal artificial, como se aprecia, la variación es similar, es decir, es posible utilizar cualquiera de los dos utilitarios.

La RNA TDNN, muestra la configuración siguiente figure No.09:

Tabla No. 12 Configuración de la red neural Retardo de tiempo (neurodinámica)

Parámetros de la red neuronal artificial utilizada en la predicción mensual																		
RNA TDNN																		
Características	Configuración																	
	POTENCIA				ENERGIA													
Número de entradas:	1				1													
Número de retardo en tiempo:	9				9													
Número de capas:	2				2													
Función en capa:	tansig-purelin				tansig-purelin													
Número de neuronas en capa:	4-1				2-1													
Número de salidas:	1				1													
Número de bias:	1-1				1-1													
IW{1,1}	-1.22	0.38	-1.16	-0.48	-1.28	0.53	-0.16	0.97	0.68	0.64	-0.03	0.02	-0.01	0.02	-0.01	-0.00	-0.03	0.01
	0.32	-0.00	-0.00	0.00	-0.01	-0.00	0.00	0.00	-0.00	8.16	3.19	-2.30	-0.26	0.97	-0.73	-0.01	1.27	-1.07
	-0.12	0.38	1.06	-0.01	1.22	-0.28	0.22	-0.52	0.12									
	0.79	-0.53	-0.01	0.52	-0.91	-0.14	0.90	0.19	-0.86									
LW{2,1}	0.01				3.18	0.02	-0.14			1.69		0.09						
					1.16					-0.20								
b{1,1}					-0.07					7.62								
					-0.41													
					2.00													
b{2,1}					0.36					0.20								

Luego de la presentación de los resultados de la predicción de la demanda de potencia y energía, tanto por los métodos Global Sectorial, Estadística Clásica

y Red Neuronal Artificial, con RNA Estática de Retropropagación y RNA Dinámica Retardo de tiempo (Utilizando red no concurrente).

Se verifica que los modelos estadísticos y neuronales, pueden ser utilizados en base a la necesidad y experiencia del problema a resolver.

CONCLUSIONES Y RECOMENDACIONES

La predicción de la demanda, en la CNEL EP Santa Elena, se realiza actualmente en la oficina central CNEL EP.

Los datos utilizados en esta predicción, contienen periodos anuales y mensuales.

El método global sectorial no contempla las cargas especiales, y sus valores son superiores a los obtenidos a los métodos ARIMA y RNA, mientras que entre estos últimos su tendencia y magnitud son similares.

El uso de uno u otro método moderno (ARIMA y RNA), dependerá de la condición requerida, el tipo de utilitario elegido y la experiencia de quién realiza el análisis.

Para la utilización de las RNA's presentadas en este informe, se generaron programas en lenguaje .m. Existe la opción de realizar su uso mediante el modo asistido, como si fuese un utilitario similar a CENTURION XV, pero se

optó por la línea de código para mostrar la versatilidad de MATLAB. La potencialidad que este software, podría realizar en las demás actividades necesarias para la planeación, luego de aprenderlo.

De los resultados mostrados en las diversas tablas y figuras del capítulo II, se nota, el método mediante hoja electrónica, mayor distancia al valor objeto de la comparación, en el año 2008. En CENTURIO XV, se utiliza todos los datos en sus modelos ARIMA, para la predicción anual y mensual, para el 2008 y extrapolación hasta el 2019. En cambio, para la predicción mensual con RNA TDNN, se utilizaron la mitad de los datos para la creación y entrenamiento de la red, luego se pronosticó los demás datos obteniéndose resultados similares en la predicción de la demanda, lo que demuestra que la herramienta es más robusta y flexible.

Para la predicción de la demanda anual fue suficiente utilizar RNA BP de tres capas de (1-3-1 y 1-1-1 neuronas por capa), y para la demanda mensual RNA TDNN con retardo de tiempo de dos capas (4-1 y 2-1 neuronas por capa) con un retardo de tiempo de 9 pasos; es decir se estableció modelos sencillos para resolver la predicción de la demanda.

Las variaciones o diferencias obtenidas en los resultados de la predicción mensual se establecieron en: un máximo de 6 MW y de 3 MWh, y un mínimo de 0,4 MW y 0,2 MWh, respectivamente para potencia y energía. Es decir, mediante el método Global Sectorial, las variaciones de potencia y energía son mayores a estos métodos, lo significa que la aplicación de los métodos RNA mejora los insumos para los planes de inversión a ser realizados.

La RNA superó ligeramente al modelo ARIMA, mejora en la facilidad de los cambios en los parámetros y las verificaciones de los datos se amplían al poder ser modificadas por el usuario por estar en lenguaje de programación, opción que no se tiene en utilitarios que solo dan opciones preestablecidas.

La mejora del uso de la energía comprada se ve en el comportamiento de la curva de carga del sistema eléctrico de distribución, tanto para la CNEL EP, como para clientes industriales, cuya tarifa se ve aplicada en valores horarios.

Un campo para disminuir y establecer eficientemente la compra de la energía a CELEC EP TRANSELECTRIC, es mejorar la predicción de la energía en periodos semanales y horarios. Investigación relevante de aplicación en las empresas eléctricas de distribución de energía y de clientes industriales.

BIBLIOGRAFIA

- Isasi Viñuela, P., & Galván León, I. M. (2004). *Redes de Neuronas Artificiales. Un Enfoque Práctico*. Madrid: Pearson Educación.
- Jimenez, J. F., Gázquez, J., & Sánchez, R. (2006). La capacidad predictiva en los métodos Box-Jenkins y Holt-Winters: una aplicación al sector turístico. *Revista Europea de Dirección Economía de la Empresa.*, 15(3), 185-198.
- Martín del Brío, B., & Sanz Molina, A. (2007). *Redes Neuronales y Sistemas Borrosos*. México: Alfaomega.
- Muñoz, M. I. (2000). <http://ohm.utp.edu.co/neuronales>.
- Sánchez Campero, E. N., & Alanís García, A. Y. (2006). *Redes neuronales. Conceptos fundamentales y aplicaciones a control automático*. Madrid: Pearson Educación.

GLOSARIO DE TÉRMINOS

Serie temporales o de tiempo.- Es una secuencia cronológica de observaciones de una variable en particular.

Predicción.- En una serie de tiempo es intentar conocer valores futuros de la serie.

Tendencia.- En una serie de tiempo, cuando en largos períodos los valores crecen o decrecen consistentemente.

Modelos ARIMA.- Modelo que analiza las propiedades probabilísticas o estocásticas de la serie de tiempo.

Red neuronal artificial (RNA).- Modelo matemático desarrollado en base al funcionamiento de los sistemas nerviosos biológicos.

Neurodinamica.- Se refiere a las propiedades de la RNA, que consiste de lo siguiente: Combinación de entradas, producción de salidas, tipo de funciones de transferencia, esquemas de pesos, y algoritmos de entrenamiento

Backpropagation (BP).- Es un RNA basado en el perceptrón multicapa entrenada mediante el algoritmo de retropropagación de errores o BP; es decir, al conjunto arquitectura MLP + aprendizaje BP, se le conoce como red de retropropagación o simplemente BP.

Time Delay Neural Network (TDNN).- Es una red estática, con retardo de tiempo entre la entrada y la primera capa de la RNA, se fundamenta en el uso de la red de retropropagación BP.

Utilitarios.- Significa que son programas que realizan actividades específicas para las que son diseñados, no pueden o no hacen labores complejas para las que son diseñadas.

ANEXO No.01

**TABLA DE DATOS Y RESULTADOS
DE LA PREDICCIÓN DE LA DEMANDA**

ANEXO No.02

PROGRAMAS DESARROLLADOS PARA PREDECIR LA DEMANDA EN PERIODO ANUAL Y MENSUAL