

2012

Modelación del consumo de energía eléctrica mediante métodos
heurísticos.

M. I. José Luis Rojas Rentería



Universidad Autónoma de Querétaro
FACULTAD DE INGENIERÍA
DOCTORADO EN INGENIERÍA

Modelación del consumo de energía eléctrica mediante
métodos heurísticos

T E S I S

Que como parte de los requisitos
Para obtener el grado de:
DOCTOR EN INGENIERÍA

Presenta:
M. en I. José Luis Rojas Rentería

Dirigido por:
Dr. Gonzalo Macías Bobadilla

Centro Universitario
Querétaro, Qro. Mayo del 2013. México.



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA
DOCTORADO EN INGENIERÍA

**Modelación del consumo de energía eléctrica mediante métodos
heurísticos**

TESIS

Que como parte de los requisitos para obtener el grado de
Doctor en Ingeniería

Presenta:

M. I. José Luis Rojas Rentería

Dirigido por:

Dr. Gonzalo Macías Bobadilla

SINODALES

Dr. Gonzalo Macías Bobadilla
Presidente

Dr. Edgar A. Rivas Araiza
Secretario

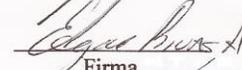
Dr. Jorge D. Mendiola Santibáñez
Vocal

Dr. Juvenal Rodríguez Reséndiz
Suplente

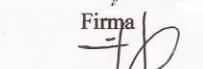
Dr. Manuel Toledano Ayala
Suplente

Dr. Aurelio Domínguez González
Nombre y
Director de la Facultad

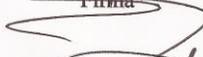

Firma

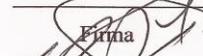

Firma


Firma


Firma


Firma


Firma


Firma


Nombre y Firma
Director de Investigación y Posgrado

Centro Universitario
Querétaro, Qro.
Mayo 2013
México

Resumen

Durante los últimos años ha crecido la demanda de energía eléctrica en los sectores industriales y comerciales, así como en edificios públicos y privados. Lo anterior representa un problema para pronosticar el consumo de electricidad en estos sectores, por lo tanto, se tiene como finalidad evitar las multas impuestas por las respectivas empresas del suministro de electricidad. A medida que el consumo de energía eléctrica en estos sectores crece, la complejidad de los sistemas de generación y consumo de energía en las empresas de electricidad se incrementa de acuerdo a su capacidad de suministro de energía. Esta tesis presenta una modelación con métodos de Redes Neuronales Artificiales (RNA) y Auto regresivos con entradas exógenas (ARX) para calcular y predecir el consumo eléctrico para el sector público mediante procedimientos heurísticos, utilizando variables climáticas como la temperatura, la radiación solar, la velocidad del viento y la humedad relativa, así como el consumo de energía y el tiempo (hr. y día). Este sistema permite la previsión el consumo eléctrico en los próximos meses y, por lo tanto, una mejor gestión de la energía eléctrica. La previsión del consumo eléctrico en el sector público requiere de avanzadas herramientas inteligentes como las que se presentan en este estudio. La validación del modelo se realizó comparando los resultados con un modelo de regresión no lineal, RNA y ARX, también se tomaron en cuenta los datos reales con el análisis de la varianza (ANOVA) y con la prueba de rango múltiple DUNCAN. Este estudio de modelación del consumo de energía eléctrica para el sector público, se llevó a cabo en el posgrado de la Facultad de Ingeniería de la Universidad Autónoma de Querétaro. Los resultados de la predicción de modelo 4-4-1 RNA fueron de los intervalos de confianza del 95%. Las variables utilizadas como insumos para la previsión de modelo neuronal fueron la temperatura, el consumo de energía y el tiempo (día y hora) con un error estimado de 0.022 comparado con los datos reales. El algoritmo utilizado para la previsión fue el Levenberg-Marquardt.

Palabras clave: ANOVA, DUNCAN, Red Neuronal Artificial, ARX, previsión, energía eléctrica, consumo eléctrico.

Summary

Growth electric energy demand in the industrial and commercial sectors and in public and private buildings represents a problem to forecast electricity consumption in these sectors, in order to avoid fines imposed by the respective companies supplying electricity. As the electric energy consumption in these sectors grows, the complexity of the generation systems and energy consumption in the electricity companies increases according to their ability to supply power. This thesis presents a modelation by methods of artificial neural networks (ANN) and Auto Regressive with exogenous input (ARX) to calculate and predict the electrical consumption for the public sector through heuristics, using climatic variables such as temperature, solar radiation, wind speed and relative humidity as well as the consumption of energy and time (hr. and day). This system allows forecasting the electrical consumption of the next few months, and therefore, a better management of electric energy. Forecasting electricity consumption in public sector requires advanced intelligent tools such as those presented in this study. Model validation was performed by comparing the results with a nonlinear regression model, RNA, ARX and the actual data with the analysis of variance (ANOVA) with Duncan's multiple range tests. This modeling study of electricity consumption for the public sector took place in the Graduate of Engineering School at the Universidad Autónoma de Querétaro. The results of the 4-4-1 ANN model forecasting were of 95% confidence intervals. The variables used as inputs to the neural model forecasting were temperature, power consumption and time (hr. and day) with an estimated error of 0.022 compared with the real data. The algorithm used to forecast was Levenberg-Marquardt.

Key words: ANOVA, DUNCAN Artificial Neural Network, ARX, Forecasting, Electric energy, Electricity consumption.

Dedicatorias

Dedico este trabajo a mis padres, a mi esposa Ma. Irma y a mis hijos Diego, Erick y Diana por su tiempo y comprensión, así como su valiosa ayuda y apoyo para la terminación de mis estudios.

Agradecimientos

Agradezco a la Universidad Autónoma de Querétaro y CONACYT por el apoyo para la terminación de este proyecto en mi vida.

También agradezco al Dr. Gonzalo Macías Bobadilla, Dr. Edgar A. Rivas Araiza, Dr. J. Domingo Mendiola Santibañez, Dr. Juvenal Rodríguez Reséndiz y al Dr. Manuel Toledano Ayala el apoyo durante el tiempo de mis estudios e investigación del doctorado.

ÍNDICE GENERAL

	Página
Resumen	i
Summary	ii
Dedicatorias	iii
Agradecimientos	iv
Índice	v
Índice de figuras	vii
Índice de tablas	viii
I. Introducción	1
1.1 Estructura del sistema de generación de energía eléctrica.	3
1.1.1 Evolución de la demanda de electricidad	1
1.1.2 Comportamiento de la demanda de electricidad nacional	5
1.1.3 Comportamiento de la demanda de energía eléctrica por región en México	6
1.1.4 Generación de la energía eléctrica en México	7
1.2 Situación general de las fuentes y usos de la energía.	9
1.2.1 El concepto del consumo de energía y su importancia.	11
1.2.2 Motivación de los consumidores para ahorrar energía	13
1.3 Desarrollo de sistemas de previsión y monitoreo del consumo de energía para el sector público	14
1.3.1 Modelos heurísticos	17
1.3.2 La previsión de energía mediante redes neuronales.	18
1.3.3 La previsión de energía mediante modelos ARX.	20
1.3.4 La previsión de energía mediante modelos difusos	22
1.4 Hipótesis.	23
1.5 Objetivo.	23
1.6 Justificación	26
1.6.1 Aspecto ecológico.	25

1.6.2	Aspecto económico.	26
1.6.3	Aspecto social.	30
1.7	Estructura de la tesis	31
II.	Consideraciones teóricas	31
2.1	Teoría de las redes neuronales artificiales	31
2.2	Teoría de los modelos ARX	35
2.3	Teoría de los modelos difusos.	37
2.	Metodología	40
3.1	Selección del edificio.	42
3.2	Previsión del consumo de energía eléctrica por medio de redes neuronales artificiales	44
3.3	Estructura de la previsión del consumo de energía en cascada	47
3.4	Previsión del consumo de energía eléctrica mediante modelos ARX	48
3.5	Mediciones de precisión	50
III.	Resultados	50
4.1	Modelado con redes neuronales artificiales	51
4.2	Modelado con ARX	51
4.3	Comparación de modelos	52
4.4	ANOVA de los resultados de los modelos resultantes	53
4.5	Método Duncan para los modelos resultantes	56
IV.	Conclusiones	58
VII.	Referencias	60

Anexos	66
Publicaciones científicas	70

ÍNDICE DE FIGURAS

Figura		Página
1	Capacidad nacional de energía eléctrica efectiva instalada	4
2	Sectores del consumo eléctrico.	6
3	Generación de energía eléctrica por región.	7
4	Promedio de energías primarias generadas por sector de los últimos años.	10
5	Origen de los energéticos utilizados en México en el año 2010	11
6	Proliferación de energía eléctrica	16
7	Estructura de la neurona artificial.	20
8	Modelo ARX.	21
9	Funciones de pertenencia	24
10	Cargos por consumo de energía eléctrica en la facultad de Ingeniería (UAQ)	30
11	Costo de energía eléctrica en la facultad de Ingeniería (UAQ).	30
12	Redes neuronales interconectadas.	33
13	Arquitectura de una red neuronal.	34
14	Estructura general del modelo difuso	38
15	Diagrama de bloques del modelo difuso	39
16	Posgrado de la facultad de Ingeniería	44
17	Localización de las cargas eléctricas en salones	44
18	Función sigmoidea de una red neuronal	45
19	Red neuronal artificial.	47
20	Predicor de previsión del consumo eléctrico en cascada	48
21	Identificación del sistema ARX	49
22	Comparación del error de previsión en los modelos de red neuronal y regresión	53
23	Valores medidos y estimados para el consumo de energía eléctrica	57

ÍNDICE DE TABLAS

Tabla	Página
1. Medición del monitoreo de energía.	43
2. Comparación del error estimado para diferentes modelos de redes neuronales en la previsión del consumo de energía eléctrica.	51
3. Comparación del error estimado para diferentes modelos ARX en la previsión del consumo de energía eléctrica.	52
4. Comparación de mediciones y valores estimados en modelos de redes neuronales, regresión no lineal y ARX.	52
5. ANOVA comparación de datos entre la regresión no lineal, ARX y la red neuronal.	54
6. Cálculo de ANOVA por medios manuales.	55

I. INTRODUCCIÓN

La calidad en la demanda de energía eléctrica es un tema muy común y de gran interés en la actualidad, es así como se ve reflejado en las exigencias de los usuarios en el suministro y transporte de energía, la operatividad de las redes eléctricas y los costos por el servicio, sin dejar a un lado el esfuerzo que se realiza día con día para ahorrar energía. Los ingenieros eléctricos necesitan más que lecturas de kW/h para planificar el crecimiento de red porque los usuarios demandan una mejor calidad de los servicios públicos, por lo tanto es importante que tengan datos sobre la calidad de energía.

Las actividades industriales, comerciales y habitacionales al tratar de ganar mercados a sus competidores están creciendo rápidamente en todas las regiones, sin embargo, estas actividades dependen del incremento de demanda de energía eléctrica ya que es la base de su desarrollo. Se puede deducir que estos sectores ven a la energía eléctrica como uno de sus insumos vitales para su proceso productivo y comercial.

En estos tiempos se conoce que el consumo de energía eléctrica es un buen índice del crecimiento económico y de producción de una nación, como consecuencia la demanda de energía eléctrica en los consumidores aumentó y sus cargas se multiplicaron. Ahora, nuevos equipos con diferentes tecnologías catalogan a la mayoría de las cargas como no lineales, puesto que cuentan con componentes más eficientes.

Por un lado, las empresas necesitan una gran cantidad de datos sobre la red existente y su rendimiento, la finalidad es planificar una expansión de la red eléctrica y así, se pueda ofrecer una mejor calidad de suministro. Mientras tanto, los ingenieros requieren el perfil detallado de información de la carga y los datos generados por las cargas del consumo y los sistemas de medición de energía; sin embargo, se puede ofrecer sólo una pequeña cantidad de los datos para realizar acciones de ahorro de energía de forma local.

Ante esta situación, 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 (Nguyen-Vu et al., 2008). Las compañías de distribución necesitan de monitorear y corregir los problemas en la calidad de energía para el bien de sus usuarios, graficando en tiempo real los valores promedio de la energía programada y realizando ajustes de producción de acuerdo a la demanda del día (Wong and Wang, 2009).

Las investigaciones recientes sobre el despliegue de datos de consumo eléctrico han demostrado que las medidas adoptadas han sido ineficientes para lograr un cambio en el comportamiento de los usuarios y con métodos electrónicos de retroalimentación se ha registrado más eficiencia (Wood, 2006). Así, Seem (2006) concluye que esa es la forma más eficaz de obtener información del consumo de energía porque capta la atención de la audiencia, gana participación, además de que es confiable y útil para los usuarios. No es simplemente el despliegue de la información, lo importante es la forma en la que la información motiva al consumidor a ahorrar energía.

La mayoría de los estudios anteriores muestran el total del consumo de energía en instalaciones del sector público, y no el consumo de los distintos aparatos o actividades. Un consumidor puede demostrar cuánta energía eléctrica se está utilizando al monitorear el consumo actual y el anterior, esta comparación podría propiciar un consumo consciente y mostrar en qué se está utilizando la energía en mayor o menor medida, y esto significa tener un mejor control de su consumo eléctrico. Alternativamente, el consumidor podría utilizar esta información comparativa como base para fijar metas, o para buscar recompensas económicas o sociales.

Esta problemática puede enfrentarse primero con un monitoreo del consumo real de energía eléctrica que se está utilizando. Posteriormente, se analiza cuánta energía se va a necesitar con modelos de previsión, logrando así, un gran interés desde la instalación de las redes eléctricas como un sistema de transporte y distribución de energía. La próxima generación de predictores de carga requiere más información para poder predecir la carga necesaria que necesitan los diferentes sectores consumidores de energía, con el objetivo de lograr su óptima operación. Incluso, se requiere realizar un análisis de energía con base a la tecnología eléctrica para comenzar a diseñar la construcción de edificios, ya que el consumo de energía en un edificio se decide de acuerdo a su control, mantenimiento y

número de ocupantes; la reducción global en el consumo de energía mediante sistemas de control provoca ambientes más funcionales con calidad de energía (Arditi and Nawakorawit, 2000; Young-Sub and Kang-Soo, 2007). Es importante mencionar que las acciones mencionadas anteriormente podrían motivar a los consumidores a ahorrar energía.

Brandon y Lewis (Brandon et al., 2009) llevaron a cabo un estudio relacionado con los beneficios de una conexión interactiva de sistemas de información de consumo de energía para el sector público y una comparación del consumo de energía antes y después de la instalación del sistema reveló una reducción en el consumo total de la energía eléctrica en los edificios. La información acerca del consumo de energía es también muy útil para detectar consumo anormal de energía en edificios (Seem, 2006).

El consumo nacional de electricidad está compuesto por dos categorías:

- i) las ventas internas de energía eléctrica, las cuales consideran la energía entregada a los usuarios con recursos de generación del sector público, incluyendo a los productores independientes de energía.
- ii) autogeneración, que incluye a los permisionarios de autoabastecimiento, cogeneración e importación de electricidad.

En términos generales, el comportamiento del crecimiento de la generación de la energía eléctrica se encuentra altamente correlacionado, en forma positiva, con el ritmo de actividad económica, lo cual implica que, ante un incremento en el Producto Interno Bruto (PIB), el consumo de energía eléctrica aumenta.

1.1. Estructura del sistema de generación de energía eléctrica

El sistema de generación está integrado por centrales de diferentes tipos que utilizan distintos combustibles o fuentes de energía primaria. En diciembre del 2010, la capacidad instalada total alcanzó 60,440 MW distribuida en las diferentes aéreas. En la figura 1 se muestra la capacidad efectiva instalada.

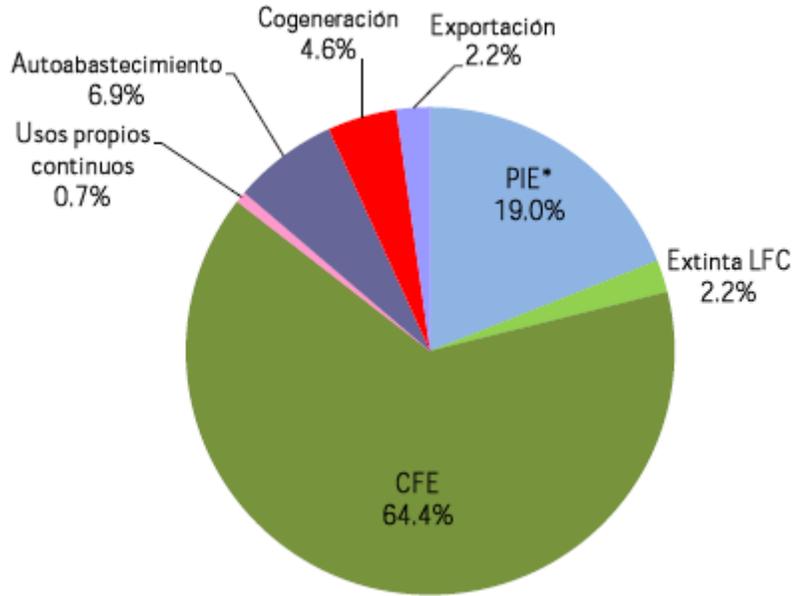


Figura 1. Capacidad nacional de energía eléctrica efectiva instalada

En lo referente a la generación de energía eléctrica, en México se creó la CFE (Comisión Federal de Electricidad), cuyo objetivo primordial fue construir la infraestructura necesaria para dotar de energía eléctrica a toda la población. Actualmente, la capacidad instalada que reporta la CFE es de 60,440 Mega watts, dividiéndose ésta en diferentes fuentes: las termoeléctricas, nucleoelectricas, las hidroeléctricas y/o ciclo combinado, las carboeléctricas, las geotérmicas, diesel, turbogas, dual y las eoléticas (CFE).

A lo largo de toda la República Mexicana, se cuenta con 177 centrales generadoras y con una red de transmisión de 48,527 km. En los últimos años se ha presentado una preocupación por satisfacer el abastecimiento de energía que cubra el ritmo acelerado de crecimiento urbano e industrial que el país presenta (Godoy, 2011).

La electricidad era la palabra mágica a fines del s. XIX, desde las tentativas iniciales de Benjamín Franklin o de Michael Faraday hasta la tecnología del telégrafo, las aplicaciones para la electricidad crecían continuamente.

La demanda de electricidad pronto condujo al deseo de construir centrales eléctricas más grandes y de llevar la energía a mayores distancias. Además, la rápida distribución de motores eléctricos industriales provocó una fuerte demanda por un voltaje diferente a los 110 V usados para la iluminación.

El sistema de Edison utilizaba la corriente continua (CC), era poco adecuado para responder a estas nuevas demandas. El problema del transporte era aún más difícil, puesto que la transmisión interurbana de grandes cantidades de CC en 110 voltios era muy costosa y sufría enormes pérdidas por disipación en forma de calor.

Nikola Tesla creyó en la superioridad de la corriente alterna (CA). Su argumento se basaba en que las pérdidas en la transmisión de electricidad dependen del voltaje: a mayor voltaje, menores pérdidas. Y a diferencia de la CC, el voltaje de la CA se puede elevar con un transformador para ser transportado largas distancias con pocas pérdidas en forma de calor. Entonces, antes de proveer energía a los clientes, el voltaje se puede reducir a niveles seguros y económicos.

1.1.1 Evolución de la demanda de electricidad

La demanda de energía eléctrica la determinan varios factores: los más importantes son el ritmo de la actividad económica, el crecimiento demográfico, el nivel de desarrollo, las condiciones climáticas y geográficas, la estructura y los niveles tarifarios; además de cambios tecnológicos tales como los avances en la eficiencia con que se utiliza la electricidad en los procesos productivos y en los aparatos eléctricos. Por todo ello, la CFE hace un estudio anual sobre el comportamiento histórico de las ventas de electricidad por sector y región, en el que se registran los principales cambios que se presentaron durante el último año.

Las ventas de electricidad en México aumentaron de 81.9 TW/h en 1988 a 130.2 TW/h en el 2010, lo que representa una tasa de crecimiento medio anual de 5.3% durante la última década. Dicho incremento de la demanda de energía eléctrica fue superior al ritmo del aumento poblacional y al del Producto Interno Bruto.

1.1.2 Comportamiento de la demanda de electricidad nacional

La energía en México se comercializa mediante una estructura tarifaria que integra 31 modalidades diferentes. En general, las tarifas se agrupan en cinco sectores según el uso:

- Residencial
- Comercial
- Servicios
- Industrial
- Agrícola

Del total de los suministros de energía eléctrica en el país durante 2010, 59.9% fue destinado a la industria, 22.7% a los usuarios residenciales, 7.6% al sector comercial, 5.9% al riego agrícola y 3.9% al sector de servicios (figura 2).

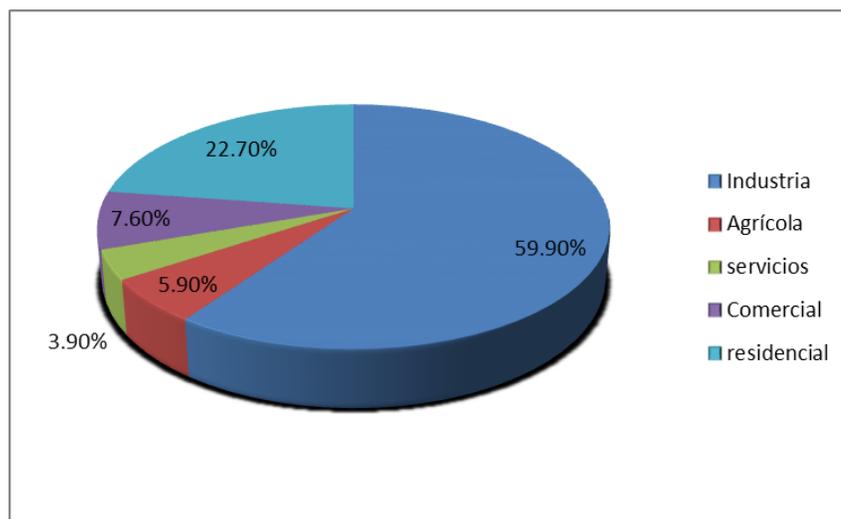


Figura 2. Sectores del consumo eléctrico

El número de usuarios del sector industrial representa solo el 0.41% del total, sin embargo, este sector demanda alrededor de 60% de las ventas. Por su parte, el número de usuarios residenciales equivale a 88.4% del total, y su consumo representa menos de la cuarta parte de la demanda nacional de electricidad. Ambos sectores, industrial y residencial, absorben más de cuatro quintas partes de la energía vencida.

1.1.3 Comportamiento de la demanda de energía eléctrica por región en México

Para el estudio del mercado eléctrico, el país se divide en 115 zonas y 12 pequeños sistemas aislados, seis de los cuales reciben energía de diferentes centrales de generación. Las zonas se agrupan en varias áreas del sistema eléctrico:

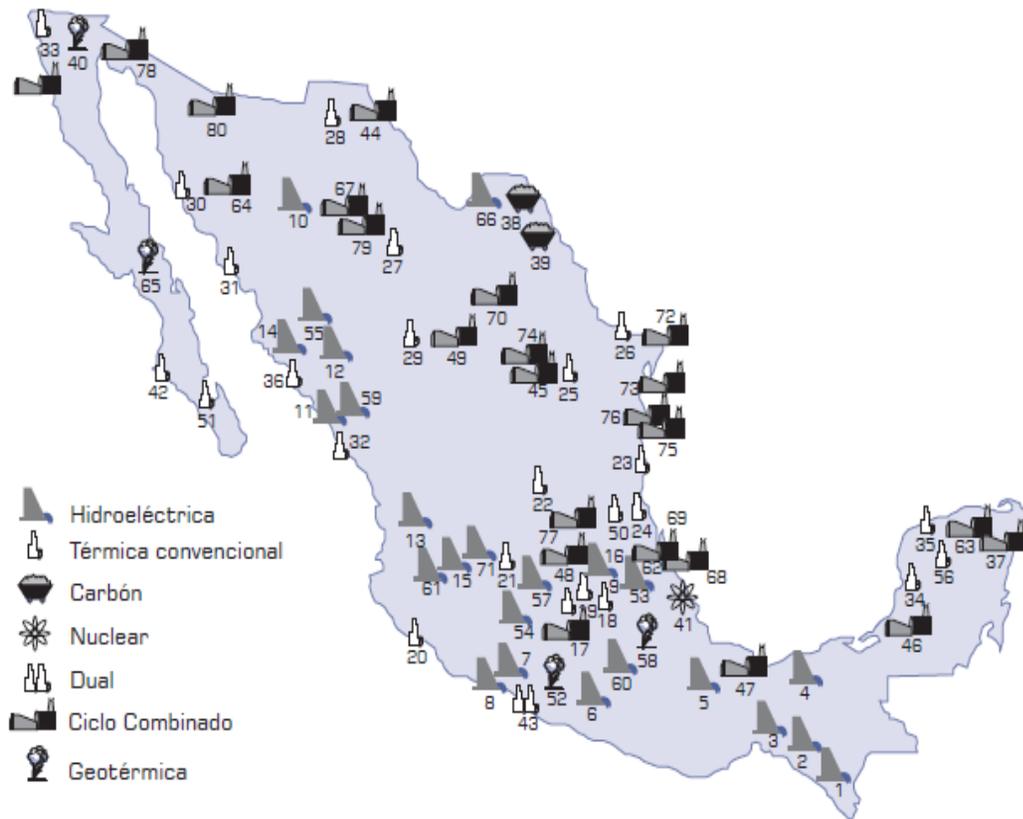


Figura 3. Generación de energía eléctrica por región

1.1.4 Generación de la energía eléctrica en México

En 1937, México tenía 18.3 millones de habitantes, de los cuales, únicamente siete millones contaban con electricidad proporcionada con serias dificultades por tres

empresas privadas. Las interrupciones de luz eran constantes y las tarifas muy elevadas, debido a que esas empresas se enfocaban a los mercados urbanos más redituables, sin contemplar a las poblaciones rurales, donde habitaba más del 62% de la población.

Para dar respuesta a esa situación que no permitía el desarrollo económico del país, el gobierno federal creó el 14 de agosto de 1937 la Comisión Federal de Electricidad, misma que comenzó a construir plantas generadoras y con ello benefició a más mexicanos mediante el bombeo de agua de riego, el arrastre y la molienda; así como con alumbrado público y a viviendas.

Los primeros proyectos de generación de energía eléctrica de CFE se realizaron en Teloloapan, Guerrero; Pátzcuaro, Michoacán; Suchiate y Xía en Oaxaca, y Ures y Altar, en Sonora. El primer gran proyecto hidroeléctrico se inició en 1938 con la construcción de los canales, caminos y carreteras de lo que después se convirtió en el Sistema Hidroeléctrico Ixtapantongo, en el Estado de México, que posteriormente fue nombrado Sistema Hidroeléctrico Miguel Alemán. En 1938, Comisión tenía apenas una capacidad de 64 kW, misma que, en ocho años, aumentó hasta alcanzar 45,594 kW. Entonces, las compañías privadas dejaron de invertir y CFE se vio obligada a generar energía para que éstas la distribuyeran en sus redes, mediante la reventa.

Para 1960, CFE aportaba 54% de los 2,308 MW de capacidad instalada; la Mexican Light, 25%; la American and Foreign, 12%, y el resto de las compañías 9%. Sin embargo, a pesar de los esfuerzos de generación y electrificación, para esas fechas apenas el 44% de la población contaba con electricidad. Por esto el entonces presidente Adolfo López Mateos decidió nacionalizar la industria eléctrica el 27 de septiembre de 1960. A partir de entonces, se comenzó a integrar el Sistema Eléctrico Nacional, extendiendo la cobertura del suministro y acelerando la industrialización. El Estado mexicano adquirió los bienes e instalaciones de las compañías privadas, las cuales operaban con serias deficiencias por la falta de inversión y los problemas laborales.

Para 1961, la capacidad total instalada en el país ascendía a 3,250 MW. CFE vendía 25% de la energía que producía y su participación en la propiedad de centrales

generadoras de electricidad pasó de cero a 54%. En poco más de 20 años se había cumplido uno de sus más importantes cometidos: ser la entidad rectora en la generación de energía eléctrica. En esa década, la inversión pública se destinó en más de 50% a obras de infraestructura. Se construyeron importantes centros generadores, entre ellos los de Infiernillo y Temascal. También se instalaron plantas generadoras, alcanzando, en 1971, una capacidad instalada de 7,874 MW.

Al finalizar esa década, se superó el reto de sostener el mismo ritmo de crecimiento, al instalarse entre 1970 y 1980 centrales generadoras que dieron una capacidad instalada de 17,360 MW. En los 80, el crecimiento fue menos espectacular, principalmente por la disminución en la asignación de recursos. No obstante, en 1991 la capacidad instalada ascendió a 26,797 MW.

1.2. Situación general de las fuentes y usos de la energía

En el mundo, el suministro de energía sigue siendo principalmente satisfecho por recursos fósiles; aproximadamente el 80% de la demanda mundial de energía es generada por petróleo, gas natural o carbón.

De acuerdo a Jochem (2005), una gran variedad de factores requieren un uso más eficiente de los recursos para, por ejemplo, ayudar a mitigar las consecuencias económicas negativas de un aumento en los precios debido al agotamiento de dichos recursos. Las políticas para el desarrollo sustentable que han implementado los diferentes gobiernos a nivel internacional, no han sido lo suficientemente exitosos y esto parece alimentar el potencial para que los conflictos internacionales se incrementen, cuando la escasez de este recurso se presente.

Según Campbell (2011), el agotamiento de la mitad del período (50% de las reservas mundiales) para el petróleo crudo y gas natural probablemente se alcanzará en 2015. En esta tesis una amplia gama de previsiones sobre el agotamiento de los recursos se han reunido y comparado de acuerdo a los estudios realizados por Rempel (2008).

Por otro lado, el panorama nacional de los últimos años en materia de generación de energía primaria en México, muestran que el Carbón genera un 2.07%, el petróleo crudo 69.99%, condensados 1.45%, gas natural 19.3%, núcleo energía 1.08%, hidroenergía 2.49%, geoenergía 0.6524% y energía eólica 0.028% (figura 4). Con estos datos obtenidos en el Sistema de Información Energética de México (SIE, 2010), se demuestra que los consumos de energía de fuentes no renovables (como carbón, petróleo y gas natural) son de aproximadamente el 91.36% (figura 4), estando en promedio un 10% arriba del panorama mundial. Los principales sectores consumidores de energía en México son:

- a) El sector industrial, que es el que tiene un mayor consumo de energía eléctrica con un 60% del total de la energía generada
- b) El sector comercial, en segundo lugar en consumo, con un 23%
- c) El sector público y comercial con un 9% y 8% (Oke et al., 2000) respectivamente.

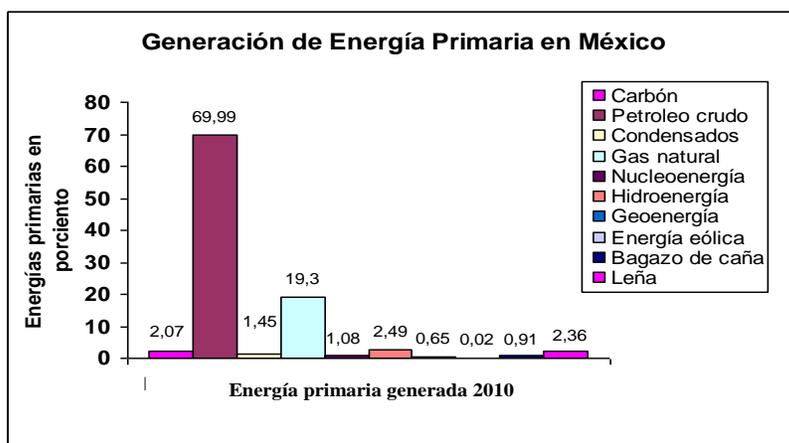


Figura 4. Promedio de energías primarias generadas por sector en los últimos años.

Todos estos factores son importantes de considerar, ya que impactan directamente al incremento de las tarifas ejerciendo presiones sobre el costo de producción de la electricidad, aumentando así los cargos que enfrentan los consumidores.

Las instituciones educativas pertenecen al sector público-agrícola y éste consume alrededor del 9% de la energía total generada. Se estima que en México será necesario tomar en cuentas el ámbito tecnológico y el científico para el ahorro de energía, así como la generación y uso de energías renovables (figura 5).

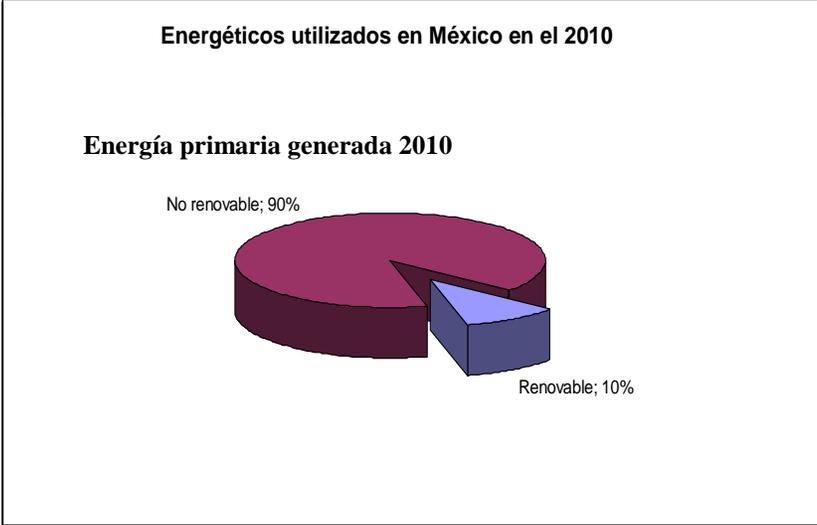


Figura 5. Origen de los energéticos utilizados en México en el año 2010

En cuanto al ámbito tecnológico, las empresas mejoran con productos nuevos de integración y dispositivos presentes en la planta en redes informáticas (sensores, actuadores, micro controladores y PLC's), reduciendo en gran mayoría el cableado, mejorando la fiabilidad del sistema y facilitando la reconfiguración de los equipos y sistemas.

Las empresas han abierto nuevas posibilidades a través de Internet y Ethernet para el manejo y control de producción a distancia, así como el monitoreo de variables desde cualquier parte fuera de la compañía.

1.2.1. El concepto del consumo de energía y su importancia.

El consumo de energía eléctrica surge de la incertidumbre para determinar la capacidad generadora, se considerara como la construcción de nuevas centrales de energía o simplemente para impulsar la adopción de medidas de conservación de energía eléctrica; o por el contrario, si existe un exceso de la capacidad que pudiera aconsejar la no utilización de una parte de la generación de energía eléctrica ya existente (Energy Information Administration, 2009).

Ruano et al. en el 2005, utilizan algoritmos para diseñar una base de modelos de redes neuronales con un sistema de adquisición de datos de climas artificiales y del medio ambiente para lograr una estimación de la climatización interna de edificios con simulaciones para realizar una regulación de la temperatura con el objetivo de economizar energía.

Los mapas auto-organizados - como modelos neuronales para la predicción a corto plazo de las curvas del consumo de energía eléctrica total -, se utilizan para obtener la curva del consumo eléctrico de las horas del día siguiente. El mapa auto-organizado es un tipo de red neuronal artificial cuyo entrenamiento se realiza mediante un algoritmo de aprendizaje no supervisado con datos históricos de años anteriores, y pueden compararse las curvas obtenidas del consumo eléctrico real con el estimado, considerando un índice de error bastante bajo a corto plazo (Senabre, et al., 2004).

Para lograr el análisis del consumo de energía eléctrica, la red eléctrica realiza el seguimiento de todas las variables (voltaje, corriente, frecuencia y variaciones de flujos magnéticos) desde un centro de control eléctrico supervisado por los operadores, ejecutando ajustes de producción de acuerdo al consumo de energía, graficando en tiempo real los valores promedio de la energía programada con la previsión realizada para ese día y el consumo real por cada 4 segundos en intervalos de un minuto (Wong, et al., 2009).

Da'na et al., 2006 plantean la utilización de una plataforma basada en conectividad GSM, a través de comunicación ethernet y protocolo TCP/IP con banda

ancha, lo que facilita el análisis del consumo con un PLC, conectado a la red a través de una computadora con el puerto serial o profibus.

Utilizando la supervisión de cargas (basado en lecturas digitales y un control programable con PLC's para controlar y analizar las variables a través de la web), se desarrolla una interface graficable utilizando técnicas de Internet basadas en pruebas de ambiente de laboratorio propuestas por arquitectura WBRELSAC, lo que permite a los usuarios el acceso con datos en tiempo real y el poder manipular los instrumentos vía web a través de protocolos como http y ethernet TCP/IP para analizar el consumo de energía eléctrica (Wei-Fu Chang et al., 2006).

Las computadoras, la creación de redes, el monitoreo de energía y el desarrollo de la tecnología de base de datos han tenido un gran impacto en el aspecto de la calidad de la energía: en lecturas de medidores eléctricos, en el registro de energía utilizada por los diferentes usuarios, así como la adquisición de datos de energía confiable. Los avances tecnológicos en la creación de redes, comunicaciones, gestión de datos y tecnología de medición se han combinado para disminuir de manera importante los costos de los sistemas de monitoreo de energía (SME), y para aumentar la capacidad de estos sistemas al incluir datos de la calidad de la energía.

Los ingenieros eléctricos no sólo necesitan las lecturas de kW/h para planificar el crecimiento de red. Ellos necesitan el perfil detallado de información de la carga, su perfil y los datos contenidos en los armónicos generados por dicha carga.

Como los usuarios demandan una mejor calidad de los servicios públicos, es importante que tengan datos sobre la calidad de energía. Con el fin de que las empresas planifiquen una expansión de la red eléctrica y ofrezcan una mejor calidad de suministro, necesitan una gran cantidad de datos sobre la red existente y su rendimiento. Los sistemas SME pueden ofrecer sólo una pequeña cantidad de los datos para tomar acciones de ahorro de energía de forma local, la próxima generación de predictores de carga requieren más información a fin de predecir la carga necesaria que requieren los diferentes sectores

consumidores de energía para su óptima operación. Las acciones mencionadas anteriormente podrían motivar a los consumidores a ahorrar energía.

1.2.2. Motivación de los consumidores para ahorrar energía

La necesidad de una mayor flexibilidad del sistema eléctrico, los nuevos escenarios legislativos y económicos, el ahorro de energía y el impacto medioambiental, han contribuido al desarrollo de nuevas investigaciones sobre el despliegue de datos de consumo eléctrico que demuestren que las medidas adoptadas son eficientes para lograr un cambio en el comportamiento en los usuarios.

Es importante el ahorro de energía ya que ayuda a reducir costos energéticos y ayuda a mantener la economía. La mayoría de los estudios anteriores muestran el total de consumo de energía en edificios, y no el consumo de los distintos aparatos o actividades. Una eficiencia energética significa simplemente, utilizar toda la energía que necesitamos o deseamos en forma inteligente:

- Sin privarse de usar algún artefacto eléctrico,
- Sin sacrificar el confort que nos brindan los electrodomésticos, los ventiladores y equipos de aires acondicionados, sino todo lo contrario.
- Significa usar todo lo que se necesita consumiendo más eficientemente y reduciendo la factura de luz.

Asimismo, podemos utilizar en forma eficiente todos los aparatos eléctricos del hogar o la oficina, evitando el gasto irracional de la energía. Aprendiendo a utilizar correctamente los mismos, seguiremos disfrutando del confort que nos brindan con el beneficio de consumir menos energía y reduciendo los costos de la factura de energía eléctrica.

El desarrollo de nuevas investigaciones en el área de energía eléctrica considera que los avances tecnológicos en el área de la electrónica y comunicación pueden crear nuevos sistemas de información, visualización, previsión y ahorro para el sector público. Una persona puede tomar las lecturas individualmente, estas lecturas tomadas por el

usuario, se conocen como comportamiento de ahorro de energía (ESB). Los ESB son comportamientos habituales para el ahorro de energía que el usuario puede aplicar cuando está usando los aparatos y equipos de la casa, en vez de tomar acciones de comparación relacionadas, según lo que mencionan Barr et al., (2005).

1.3. Desarrollo de sistemas de previsión y monitoreo del consumo de energía para el sector público

El problema del consumo de energía eléctrica para el sector público puede ser tan sencillo o complicado como se quiera. Por lo general, el problema tiene que ser dividido para el análisis de restricciones que dan origen a diferentes problemas del consumo de energía. Las diferentes soluciones son iteradas hasta que no se viola ninguna restricción. El problema es fácil de resolver cuando se hacen las consideraciones adicionales como utilizar funciones de costo convexas de segundo orden, que lo convierten en un problema de programación lineal.

El problema de consumo es que se plantea para un sólo intervalo de tiempo, esto provoca que la demanda sea constante y generalmente se asume que las curvas de entrada-salida son suaves y convexas, las cuales pueden ser representadas por funciones lineales o cuadráticas. Un caso simple del consumo son las pérdidas de transmisión, en donde las únicas restricciones son el balance de potencia y los límites de potencia de cada generador.

Convencionalmente, se aplican diferentes técnicas para atacar los diferentes tipos de problemas del consumo. Sin embargo, cualquier cambio en la formulación del problema, puede requerir una alteración parcial o el reemplazo total de la técnica utilizada. El tiempo y esfuerzo que se requiere para adecuar la técnica son inadecuados para muchas aplicaciones prácticas.

Algunas de las técnicas utilizadas para solucionar los problemas de consumo de energía eléctrica son las tablas de mérito, método de lambda iterativa, programación dinámica y el método del gradiente que utiliza métodos heurísticos y reglas determinísticas transitorias para obtener estrategias de solución.

En contraste a las técnicas convencionales, los algoritmos genéticos han exhibido robustez en la habilidad para encontrar óptimos globales en la solución de los problemas de consumo de energía de diferente complejidad. La mayor atracción de estos algoritmos es que no son computacionalmente simples, pero bastantes poderosos en la búsqueda de óptimos globales. En el caso del problema del consumo eléctrico, estos algoritmos permiten utilizar de igual manera funciones de costo lineal o no lineales.

La previsión del consumo de la energía eléctrica ha causado interés desde el momento en que las redes eléctricas se instalaron como sistema básico de transporte y distribución de energía y al haber proliferado el uso masivo de la energía eléctrica en el entorno industrial, comercial y doméstico, como se muestra en la figura 6.

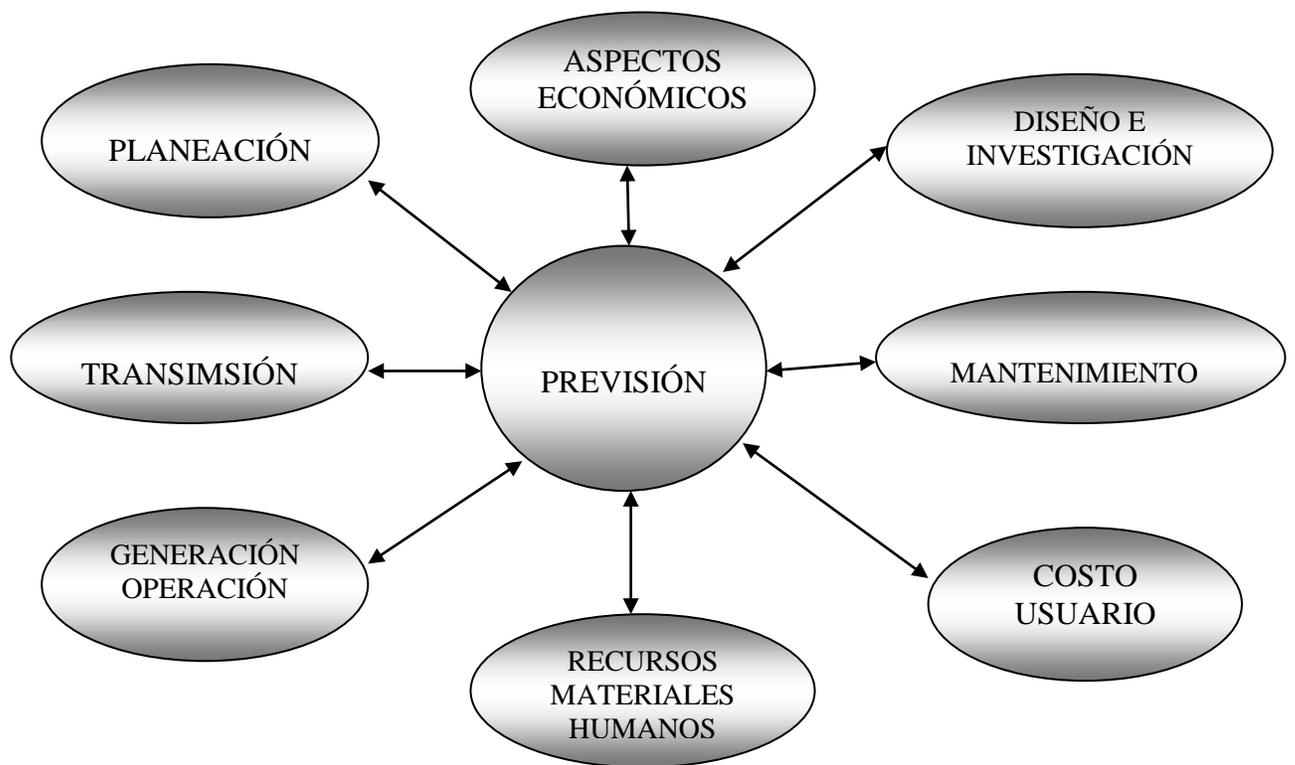


Figura 6. Proliferación de energía eléctrica

Debido a la naturaleza del tipo de modelo utilizado, la bondad de las previsiones varía notablemente. Existen algunas realmente certeras, con márgenes de error de menos de 50 kW, y otras en las que el modelo no ha sido capaz de estabilizarse lo suficiente y que oscilan amplificándose alrededor del valor real (aproximadamente un 10). Los modelos poco adecuados (los cuales se descubren a posteriori, es decir, una vez que se ha recopilado la información real de los consumos) están motivados por datos de origen a su vez irregulares. Intentar predecir un día laboral empleando como datos de partida los consumos de un festivo, por ejemplo, suele desembocar en predicciones erráticas y a menudo bastante inciertas.

A pesar de que esas previsiones no son del todo útiles, el procedimiento de obtención del modelo no pierde validez pues de una manera más o menos acertada, es capaz de decir de antemano el nivel de confianza que podemos asignarle a una predicción en concreto. Además, la previsión misma nos informa de su validez, pues observando la gráfica que se obtiene, si vemos grandes oscilaciones de alta frecuencia y que se van amplificando, podemos asegurar que esa predicción no será muy válida.

En estos tiempos en que la energía y las finanzas escasean, el consumo de electricidad se vuelve significativo. Los costos de generación están aumentando por lo que también los precios van al alza

En las facturas que entregan las compañías que proveen el servicio, vienen tendencias generales de consumo pero no un detalle que permita saber a priori cuánto consumo hubo en una fiesta, o en una noche de películas en la TV, o conectando un nuevo dispositivo electrónico (computadora, equipo de música, cámaras de seguridad). Por lo tanto, el costo de energía eléctrica es un ítem que no se puede administrar, de manera determinística y anticipativa, lo que constituye una debilidad a la hora de manejar presupuestos.

Las nuevas tecnologías son un aliado indispensable a la hora de hacer más eficiente el sistema. Un ejemplo concreto es la distribución estratégica a lo largo de la red de capacitores tele comandados para que mediante Internet, se controle su flujo y resulte

más eficiente, éste es un sistema utilizado con éxito en Estados Unidos. Un monitoreo similar podría implementarse en los medidores de consumo eléctrico mediante el reemplazo de los medidores analógicos por otros digitales. De este modo, la red estaría constantemente monitoreada y se podrían implementar programas de administración eficiente del suministro y orientación de la demanda.

1.3.1 Modelos heurísticos

Entendemos como modelo heurístico una representación sistemática de un proceso analítico a partir de su conocimiento factual o experiencial y que es efectivo en términos prácticos (útil para la acción). En otras palabras, los modelos heurísticos son representaciones gráficas de un sistema.

En la formación de un modelo contingente se puede combinar lenguajes de diverso tipo, desde lenguaje natural al científico, sin que ninguno de ellos tenga preeminencia sobre el otro. Dada la naturaleza no objetiva de la casualidad heurística estos modelos carecen de capacidad predictiva de los actos que informan.

Los modelos de conocimiento contingentes pueden ser entendidos en primera instancia como la antípoda del modelo racional-determinista. Y esa primera aproximación es útil, pero válida únicamente en el marco del modelo racional.

Los modelos heurísticos-contingentes pueden ser entendidos no como antípoda, sino como otra cosa a costa de intentar entenderlos desde su óptica sistémica. La mayoría de los modelos heurísticos-contingentes constituyen representaciones de problemas que en primera instancia aparecen como problemas complejos.

En todos los casos resulta evidente que no hay descripción casual-objetiva de las relaciones que comprende el problema analítico. Es decir, no hay descripción posible que pueda ser entendida en un sentido casual-objetivo determinista. No se trata de discutir, ni la propiedad de la pregunta ni la posibilidad de hallar alguna forma de hacerla operativa en forma heurística, como tan profusamente se ha hecho en los últimos años; sino que se pueda representar en el marco lógico.

Los modelos heurísticos son una herramienta mediante la cual se pueden solucionar problemas que aparentemente son complejos pero en realidad no lo son, simplemente nos ayuda a tomar decisiones de acuerdo a lo que nos arroje el modelo, en este caso, basado en los inventarios para poder ensamblar un producto a lo largo del proceso. Dichos modelos se plantean a partir del comportamiento de variables inter temporales o series de datos.

1.3.2. La previsión de energía mediante redes neuronales

Debido a las limitaciones de las técnicas clásicas de modelación se realizan intentos por evitar un modelo matemático restrictivo (Wong et al., 2009). La capacidad de las redes neuronales para aprender motiva su elección para la modelación e identificación de sistemas dinámicos complejos.

Las redes neuronales artificiales se componen de elementos que funcionan de forma similar a las funciones más elementales de la neurona biológica, mostrando características del cerebro (Srinivasan et al. 2000).

Cada entrada aplicada representa la salida de otra neurona y se multiplica por un peso, análogo a la fuerza sináptica de la neurona biológica, y todas las entradas pesadas se suman para determinar el nivel de activación de la neurona (figura 7). La señal SUMA es procesada por una función de activación para producir la señal de salida de la neurona, esa función es normalmente la sigmoidea.

Estas redes poseen la capacidad de aprender a través de ejemplos, aun sin conocimiento previo, y pueden aproximar correctamente cualquier función no lineal continua, así como modificar su comportamiento en respuesta al entorno. Dado un conjunto de entradas, pueden auto ajustarse para producir respuestas consistentes (Zhou and Si, 2001). Una vez entrenada, la respuesta de una red puede ser insensible a pequeñas variaciones en su entrada, habilidad que le permite reconocer patrones a pesar del ruido y la distorsión que se producen en un ambiente real, es decir, la red neuronal puede

generalizar automáticamente, como resultado de su estructura y produce salidas correctas partiendo de entradas imperfectas (Ayata et al, 2007).

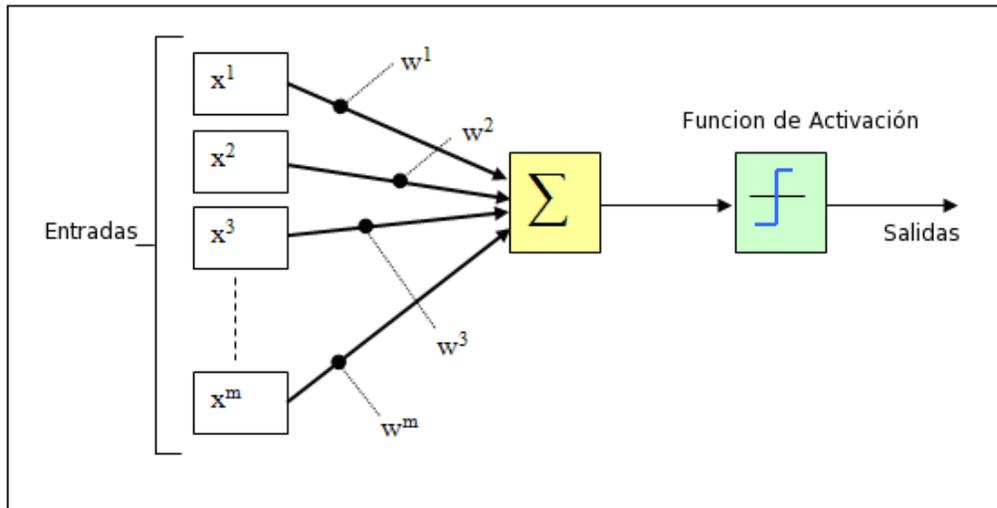


Figura 7. Estructura de la neurona artificial.

1.3.3 La previsión de energía mediante modelos ARX

Un modelo autorregresivo tipo ARX es un modelo discreto lineal en el que la salida en el instante de muestreo n se obtiene a partir de valores pasados de la salida y de la entrada (en $n-1$, $n-2$, etc.).

Los parámetros de un modelo lineal ARX se determinan a partir de valores muestreados con un intervalo de tiempo de la entrada y de la salida. Esta determinación se realiza mediante regresión lineal multivariable, esto es, se determinan los parámetros que minimizan la diferencia cuadrática entre los valores reales y los calculados por el modelo.

En realidad los modelos ARX determinan los valores muestreados de la respuesta de un proceso lineal continuo a una entrada escalonada como la representada en la figura 8. Lo normal es que la variable de entrada no varíe de forma escalonada, aunque, como se aprecia en la figura, si el intervalo de muestreo es suficientemente pequeño la aproximación de la entrada real por una escalonada será buena.

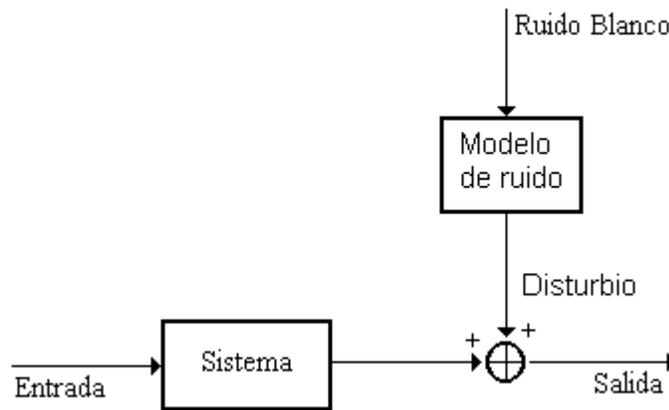


Figura 8. Modelo ARX

Los ARX son modelos matemáticos dinámicos derivados de la teoría de Identificación de Sistemas. Cuando se aplica a la identificación en el espacio de estados se obtiene un nuevo método de identificación que comienza calculando un ARX, basado en el modelo de parametrización completa y las realizaciones equilibradas. De esta manera se consiguen realizaciones de baja sensibilidad y que evitan los problemas de estructura de las realizaciones canónicas (Preminger and Franck, 2007).

ARX es un modelo de entrada-salida, es un modo de describir un sistema dinámico basándose exclusivamente en la relación entre las entradas y salidas del sistema.

Un modelo es estable cuando cumple alguna de las dos condiciones siguientes:

- 1.- Ante una variación puntual en el valor de una variable explicativa, la variable dependiente retorna a su valor de equilibrio.
- 2.- Ante una variación permanente en el valor de una variable explicativa, la variable dependiente evoluciona hacia un nuevo valor de equilibrio.

Se demuestra que para que un modelo dinámico sea estable en las raíces del polinomio deben ser en valores absolutos mayores que la unidad.

Esta condición de estabilidad nos asegura que al pasar del modelo dinámico, la suma de los coeficientes del polinomio es finita, es decir, la serie es convergente. Por lo tanto, el impacto sobre la variable endógena es finito, pasado un tiempo se retorna al equilibrio o bien, se tiende hacia un nuevo equilibrio.

Los modelos autorregresivos pueden describirse, de una forma general, como aquellos en los que una variable se explica, al menos en parte, en función de sus valores pasados. Pueden plantearse como una generalización de un vector de n variables. Estos modelos han cobrado una gran importancia en las últimas décadas en el campo de la econometría y la economía.

Se ha demostrado que modelos sencillos de este tipo, con un pequeño número de variables y parámetros, compiten, incluso con ventaja, en su capacidad de predicción y simulación frente a los grandes modelos macro econométricos que, incluyendo cientos de variables y parámetros, se habían desarrollado en los años cincuenta y sesenta.

Los modelos autorregresivos son modelos que relacionan entre sí varias variables y en los que el valor que toma cada una de ellas en un período de tiempo se relaciona con los valores que toma esa misma variable y todas las demás variables en períodos anteriores.

Las técnicas de series temporales en ARX, desarrolladas originalmente para analizar largas secuencias de datos muestreados regularmente, son totalmente adecuadas para el análisis de previsión. Se discute la utilización de métodos de enfoque en modelos para la detección de defectos y su aislamiento basado en el uso de técnicas de estimación de parámetros de series temporales. Además se explora una serie de tácticas variadas para generación de residuos haciendo uso de la estadística para detectar la presencia de defectos del vector. Estas tácticas suelen clasificarse como paramétricas y no paramétricas. En concreto, tanto los modelos de series temporales como los modelos autorregresivos se enmarcan dentro de la categoría de técnicas paramétricas.

Se han llevado a cabo un gran número de estudios en los que los modelos de series temporales se usan como herramientas auxiliares para la identificación de características dinámicas, usualmente parámetros modales.

1.3.4 La previsión de energía mediante modelos difusos

Los modelos basados en lógica difusa de Zadeh constituyen un conjunto de herramientas de representación o modelización que pertenecen al campo conocido como “soft computing”. La lógica difusa es una técnica para la incorporación del conocimiento estructurado humano en algoritmos eficientes (Pan et al., 2011).

Muchos de los procesos intelectuales humanos están basados en un razonamiento inductivo, cuyo mejor exponente son los razonamientos que lingüísticamente responden a estructuras lógicas del tipo “SI...ENTONCES...”. Se puede argumentar que el conocimiento de reglas conlleva a acciones, toma de decisiones, etc. Una regla de este tipo es una función de múltiples variables que relaciona las variables asociadas al “SI” y denominadas como antecedentes o causas, con las variables asociadas al “ENTONCES”, denominadas consecuentes o efectos.

Una de las características del conocimiento humano es caracterizar las situaciones, elementos, propiedades, etc., mediante términos vagos o difusos. Así, para la mente humana, por ejemplo, un rascacielos no es un edificio de más de 100 metros de altura, sino que es un edificio “muy alto”, pero en esta última idea hay una incertidumbre inherente: ¿Cuál es la frontera entre un edificio muy alto y otro que no lo es? Esta incertidumbre puede ser acotada en términos matemáticos mediante lo que determinamos función de pertenencia, que es la expresión matemática del grado (entre 0 y 1) en que se valora la pertenencia de un elemento a un conjunto determinado por un específico término difuso (en este caso “muy alto”).

La función de pertenencia es una función que asocia a cada elemento (del conjunto difuso) con un valor dentro del intervalo (0,1) y dentro del universo de discurso. Las funciones de pertenencia más usuales son triangular, trapezoidal, gaussiana, sigmoidea

y campana. La figura 9 muestra tres funciones de pertenencia, para otros tantos conjuntos difusos, definidos para un universo en el intervalo (0,20).

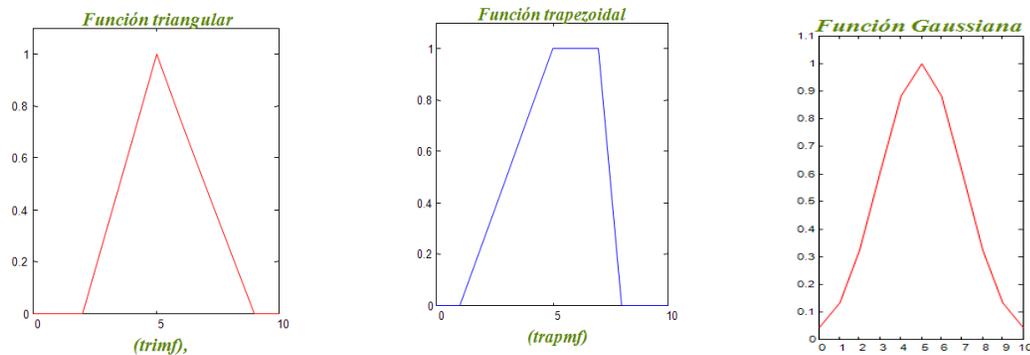


Figura 9. Funciones de pertenencia

1.4. Hipótesis

Es posible modelar el consumo de energía eléctrica a partir del comportamiento de sus cargas, generando análisis de modelos con métodos heurísticos.

1.5. Objetivo

El objetivo general

Realizar un modelo de la energía eléctrica basado en la previsión del consumo eléctrico de energía a partir de sus estimaciones; considerando los cambios tecnológicos como la eficiencia de la electricidad.

Objetivos específicos

1. Obtener una base de datos a partir de un historial del consumo de energía eléctrica.
2. Desarrollar un algoritmo de previsión del consumo eléctrico basado en métodos heurísticos.

3. Desarrollar una estrategia para minimizar el consumo de energía eléctrica, estableciendo prioridades de conexión y desconexión en forma inteligente.

1.6. Justificación

El consumo energético mundial ha crecido de forma continua. En 1890 el consumo de combustibles fósiles alcanzó al de biomasa utilizada en la industria y en los hogares. En 1900, el consumo energético global supuso 0,7 TW ($0,7 \times 10^{12}$ vatios). Durante el siglo veinte se observó un rápido incremento en el uso de los combustibles fósiles que se multiplicaron por veinte. Entre 1980 y 2004, las tasas anuales de crecimiento fueron del 2%. (Chen et al., 2000).

Los sistemas de control del consumo eléctrico por horarios ayudan a los consumidores de energía eléctrica a obtener ahorros económicos hasta de un 20% anual (Jayante et al., 2000), sin considerar las multas.

Al no tener un sistema de control automático del consumo se tienen sanciones económicas que podrían ser resueltas mediante diferentes algoritmos de control como son Relaxed Programming Dinamic (RDP) (Tsair-Fwu et al., 2008), lógica difusa (Chang, 2002), redes neuronales artificiales y PLC`s (Da'na et al., 2006); con todas estas técnicas de control ligadas con la predicción se obtendría un sistema de control en línea.

Actualmente se pagan multas excesivas por cargos en el consumo de energía eléctrica, - impuestos por la compañía suministradora de energía eléctrica -, aparte del consumo mensual de energía eléctrica. Por estas razones se propone desarrollar un sistema de análisis y prevención del consumo de energía eléctrica para edificios, buscando obtener ahorros potenciales en la energía eléctrica total consumida por la subestación.

El consumo de energía eléctrica es una herramienta de particular interés para la generación y operación de sistemas de suministro eléctrico, considerado como una necesidad para todas las actividades. En México tenemos un potencial de ahorro de energía superior al 20%, lo que significa una economía de 100 mil millones de pesos al año. (Abido, 2006).

Son múltiples los factores que influyen en el consumo de energía eléctrica, pero toda la literatura consultada coincide en que existen dos variables claves, que son de uso obligatorio en cualquier modelo de previsión: la temperatura y la laboralidad. Sin embargo, a pesar de que todos los modelos de previsión deben considerar dichas variables, el impacto de las mismas puede ser radicalmente distinto dependiendo de la topología de clientes que se estén modelando (Voorspools, 2004; Omer, 2008; Basaran, et al., 2010).

El consumo de energía eléctrica lo determinan varios factores. Los más importantes son el ritmo de la actividad económica, el crecimiento demográfico, el nivel de desarrollo, las condiciones climáticas y geográficas, la estructura y los niveles tarifarios; además de cambios tecnológicos como la eficiencia de la electricidad en procesos productivos y aparatos eléctricos.

1.6.1. Aspecto ecológico

Aunque México no está obligado por ningún convenio internacional a satisfacer metas cuantitativas en la reducción de emisiones de gases en efecto invernadero, el Gobierno Federal ha trabajado en la definición de metas propias que muestren la voluntad de nuestro país para actuar contra el cambio climático.

La disminución del cambio climático, la estabilización de las concentraciones de CO₂ atmosférico y los altos costos energéticos son cuestiones importantes a tratar en cualquier tema de sustentabilidad. Los expertos suponen que el calentamiento global, a una velocidad de 0.2 grados kelvin por cada 10 años, no representa una amenaza para la biodiversidad y el ecosistema. Un estudio preparado por un grupo intergubernamental de expertos sobre el cambio climático (Watson et al., 2009), pone de manifiesto la necesidad de una estabilización a largo plazo de las concentraciones atmosféricas de CO₂ en 550 partes por millón.

Por lo tanto, para mantener el incremento de la temperatura a este nivel, de acuerdo a los escenarios elaborados por Shing et al. (2007) y Flax (2001), es posible escribir las tendencias de las emisiones de CO₂ que puedan estabilizar dichas

concentraciones en la atmósfera. Ambos informes llegaron a la conclusión de que las emisiones per cápita no deben ser superiores a 1 tonelada anual. En el periodo 2150-2200, con el consumo de combustibles fósiles que representa las emisiones antropogénicas de CO₂, el uso de tecnologías y técnicas de ahorro de energía serán cruciales para ahorrar energía y mantener los niveles de CO₂ recomendados.

Es imprescindible reducir la dependencia que la economía del país tiene en el petróleo y los combustibles fósiles. Es una tarea urgente, según muchos de los estudiosos del ambiente, porque la amenaza del cambio climático global y otros problemas ambientales son muy serios y porque, a medio plazo, no podemos seguir basando nuestra forma de vida en una fuente de energía no renovable que se va agotando.

Además esto lo debemos hacer compatible, por un deber elemental de justicia, con lograr el acceso a una vida más digna para todos los habitantes del mundo.

Para lograr estos objetivos son muy importantes dos cosas:

- Por una parte, aprender a obtener energía, de forma económica y respetuosa con el ambiente, de las fuentes alternativas.
- Pero más importante aún, es aprender a usar eficientemente la energía. Hacerlo significa no emplearla en actividades innecesarias y conseguir hacer las tareas con el mínimo consumo de energía posible. Desarrollar tecnologías y sistemas de vida y trabajo que ahorren energía es lo más importante para lograr un auténtico desarrollo, que se pueda llamar sostenible.

1.6.2. Aspecto económico

Es necesario tomar conciencia que uno de los aspectos de la eficiencia de la economía de cualquier empresa consiste en utilizar adecuadamente la energía eléctrica que se requiere para la operación en su planta o edificio, la que normalmente constituye uno de los costos más significativos en un mercado competitivo y globalizado. Para ello, es necesario realizar un diagnóstico energético a fin de determinar las acciones a realizar, las

que deben sustentarse en un sistema de control adecuado del consumo eléctrico (Kleines, et al., 2004).

A partir del aumento a las tarifas para uso residencial en todo el país (1, 1a, 1b, 1c, 1d y 1e), el 8 de febrero de 2002, se complicó todavía más el “cómo”, porque ahora se aplican de hecho tres tarifas, la que ya existía, otra con aumentos hasta del 80.9 % y la nueva tarifa DAC, doméstica de alto consumo, con enormes aumentos (Comisión Federal de Electricidad, 2010). Sin embargo, ahora es necesario conocer y entender la estructura de esta mezcla de tarifas, precisamente porque nos afecta más que antes.

Un hecho importante es que el sector de edificios en sector público actualmente representa alrededor del 60% del total de consumo bruto de energía, lo anterior provoca que sea necesario enfocarse en el ahorro de energía y en estrategias para impulsar la eficiencia energética, además de nuevos desarrollos y modelos que impacten directamente en el ahorro de energía.

Los principios son los siguientes:

1. Mejoras al diseño en la construcción de las instalaciones, en general, del sector público.
2. Considerar un cambio de actitud en el comportamiento de los ocupantes en las instalaciones.
3. Mejorar la eficiencia en los sistemas de previsión y transporte de energía eléctrica.
4. Generación de energía renovable.
5. Mejorar la gestión de la energía eléctrica en el sector público, partiendo de ahí a lo general.

Los altos costos económicos ecológicos y sociales en materia de energía eléctrica a nivel mundial son patentes, y México no es la excepción; lo anterior ha provocado la búsqueda de nuevas tecnologías y técnicas de modelado para la previsión y ahorro de energía, no solamente en los sectores industrial y comercial sino también en el sector público. En México, el 90% de la energía eléctrica es generada a base de combustibles

fósiles; por esta razón, cualquier esfuerzo que contribuya al ahorro de energía contribuye directamente al cuidado del medio ambiente. La fracción que representa la electricidad, respecto del consumo de energía final, es más alto cuanto más evolucionadas están las sociedades.

En estas circunstancias, es necesaria la producción de energía eléctrica utilizando fuentes energéticas renovables. México consume un promedio anual de 1700 KW/h de energía anuales por persona comparado con los países desarrollados. Es poco, pero según las tendencias mundiales, es bueno para el país mantenerse en un promedio de 2000 kW/h por persona, ya que hacia allá van las tendencias. Mientras las tecnologías de energías renovables y de ahorro de energía no abaraten sus costos, será necesario seguir consumiendo combustibles fósiles, y la idea es buscar métodos que contribuyan al ahorro de energía y al mismo tiempo, motiven a los usuarios a ahorrarla.

El consumo energético mundial ha crecido de forma continua. En 1890 el consumo de combustibles fósiles alcanzó al de biomasa utilizada en la industria y en los hogares. En 1900, el consumo energético global supuso 0,7 TW ($0,7 \times 10^{12}$ vatios). Durante el siglo veinte se observó un rápido incremento en el uso de los combustibles fósiles que se multiplicaron por veinte. Entre 1980 y 2004, las tasas anuales de crecimiento fueron del 2%.(Chen et al., 1990).

Los sistemas de control del consumo eléctrico por horarios ayudan a los consumidores de energía eléctrica a obtener ahorros económicos hasta de un 20% anual (Wei-Fu et al., 2006), sin considerar las multas.

Al no tener un sistema de control automático del consumo se tienen sanciones económicas que podrían ser resueltas mediante diferentes algoritmos de control como son Relaxed Programming Dinamic (RDP) (Tsair-Fwu Lee, et al., 2008), lógica difusa (Chang, 2002), redes neuronales artificiales y PLC's (Da'na, et al., 2006); con todas estas técnicas de control ligadas con la predicción se obtendría un sistema de control en línea.

Actualmente la Facultad de Ingeniería paga multas excesivas por cargos en el consumo de energía eléctrica, impuestos por la compañía suministradora de energía eléctrica, de aproximadamente 47,000 pesos mensuales (figura 10), a parte del consumo mensual de energía eléctrica (figura 12). Por estas razones se propone desarrollar un sistema de análisis y prevención del consumo de energía eléctrica para edificios, buscando obtener ahorros potenciales en la energía eléctrica total consumida por la subestación.

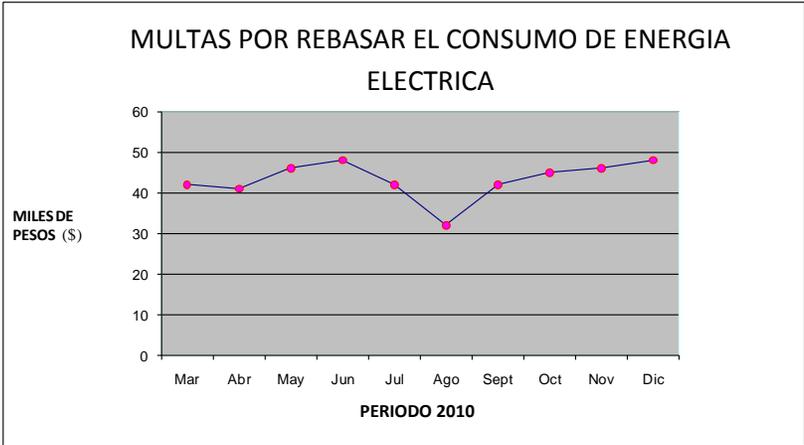


Figura 10. Cargos por consumo de energía eléctrica en la facultad de Ingeniería (UAQ)

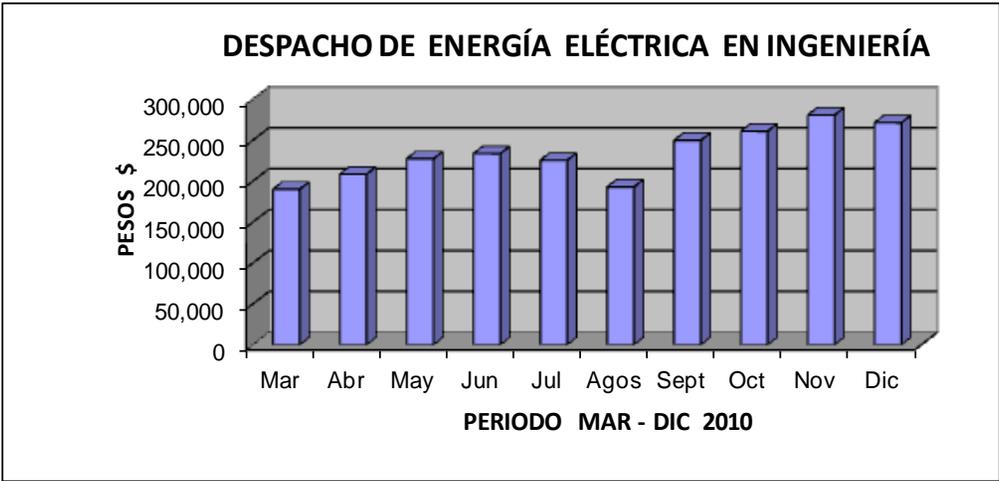


Figura 11. Costo de energía eléctrica en la facultad de Ingeniería (UAQ)

1.6.3. Aspecto social

La energía segura de hoy nos permite acceder a una mejor calidad de vida. Sin ella, no accedemos a ciertas ventajas como:

- Conservar mejor los alimentos, a través de la refrigeración
- Conservación de vacunas y medicinas
- Acceso a mayor información mediante la tecnología
- Productividad en horarios de trabajo no comunes
- Desarrollar investigación.

La abundancia de energía y la falta de conciencia sobre el impacto de su uso en el ambiente, han facilitado por un lado, actividades humanas, comerciales e industriales de consumo intensivo e ineficiente de energía y, por el otro, el crecimiento desordenado de las ciudades, que hoy en día son verdaderas máquinas de consumir de energía, que producen enormes cantidades de residuos y devoran el medio natural. Ahorrar energía y utilizarla más eficientemente implica un cambio de hábitos y actitudes que favorezcan la economía familiar y protejan el entorno natural sin sacrificar o reducir la comodidad y bienestar.

En el aspecto social, contribuir al ahorro de energía eléctrica es contribuir a que las próximas generaciones tengan este servicio; de ahí, los esfuerzos que se han realizado a nivel nacional e internacional en la búsqueda del uso de nuevas tecnologías y técnicas de modelado para el control, ahorro, y administración de la energía eléctrica.

El acceso a la energía permite mejorar las condiciones de vida de los individuos; por ello, surge la importancia del desarrollo de nuevas tecnologías para su correcta administración, distribución, y control.

La electricidad permite alargar las horas de luz (mejoras a la productividad en talleres de artesanías, niños y adultos pueden estudiar tras la puesta del sol, etc.), además de permitir, por ejemplo, conservar medicamentos en neveras en puestos de asistencia técnica.

Por los tres aspectos anteriores, es importante tener un sistema de previsión, control, y administración de la energía eléctrica. Al mismo tiempo, es fundamental conocer los consumos en tiempo real con la capacidad de medir en diferentes equipos y edificios para una mejor gestión de la energía eléctrica.

1.7. Estructura de la tesis

La tesis está organizada de la siguiente forma: en el capítulo 2 se muestra las consideraciones teóricas más reciente, para la implementación de los algoritmos de análisis de energía y los sistemas de previsión basados en métodos heurísticos. El capítulo 3 describe la metodología utilizada para el análisis y previsión de la energía eléctrica. Posteriormente, en el capítulo 4 se muestran los resultados obtenidos del análisis y finalmente, en el capítulo 5 se presentan las conclusiones del trabajo.

II. CONSIDERACIONES TEÓRICAS

2.1 Teoría de las redes neuronales artificiales

Actualmente 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 qué personas entran y salen del mismo), realizar comprensión de datos, videojuegos, aprendizaje artificial y predicciones. Muchas veces se opta por aplicarlas para resolver un problema 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 (Shina et al. 2001). Los modelos de redes neuronales pueden ser aplicados en la ingeniería hacia problemas con naturaleza no lineal, una de las características fundamentales de estos modelos es la velocidad de respuesta para obtener soluciones.

Las ANN son buenas para las tareas que implican conjuntos de datos incompletos, la información confusa o incompleta, y para problema muy complejo y mal definido, donde los seres humanos suelen decidir de forma intuitiva. Ellos pueden aprender de los ejemplos

y son capaces de hacer frente a problemas no lineales. Además, exhiben robustez y tolerancia a fallos. En el aprendizaje de una red se puede determinar que el ajuste de los pesos y las variables de la activación y las funciones de transferencia con el fin de realizar una función deseada (González and Zamarreno, 2005).

Una red neuronal se compone de neuronas interconectadas, como los elementos de procesamiento que tiene características similares a los insumos, la fuerza sináptica, la salida de la activación y el sesgo (figura 12). Las interconexiones entre las neuronas llevan el peso de la red (Gareta et al., 2006). La ventaja de ANN ante otros métodos es su realización en el modelado de los complejos problemas que tienen muchas variables (Wong et al., 2010). Una red backpropagation es la red más popular debido a la capacidad de encontrar soluciones no lineales indefinidas en problemas complejos. Los errores de la salida de una red de backpropagation se propagan hacia atrás a través de las mismas conexiones que se utilizan en el mecanismo de feedforward de la derivación de la función de transferencia hacia adelante.

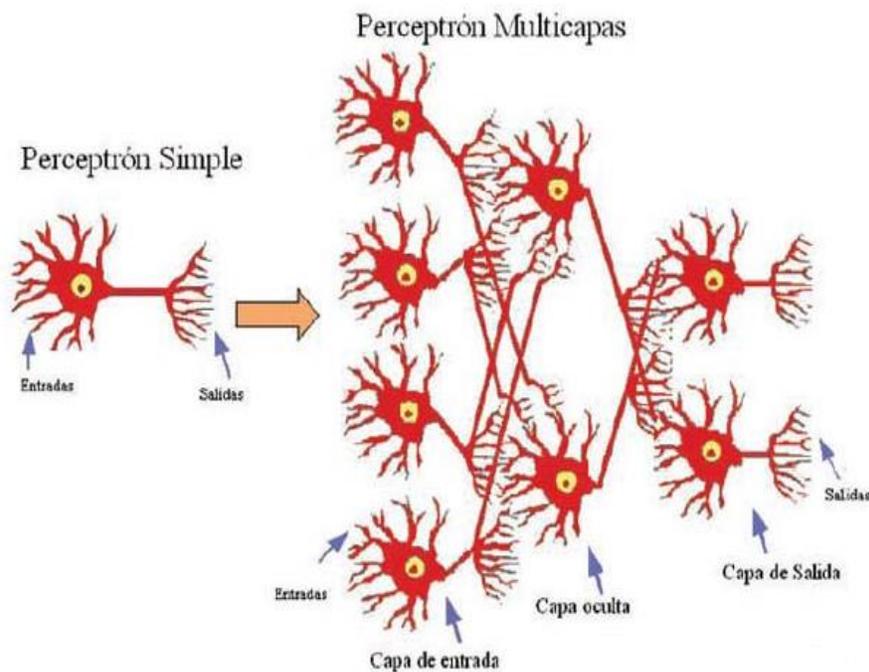


Figura 12. Redes neuronales interconectadas

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, la de salida, suele tener una menor cantidad de neuronas que las de entrada (figura 13). 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.

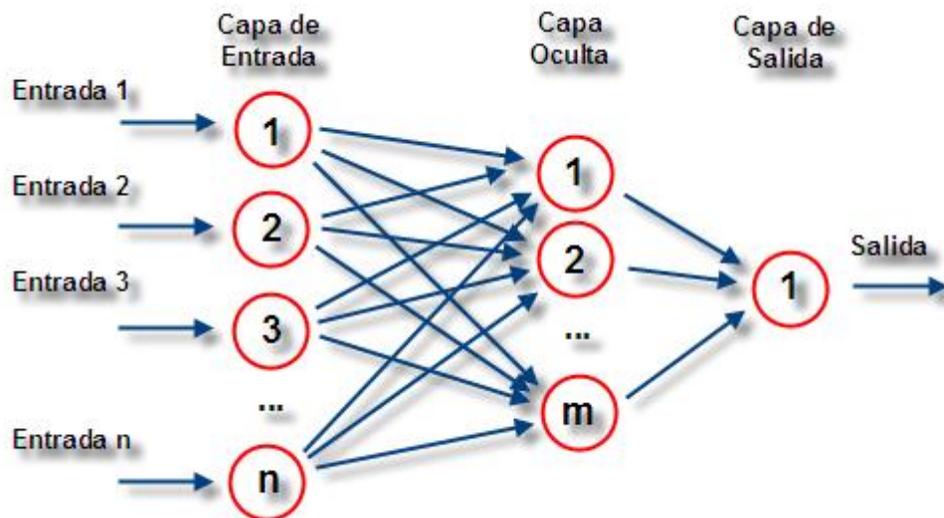


Figura 13. Arquitectura de una red neuronal

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:

$$y_t = \alpha_0 + \sum_{j=1}^n \alpha_j f\left(\sum_{i=1}^m \beta_{ij} y_t + \beta_{0j}\right) + \varepsilon_t \quad (1)$$

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:

$$f(x) = \frac{1}{1 + \exp(-x)} \quad \{\alpha_{i,j} = 0, 1, \dots, n\} \quad (2)$$

Esta función representa a un vector de pesos desde los nodos escondidos hasta los nodos de salida para introducir la no linealidad al modelo. α_0 y β_{0j} son los pesos de los arcos principales de los términos parciales, los cuales tienen valores siempre igual a 1 (Cheng and Titterton 2004; Zhiwei et al., 2007).

Una normalización de los datos es necesaria para evitar que las condiciones de las neuronas sean saturadas. Si las neuronas se saturan, se produce un pequeño cambio en el valor de la entrada que puede ocasionar un error en el valor de salida. Para ello, los datos deben ser normalizados antes de ser presentados a la red neuronal artificial. La normalización comprime el rango de los datos de entrenamiento entre 0 y 1. La normalización es llevada a cabo por medio de la siguiente expresión:

$$X_n = \frac{(x - x_{\min}) * \text{range}}{x_{\max} - x_{\min}} + \text{starting value} \quad (3)$$

Donde X_n es el valor de los datos normalizados, y X_{\min} y X_{\max} son los mínimos y máximos de los datos de todo el conjunto.

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 ANN, son temas de investigación reciente; algunas mejoras del algoritmo de retro propagación son el descenso del gradiente y el algoritmo de Levenberg-Marquardt (Doukas et al. 2007; Wojciech and Piotr, 2005.; Zhou and Si, 2001).

2.2 Teoría de los modelos ARX

Los parámetros para un modelo lineal ARX se determinaron a partir de valores muestreados con un intervalo de tiempo T de la entrada y de la salida. Esta determinación

se realiza mediante regresión lineal multivariable, esto es, se determinan los parámetros a_1 , a_{na} y b_1 que minimizan la diferencia cuadrática entre los valores reales y los calculados por el modelo autorregresivo siguiente:

$$\begin{aligned}
 y_n = & -a_1 y(t-1) - \dots - a_{na} y(t-n_a) + b_1 u(t-1) \\
 & + \dots + b_{nb} u(t-n_b) + \varepsilon(t) + c_1 \varepsilon(t-1) \\
 & + \dots + c_{nc} \varepsilon(t-n_c)
 \end{aligned} \tag{4}$$

También llamada estructura de ecuación del error, donde y = señal de salida, u = señal de entrada, t = tiempo discreto, a_n , b_n , c_n = parámetros del modelo, ε = error y n_a , n_b , n_c = número de polos. La salida en el instante de muestreo t se obtiene a partir de valores pasados de la salida y de la entrada (en $t-1$, $t-n_a$, etc.). La selección de los valores del mejor modelo se obtiene por medio de los procedimientos de estimación (Abhijit et al., 2011). La estructura ARX tiene un sistema que se puede definir por medio del número de polos, número de ceros, y el tiempo de retardo.

Los valores se obtienen mediante el procedimiento de estimación, ingresando los coeficientes como parámetros para determinar el vector θ a estimar:

$$y(t, \theta) = G(z, \theta)u(t) + H(z, \theta)\varepsilon(t) \tag{5}$$

Para evitar el ruido blanco como un error directo en las ecuaciones, los parámetros de ajuste de la estructura ARX serán los siguientes:

$$\theta = [a_1 \ a_2 \ \dots \ a_{na} \ b_1 \ b_2 \ \dots \ b_{na}]^T \tag{6}$$

A menudo la ecuación del modelo ARX (4) se representa como:

$$V(z) y(t) = W(z) u(t-n_k) + \varepsilon(t) \tag{7}$$

Donde las matrices $V(z)$ y $W(z)$ están dadas por:

$$V(z): 1 + a_1 z^{-1} + \dots + a_{na} z^{-na} \tag{8}$$

$$W(z): 1 + b_1 z^{-1} + \dots + a_{n_b} z^{-n_b} \quad (9)$$

El número de entradas se representa por n_u y n_y , el número de salidas, $V(z)$ y $W(z)$, n_y por n_y , n_u y n_u son matrices, respectivamente, los cuales son elementos del polinomio en el operador de desplazamiento z^{-m} (con m como cualquier número natural). Las entradas $a_{ij}(z)$ y $b_{ij}(z)$ de las matrices $V(z)$ y $W(z)$ pueden expresarse como:

$$a_{ij}(z) = \delta_{ij} + a_{1ij} z^{-1} + \dots + a_{n_{aij}} z^{-n_{aij}} \quad (10)$$

$$y \quad b_{ij}(z) = b_{ij} z^{-n_{kij}} + \dots + b_{n_{kij}} z^{-n_{kaij} - n_{kaij} + 1} \quad (11)$$

y z^{-1} es la retroalimentación del operador de desplazamiento

$$z^{-1}u(t) = u(t - 1) \quad (12)$$

2.3 Teoría de los modelos difusos

La identificación de sistemas implica el uso de herramientas matemáticas y algoritmos para construir modelos dinámicos que describan el comportamiento de sistemas del mundo real a partir de los datos medidos. Siempre hay dos requerimientos en conflicto durante el proceso de modelado: la interpretabilidad, es decir, la capacidad del modelo para expresar el comportamiento del sistema real de manera comprensible; y la precisión, entendida como su capacidad para representar con exactitud el sistema real. Obtener altos grados de interpretabilidad y precisión es un objetivo contradictorio en sí mismo y, en la práctica, una de las dos propiedades prevalece sobre la otra.

Los sistemas difusos han demostrado su capacidad destacada como herramientas de modelado. La lógica difusa ha mostrado su habilidad para generar distintos tipos de modelos difusos, con un equilibrio precisión-comprensibilidad diferente y para permitir la incorporación de conocimiento experto humano, así como para integrar el procesamiento numérico y simbólico dentro de un esquema común.

La idea del modelamiento difuso es dividir (partición) los posibles valores de entrada (antecedentes). Los consecuentes pueden ser funciones de pertenencia (Mamdani y sukamoto), valores constantes (Sugeno de orden zero) o funciones lineales (Sugeno). Los diferentes consecuentes resultan en diferentes sistemas de inferencia pero los antecedentes son los mismos.

La figura 14 muestra la estructura general de un sistema de inferencia difusa. El vector de entradas está representado por \vec{x} y corresponde al conjunto de valores numéricos de las variables de entrada del sistema. La primera tarea del sistema es convertir esas variables numéricas de entrada en variables que pueda manipular ese sistema de inferencia difusa. Esta labor la realiza el bloque “fuzzyficador” que calcula los niveles de pertenencia de los valores de entrada a los diferentes conjuntos difusos en los cuales se ha dividido el universo de las diferentes variables de entrada al sistema.



Figura 14. Estructura general del modelo difuso

La base del razonamiento difuso son las reglas del tipo “SI ... ENTONCES ...”. El conjunto de reglas (base de reglas) constituye el conocimiento lingüístico que “tiene” el sistema de inferencia difuso y que le permite resolver el problema. Cada una de las reglas responde a una expresión como la reflejada en la ecuación (13), donde x_1 y x_2 representan dos de las variables de entrada, y representa la variable de salida.

$$\text{IF } x_1 \text{ is } A \text{ and } x_2 \text{ is } B \text{ THEN } y \text{ is } C \quad (13)$$

En la ecuación (13) A, B y C son conjuntos difusos definidos en el universo de discurso de x_1, x_2 e y representados por la etiqueta lingüística correspondiente. A la proposición difusa “ x_1 es A Y x_2 es B ” se le llama antecedente o premisa y a la proposición difusa “ y es C ” se le llama consecuente o conclusión. Una regla expresa un tipo de relación entre A, B y C que se denomina implicación lógica. El bloque agregador manipula los resultados de las distintas reglas para producir un resultado, todavía en términos difusos, que el bloque “defuzzificador” se encarga de convertir en una variable numérica (figura 15).

Existen varios tipos de sistemas de inferencia difusa que difieren, fundamentalmente, en la parte consecuente de las reglas, el método de agregación y la correspondiente “defuzzyficación” posterior. Entre estos sistemas se pueden citar los de Mandini, Takagi-Sugeno y Tsukamoto (Kazemian, 2004). De ellos, el sistema utilizado en los trabajos de investigación reflejados en este documento ha sido el de inferencia difusa de Takagi-Sugeno.

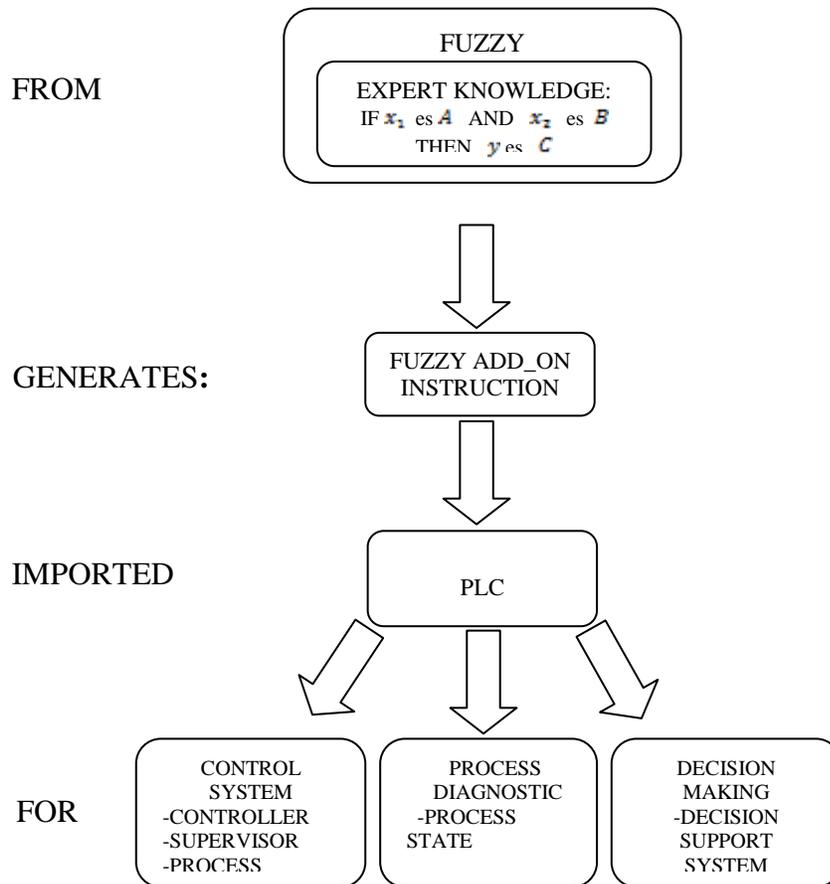


Figura 15. Diagrama de bloques del modelo difuso

III. METODOLOGÍA

En este capítulo se muestran las diferentes estrategias y métodos utilizados para desarrollar la investigación y la descripción del lugar donde se realizaron las mediciones de campo. Se muestran las diferentes pruebas de previsión de consumo eléctrico para la obtención de los resultados, así como las definiciones, notación y fundamentos teóricos necesarios para comprender el estudio presentado. Se consideran los cambios evolutivos de los indicadores de la calidad para el consumo de energía en diferentes etapas de la instalación de las redes eléctricas.

Computadoras, redes, control de la energía y el desarrollo de la tecnología de base de datos han tenido un impacto importante en el aspecto de la calidad y consumo de la energía eléctrica: en las lecturas del medidor de electricidad, en el registro de la energía utilizada por diferentes usuarios, así como la adquisición de datos de energía fiable.

Los avances tecnológicos en redes, comunicaciones, gestión de datos y tecnología de medición se han combinado para reducir significativamente el costo de los sistemas de control de energía (EMS), y para aumentar la capacidad de estos sistemas para incluir la calidad de los datos de la energía.

Las mediciones del consumo de energía eléctrica se deberán realizar por los contadores o medidores de lecturas de consumo de energía. Estos equipos se utilizan para calcular el valor de la energía eléctrica que se intercambia entre los consumidores y las empresas generadoras que proveen la energía para tomar el control de la cantidad de energía que se consume en los sistemas de distribución interior de los edificios e instalaciones en el sector público. Esto debido a que las relaciones monetarias se basan en lecturas de los contadores, durante la producción, venta y uso de estos instrumentos en todos los países sujetos a un estricto control de pesos y medidas.

La energía desarrollada entre dos puntos en el tiempo T_1 y T_2 se determina mediante la integración de contadores o medidores de energía, lo que indica el trabajo eléctrico (W) correspondiente a la energía de forma continua. En consecuencia, la medición de la energía es la medida de la potencia (P) con tiempo de integración simultánea, y un indicador o medidor se implementa mediante un conversor que realiza el producto instantáneo de voltaje y corriente seguido por un dispositivo integrado. Dada la importancia y la extensión mundial de las redes de corriente alterna, el medidor más utilizado hoy en día es el contador de corriente alterna.

Se utilizaron instrumentos tradicionales de medición con circuitos individuales analógicos para medir y calcular los parámetros de energía. Un sistema de control de potencia en la actualidad puede realizar todas las mediciones en un solo chip. Conforme

aumenta el nivel de integración, los indicadores en un futuro serán más pequeños, más capaces y menos costosos.

En Ilyas and Yunis, 2006, se enumeró una lista de los componentes de instalaciones para el sector público, en el que los sistemas de gestión de energía (SAE) son los más importantes. SAE permite al usuario controlar y monitorizar el consumo de energía de una instalación situada de forma local o remota. Para un correcto funcionamiento de un sistema SAE del consumo de energía eléctrica exacto es necesario conocer cómo es su comportamiento (Nguene and Finger, 2007).

3.1 Selección del edificio

El procedimiento para diseñar el modelo de previsión del consumo de energía eléctrica mediante métodos heurísticos se llevó a cabo en el edificio de posgrado de la facultad de ingeniería en la Universidad Autónoma de Querétaro. La estructura cuenta con cinco aulas con una superficie de 40 m² y una sala de juntas con una superficie de 56 m², 1 aula está equipada con un equipo de aire acondicionado marca York Split de 18000 BTU. La estructura del edificio es de un solo nivel de 3 m de altura, con paredes de tabique blanco y techos de concreto, además cuenta con un sistema de predicción de temperatura interior el cual nos permite saber con tiempo de anticipación el comportamiento térmico de la instalación.

Los datos del consumo de energía usados para la formación del modelo, se obtuvieron midiéndolos en la subestación principal de posgrado, en la facultad de ingeniería de la Universidad Autónoma de Querétaro, con un sistema de monitoreo de energía eléctrica (SME) desarrollado en la facultad, y embebido en un servidor web basado en un micro controlador modular que permite comprobar el consumo de energía en tiempo real a través de Internet. Los datos de temperatura y humedad relativa fueron obtenidos del día 25 de Febrero al día 14 de Julio del 2010 con los sensores HOBOWare 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 contar con el día y la hora en que los datos de energía temperatura y humedad relativa fueron obtenidos. Los datos fueron comparados con un analizador de la calidad de la energía de tres fases, el cual cumple con la norma ANSI / ISA S82.01-1994. La Tabla 1 muestra una parte de los datos de monitoreo obtenidos.

Tabla 1. Medición del monitoreo de energía

Title	W Full Total	t	min	prom	max
ID	1	0.00E+00	1.10E+04	1.17E+04	1.44E+04
Type	MinAvgMaxFlagged	9.00E+02	9.71E+03	1.15E+04	1.42E+04
Date	06/16/10	1.80E+03	9.10E+03	9.91E+03	1.22E+04
Time	12:37:40	2.70E+03	7.96E+03	9.44E+03	1.30E+04
X Scale	7.70E+04	3.60E+03	7.96E+03	8.50E+03	1.21E+04
X At 0%	0.00E+00	4.50E+03	7.62E+03	9.10E+03	1.19E+04
X Resolution	8.55E+01	5.40E+03	7.55E+03	8.02E+03	1.02E+04
X Size	855	6.30E+03	7.62E+03	8.23E+03	1.02E+04
X Unit	s	7.20E+03	7.35E+03	7.96E+03	1.05E+04
X Label	76950 s/Div	8.10E+03	7.82E+03	9.10E+03	1.20E+04
Y Scale	2.00E+05	9.00E+03	6.68E+03	7.28E+03	9.64E+03
Y At 50%	0.00E+00	9.90E+03	6.68E+03	8.09E+03	1.19E+04
Y Resolution	2.97E+03	1.08E+04	7.42E+03	8.09E+03	9.98E+03
Y Size	65536	1.17E+04	7.49E+03	8.16E+03	9.51E+03
Y Unit	W	1.26E+04	7.22E+03	8.02E+03	1.02E+04
Y Label	kW	1.35E+04	7.28E+03	8.02E+03	1.02E+04

La figura 16 muestra el edificio donde se obtuvieron los datos de medición, localizado en la Universidad Autónoma de Querétaro, Querétaro, México. La Universidad Autónoma de Querétaro cuenta con 13 facultades, 2 preparatorias y 3 bachilleres, una biblioteca central, 2 edificios de servicios académicos, 1 de Investigación 1 de Posgrado y una unidad deportiva. Con aproximadamente 27, 000 estudiantes, 3,000 docentes y un consumo global de energía en el año 2011 de 335, 698. 56 dólares (departamento de planeación de la Universidad Autónoma de Querétaro).



Figura 16. Posgrado de la facultad de Ingeniería

La localización y la ubicación de las cargas eléctricas en los salones son mostradas en la figura 17 Cada uno de los salones de clases cuenta con 4 lámparas fluorescentes de 2x39 Watts tipo slim-line con balastro electrónico.

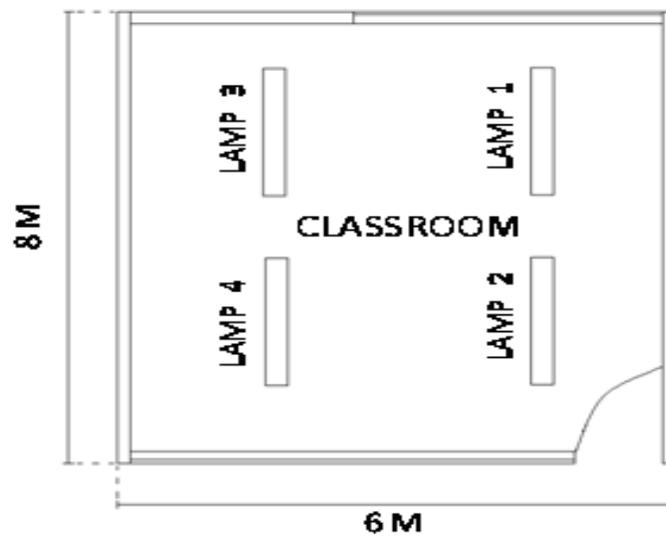


Figura 17. Localización de las cargas eléctricas en salones

3.2 Previsión del consumo de energía eléctrica por medio de Redes Neuronales

Se realizó una propuesta de la estimación del consumo de electricidad en las instalaciones para sectores públicos, por medio de un modelo de red neuronal artificial con

el algoritmo de Levenberg-Marquardt, con el fin de llevar a cabo el control del consumo de energía eléctrica en el sector público. Se realizaron varias ejecuciones o corridas del software se para generar 975 datos para la formación y la validación de la red.

También se trabajó con una serie de redes de diferente peso y con parámetros diferentes de aprendizaje con el objetivo de encontrar el modelo que podría resultar en el mejor rendimiento general. Se utilizó una red neuronal de propagación (perceptron multicapa), con cuatro neuronas en la capa de entrada, cuatro en la capa oculta y una en la salida. La función de activación utilizada en la capa de entrada es al mismo tiempo puramente lineal para las otras capas con una función sigmoidea logarítmica (figura 18).

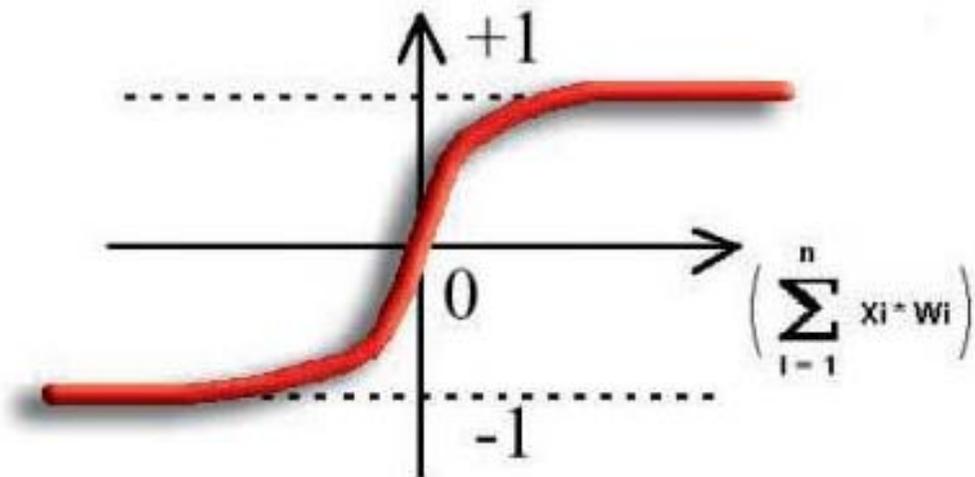


Figura 18. Función sigmoidea de una red neuronal

Con esta arquitectura de la red el mejor promedio de las diferencias absolutas entre los valores medidos y estimados fue seleccionado, expresado como porcentaje de los valores medidos donde su resultado como un porcentaje no depende de aspectos tales como la magnitud de los datos de entrada. El objetivo de una red neuronal es encontrar una configuración óptima de pesos, para que pueda aprender un conjunto de patrones. En consecuencia, la formación se convierte en un problema de programación lineal.

La descripción del algoritmo fue: a) la determinación de variables de entrada y de salida, b) un conjunto de datos que describe la relación entre el modelo de insumo-producto fue agrupada; c) el conjunto de datos se divide en dos partes: una parte se utiliza como un entrenamiento conjunto para determinar los parámetros del clasificador neuronal y la otra parte (llamada prueba de conjunto o conjunto de generalización) se utiliza para estimar el error de generalización. El conjunto de entrenamiento se divide en un subconjunto de validación para el ajuste del modelo: d) un modelo convencional se ha desarrollado para entrenar a la red con el conjunto de datos, e) la relación entre las entradas y salidas de la red neuronal se estima. Estos pasos se repiten para encontrar el número adecuado de nodos ocultos, utilizando diferentes parámetros de entrenamiento para la red 80% de los datos se utilizan para entrenar a la red, otro 10% para el conjunto de validación y el restante 10% para estimar la generalización. Los pesos iniciales se inicializan al azar y una serie de redes son simuladas, cada una por un máximo de 1000 épocas, de los cuales se selecciona la red con un mejor desempeño. En las redes de propagación forward back, el número de neuronas ocultas determina qué tan bien un problema se puede aprender.

La ANN aplicada 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), tiempo (Hr y DIA) y el consumo de energía (KW) con una capa de salida con un solo nodo, como se muestra en la figura 19.

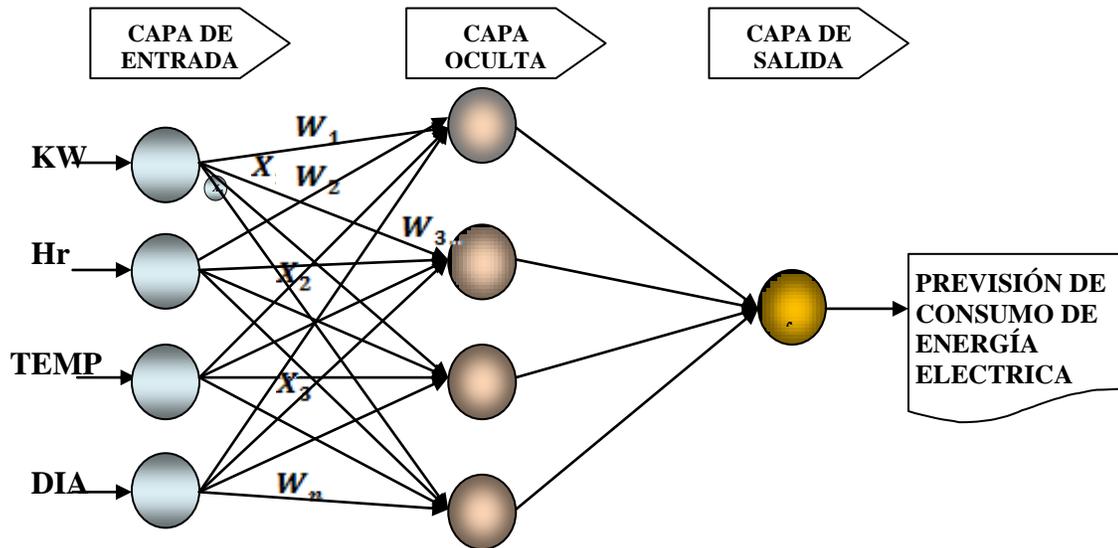


Fig. 19. Red neuronal artificial.

3.3 Estructura de la previsión del consumo de energía en cascada

El consumo de energía eléctrica en el sector público depende en gran medida de las variables de temperatura y humedad para mantener un ambiente de confort y funcionalidad necesaria (iluminación, ventilación, calefacción y enfriamiento). Un modelo de predicción en cascada para la demanda máxima de energía eléctrica fue utilizado basándose en el análisis de la temperatura exterior (T_o), radiación solar (R_a), velocidad del viento (VW) y la humedad relativa (HR_o), teniendo como respuesta de salida la temperatura interna. El tiempo y el consumo de energía en KW se consideran como entradas a la red neuronal artificial. El tiempo es necesario porque hay algunas tareas que deben llevarse a cabo en diferentes horarios, y en consecuencia el consumo de energía (KW) tendrá variación. Una vista general del predictor de la previsión del consumo eléctrico en cascada se presenta en la figura 20.

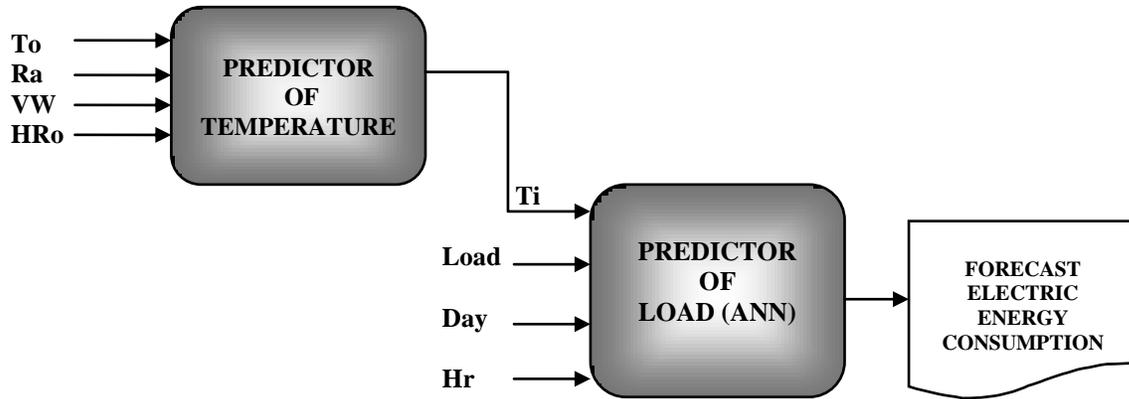


Figura 20. Predictor de previsión del consumo eléctrico en cascada.

3.4 Previsión del consumo de energía eléctrica mediante modelos ARX

Los datos medidos fueron utilizados para obtener los coeficientes en el modelo (ARX) basándose en el análisis de las variables de entrada: temperatura (TEMP), hora (Hr) y día, como variable de salida: el consumo de energía (KW). Una vez que los datos fueron registrados, se dividieron en 2 subgrupos: a) el primer grupo de datos se utilizó para determinar los coeficientes del modelo; b) el grupo restante fue utilizado en la validación del modelo ARX (Ljung, 2000).

Una vez que los coeficientes son calculados, se lleva a cabo una comparación del mejor modelo de predicción con los datos medidos del consumo máximo de energía eléctrica en tiempo real en el edificio de posgrado de la facultad.

a) Los datos de entrada y salida se registran durante un experimento de identificación, donde se determinan las señales a medir y cuándo medir, así como sus restricciones.

b) Un conjunto de modelos candidatos se obtiene mediante su especificación para seleccionar cuidadosamente el más adecuado, combinando las propiedades formales de los modelos con el conocimiento a priori y la intuición de ingeniería (figura 21). A continuación, un modelo con algunos parámetros físicos desconocidos es construido a partir

de las leyes físicas básicas y otras relaciones bien establecidas. Se construye un conjunto modelo para el ajuste de datos, llamado caja negra.

c) Se determinó del mejor modelo en el conjunto, guiado por los datos. Este es el método de identificación. La evaluación de la calidad del modelo generalmente se basa cuando los modelos intentan reproducir los planteamientos básicos de los primeros resultados, tratados de manera independiente a la estructura del modelo utilizado. La evaluación de la calidad se basa a menudo sobre cómo los modelos que tratan de mejorar cuando se trate de reproducir el enfoque básico de la estructura del modelo.

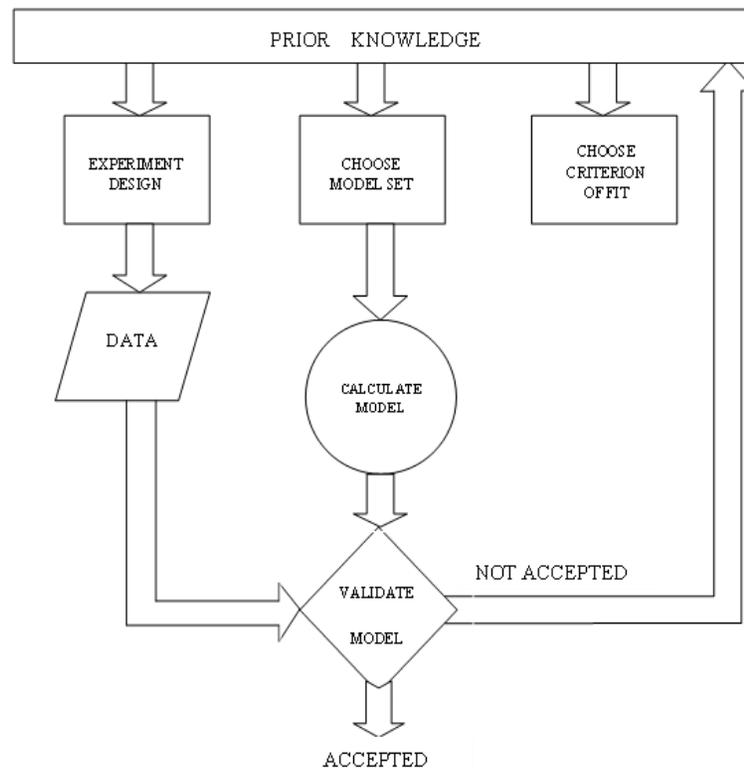


Figura 21. Identificación del sistema ARX

3.5 Mediciones de precisión

La medida de funcionamiento más importante y decisiva en los modelos de previsión del consumo de energía eléctrica es la exactitud de la previsión. Una medida de la exactitud se define a menudo en términos del error de la previsión, que es la diferencia entre el valor medido y el estimado. Hay un número de medidas de exactitud en la literatura de la previsión, y cada uno tiene ventajas y limitaciones (Vandad et al.2009). Entre los más frecuentemente usados están: el error medio cuadrático (MSE) (ecuación 14); el error medio cuadrático de la raíz (RMSE), (ecuación 15); y el error de porcentaje de la media absoluta (MAPE) (ecuación 16).

$$MSE = \frac{\sum(e_t)^2}{N} \quad (14)$$

$$RMSE = \sqrt{MSE} \quad (15)$$

$$MAPE = \frac{1}{N} \sum \left| \frac{e_t}{y_t} \right| \quad (100) \quad (16)$$

Dónde: e_t es el error de predicción individual; y_t es el valor actual; y N es el número de términos del error. La gama de usos de las ANN está aumentando constantemente. Su uso en aplicaciones relacionadas con la administración y manejo de energía comienza a principios de los años 90 y proporciona una exhaustiva descripción de las aplicaciones de las ANN en sistemas de energía renovable y en edificios (Kalogirou, 2000).

IV. RESULTADOS

Fueron generados varios modelos de redes neuronales y ARX, también fueron probados de acuerdo a su rendimiento y estructurados con 975 hrs. Los datos registrados se obtuvieron del consumo de energía eléctrica del día 25 de Febrero al 14 de Julio del 2011.

El error de porcentaje de la media absoluta (MAPE) se utilizó para examinar la calidad de previsión de los modelos con la finalidad de determinar el mejor desempeño de la red neuronal y de ARX. Se calcularon los valores MAPE para cada uno de los modelos y los resultados se muestran en la tabla 2 para los modelos de redes neuronales, y en la tabla 3 para los modelos ARX, donde se visualizan los mejores modelos, su confiabilidad y el mejor rendimiento.

4.1 Modelado con redes neuronales artificiales

El modelo de red neuronal 4-4-1 es el que obtuvo el mejor resultado con un 0.0223 MAPE, 0.9944 R^2 y con 0.0934 SEP en comparación con los resultados de los modelos restantes de la tabla 2.

Tabla 2. Comparación del error estimado para diferentes modelos de redes neuronales en la previsión del consumo de energía eléctrica

Modelo	R^2	MAPE	SEP
4-2-1	0.9721	0.0303	0.1114
4-3-1	0.9308	0.0440	0.1734
4-4-1	0.9944	0.0223	0.0934
4-5-1	0.9718	0.0303	0.1134
4-6-1	0.9703	0.0326	0.1230

4.2 Modelado con ARX

El mejor modelo ARX fue 3,2,1 con un 0.0342 MAPE, 0.9878 R^2 y con 0.1379 SEP, mostrado en la tabla 3.

Tabla 3. Comparación del error estimado para diferentes modelos de ARX en la previsión del consumo de energía eléctrica

Modelo	R²	MAPE	SEP
3,2,1	0.9878	0.0342	0.1379
4,1,0	0.9713	0.0349	0.1167
4,1,2	0.9482	0.0526	0.0806
4,1,3	0.9388	0.0587	0.0876
4,4,2	0.9455	0.0513	0.0834

4.3 Comparación de modelos

La tabla 4 muestra los resultados de los modelos de previsión utilizando los métodos de redes neuronales, de regresión y ARX respecto a los datos medidos, donde se observa el error porcentual absoluto medio (MAPE) de cada modelo que nos indica la previsión más adecuada y con más posibilidad de ser una predicción acertada.

Tabla 4. Comparación de mediciones y valores estimados en modelos de Redes neuronales, regresión no lineal y ARX

HOURS	MEASUREMENT	ANN	ARX	REGRESSION
143	6030.2	5801.88	5949.25	5489.67
143.5	6280.4	6003.26	5893.09	5807.83
144	6660.5	6352.55	5848.51	6009.21
144.5	7800.6	6913.14	6814.97	6358.51
145	8289.8	7928.31	7793.88	6919.10
145.5	8499.9	8313.97	7770.57	7934.26
146	8619.8	8545.87	8746.28	8319.92
146.5	9700.3	8670.03	8726.46	8551.82
...
MAPE error		0.0223	0.0342	0.0973

La figura 22 compara los modelos de red neuronal, regresión y ARX, en cuanto al MAPE, MSE y R^2 . El modelo de previsión con la red neuronal artificial tiene un error menor en comparación con los resultados de los modelos restantes.

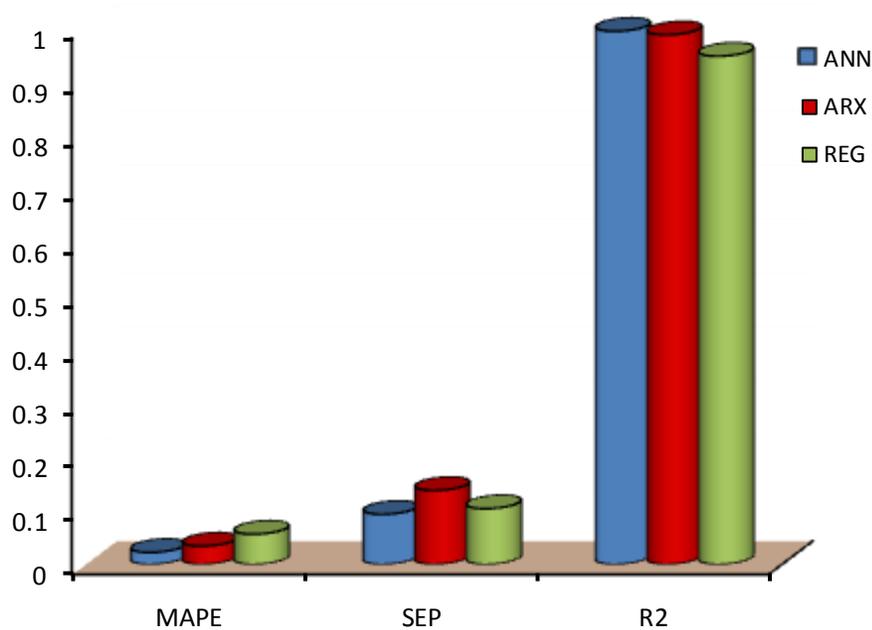


Figura 22. Comparación de error de previsión en los modelos de red neuronal ARX y regresión

4.4 ANOVA de los resultados de los modelos resultantes

Comparando los resultados de la red neuronal con los resultados de la regresión, de ARX y los datos medidos, mediante un análisis de varianza para una estimación de los componentes de variación, mediante 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 5).

Tabla 5. ANOVA comparación de datos entre la regresión no lineal, ARX y la red neuronal

Summary						
Groups	Count		Sum (KW)		Average (KM/h)	
Measured	17		149002.41		8764.84	
Neural networks	17		145468.24		8556.95	
Regression	17		141465.3		8321.48	

Source	Sum square	Degree	Mean square	F	$F_{0.01(2,32)}$	$F_{0.025(2,32)}$
Between groups	1672980.06	2	836490.03	10.27	5.3	4.15
Blocks	98826859.8	16	6176678.74			
Within groups	2605668.59	32	81427.14			
Total (corr.)	103105508					

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.

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

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

Se muestra a continuación el cálculo del ANOVA por medios manuales para comparar los resultados y eliminar el error de significancia (Tabla 6).

Tabla 6. Cálculo de ANOVA por medios manuales

PeriodoM	MedVal	ANNVal	RegVal	arxVal	Tj2	Nj2	Media2	Xij22	Tj2/nj 2		
214	6.03E+03	36382568	5801.88	33661811.5	5489.67	30136476.7	5949.25478	35393632.4	17323.3464		
215	6.28E+03	39472986.4	6003.26183	36039152.6	5807.83	33730889.3	5893.09219	34728535.5	18093.8449		
216	6.66E+03	44321872.5	6352.55975	40355015.4	6009.21	36110604.8	5848.5195	34205180.4	19019.2372		
217	7.80E+03	60792127	6913.14396	47791559.4	6358.51	40430649.4	5814.97285	33813909.2	21068.5846		
218	8.29E+03	68794526.3	8928.31268	79714767.2	6919.1	47873944.8	5793.88899	33569149.6	24141.6593		
219	8.50E+03	72191281.6	8413.97184	70794922.1	7934.26	62952481.7	5770.57777	33299567.8	24844.7771		
220	8.62E+03	74302979.2	8545.87248	73031936.5	8319.92	69221068.8	5746.2837	33019776.4	25485.7101		
221	9.70E+03	94096546.8	9679.03987	93683812.8	8551.82	73133625.3	5726.46524	32792404.1	27931.1973		
222	9.70E+03	94143164.7	9674.43447	93594682.3	8675.99	75272802.5	5709.80899	32601918.7	28053.1645		
223	9.80E+03	96102200.1	9672.78055	93562683.6	9680.39	93709950.6	5698.21215	32469621.7	29156.3435		
224	9.80E+03	96083444.1	9716.29214	94406333	9677.73	93658458	5691.43894	32392477.2	29196.2384		
225	9.78E+03	95662538.5	9677.00102	93644348.7	9722.24	94521950.6	5683.47906	32301934.3	29179.9638		
226	9.71E+03	94253498.5	9698.31313	94057277.6	9682.95	93759520.7	5678.3683	32243866.6	29089.6872		
227	9.67E+03	93548837.9	9760.31868	95263820.8	9684.26	93784891.7	5676.50341	32222691	29116.6435		
228	9.60E+03	92136892.6	9653.89322	93197654.3	9666.27	93436775.7	5678.42216	32244478.2	28918.9596		
229	9.58E+03	91839445.3	9719.36272	94466011.7	9659.84	93312508.8	5684.21966	32310353.2	28962.4926		
230	9.47E+03	89699674.4	9687.80549	93853575.2	9625.31	92646592.6	5693.86725	32420124.3	28784.1067		
suma grupos Tj	149002.41	147898.244	141465.3	141465.3	97737.375	5.36E+05	T (suma total)	(media de totales)	(sum2 total)	438365.957	T (suma total)
no. datos nj	17	17	17	17	17	68	N (total de datos)			68	N (sumtotal datos)
media medij	8764.84782	8699.8967	8321.48824	8321.48824	5749.25735	4226570329	I (sumtotal2/med)			2825951649	I (sumtotal2/med)
suma2 Xij2	1333824584	1321119365	1217693192	1217693192	562029621	4434666762	II (suma2 total)			3872637141	II (suma2 total)
suma grupos Tj2/nj	1305983475	1286699443	1177201830	1177201830	561917321	4331802069	III (sumpos2/med)			2900366732	III (sum2/medtotal)
no. grupos Numgpos	4										
grupos	4										
total datos	17										
Fuente de V.	SumCuad	GradLib	CuadMed	F0							
EntreGpos	105231740	3	35077246.8	59.1821076							
Bloques	74415083	16	4650942.69								
DentroGpo	28449609.4	48	592700.196								
Total	208096433										
medias	Sy1	8764.84782		DMRT							
	Sy2	8699.8967		186.720961							
	Sy3	8321.48824									
	Syi	186.720961									
	r0.05(3,48)	2.79									
	r0.05(16,48)	1.8608									
	R2	520.951482									
	R89	347.450365									
Comparando Diferencia	Referencia										
2 y 3	378.408461	347.450365	2 dist 3								
1 y 3	443.359588	520.951482	1 dist 3								
1 Y 2	64.9511264	347.450365	1 igual a 2	medias iguales							
1 Y 4	3015.59047	520.951482	1 dist 4								
kw	ann	reg	arx								
6.03E+03	5801.88	5489.67	5949.25478								
6.28E+03	6003.26183	5807.83	5893.09219								
6.66E+03	6352.55975	6009.21	5848.5195								
7.80E+03	6913.14396	6358.51	5814.97285								
8.29E+03	8928.31268	6919.1	5793.88899								
8.50E+03	8413.97184	7934.26	5770.57777								
8.62E+03	8545.87248	8319.92	5746.2837								
9.70E+03	9679.03987	8551.82	5726.46524								
9.70E+03	9674.43447	8675.99	5709.80899								
9.80E+03	9672.78055	9680.39	5698.21215								
9.80E+03	9716.29214	9677.73	5691.43894								
9.78E+03	9677.00102	9722.24	5683.47906								
9.71E+03	9698.31313	9682.95	5678.3683								
9.67E+03	9760.31868	9684.26	5676.50341								
9.60E+03	9653.89322	9666.27	5678.42216								
9.58E+03	9719.36272	9659.84	5684.21966								
9.47E+03	9687.80549	9625.31	5693.86725								
Análisis de varianza de un factor con excel											
RESUMEN											
	Grupos	Cuenta	Suma	Promedio	Varianza						
	Columna 1	17	149002.413	8764.84782	1740069.3						
	Columna 2	17	147898.244	8699.8967	2151245.12						
	Columna 3	17	141465.3	8321.48824	2530710.15						
	Columna 4	17	97737.375	5749.25735	7018.70739						
ANÁLISIS DE VARIANZA											
Origen de la varianza de cuadrados de libertad de los cua											
	Entre grupos	105231740	3	35077246.8	21.8242406	F	7.5225E-10	Probabilidad	crítico para F	2.74819091	
	Dentro de lo	102864692	64	1607260.82							
	Total	208096433	67								
el valor calculado es mayor que el valor crítico, existe variación entre Las mediciones de los 2 grupos 21.82>2.74 se rechaza hip nula Ho											
la mayor varianza indica mayor variación											

Tabla F de snedecor para G.L.

P	48	
	TA	PA
A	4.313	40
	TB	PB
B	4.199	50
	4.2218	

Buscar en tablas TA para A y B según el inmediato inferior y superior PA P es el 2do, grado de libertad (2,32)

4.5 Método Duncan para los modelos resultantes

Con el fin de encontrar cuáles medias de los tratamientos de regresión, ARX y ANN están más cerca de los datos reales, se aplica la prueba de rango múltiple de Duncan (DMRT). Para realizar esta prueba, se encuentra la desviación estándar de cada media de los tratamientos, de la siguiente manera:

$$S\bar{x} = \sqrt{\frac{MS(\text{error})}{n_j}} \quad (17)$$

Donde n_j es el número de bloques para los tres tratamientos (medición actual, RNN, ARX y regresión), se puede calcular los valores de estado de R_p como sigue:

$$R_p = r\alpha(p, f)S\bar{x} \quad (18)$$

$r\alpha(p, f)$ Es obtenido de la tabla de la prueba de Duncan. Después de la clasificación de la media de tratamiento, podemos comparar cada tratamiento como sigue:

$$S\bar{x} = 186.7$$

$$r_{0.05}(3,48) = 2.79$$

$$r_{0.05}(16,48) = 1.86$$

$$R_2 = r_{0.05}(2,32) \quad S\bar{x} = 2.79 \times 186.7 = 520.95$$

$$R_2 = r_{0.05}(16,32) \quad S\bar{x} = 1.86 \times 186.7 = 347.45$$

$$\text{Comparing treatments} \quad 1 \text{ y } 3 = 8764.84 - 8321.48 = 443.3$$

$$443.3 > 347.45 \quad \longrightarrow \quad \mu_2 \neq \mu_3$$

$$\text{Comparing treatments} \quad 1 \text{ y } 4 = 8764.84 - 5749.25 = 3015.6$$

$$3015.6 > 520.95 \quad \longrightarrow \quad \mu_2 \neq \mu_3$$

$$\text{Comparing treatments} \quad 1 \text{ y } 2 = 8764.84 - 8699.89 = 64.95$$

$$64.95 < 347.45 \quad \longrightarrow \quad \mu_1 = \mu_2$$

De lo anterior se puede observar que la media del primer tratamiento (datos reales) y el segundo tratamiento (la ANN seleccionada) es igual $\alpha = 0.05$. Estos resultados muestran que el promedio de los valores estimados del consumo de energía eléctrica de la ANN seleccionada y los datos reales son aproximadamente iguales en un 95% de nivel de confianza, superando significativamente a los resultados del tratamiento con la regresión y ARX. Definiendo la hipótesis nula al comparar los dos modelos de previsión, 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, se indica que el consumo de energía estimado para los valores seleccionados del modelo de la red neuronal artificial y los datos medidos son significativamente mejores que los valores obtenidos por el modelo de regresión no lineal y ARX (Figura 23).

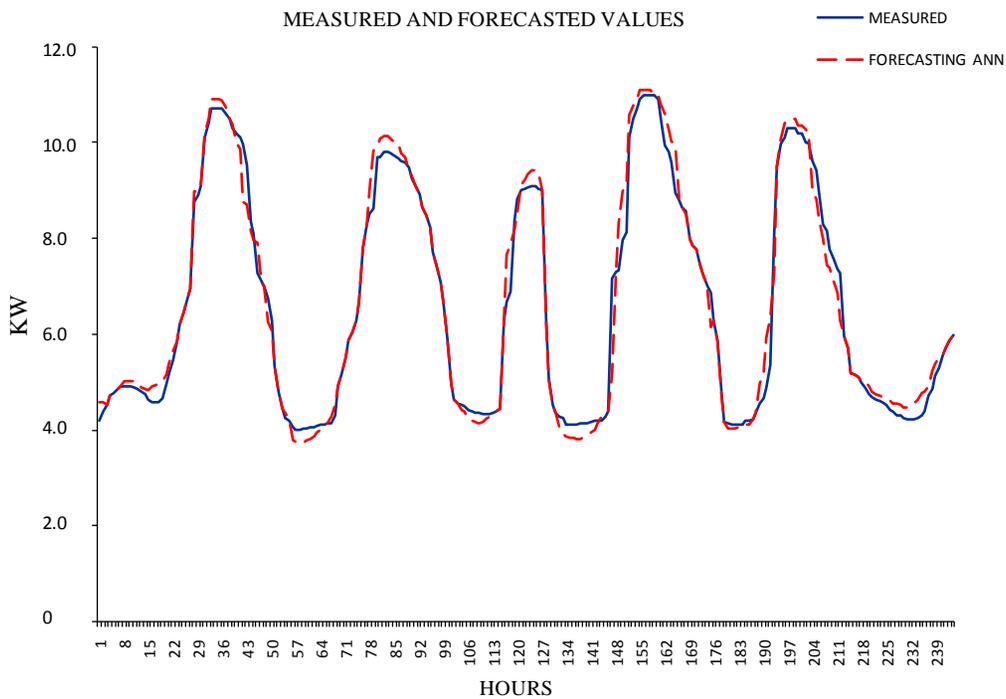


Figura 23. Valores medidos y estimados para el consumo de energía eléctrica

V. CONCLUSIONES

En el presente proyecto se ha desarrollado un modelo de previsión del consumo de energía eléctrica para el sector público, pero con aplicación a todo tipo de actividades (industriales, comerciales, de construcción y de investigación).

Entre las virtudes de esta metodología se encuentra la flexibilidad de los modelos. La idea de agruparlos atendiendo las características que definen a cada uno, permite realizar diferentes comparaciones entre ellos en función de los rasgos que se elijan. De esta manera, es posible obtener los modelos más homogéneos y que permita una previsión con el mínimo de error.

Otra virtud de esta investigación con los diferentes modelos utilizados, es su versatilidad. En el estado del arte se han mencionado las diferentes tipos de metodologías para la previsión como RNA, ARX, Regresión y lógica difusa. Una vez que estos modelos están definidos y calculados, es sencillo cambiar cualquiera de los modelos por otros métodos que se consideren los más adecuados con diferentes variables o utilizar los mismas metodologías con más variables de entrada, pudiendo encontrar una metodología que mejor se ajuste a las particularidades de las series en concreto.

El desarrollo de una nueva metodología para la previsión de la demanda del consumo de energía eléctrica conlleva explorar distintas variantes que pueden añadirse al modelo propuesto, actualizándose y mejorando las debilidades encontradas.

Se considera que la modelización sobre una variable utilizada es claramente necesaria y relevante, dado que su omisión podría acarrear la obtención de conclusiones erróneas sobre los movimientos y resultados en las salidas de los modelos.

La modelización del consumo de energía eléctrica requiere de un programa continuo de análisis de la información y esta debe ser validada con la disciplina que exige la metrología, en la cual las grandes redes eléctricas del mundo han iniciado en este camino de estudio.

La concientización y uso de la información inherentes a la calidad de la energía puede ser de gran beneficio a los procesos productivos, pues será esta una herramienta para proteger a sus equipos y evitar verse afectados en las actividades económicas o de investigación.

Para México es conveniente y necesario iniciar ese camino de investigación, al ser requerido y demandado por los mercados altamente competitivos y de los cuales los procesos industriales de nuestro país no son ajenos.

En esta tesis se han estudiado diversos métodos para el modelado del consumo de energía eléctrica de tiempo discreto usado en modo de previsión buscando una mejor gestión de la energía y por consecuencia, mejorando la calidad del consumo eléctrico. Se ha llevado a cabo planteando inicialmente los problemas a resolver, con una estimación adecuada de los elementos con secuencia temporal para comprimir secuencias simbólicas, así como inferir lenguajes.

Con el fin de evaluar el análisis de la calidad del consumo de energía eléctrica, se consideró el control del consumo de electricidad y la estimación de la demanda a través de la construcción del modelo 4-4-1 en el algoritmo de red neuronal artificial (ANN). Este modelo fue capaz de reproducir los mejores resultados en la predicción de la energía eléctrica, con un error estimado de 0.0223 a los datos medidos.

Se utilizó el método estadístico ANOVA para la estimación de la variación, comparando los resultados del modelo de red neuronal artificial con los datos medidos, con los resultados del modelo de regresión y con los resultados del modelo ARX obteniendo 95% de fiabilidad en los modelos de redes neuronales, la búsqueda de los resultados del modelo más cercano a los valores de los datos medidos para la previsión de consumo de electricidad en el sector público.

VI. REFERENCIAS

Abhijit, S., Sachin, C. and Ravindra D. 2011. Closed-loop identification using direct approach and high order ARX/GOBF-ARX models. *J. of Process Control*. 21: 1056-1071.

Abido, M. A. 2006. Multiobjective evolutionary algorithms for electric power dispatch problem. *Transaction on Evolutionary Computation*. 10: 315-329.

Arditi, D., and Nawakorawit, M. 2000. Issues in building maintenance: property managers' perspective. *Architectural Engineering*, 5: 117-132.

Ayata, T., Yıldız, O. and Arcaklıoğlu, E. 2007. Application of ANN to explore the potential use of natural ventilation in buildings in Turkey. *Applied Thermal Engineering*. 27: 12-20.

Barr, A., Grant, R. F., Arora, V. Black, T. A., Wang, S. and Yuan, F. 2005. Intercomparison of techniques to model high temperature effects on CO₂ and energy exchange in temperate and boreal coniferous forests. *Ecological Modelling*. 188: 217-252.

Basaran, U. F., Omer, G. N., and Kurban, M. 2010. A novel modeling approach for hourly forecasting of long-term electric energy demand. *Energy Conver. and manage*. 52: 199-211.

Brandon, G. and Lewis, A. 2009. Reducing household energy consumption: a qualitative and quantitative field study. *Journal of Experimental Psychology*. 19: 75–85.

Campbell, H., Montero, G., Pérez, A. and Lambert A. 2011. Efficient energy utilization and environmental issues applied to power planning. *Energy Policy*. 39:3630-3637.

Chang, C. S., Liew, A. C. and Srinivasav D. 2002. Applications of fuzzy systems in power systems. *Electric power systems research*. 35: 39-43.

Chen, C. S. and J. T. Leu. 2000. Interruptible load control for Taiwan power company. *IEEE, Transaction on Power System*. 5: 460–465.

Cheng, B., and Titterington, D.M. 2004. Neural networks: A review from a statistical perspective. *Statistical Science*. 9: 2–54.

CFE, Comisión Federal de Electricidad, <<http://www.cfe.gob.mx/ConocerTarifa/acuerdosmodificantarifas/Paginas.aspx> (May 26, 2011).

Da'na, S. A., Sagahyroon, A., Elrayes, A.R., Al-Ali, R. and Al-Aydi. 2006, Development of a monitoring and control platform for PLC-based applications. *Computer Standards & Interfaces*. 30: 157-166.

Doukas, H., Patlitzianas, K. D., Iatropoulos, K., and Psarras, J. 2007. Intelligent building energy management system using rule sets. *Building and Environment*. 42: 3562-3569.

Energy Information Administration. 2009. www.eia.doe.gov, Official Energy Statistics from the U.S. Government.

Flax, B.M. 2001. Intelligent Buildings. *IEEE Communications Magazine*. 29: 24- 27.

Gareta, R., Romero, L. M., and Gil, L. 2006. Forecasting of electricity prices with neural networks. *Energ. Conver. and Manage.*47: 1770-1778.

Godoy, A. and Cruz, M. 2011. Optimal scheduling and self-generation for load management in the Mexican power sector. *Electric Power Syst. Res.* 81: 1357-1362.

González, P. A. and Zamarreno, J. M. 2005. Prediction of hourly energy consumption in buildings based on a feedback artificial neural network. *Energ. and Buildings*. 37: 595–601.

Ilyas, E. and Yunis, T. 2006. Fuzzy logic control to be conventional method. *Energy Conver. and Manage.* 47: 377-394.

Jayante, K. P. and Frederick, C. H. 2000. Advantages of an electrical control and energy management system. *ISA transactions*. 39: 103-114.

Jochem, E., Favrat, D. and Marechal, F. 2005. Energy in the perspective of the sustainable development: The 2000 W society challenge. *Resources, Conservation and Recycling*. 44: 245-262.

Kalogirou, S. A. 2000. Applications of artificial neural networks for energy systems. *Applied Energy*. 67: 17-35.

Kazemian, H. B. 2004. Comparative study of a learning fuzzy PID controller and a self-tuning controller. *ISA Trans.* 40: 245-253.

Kleines, H., Sarkadi, J., Suxdorf, F., and Zvoll, K. 2004. Measurement of real time aspects of simatic operation in the context of physics experiments. *Transaction on nuclear science*. 51: 489-494.

Ljung, L. 2000. *System identification, theory for the user*. Prentice-Hall, Upper Saddle River. 520-537.

Nguene, G. N. and Finger, M. 2007. A fuzzy-based approach for strategic choices in electric energy supply. The case of a Swiss power provider on the eve of electricity market opening. *Eng. Appl. of Artif. Intell.* 20: 37-48.

Nguyen-Vu, T., Wang, L., and Wong, P. K. C. 2008. Modelling and short-term forecasting of daily peak power demand in Victoria using two-dimensional wavelet based SDP models. *Electrical Power and Energy Systems*. 30: 511-518.

Oke, T. R., Spronken-Smith, R.A., Jáuregui, E. and Grimmond, C. S. B. 2000. The energy balance of central Mexico city during the dry season. *Atmospheric environment*. 33: 3919-1939.

Omer, A. M. 2008. Energy, environment and sustainable development. *Renewable and Sustainable Energy Reviews*. 12: 2265 - 2300.

Pan, I., Das, S., and Gupta, A. 2011. Tuning of an optimal fuzzy PID controller with stochastic algorithms for networked control systems with random time delay 2011. *ISA Trans.* 50: 28-36.

Preminger, A., and Franc, R. 2007. Forecasting exchange rates: a robust regression approach. *International journal of Forecasting.* 23: 71-84.

Rempel, E., Harter, F., Velho, H. and Chian, A. 2008. Neural networks in auroral data assimilation. *J. of atmospheric and solar-terrestrial physics.* 70: 1243-1250.

Ruano, A. E., Crispim, E. M., Conceicao, E. M., and Lucio, M. M. 2005. Prediction of building's temperature using neural networks models. *Energy and Buildings.* 38: 682-695.

Seem, J. E. 2006. Using intelligent data analysis to detect abnormal energy consumption in buildings. *Energy and Buildings.* 39:52-58.

Senabre, C., Valero, S., Gabaldón, A., Ortiz, M. and González, M. 2004. Forecasting total electricity demand using spanish self-organized maps as neural network model. *Transaction on Power System.* 1-6.

Shina, S., Kumar, S., Matsumoto, T. and Kojima, T. 2001. Application of system identification modelling to solar hybrid systems for predicting radiation, temperature and load. *Renewable Energy.* 22: 281-286.

SIE 2011. Información estadística, balance de energía eléctrica. Secretaria de Energía México, <http://sie.energia.gob.mx> (Abril 7, 2011).

Singh, T. N. and Sinha, S. and Singh, V. K. 2007. Prediction of thermal conductivity of rock through physico-mechanical properties. *Building and Environment.* 42: 146–155.

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

- Srinivasan, D., Liew, A.C. and Chang, C.S. 2000. A neural network learning short-term load forecaster. *Electric Power Systems Research*. 28: 227–234.
- Tsair-Few, L., Ming, Y., Ying, H., Pei-Ju, C. and Fu-Min, F. 2008. Optimization and implementation of load control scheduler using relaxed dynamic programming for large air conditioner loads. *IEEE, Transaction on power system*. 1: 691-701.
- Vandad, H., Furong, L., and Robinson, R. 2009. Demand response in the UK's domestic sector. *Electric Power Syst. Res.*79: 1722-1726.
- Voorspools, K. 2004. Sustainability of the future; rethinking the fundamentals of energy research. *Renewable and Sustainable Reviews*. 8: 599–608.
- Watson, H., Monteith, W. A., Smith, R. I. and Walmsley, C. 2009. The UK environmental change network. *Biological Conservation*. 142: 2814-2832.
- Wei-Fu, C., Yu-Chi, W. and Chui-Wen, C. 2006. Development of a web based remote load supervision and control system. *International Journal of Electrical Power & Energy Systems*. 28: 401-407.
- Wojciech, G., and Piotr, B. 2005. Heating system control in commercial building with peak demand adjustment. *Electrical Power & Energy System*. 9: 64- 70.
- Wood, G., Newborough, M. 2006. Energy-use information transfer for intelligent homes: Enabling energy conservation with central and local displays. *Energy and Buildings*. 39: 495-503.
- Wong, H. L., and Wang, S. W. 2009. Intelligent building research: review. *Automation in Construction*. 14: 143 – 159.
- Wong, S. L., Wan, K.W., and Lam, N.T. 2010. Artificial neural networks for energy analysis of office buildings with daylighting. *Applied Energy*. 87: 551-557.
- Young-Sub, K., and Kang-Soo, K. 2007. Simplified energy prediction method accounting for part-load performance of chiller. *Building and Environment*. 42: 507-515.

Zhiwei, L., Weiwei, L., Zhijian, H., and Yao, Y. 2007. An innovate air-conditioning load forecasting model based don RBF neural network and combined residual error correction. *International Journal of Refrigeration*. 2: 528-538.

Zhou, G. and Si, J. 2001. Advanced neural network training algorithm with reduced complexity based on Jacobian deficiency. *Transaction of Neural Networks*. 9: 448-453.