

*Universidad Nacional de
Mar del Plata*

Facultad de Ingeniería

PROYECTO FINAL

“Predicción y comparación de la demanda de la energía eléctrica mediante la utilización de redes neuronales artificiales y métodos estadísticos tradicionales”

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

AÑO 2003

AUTORES:

**FEDERICO RAFAEL MARZULLO
CARLOS ANTONIO MANSILLA**

**MATRICULA: 7929
MATRICULA: 7925**

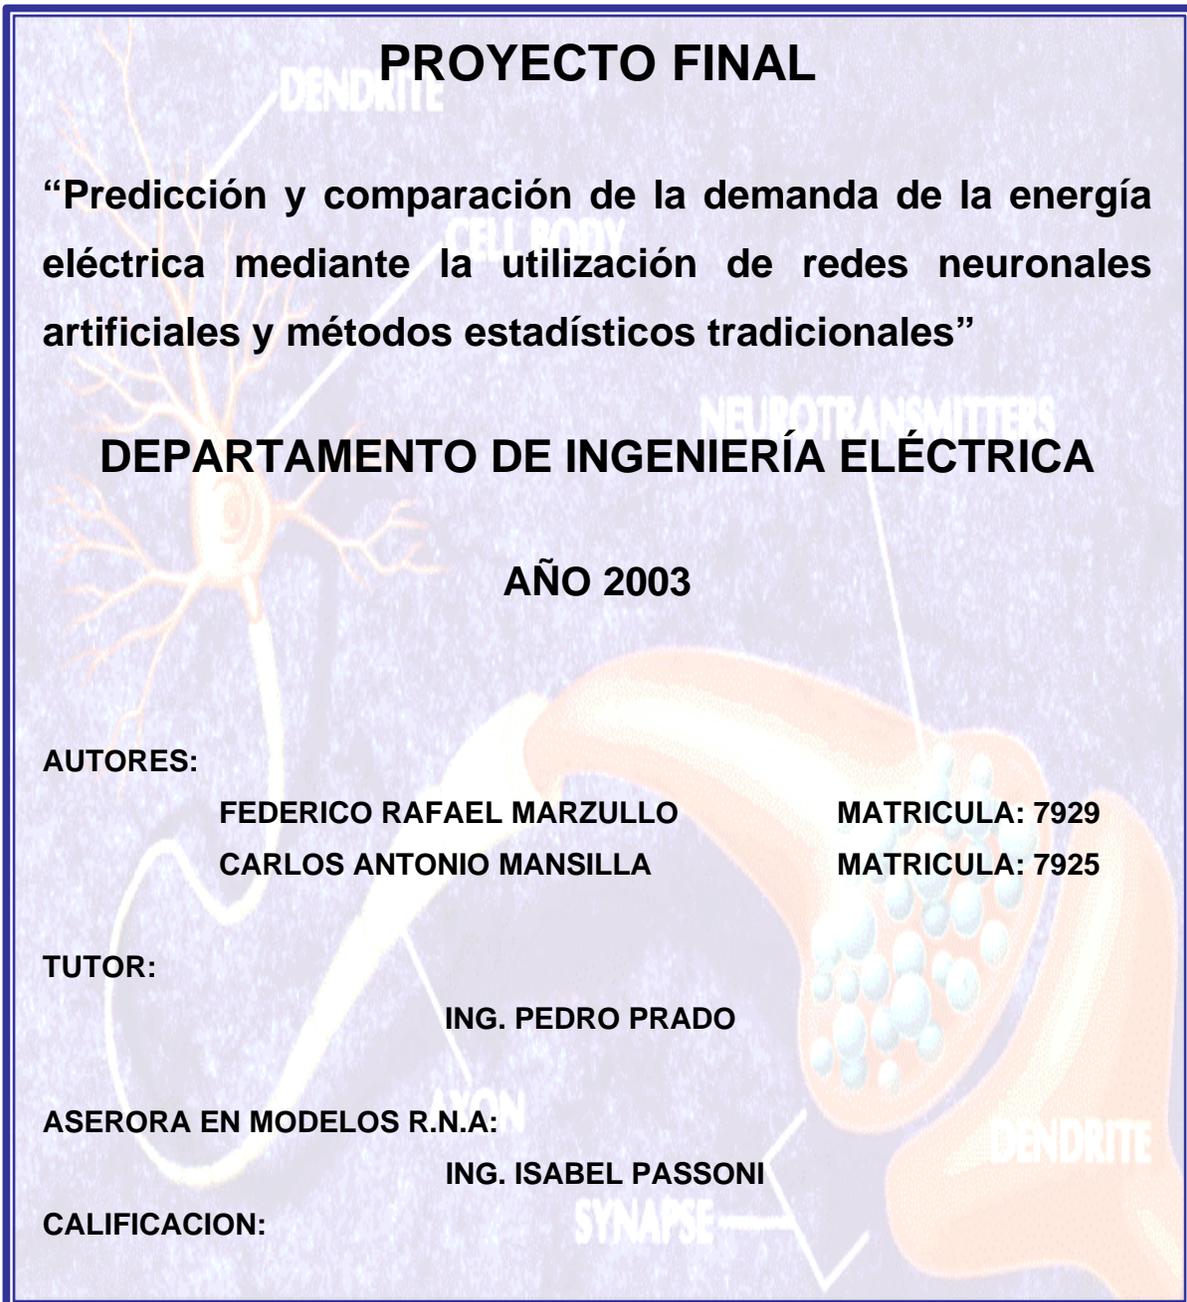
TUTOR:

ING. PEDRO PRADO

ASERORA EN MODELOS R.N.A:

ING. ISABEL PASSONI

CALIFICACION:





RINFI es desarrollado por la Biblioteca de la Facultad de Ingeniería de la Universidad Nacional de Mar del Plata.

Tiene como objetivo recopilar, organizar, gestionar, difundir y preservar documentos digitales en Ingeniería, Ciencia y Tecnología de Materiales y Ciencias Afines.

A través del Acceso Abierto, se pretende aumentar la visibilidad y el impacto de los resultados de la investigación, asumiendo las políticas y cumpliendo con los protocolos y estándares internacionales para la interoperabilidad entre repositorios



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial-CompartirIgual 4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/).



*Universidad Nacional de
Mar del Plata*

Facultad de Ingeniería

PROYECTO FINAL

“Predicción y comparación de la demanda de la energía eléctrica mediante la utilización de redes neuronales artificiales y métodos estadísticos tradicionales”

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

AÑO 2003

AUTORES:

**FEDERICO RAFAEL MARZULLO
CARLOS ANTONIO MANSILLA**

**MATRICULA: 7929
MATRICULA: 7925**

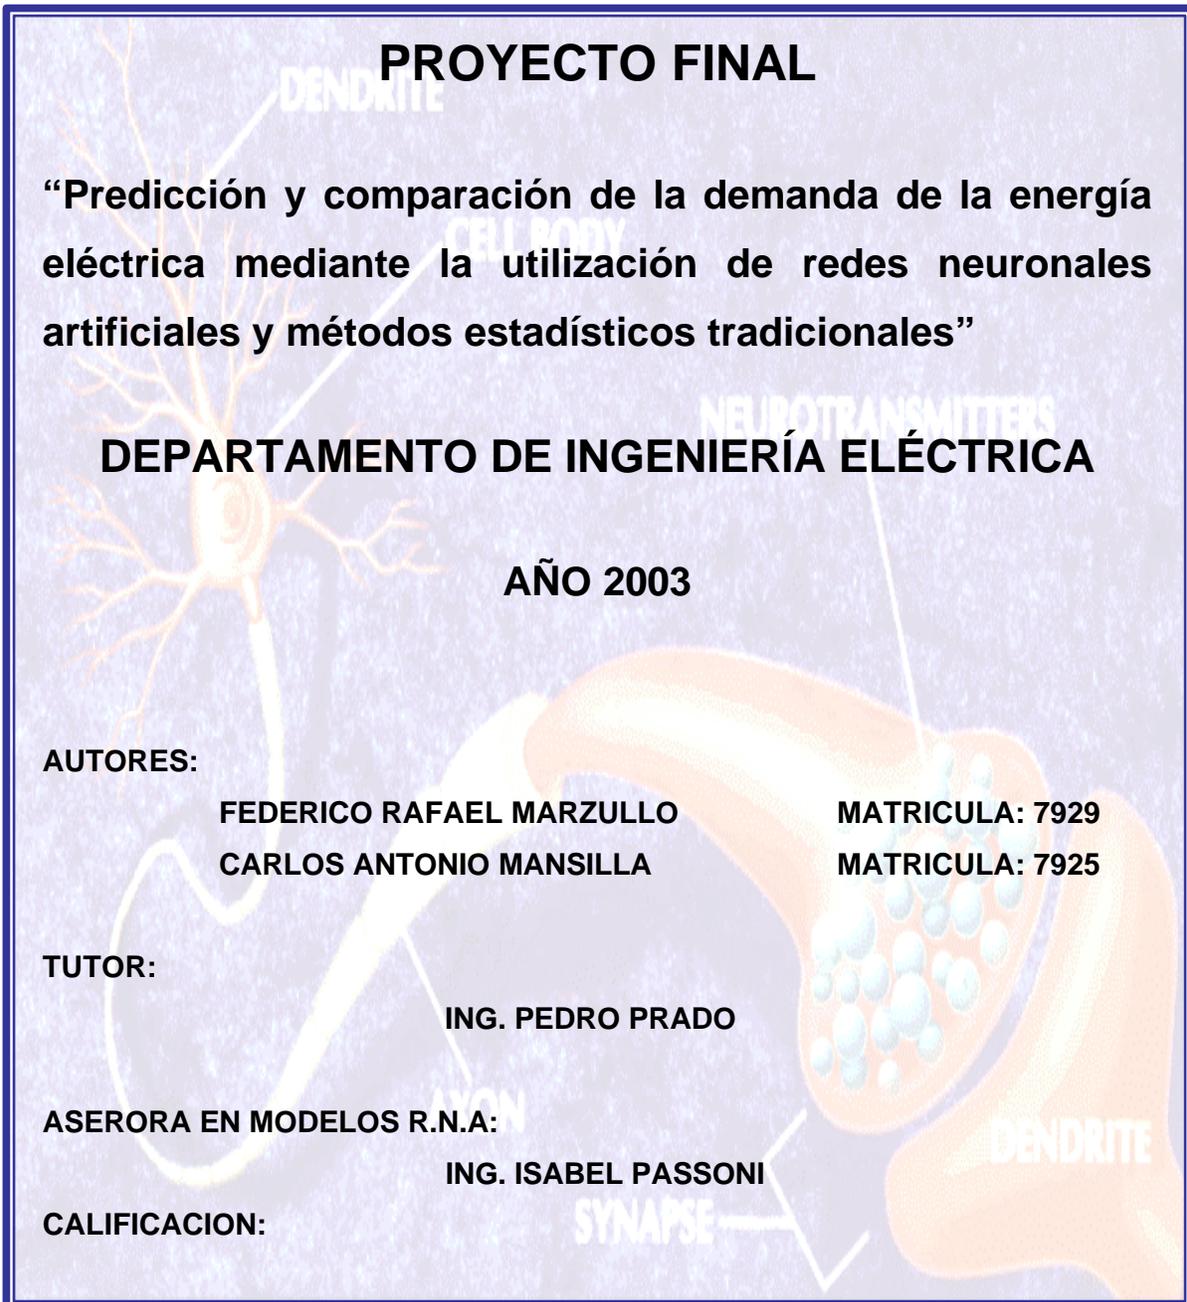
TUTOR:

ING. PEDRO PRADO

ASERORA EN MODELOS R.N.A:

ING. ISABEL PASSONI

CALIFICACION:





*Universidad Nacional de Mar del Plata. Facultad de Ingeniería.
Departamento de Ingeniería Eléctrica.*

PROYECTO FINAL

“Predicción y comparación de la demanda de la energía eléctrica mediante la utilización de redes neuronales artificiales (R.N.A.) y métodos estadísticos tradicionales”

Alumnos: Federico MARZULLO - Carlos MANSILLA

Director: Ing. Pedro O. PRADO

Asesor: Ing. Isabel Passoni (tema: Redes neuronales artificiales)

RESUMEN

El objetivo de este trabajo consistió en realizar un estudio comparativo de dos técnicas predictivas empleadas para el pronóstico de la demanda de energía eléctrica: las redes neuronales artificiales (R.N.A.) y los métodos estadísticos tradicionales.

Las simulaciones y los análisis de las series se realizaron con la información de dos muestras de características económicas, de consumos de energía, de infraestructura y desarrollo, muy distintas: las ciudades de Gral. Madariaga y Pinamar.

El método predictivo tradicional, basado en la descomposición de las series temporales en sus componentes fundamentales y la teoría básica de las redes neuronales se analizaron y se describieron en este trabajo.



Los resultados de las predicciones para el mediano plazo se representaron en un Sistema de Información Geográfica (G.I.S.), se puede observar gráficamente la dinámica de los consumos proyectados para ambas ciudades.

Efectuado el análisis comparativo final con las predicciones para el corto y en el mediano plazo, el modelo de las R.N.A. presentó un error menor y también su dispersión fue menor.

Como conclusión y para las dos muestras consideradas, se demuestra que la técnica predictiva de las redes neuronales artificiales presentó un comportamiento superior frente al modelo tradicional .



Índice

Resumen	2
Agradecimientos	7
objetivos.....	8
introducción.....	8
Horizonte de predicción	9
CAPITULO 1: Análisis de las muestras.	11
Gral. Madariaga	11
Pinamar.....	12
Técnicas de predicción de la demanda.....	13
Series Temporales	13
Selección de variables explicativas.....	14
CAPITULO 2: Técnica Predictiva Tradicional.....	17
Métodos tradicionales	17
Tendencia.....	17
Componente o variación cíclica.....	18
Componente o variación estacional.....	18
Componente o variación irregular.....	18
Descomposición de las series de tiempo	19
Descripción del procedimiento	19
Desarrollo para la ciudad de Gral. Madariaga.....	20
Determinación de la demanda mensual de energía.....	25
Desarrollo para la ciudad de Pinamar	26
Determinación de la demanda anual de energía	31
CIERRE DEL CAPITULO.....	32
CAPITULO 3: Redes Neuronales Artificiales.....	34
Introducción a las Redes Neuronales Artificiales	34



La neurona biológica	34
Historia	36
Modelos Neuronales.....	37
<i>Esquema de un modelo Neuronal</i>	37
Función escalón.....	38
Función lineal:.....	38
Función Logarítmica Sigmoidea.....	39
Función Tangente Sigmoidea	39
Arquitecturas Neuronales.	39
Redes Neuronales monocapas.....	40
Redes Neuronales Multicapa.....	40
Redes Neuronales Recurrentes.....	41
Métodos De Aprendizaje	41
Aprendizaje supervisado.....	41
Aprendizaje no supervisado.....	42
Principales Arquitecturas.....	42
Ventajas de las R.N.A	43
Desventajas de las R.N.A.....	44
Aplicaciones	44
BACKPROPAGATION.....	45
Antecedentes:	45
Regla de Aprendizaje	47
Inconvenientes en el aprendizaje del Backpropagation	49
OVERFITTING	49
REDES NEURONALES COMO MODELOS DE PREDICCIÓN	49
Desarrollo.....	50
PRE- PROCESOS.....	50
Pre-procesamiento de la serie temporal	50
Desestacionalización de la serie temporal	51
Centrado	51
Interpolación por el Método de los splines cúbicos	51
Normalización.....	51
Inicialización de los pesos	52



MODELIZACIÓN DE LA RED PARA LA CIUDAD DE GRAL. MADARIAGA	52
Entrenamiento de la red Perceptrón Multicapa	52
Topología de la red	59
PREDICCIÓN	66
MODELIZACIÓN DE LA RED PARA LA CIUDAD DE PINAMAR	68
Entrenamiento de la red Perceptrón Multicapa	68
Modelización de la red para la ciudad de Pinamar	69
Entrenamiento de la red Perceptrón Multicapa	69
Topología de la red	74
PREDICCIÓN	79
RESUMEN DEL CAPÍTULO	81
CAPÍTULO 4: ANÁLISIS COMPARATIVO.....	84
Evaluación de los Resultados	84
Aplicación a un caso real.....	84
ANÁLISIS de RNA y TÉCNICA TRADICIONAL	86
CAPÍTULO 5: REPRESENTACIÓN DE LOS RESULTADOS	89
CONCLUSIONES	91
Modelo Tradicional.	91
Modelo Neuronal	91
Bibliografía.....	95
Paginas web	95
Anexos.....	96



AGRADECIMIENTOS

Los autores agradecen a nuestras familias, novias y amigos por el tiempo quitado a lo largo de nuestra carrera.

A nuestro director de tesis, Pedro O. Prado y a la Ingeniera Isabel Passoni, por el tiempo dedicado y los aportes realizados en este trabajo.

A el Ingeniero Anaut, por el material bibliográfico cedido.

Al Ing. Luis Mainenti , de COEMA Ltda. Y Ing. Rizzo, de CALP Ltda y al Arquitecto Juan Antonio Chalde, por habernos cedidos la información necesaria para realizar este trabajo.

A nuestros compañeros, con quienes hemos discutido y aprendido diversos temas juntos.

A Dios, por habernos permitido recibirnos.

Mil Gracias a todos, lo que hicieron esto posible.

Federico Marzullo – Carlos Mansilla.

OBJETIVOS

El principal objetivo de esta tesis de grado es analizar y comparar los resultados de las predicciones de la demanda eléctrica, obtenidos mediante la utilización de redes neuronales artificiales (RNA) y métodos estadísticos tradicionales.

Estos estudios serán realizados sobre dos muestras de características distintas, tomadas sobre las ciudades de Gral. Madariaga y Pinamar.

Siendo la ciudad de Gral. Madariaga de características agroganadera y crecimiento vegetativo. En cambio la ciudad de Pinamar, es una localidad turística, la cual muestra un marcado crecimiento en la demanda eléctrica.

Un objetivo complementario consiste en representar los resultados obtenidos a través de la predicción para distintos horizontes en un sistema de información geográfica.

INTRODUCCIÓN

Un componente clave en la planificación de las actividades de una compañía eléctrica es la predicción de la demanda eléctrica.

Se pueden realizar tres tipos de pronósticos:

- ✓ Corto plazo
- ✓ Mediano plazo
- ✓ Largo plazo

Estos pronósticos son de suma importancia, debido a su influencia en la economía de las compañías. El conocimiento de estos pronósticos permite:

- ✓ Compra de energía a otras compañías eléctricas en función de los consumos previstos, evitando el pago de sobrepagos por una mala elección de la potencia requerida.

- ✓ Simulación: El conocimiento de las curvas de demanda permite formular y comprobar cual será el posible estado de la red para dichas demandas.
- ✓ Maniobras en alimentadores y control de interruptores para la transferencia de cargas, teniendo en cuenta el consumo actual y futuro correspondiente a la nueva configuración de la red.
- ✓ Supervisión de la red para comprobar el buen funcionamiento del sistema y conocer si hay posibles elementos utilizados por encima de su valor nominal.
- ✓ Diseño y coordinación de protecciones, en función de la demanda prevista en diferentes puntos de la red.

Los pronósticos, o predicciones, son una herramienta esencial en cualquier proceso de toma de decisiones.

Toda compañía de distribución eléctrica maximizará su eficiencia cuanto mas precisos sean esos pronósticos.

HORIZONTE DE PREDICCIÓN

Debido a las características de las compañías eléctricas de las ciudades en estudio, ambas cooperativas, se tomarán dos horizontes distintos de predicción.

El primero, de corto plazo, será con un horizonte de un año de predicción.

Con esta predicción, las compañías eléctricas pueden estimar sus consumos para realizar los contratos correspondientes con las empresas proveedoras de energía.

El segundo, de mediano plazo, será con un horizonte de cinco años de predicción.

Esta estimación de mediano plazo es útil para la planificación de obras de pequeña y mediana envergadura como construcción de nuevos alimentadores o ampliación de los ya existentes.

Para la mejor comprensión y desarrollo del estudio, el trabajo estará ordenado en cinco capítulos, los cuales se detallan a continuación.



En el *Capítulo 1: Análisis de las Muestras*, se describen las dos ciudades, sus principales actividades económicas y las variables que influyen en la predicción de la demanda eléctrica.

En el *Capítulo 2: Técnica Predictiva Tradicional*, se describen el método predictivo tradicional, basado en la descomposición de las series temporales en sus componentes fundamentales, así como sus ventajas, desventajas y los recursos necesarios.

Capítulo 3: Redes Neuronales Artificiales. En este capítulo, se muestra el origen y la teoría básica de las Redes Neuronales; además se desarrollará la aplicación de estas en el análisis predictivos de series temporales.

En el *Capítulo 4: Análisis de Resultados*, se analizan y comparan los resultados de las distintas alternativas planteadas.

Luego en el *Capítulo 5: Representación Geográfica de los Resultados*, se grafican sobre los mapas de las ciudades los resultados obtenidos de los estudios para los distintos horizontes propuestos.

CAPITULO 1: ANÁLISIS DE LAS MUESTRAS.

En este capítulo, se desarrollará una breve descripción de las dos ciudades, su historia, sus principales actividades económicas. También se dará una introducción a las técnicas de predicción de la demanda eléctrica y las variables que influyen en ella.

GRAL. MADARIAGA

La ciudad de General Juan Madariaga fundada el 1 de mayo de 1907, está ubicada al sudeste de la Pcia. de Buenos Aires y dista 340 Km. de la Capital Federal. El Partido tiene una superficie de 2862,88 Km² (286.288 has.) Limita con los Partidos de Gral. Lavalle, Maipú, Mar Chiquita, Pinamar y Villa Gesell: Los límites son rectas convencionales, salvo la Laguna "Salada Grande", límite natural, que lo divide del Partido de Gral. Lavalle.

Posee 18.278 habitantes, según datos del censo de año 2002 suministrados por el INDEC, de los cuales un 82 % corresponde al casco urbano, aunque, según datos extraoficiales, la población de Gral. Madariaga se estimaría en los 20.000 habitantes, encontrándose en sostenido incremento, a través del crecimiento vegetativo y el aporte de migraciones internas.

Dicha proyección, se sustenta en el fenómeno que se registra en toda esta región (Gral. Madariaga, Pinamar, Villa Gesell y la Costa), debido a atractivos diversos en el campo laboral y empresario, además de gente de la tercera edad que busca lugares turísticos o cercanos como residencia permanente.

Hoy en día, aunque las explotaciones predominantes son la ganadera y la de los grandes montes naturales de tala conocidos desde antiguo por "Montes Grandes", tiene cierta importancia la agricultura. Poco a poco se van aprovechando los terrenos que han sido desmontados, para cultivarlos con sembrados de papa y maíz, alfalfa y cereales, con muy buenas perspectivas para el futuro.

PINAMAR

El Partido de Pinamar está conformado por las Localidades de Montecarlo, Pinamar, Mar de Ostende, Ostende, Valeria del Mar y Cariló. Con sus 22 Kms. de playa, limita al Norte con el Municipio de la Costa, al Oeste con el partido de Gral. Madariaga, al Sur con el Municipio de Villa Gesell y al Este con el Océano Atlántico.

En el año 1908 los belgas Fernando Robette y Agustín Poli llegan al actual partido de Pinamar con la idea de instalar un balneario en la costa, similar al de su lugar natal, Ostende. Así nace un proyecto urbanístico-turístico que contenía avenidas, diagonales, reservas para edificios públicos, estación de ferrocarril, terrenos para cementerio, corralón municipal, y una avenida central proyectándose la concentración de hoteles y edificios turísticos.

Recién hacia el año 1943, un 14 de febrero se inaugura como localidad balnearia Pinamar, y al año siguiente es aprobado por el Poder Ejecutivo Provincial el Plan Director, creación del Arquitecto Jorge Bunge y que fue la guía para construir y urbanizar.

Entre los años 1949 y 1953 se incremento la población, debido a las migraciones de la posguerra. Luego en la década del setenta se produce un desarrollo relevante en la construcción, surgiendo las residencias multifamiliares.

El 1º de julio de 1978, por Ley 9.024 de la Provincia de Buenos Aires, se crea el "Municipio Urbano de Pinamar", tomando parte del territorio perteneciente al partido de Gral. Juan Madariaga.

A partir de la fecha, las localidades de Montecarlo, Pinamar, Mar de Ostende, Ostende, Valeria del Mar y Cariló forman el Municipio de Pinamar, y conforman un Centro Productor de Servicios que están relacionados directa o indirectamente con la actividad turística. Esta última, es la actividad económica más importante del partido de Pinamar, alcanzando su pico máximo en los meses de verano.

El partido de Pinamar, cuenta con una capacidad hotelera de alrededor de 4000 plazas y 22000 módulos habitacionales aproximadamente.

Con esta capacidad habitacional instalada, Pinamar puede recibir un máximo de unas 120000 turistas (datos suministrados por la secretaria de planeación y urbanismo del municipio de Pinamar).

Durante el resto del año, la población estable disminuye notablemente y según datos del INDEC del último censo, la población actual es de 20000 personas.

TÉCNICAS DE PREDICCIÓN DE LA DEMANDA

Los primeros modelos de demanda datan de los años cincuenta, siendo su principal aplicación la predicción de la demanda eléctrica. Desde entonces, se han propuesto una gran variedad de técnicas para predecir la demanda, las cuales se diferencian en tres aspectos fundamentales: la información que se necesita, el modelo matemático que emplean y las herramientas de cálculo que utilizan para estimar los parámetros del modelo.

Los métodos tradicionales de predicción de la demanda, consideran a la demanda como una serie temporal.

Series Temporales

Una serie temporal es una sucesión de observaciones de una variable en distintos momentos del tiempo. Aunque el tiempo es, en realidad, una variable continua, en la práctica se utilizan mediciones en periodos mensuales. En nuestro caso la sucesión de valores de consumo de energía eléctrica.

Básicamente, lo que se pretende con el estudio de las series temporales es el conocimiento de una variable a lo largo del tiempo para, a partir de este conocimiento y bajo el supuesto de que no van a producirse cambios significativos, poder realizar predicciones.

Existen casos en los que la variable observada tiene un patrón de comportamiento fijo. En términos estadísticos estamos ante una serie determinística. Por el contrario hay series que resultan impredecibles. Su pauta de comportamiento no responde a un patrón fijo, por lo que son puramente aleatorias. Un ejemplo típico es la sucesión de números premiados en un sorteo de loterías. Las series que nosotros estudiaremos contienen una componente determinista y una componente aleatoria.

SELECCIÓN DE VARIABLES EXPLICATIVAS

En este trabajo se consideran las variables Producto Bruto Interno (PBI), el crecimiento de la población y el desarrollo histórico de la demanda de energía.

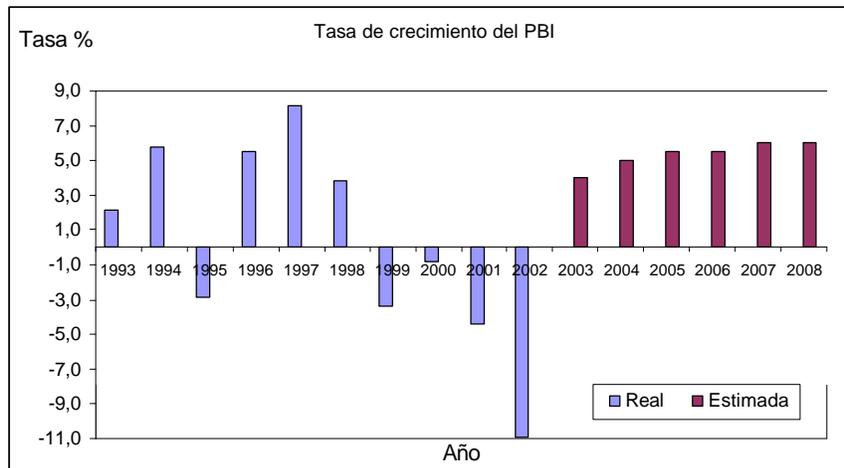
✓ **Producto Bruto Interno (PBI)**

La actividad económica en la Argentina viene de cuatro años de recesión que culminó en el año 2002 con la cesación de pagos de los servicios de la deuda por parte del Gobierno Nacional.

Este hecho sumado a la devaluación del peso frente al dólar, la falta total de crédito y los vaivenes políticos llevaron a la Argentina a la peor crisis en muchas décadas.

Este panorama desalentador cambió radicalmente a mediados del año 2003, ya que la devaluación del peso y la estabilidad política hicieron mas competitivo a varios sectores de la economía Argentina como lo son el Turismo y el sector Agroganadero, ambos de especial interés en esta tesis.

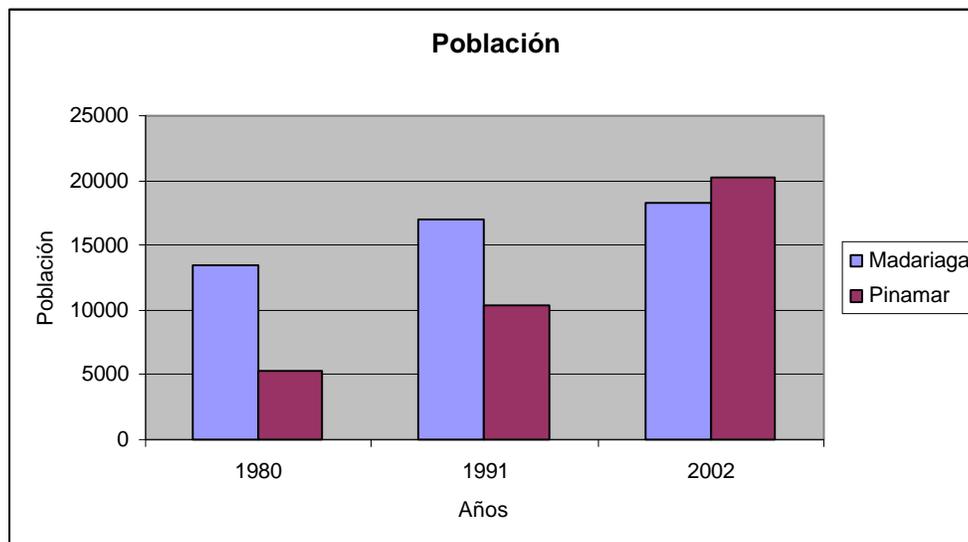
Esto trajo como consecuencia el fin de la recesión económica en la Argentina. El comportamiento del PIB durante 1993 al 2002, junto con los valores estimados para el cálculo de la demanda de energía es mostrado en el siguiente gráfico:



Los datos reales fueron proporcionados por el Instituto de Nacional de Estadísticas y Censo INDEC.

✓ Población

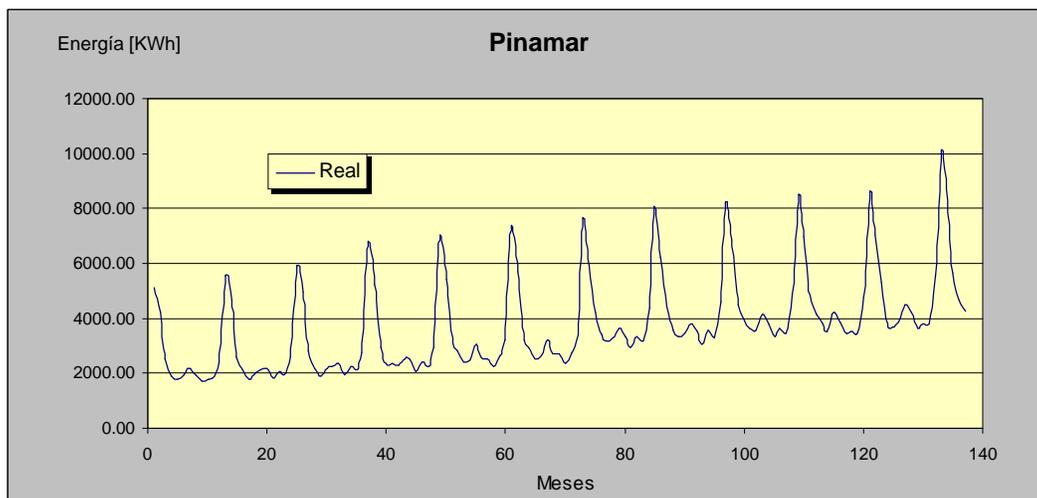
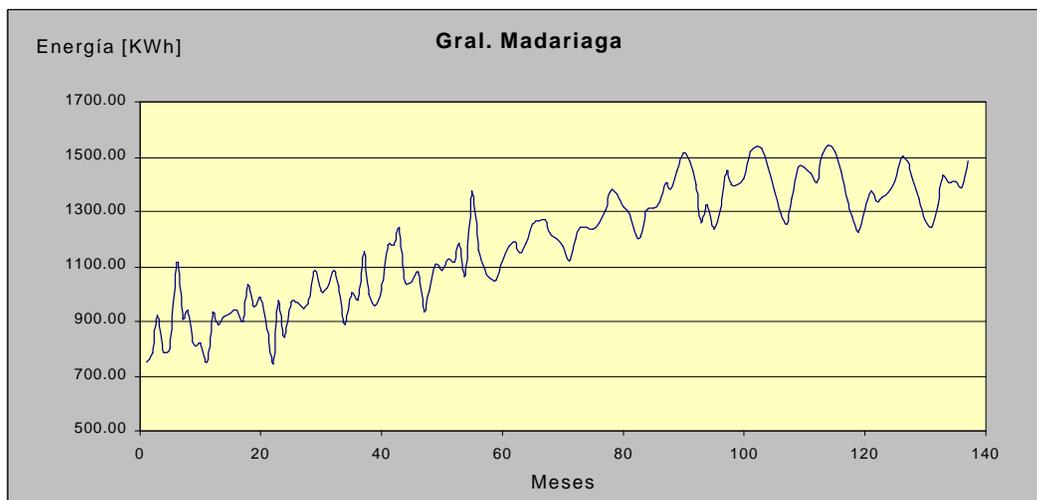
Con respecto al crecimiento poblacional, se consideran como base los tres últimos censos efectuados por el Instituto Nacional de Estadísticas y Censo (INDEC), con lo que se estima la población para los años a ser predicha la demanda de energía.



✓ Demanda de energía^(*)

^(*) Los datos históricos son mostrados en el Anexo II

Históricamente la demanda de energía ha mostrado un comportamiento creciente en la década de los años 90's, pasando de 750.26 MWh en Enero de 1992 a 1377.27 MWh en el mismo mes de 2002 para la ciudad de Madariaga y de 5116,24 MWh a 8594,74 MWh para el mismo período para la ciudad de Pinamar. Sin embargo este crecimiento se ha estancado en los últimos años, debido tal vez a la recesión económica imperante en la Argentina en los últimos años de la década de los años 90's. Las series temporales para ambas ciudades, se muestran en los siguientes gráficos:



CAPITULO 2: TÉCNICA PREDICTIVA TRADICIONAL.

En este capítulo, se describirá el método predictivo tradicional, basado en la descomposición de las series temporales en sus componentes fundamentales, así como sus ventajas, desventajas y los recursos necesarios.

MÉTODOS TRADICIONALES

Hasta el primer cuarto del siglo XX, los métodos de análisis de series temporales se basaban en los modelos de descomposición. Según éstos, las series reales resultan de la agregación de cuatro componentes básicas: tendencia, componente estacional, componente cíclica y componente irregular.

Cada una de estas componentes se estudia por separado mediante el uso de métodos matemáticos.

Tendencia

Dada una serie cronológica definida en un periodo largo, si se prescinde de las variaciones de corto plazo, resulta característica la variación de la serie que pone de manifiesto la modalidad de crecer o decrecer, de acuerdo con una ley simple, llamada tendencia o ley básica de movimiento de la serie. La determinación de la tendencia tiene gran importancia en el estudio del comportamiento de la serie y más aún en la previsión del movimiento futuro del fenómeno, ya que resulta lógico suponer que si no ocurren acontecimientos imprevisibles intensos, la tendencia continuará actuando como una ley permanente del fenómeno, permitiendo, mediante una extrapolación, tener un elemento valioso de previsión del desarrollo futuro del fenómeno.

Existen tres razones por las cuales resulta útil estudiar las tendencias.

- ✓ El estudio de tendencias nos permite describir un patrón histórico.
- ✓ El estudio de tendencias nos permite proyectar patrones pasados, o tendencias, hacia el futuro. El conocimiento del pasado nos puede hablar en gran medida acerca del futuro.

- ✓ En muchas situaciones, el cálculo de la tendencia de una serie temporal nos permite eliminar la componente de tendencia de una serie. Esto facilita el estudio de las otras tres componentes.

Componente o variación cíclica

Se caracteriza por oscilaciones alrededor de la tendencia con una duración aproximada de dos a ocho años. Los movimientos cíclicos no siguen ningún patrón regular, sino que se mueven de una forma un tanto impredecible.

Componente o variación estacional

Este tipo de variación implica patrones de cambio en el lapso de un año que tienden a repetirse anualmente. Las variaciones estacionales provienen generalmente, en economía, de causas climáticas que determinan los ciclos vegetativos, los que, a su vez, influyen en la producción, el consumo, la ocupación y otros factores económicos. Tenemos dos razones principales para el estudio de la variación estacional:

- ✓ Podemos establecer el patrón de cambios pasados. Esto nos da una forma de comparar dos intervalos de tiempo que de otro modo serían bastante disímiles.
- ✓ Es útil proyectar los patrones pasados hacia el futuro. En el caso de decisiones de largo alcance, el análisis de tendencia puede resultar adecuado. Pero para decisiones de corto alcance, la habilidad de predecir fluctuaciones estacionales a menudo es esencial.

Ya que hemos establecido el patrón estacional que existe, podemos eliminar sus efectos de la serie temporal. Este ajuste nos permite calcular la variación cíclica que se lleva a cabo cada año. Cuando eliminamos el efecto de la variación estacional de una serie temporal, hemos desestacionalizado la serie.

Componente o variación irregular

Son movimientos erráticos que no siguen un patrón específico y que obedecen a causas diversas. Este componente es prácticamente impredecible.

En este punto debe hacerse la aclaración de que las herramientas tradicionales de descomposición de series de tiempo realizan una estimación de la tendencia y el ciclo en forma conjunta, es decir se obtiene una descomposición de las series en componente estacional, componente irregular y componente tendencia- ciclo.

Descomposición de las series de tiempo

Para efectos del análisis, la estimación de los componentes no observables de una serie de tiempo cobra relevancia. Por ejemplo, el conocimiento de los movimientos estacionales contribuye a explicar si los cambios que se están observando en una variable, en determinado momento, obedecen efectivamente a aumentos o disminuciones en su nivel medio o bien a fenómenos estacionales.

Adicionalmente, la posibilidad de aislar los factores estacionales permite el estudio de su comportamiento e identificar si son o no estables a lo largo del tiempo. Por otro lado, contar con una estimación de la tendencia de la serie permite efectuar consideraciones acerca del crecimiento de la misma.

DESCRIPCIÓN DEL PROCEDIMIENTO

El procedimiento para describir una serie temporal consiste en tres etapas:

- ✓ Desestacionalización de la serie temporal
- ✓ Desarrollo de la línea de tendencia
- ✓ Búsqueda de la variación cíclica alrededor de la línea de tendencia.

Paso 1: Cálculo de los índices estacionales

Con el fin de medir la variación estacional, usamos el método de razón de promedio móvil. Esta técnica proporciona un índice que describe el grado de variación estacional. El índice está basado en una media de 100, con el grado de estacionalidad medido por las variaciones con respecto a la base.

Paso 2: Desarrollo de la línea de tendencia

El segundo paso en la descripción de las componentes de la serie temporal consiste en desarrollar la línea de tendencia. Para ello se aplicará el método de los mínimos cuadrados a la serie temporal desestacionalizada.

Paso 3: Búsqueda de la variación cíclica

Una vez identificadas las componentes estacional y de tendencia, estaremos en condiciones de encontrar la variación cíclica alrededor de la línea de tendencia. Para hallar esta variación cíclica, utilizaremos el método de los residuos.

Paso 4: Predicción de la serie temporal

En este paso se debe determinar el valor desestacionalizado de consumo de energía mediante el uso de la ecuación de tendencia. Con esto, obtenemos el valor de tendencia desestacionalizado.

Luego, este valor debe ser multiplicado por su correspondiente índice estacional, para de esta manera, obtener el valor estacionalizado de la serie.

DESARROLLO PARA LA CIUDAD DE GRAL. MADARIAGA

A continuación, presentamos los consumos mensuales para la ciudad de Gral. Madariaga desde el año 1992 hasta el año 2001.

Demanda mensual de energía (MWh)						
MES	1992	1993	1994	1995	1996	1997
ENERO	750.26	885.60	970.43	1152.90	1110.54	1173.83
FEBRERO	785.42	916.26	970.84	995.91	1087.82	1190.31
MARZO	923.40	926.36	947.79	955.31	1128.23	1150.20
ABRIL	782.33	938.30	964.44	1015.20	1114.76	1184.28
MAYO	803.08	901.15	1087.82	1179.81	1186.65	1254.27
JUNIO	1116.40	1035.31	1011.27	1178.46	1071.00	1264.16
JULIO	910.47	952.32	1019.03	1238.83	1373.24	1269.17
AGOSTO	939.60	989.50	1085.57	1038.93	1160.10	1221.14
SEPTIEMBRE	812.36	868.39	1029.96	1046.11	1088.94	1199.81
OCTUBRE	819.72	741.72	889.20	1071.36	1059.12	1174.76
NOVIEMBRE	751.58	976.82	1006.32	935.72	1049.40	1121.27
DICIEMBRE	931.50	842.74	982.26	1008.06	1121.27	1202.68

Demanda mensual de energía (MWh)						
MES	1998	1999	2000	2001	2002	2003
ENERO	1242.87	1310.76	1448.31	1464.48	1377.28	1429.24
FEBRERO	1241.04	1333.41	1400.74	1462.34	1336.33	1402.48
MARZO	1235.55	1406.95	1395.66	1438.43	1353.83	1408.87
ABRIL	1261.62	1381.50	1421.57	1403.75	1367.61	1389.02
MAYO	1307.92	1450.86	1521.01	1506.80	1408.84	1487.98
JUNIO	1377.49	1512.90	1535.47	1542.64	1497.39	-
JULIO	1364.11	1485.56	1530.08	1520.94	1484.43	-
AGOSTO	1318.47	1399.09	1462.10	1445.39	1414.02	-
SEPTIEMBRE	1286.64	1256.90	1376.18	1339.76	1346.22	-
OCTUBRE	1214.46	1321.92	1296.03	1281.86	1267.51	-
NOVIEMBRE	1205.94	1238.29	1255.47	1225.81	1239.78	-
DICIEMBRE	1306.26	1304.55	1348.35	1307.50	1323.69	-

Con estos datos y utilizando el método de los promedios móviles, se obtuvieron los índices estacionales para la ciudad de Gral. Madariaga.

MES	Indices	Factor de ajuste	Indices temporales
ENERO	101.18	1.00	101.29
FEBRERO	99.69	1.00	99.80
MARZO	99.48	1.00	99.58
ABRIL	99.90	1.00	100.01
MAYO	105.96	1.00	106.07
JUNIO	108.41	1.00	108.53
JULIO	107.52	1.00	107.63
AGOSTO	103.09	1.00	103.20
SEPTIEMBRE	96.04	1.00	96.15
OCTUBRE	92.16	1.00	92.26
NOVIEMBRE	90.17	1.00	90.27
DICIEMBRE	95.12	1.00	95.22

Con los índices estacionales calculados, podemos encontrar el valor desestacionalizado de la serie temporal. Para ello, se multiplica el valor de consumo real por el valor del índice estacional dividido 100. De esta forma obtenemos la siguiente tabla:

SERIE DESESTACIONALIZADA						
MES	1992	1993	1994	1995	1996	1997
ENERO	740.69	874.30	958.05	1138.19	1096.37	1158.85
FEBRERO	787.02	918.13	972.82	997.95	1090.04	1192.74
MARZO	927.27	930.24	951.76	959.31	1132.95	1155.02
ABRIL	782.28	938.24	964.38	1015.14	1114.70	1184.21
MAYO	757.09	849.54	1025.53	1112.25	1118.70	1182.45
JUNIO	1028.65	953.94	931.79	1085.83	986.82	1164.80
JULIO	845.92	884.79	946.78	1150.99	1275.87	1179.18
AGOSTO	910.49	958.84	1051.94	1006.74	1124.15	1183.31
SEPTIEMBRE	844.93	903.20	1071.25	1088.04	1132.60	1247.91
OCTUBRE	888.50	803.95	963.81	1161.26	1147.99	1273.33
NOVIEMBRE	832.63	1082.16	1114.83	1036.62	1162.56	1242.18
DICIEMBRE	978.28	885.06	1031.59	1058.68	1177.58	1263.08

SERIE DESESTACIONALIZADA						
MES	1998	1999	2000	2001	2002	2003
ENERO	1227.01	1294.03	1429.83	1445.79	1359.70	1411.00
FEBRERO	1243.57	1336.14	1403.60	1465.32	1339.06	1405.34
MARZO	1240.73	1412.84	1401.50	1444.46	1359.50	1414.78
ABRIL	1261.55	1381.42	1421.49	1403.67	1367.53	1388.94
MAYO	1233.02	1367.78	1433.91	1420.51	1328.16	1402.77
JUNIO	1269.22	1393.99	1414.79	1421.39	1379.70	-
JULIO	1267.39	1380.23	1421.59	1413.10	1379.18	-
AGOSTO	1277.62	1355.74	1416.79	1400.60	1370.21	-
SEPTIEMBRE	1338.22	1307.28	1431.35	1393.47	1400.19	-
OCTUBRE	1316.36	1432.84	1404.78	1389.42	1373.86	-
NOVIEMBRE	1335.98	1371.82	1390.86	1358.00	1373.47	-
DICIEMBRE	1371.86	1370.07	1416.07	1373.17	1390.17	-

Desarrollaremos ahora la línea de tendencia, para lo cual aplicaremos el método de los mínimos cuadrados a la serie temporal desestacionalizada. La ecuación de la recta de tendencia queda de la siguiente forma:

$$Y = 4.76 \times X + 862.97$$

Una vez identificadas la componente estacional y la línea de tendencia, estamos en condiciones de encontrar la variación cíclica alrededor de la línea de tendencia. Para ello, tomamos el promedio móvil centrado de 12 meses. De esta forma se obtiene la siguiente tabla:

Variacion cíclica (MWh)						
MES	1992	1993	1994	1995	1996	1997
ENERO	-	-25.75	12.85	94.71	6.88	-15.15
FEBRERO	-	15.85	22.66	-61.27	-9.40	26.63
MARZO	-	24.36	-6.97	-96.47	23.49	-15.79
ABRIL	-	27.42	-8.23	-42.46	1.60	3.70
MAYO	-	-57.69	39.91	37.41	6.94	-8.24
JUNIO	-	29.18	-57.60	18.06	-135.26	-32.06
JULIO	-16.87	-34.09	-54.53	80.78	142.61	-24.80
AGOSTO	38.03	35.49	36.30	-59.91	-13.29	-26.36
SEPTIEMBRE	-40.71	-26.80	53.51	14.00	-13.36	32.89
OCTUBRE	3.93	-131.85	-55.27	72.08	0.06	50.66
NOVIEMBRE	-66.50	155.67	92.30	-59.96	8.77	13.82
DICIEMBRE	73.32	-64.43	1.46	-38.69	18.37	30.08

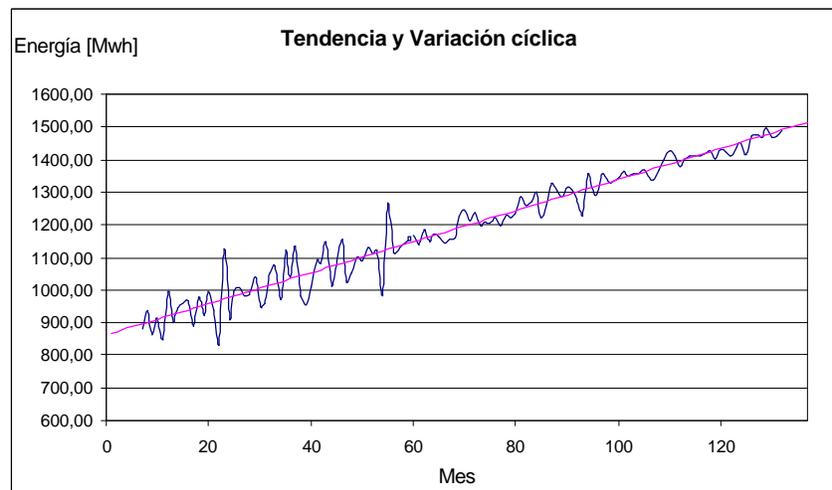
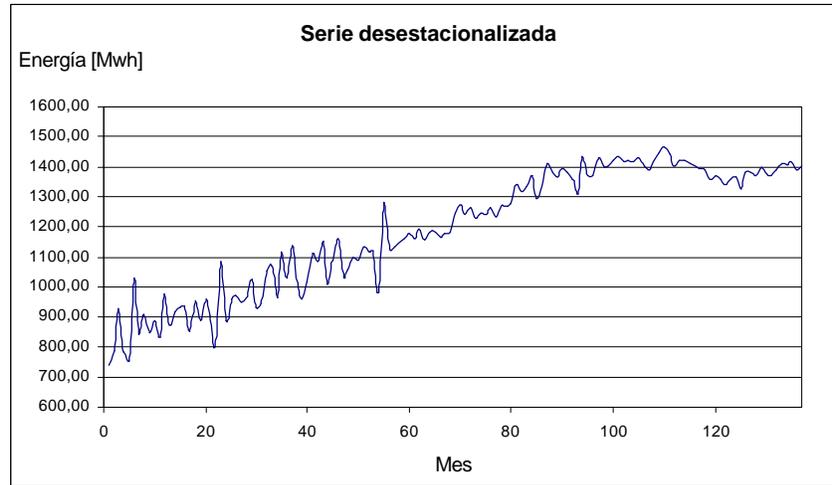
Variación cíclica (MWh)						
MES	1998	1999	2000	2001	2002	2003
ENERO	-13,76	-46,61	32,07	19,01	-15,43	-
FEBRERO	-4,85	-15,79	3,94	38,77	-34,16	-
MARZO	-15,31	50,04	-2,93	19,84	-9,95	-
ABRIL	-2,27	22,97	6,07	-17,03	-1,94	-
MAYO	-33,31	0,95	20,18	0,72	-42,46	-
JUNIO	-5,69	22,82	0,39	4,18	11,13	-
JULIO	-16,05	10,04	3,16	-0,54	9,13	-
AGOSTO	-11,65	-23,78	-2,62	-5,89	-5,00	-
SEPTIEMBRE	39,26	-74,74	6,43	-2,46	21,16	-
OCTUBRE	4,47	44,68	-22,43	0,69	-11,91	-
NOVIEMBRE	13,63	-16,16	-34,53	-28,60	-14,28	-
DICIEMBRE	36,82	-22,99	-9,21	-5,05	-3,12	-

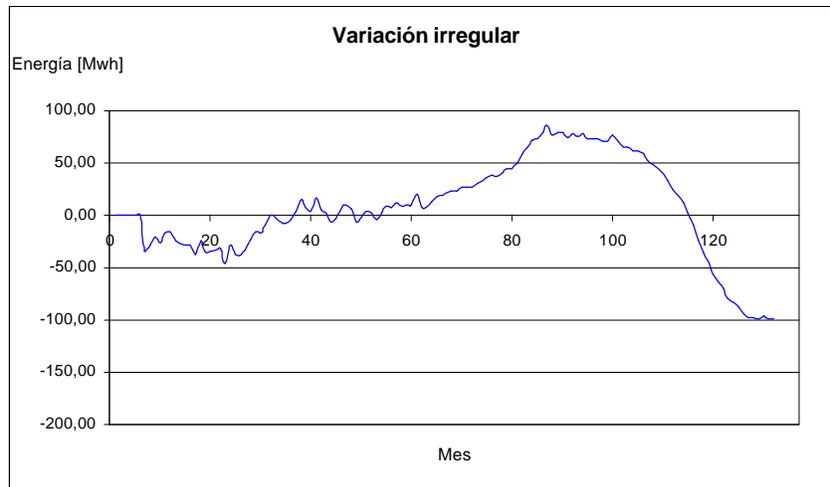
Ya hemos identificado tres de las cuatro componentes en que hemos dividido la serie temporal, por lo tanto solo falta encontrar la componente irregular o aleatoria de la serie. A continuación, se muestra en una tabla, los valores correspondientes a dicha componente.

Variación Irregular (MWh)						
MES	1992	1993	1994	1995	1996	1997
ENERO	.	-24.82	-36.80	4.35	-6.77	20.59
FEBRERO	-	-27.34	-36.59	15.32	-1.59	7.95
MARZO	-	-28.51	-32.79	7.13	3.67	7.88
ABRIL	-	-28.32	-23.67	4.19	2.54	12.82
MAYO	-	-36.67	-15.42	16.66	-3.56	18.24
JUNIO	-	-23.91	-16.42	4.83	2.00	19.65
JULIO	-33.51	-34.55	-9.25	2.51	8.42	22.01
AGOSTO	-28.60	-34.84	0.31	-5.82	7.84	22.93
SEPTIEMBRE	-20.18	-32.96	-2.36	-3.18	11.60	23.52
OCTUBRE	-26.01	-31.91	-5.77	7.20	8.81	26.42
NOVIEMBRE	-16.22	-45.99	-7.08	9.83	9.91	27.35
DICIEMBRE	-15.15	-27.75	-4.24	5.86	10.57	27.23

Variación Irregular (MWh)						
MES	1998	1999	2000	2001	2002	2003
ENERO	30.24	72.97	72.95	44.83	-63.95	-
FEBRERO	33.12	79.49	70.10	39.85	-70.62	-
MARZO	35.98	85.61	70.11	33.15	-79.15	-
ABRIL	39.00	76.49	76.33	24.48	-83.89	-
MAYO	36.75	80.11	69.88	18.80	-87.50	-
JUNIO	40.57	79.69	65.79	11.46	-94.31	-
JULIO	44.33	73.94	65.06	3.13	-97.60	-
AGOSTO	45.40	78.52	61.28	-8.78	-97.20	-
SEPTIEMBRE	50.33	76.26	62.02	-24.10	-98.14	-
OCTUBRE	58.51	77.64	59.55	-36.06	-96.15	-
NOVIEMBRE	64.20	72.69	52.96	-42.96	-98.93	-
DICIEMBRE	72.13	73.01	48.10	-56.10	-98.16	-

Ya hemos calculado las cuatro componentes de la serie, por lo tanto procedemos a mostrar las gráficas correspondientes.





Determinación de la demanda mensual de energía

Vamos a estimar ahora la demanda de energía para los próximos *cinco años* para la ciudad de General Madariaga, a partir de las componentes antes expuestas.

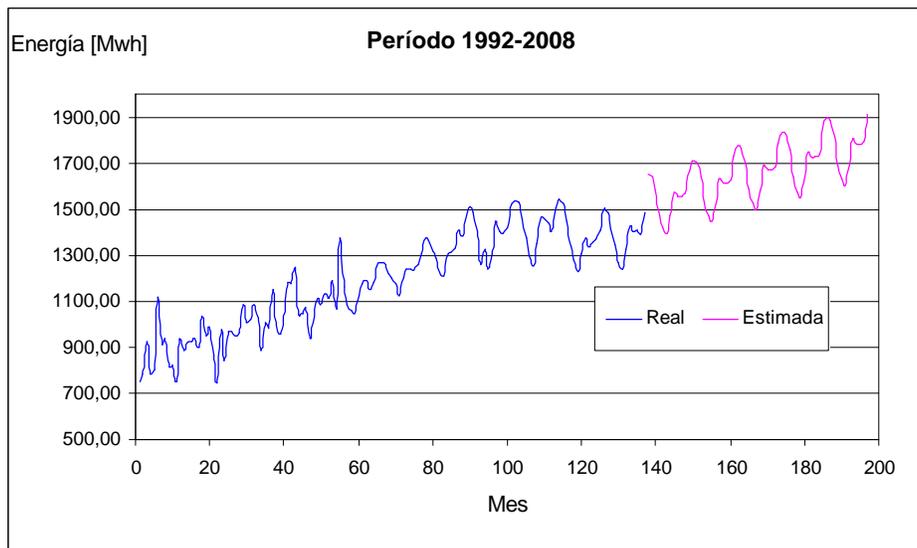
La estimación de la tendencia lineal es la siguiente:

Estimación lineal (MWh)						
MES	2003	2004	2005	2006	2007	2008
ENERO	-	1553.34	1610.48	1667.61	1724.75	1781.88
FEBRERO	-	1558.11	1615.24	1672.37	1729.51	1786.64
MARZO	-	1562.87	1620.00	1677.14	1734.27	1791.40
ABRIL	-	1567.63	1624.76	1681.90	1739.03	1796.17
MAYO	-	1572.39	1629.52	1686.66	1743.79	1800.93
JUNIO	1520.02	1577.15	1634.28	1691.42	1748.55	-
JULIO	1524.78	1581.91	1639.05	1696.18	1753.31	-
AGOSTO	1529.54	1586.67	1643.81	1700.94	1758.08	-
SEPTIEMBRE	1534.30	1591.43	1648.57	1705.70	1762.84	-
OCTUBRE	1539.06	1596.19	1653.33	1710.46	1767.60	-
NOVIEMBRE	1543.82	1600.96	1658.09	1715.22	1772.36	-
DICIEMBRE	1548.58	1605.72	1662.85	1719.99	1777.12	-

Con esta estimación lineal y con los índices estacionales, podemos calcular la serie temporal estacionalizada:

Estimación lineal Estacionalizada(MWh)						
MES	2003	2004	2005	2006	2007	2008
ENERO	-	1573.42	1631.30	1689.17	1747.04	1804.91
FEBRERO	-	1554.93	1611.95	1668.97	1725.98	1783.00
MARZO	-	1556.35	1613.24	1670.14	1727.03	1783.93
ABRIL	-	1567.72	1624.85	1681.99	1739.13	1796.27
MAYO	-	1667.90	1728.50	1789.11	1849.71	1910.32
JUNIO	1649.68	1711.69	1773.69	1835.70	1897.71	-
JULIO	1641.14	1702.64	1764.13	1825.63	1887.12	-
AGOSTO	1578.45	1637.41	1696.37	1755.33	1814.29	-
SEPTIEMBRE	1475.17	1530.10	1585.03	1639.96	1694.90	-
OCTUBRE	1419.92	1472.63	1525.34	1578.05	1630.76	-
NOVIEMBRE	1393.55	1445.12	1496.69	1548.27	1599.84	-
DICIEMBRE	1474.53	1528.93	1583.34	1637.74	1692.14	-

Debemos aclarar que esta estimación no toma en cuenta la componente cíclica e irregular, ya que la variación irregular es netamente aleatoria.



Serie temporal real y estimada la ciudad de Gral. Madariaga

DESARROLLO PARA LA CIUDAD DE PINAMAR

De la misma forma procederemos a calcular las distintas componentes de la serie temporal para la ciudad de Pinamar.

Presentamos aquí, los consumos de energía de la ciudad de Pinamar en el periodo Enero de 1992 hasta Mayo de 2003.

Demanda mensual de energía (MWh)						
MES	1992	1993	1994	1995	1996	1997
ENERO	5116.24	5558.72	5908.32	6746.40	6961.68	7309.76
FEBRERO	4222.35	4649.71	4966.56	5270.40	5445.36	5717.63
MARZO	2564.24	2608.89	2820.24	2916.00	3102.48	3257.60
ABRIL	1908.01	2158.08	2187.00	2352.24	2808.72	2949.16
MAYO	1779.98	1802.69	1928.88	2352.24	2406.24	2526.55
JUNIO	1974.01	2040.22	2183.04	2311.92	2506.30	2631.62
JULIO	2199.79	2127.03	2275.92	2517.84	3067.92	3221.32
AGOSTO	1952.36	2214.50	2369.52	2525.76	2594.16	2723.87
SEPTIEMBRE	1734.98	1826.58	1954.44	2080.80	2558.88	2686.82
OCTUBRE	1773.63	2098.43	2245.32	2448.00	2275.92	2389.72
NOVIEMBRE	1824.10	1981.01	2119.68	2277.36	2632.32	2763.94
DICIEMBRE	2411.85	2602.09	2784.24	2959.20	3216.24	3377.05

Demanda mensual de energía (MWh)						
MES	1998	1999	2000	2001	2002	2003
ENERO	7619.62	8020.65	8170.53	8465.88	8594.74	10065.94
FEBRERO	5945.49	6258.41	6842.70	6995.66	7064.67	9055.73
MARZO	4206.79	4428.20	4479.14	4825.97	5297.97	5659.15
ABRIL	3384.11	3562.22	3913.07	4176.56	3683.12	4653.31
MAYO	3200.42	3368.87	3649.06	3816.58	3678.67	4246.57
JUNIO	3279.29	3451.88	3548.56	3543.15	3867.48	-
JULIO	3643.90	3835.69	4170.17	4233.80	4474.38	-
AGOSTO	3319.02	3493.71	3824.51	3869.22	4202.12	-
SEPTIEMBRE	2925.58	3079.55	3343.36	3435.29	3627.08	-
OCTUBRE	3372.10	3549.58	3644.26	3545.04	3835.15	-
NOVIEMBRE	3181.59	3349.04	3470.53	3460.99	3814.35	-
DICIEMBRE	4407.71	4639.70	4897.12	4779.82	5589.28	-

Mostraremos ahora los índices estacionales obtenidos para esta ciudad.

MES	Indices	Factor de ajuste	Indices temporales
ENERO	203.52	1.00	204.30
FEBRERO	163.04	1.00	163.67
MARZO	101.81	1.00	102.20
ABRIL	83.75	1.00	84.07
MAYO	76.55	1.00	76.85
JUNIO	78.32	1.00	78.63
JULIO	88.46	1.00	88.80
AGOSTO	80.96	1.00	81.27
SEPTIEMBRE	70.89	1.00	71.17
OCTUBRE	75.58	1.00	75.87
NOVIEMBRE	74.24	1.00	74.53
DICIEMBRE	98.27	1.00	98.65

A continuación, se mostrarán los valores de la serie temporal desestacionalizada con los anteriores índices temporales.

SERIE DESESTACIONALIZADA (MWh)						
MES	1992	1993	1994	1995	1996	1997
ENERO	2504.23	2720.81	2891.93	3302.14	3407.51	3577.89
FEBRERO	2579.79	2840.90	3034.50	3220.14	3327.03	3493.39
MARZO	2509.09	2552.78	2759.59	2853.29	3035.76	3187.55
ABRIL	2269.45	2566.89	2601.29	2797.84	3340.79	3507.83
MAYO	2316.28	2345.83	2510.04	3060.96	3131.23	3287.79
JUNIO	2510.64	2594.86	2776.50	2940.42	3187.64	3347.02
JULIO	2477.21	2395.26	2562.93	2835.36	3454.81	3627.55
AGOSTO	2402.35	2724.92	2915.66	3107.91	3192.08	3351.68
SEPTIEMBRE	2437.93	2566.65	2746.31	2923.87	3595.65	3775.43
OCTUBRE	2337.68	2765.78	2959.38	3226.52	2999.72	3149.70
NOVIEMBRE	2447.62	2658.17	2844.24	3055.82	3532.11	3708.72
DICIEMBRE	2444.85	2637.70	2822.34	2999.70	3260.25	3423.27

SERIE DESESTACIONALIZADA (MWh)						
MES	1998	1999	2000	2001	2002	2003
ENERO	3729.55	3925.84	3999.20	4143.77	4206.84	4926.94
FEBRERO	3632.60	3823.79	4180.79	4274.25	4316.41	5532.92
MARZO	4116.32	4332.97	4382.81	4722.18	5184.04	5537.45
ABRIL	4025.18	4237.03	4654.34	4967.74	4380.83	5534.81
MAYO	4164.69	4383.89	4748.50	4966.49	4787.04	5526.04
JUNIO	4170.76	4390.28	4513.24	4506.35	4918.85	-
JULIO	4103.43	4319.40	4696.06	4767.72	5038.63	-
AGOSTO	4084.01	4298.96	4706.01	4761.02	5170.66	-
SEPTIEMBRE	4110.92	4327.28	4697.97	4827.15	5096.64	-
OCTUBRE	4444.51	4678.43	4803.21	4672.44	5054.82	-
NOVIEMBRE	4269.13	4493.82	4656.84	4644.04	5118.19	-
DICIEMBRE	4468.03	4703.19	4964.14	4845.23	5665.77	-

Estamos en condiciones de calcular la ecuación de la recta de tendencia, aplicando el método de los mínimos cuadrados. La ecuación queda de la siguiente forma:

$$Y = 22,807 \times X + 2155.8$$

Con las componentes estacional y la línea de tendencia identificadas, estamos en condiciones de encontrar la variación cíclica alrededor de la línea de tendencia. Se obtiene la siguiente tabla:

Variacion cíclica (MWh)						
MES	1992	1993	1994	1995	1996	1997
ENERO	-	188.25	187.62	381.31	276.37	205.27
FEBRERO	-	314.65	316.14	272.08	137.21	102.95
MARZO	-	5.67	23.40	-119.39	-171.59	-233.87
ABRIL	-	8.77	-153.07	-192.82	85.83	89.97
MAYO	-	-243.23	-261.81	55.54	-111.83	-158.25
JUNIO	-	-16.57	-6.39	-87.00	-93.72	-110.11
JULIO	23.61	-229.60	-240.99	-211.60	158.83	172.80
AGOSTO	-62.72	83.08	86.91	63.33	-126.20	-132.99
SEPTIEMBRE	-47.43	-87.05	-99.35	-135.57	278.99	308.02
OCTUBRE	-146.60	93.79	111.01	163.50	-355.39	-436.38
NOVIEMBRE	-65.75	-16.76	-25.40	-61.70	185.54	107.28
DICIEMBRE	-72.76	-53.15	-95.32	-126.56	-113.03	-263.96

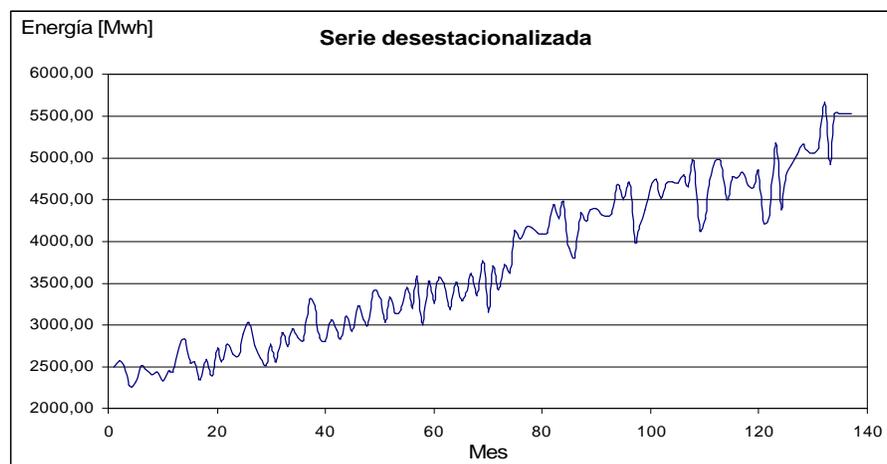
Variacion cíclica (MWh)						
MES	1998	1999	2000	2001	2002	2003
ENERO	-18.26	-291.56	-445.66	-539.17	-520.29	-
FEBRERO	-156.25	-408.42	-297.59	-417.13	-428.46	-
MARZO	269.33	67.90	-132.66	23.84	442.42	-
ABRIL	150.01	-43.04	102.14	259.15	-417.26	-
MAYO	176.75	82.44	185.43	271.08	-26.64	-
JUNIO	135.93	70.98	-57.96	-192.51	69.36	-
JULIO	-15.44	-15.77	101.32	83.99	123.17	-
AGOSTO	-51.46	-43.71	96.90	69.62	193.74	-
SEPTIEMBRE	-43.18	-46.86	79.77	132.32	14.12	-
OCTUBRE	261.56	293.64	155.10	-64.69	-56.09	-
NOVIEMBRE	75.26	78.32	-13.90	-44.27	-88.73	-
DICIEMBRE	250.60	253.99	271.89	182.94	387.94	-

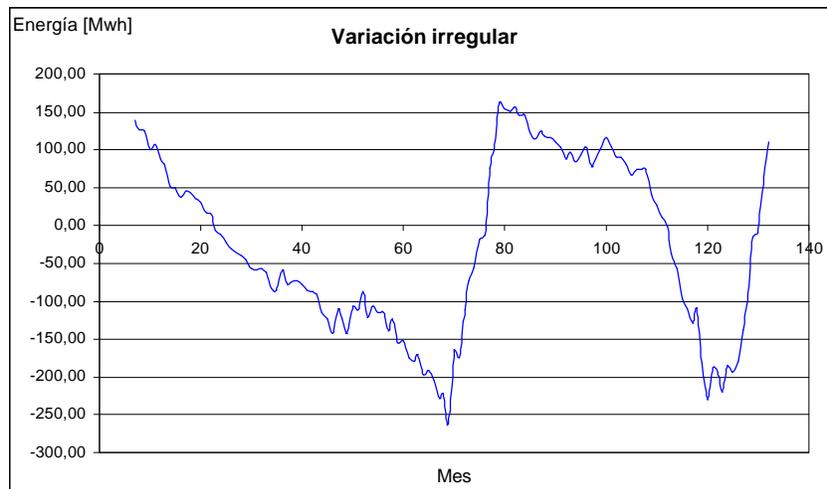
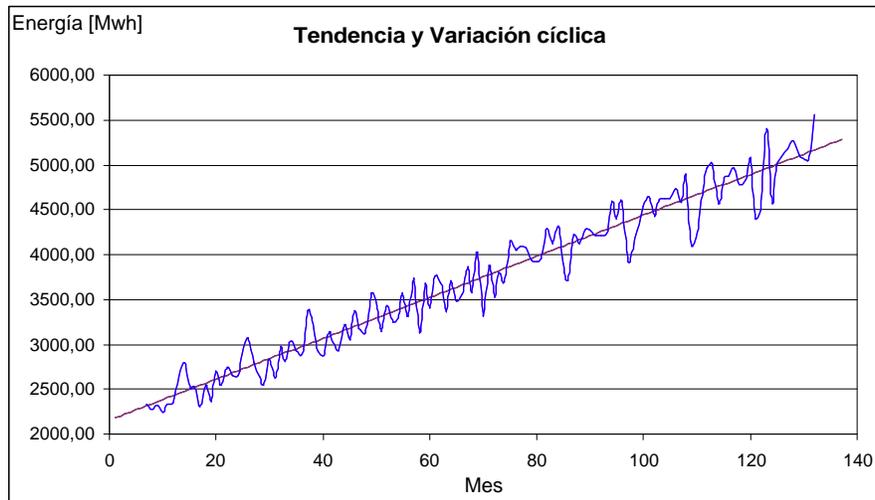
Con estas tres componentes calculadas, podemos obtener la componente irregular o aleatoria de la serie en estudio.

Variacion Irregular (MWh)						
MES	1992	1993	1994	1995	1996	1997
ENERO	-	80.27	-21.67	-78.83	-142.20	-174.41
FEBRERO	-	51.15	-30.43	-74.41	-106.32	-179.40
MARZO	-	49.21	-35.40	-72.59	-111.60	-171.22
ABRIL	-	37.41	-40.03	-77.42	-86.80	-197.59
MAYO	-	45.54	-45.36	-85.48	-121.52	-192.21
JUNIO	-	45.10	-57.12	-86.28	-106.02	-203.93
JULIO	138.15	35.73	-58.90	-89.54	-114.21	-229.12
AGOSTO	126.82	29.90	-56.87	-114.72	-114.71	-222.00
SEPTIEMBRE	124.30	18.95	-62.77	-122.68	-139.14	-262.07
OCTUBRE	100.41	14.44	-82.86	-141.90	-123.50	-166.21
NOVIEMBRE	106.69	-5.43	-84.40	-110.21	-154.85	-173.66
DICIEMBRE	88.13	-12.32	-59.19	-124.28	-150.93	-110.68

Variacion Irregular (MWh)						
MES	1998	1999	2000	2001	2002	2003
ENERO	-72.90	123.01	76.78	41.17	-188.32	-
FEBRERO	-54.67	115.01	87.49	26.80	-193.39	-
MARZO	-19.33	125.06	101.78	10.97	-219.45	-
ABRIL	-13.97	117.25	115.70	-1.60	-185.78	-
MAYO	76.00	115.83	103.77	-37.59	-193.00	-
JUNIO	100.09	110.86	89.09	-56.93	-179.99	-
JULIO	161.32	103.94	89.83	-94.87	-136.82	-
AGOSTO	155.11	88.63	81.38	-110.01	-98.18	-
SEPTIEMBRE	150.93	97.29	67.66	-129.39	-15.38	-
OCTUBRE	156.97	85.13	74.77	-109.89	-9.80	-
NOVIEMBRE	145.09	93.03	74.59	-181.53	63.40	-
DICIEMBRE	145.85	103.93	73.29	-230.35	111.51	-

Mostraremos entonces, las gráficas de las cuatro componentes ya calculadas para la serie temporal de la ciudad de Pinamar.





Determinación de la demanda anual de energía

Calcularemos ahora la estimación de la demanda de energía para los próximos cinco años para la ciudad de Pinamar, a partir de las componentes antes expuestas.

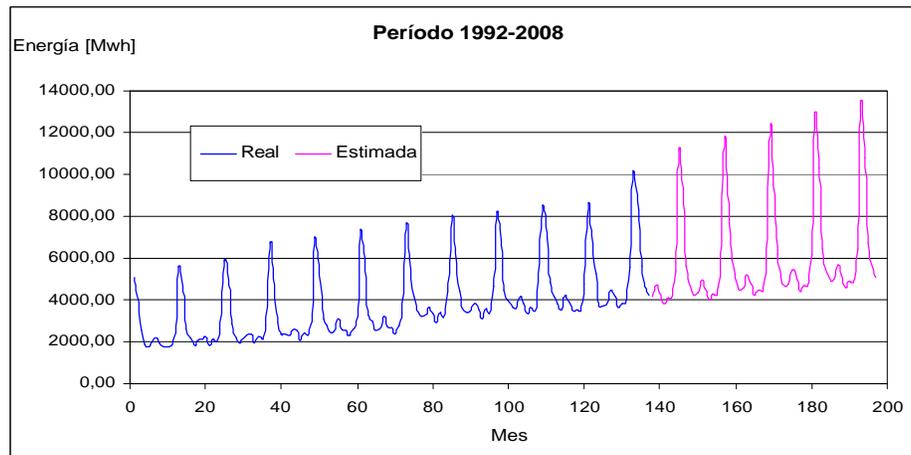
En primer término, mostramos la estimación de la tendencia lineal.

Estimación lineal desestacionalizada(MWh)						
MES	2003	2004	2005	2006	2007	2008
ENERO	-	5462.815	5736.499	6010.183	6283.867	6557.551
FEBRERO	-	5485.622	5759.306	6032.99	6306.674	6580.358
MARZO	-	5508.429	5782.113	6055.797	6329.481	6603.165
ABRIL	-	5531.236	5804.92	6078.604	6352.288	6625.972
MAYO	-	5554.043	5827.727	6101.411	6375.095	6648.779
JUNIO	5303.166	5576.85	5850.534	6124.218	6397.902	-
JULIO	5325.973	5599.657	5873.341	6147.025	6420.709	-
AGOSTO	5348.78	5622.464	5896.148	6169.832	6443.516	-
SEPTIEMBRE	5371.587	5645.271	5918.955	6192.639	6466.323	-
OCTUBRE	5394.394	5668.078	5941.762	6215.446	6489.13	-
NOVIEMBRE	5417.201	5690.885	5964.569	6238.253	6511.937	-
DICIEMBRE	5440.008	5713.692	5987.376	6261.06	6534.744	-

A estos valores calculados, los estacionalizamos con los índices estacionales correspondientes. La siguiente tabla muestra dichos valores.

Estimación lineal estacionalizada(MWh)						
MES	2003	2004	2005	2006	2007	2008
ENERO	-	11160.74	11719.886	12279.03	12838.2	13397.33
FEBRERO	-	8978.321	9426.2594	9874.198	10322.1	10770.08
MARZO	-	5629.491	5909.1896	6188.889	6468.59	6748.286
ABRIL	-	4650.307	4880.4033	5110.499	5340.6	5570.691
MAYO	-	4268.093	4478.4095	4688.726	4899.04	5109.36
JUNIO	4169.645	4384.83	4600.0158	4815.201	5030.39	-
JULIO	4729.538	4972.574	5215.6089	5458.644	5701.68	-
AGOSTO	4346.882	4569.302	4791.721	5014.14	5236.56	-
SEPTIEMBRE	3822.745	4017.515	4212.2848	4407.055	4601.82	-
OCTUBRE	4092.79	4300.438	4508.0849	4715.732	4923.38	-
NOVIEMBRE	4037.19	4241.154	4445.1183	4649.082	4853.05	-
DICIEMBRE	5366.567	5636.556	5906.5455	6176.535	6446.52	-

Debemos aclarar que esta estimación no toma en cuenta la componente cíclica e irregular, ya que la variación irregular es netamente aleatoria.



Serie temporal real y estimada para la ciudad de Pinamar

CIERRE DEL CAPITULO

En este capítulo se calculó para las dos muestras, mediante la implementación de la técnica predictiva tradicional los valores de consumo para los horizontes de uno y cinco años.

Si bien los cálculos fueron realizados utilizando el ajuste lineal de la tendencia, en el Anexo IV, se muestran los resultados obtenidos por el método de ajuste cuadrático.

Las predicciones para las dos muestras, dieron los siguientes resultados relevantes:

Pinamar

- ✓ Máximo consumo en el primer año estimado, se observa en el periodo estival, con un valor de 11160,74 MWh correspondiente al mes de enero de 2004.
- ✓ En el desarrollo predictivo, para los cinco años estimados, los máximos consumos anuales, corresponden a los meses de verano, como era de esperar.
- ✓ Máximo consumo, para los cinco años se observa para enero de 2008, con un valor de 13397,33 MWh.

Gral. Madariaga

- ✓ Máximo consumo en el primer año estimado, se observa en el periodo invernal, con un valor de 1649 MWh correspondiente al mes de junio de 2003.
- ✓ En el desarrollo predictivo, para los cinco años estimados, los máximos consumos anuales, corresponden a los meses de invierno.
- ✓ Máximo consumo, para los cinco años se observa para mayo de 2008, con un valor de 1910,32 MWh.

Como se mencionó con antelación, la curva de ajuste cuadrático no se utilizó para la predicción, ya que la pendiente en la ciudad de Gral. Madariaga de esta curva era negativa, lo que provocó que el error se incrementara continuamente debido a la característica de la ecuación.

En cambio en Pinamar, los errores entre curvas de ajustes eran similares para los primeros meses, pero la pendiente era positiva lo que se provoca valores de consumo excesivamente grandes en el mediano y largo plazo. Por ello se utilizó el ajuste lineal.

CAPITULO 3: REDES NEURONALES ARTIFICIALES

Este capítulo, tiene como objetivo brindar al lector los elementos esenciales para comprender tanto el origen como la teoría básica de las Redes Neuronales, además desarrollaremos la aplicación de estas en el análisis predictivos de series temporales.

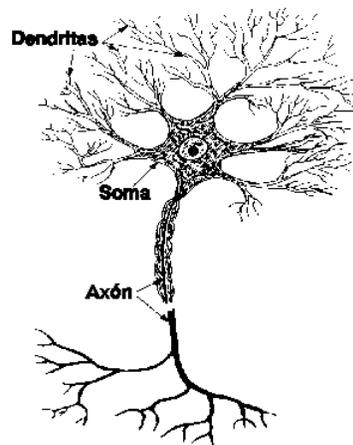
INTRODUCCIÓN A LAS REDES NEURONALES ARTIFICIALES

Las Redes Neuronales Artificiales (RNA) son un conjunto de algoritmos matemáticos que encuentran las relaciones no lineales entre conjuntos de datos. Suelen ser utilizadas como herramientas para la predicción de tendencias y como clasificadoras de conjuntos de datos.

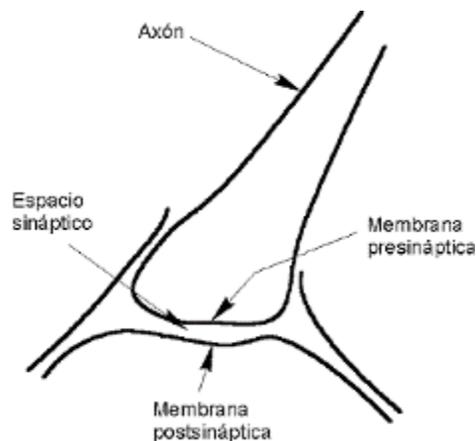
Se denominan Neuronales porque están basadas en el funcionamiento de una neurona biológica cuando procesa información.

La neurona biológica

El cerebro humano contiene aproximadamente 100.000 millones de células nerviosas o neuronas ampliamente conectadas entre sí.



Estas conexiones transportan los impulsos enviados desde otras neuronas y están conectadas a la membrana de la neurona. Cada neurona tiene una salida denominada axón. El contacto de cada axón con una dendrita se realiza a través de la *sinapsis*. Tanto el axón como las dendritas transmiten la señal en una única dirección.



La sinapsis consta de un extremo presináptico de un axón conectado a un extremo postsináptico de una dendrita, existiendo normalmente entre éstos un espacio denominado *espacio sináptico*.

Las neuronas son eléctricamente activas e interactúan entre ellas mediante un flujo de corrientes eléctricas locales. Estas corrientes se deben a diferencias de potencial entre las membranas celulares de las neuronas.

Un impulso nervioso es un cambio de voltaje que ocurre en una zona localizada de la membrana celular. El impulso se transmite a través del axón hasta llegar a la sinapsis, produciendo la liberación de una sustancia química denominada *neurotransmisor* que se esparce por el fluido existente en el espacio sináptico.

Cuando este fluido alcanza el otro extremo transmite la señal a la dendrita. Los impulsos recibidos desde la sinapsis se suman o restan a la magnitud de las variaciones del potencial de la membrana. Si las contribuciones totales alcanzan un valor determinado (alrededor de 10 milivoltios) se disparan uno o más impulsos que se propagarán a lo largo del axón.

Aunque todavía no está del todo claro, parece que este impulso se inicia en la conexión entre el axón y la membrana. Su amplitud y velocidad dependen del diámetro del axón y su frecuencia del número de disparos que se efectúen.

Historia

El trabajo que es considerado comúnmente como el primero en el área de las RNAs es el presentado en 1943 por Mc Culloch y Pitts , por ser ellos los primeros en describir al cerebro como un modelo computacional. La teoría que presentaron describía al cerebro como una agrupación de elementos simples, que en este caso son las neuronas.

Una limitante importante de esta RNA, se debe al hecho de que tanto la arquitectura como los pesos deben ser determinados de antemano. Esto fue uno de los principales detonantes para el desarrollo del área que investiga los procedimientos que definen como se deben realizar las conexiones de las RNAs para así poder alcanzar una salida deseada para una entrada determinada. El primer trabajo que se dedicó a la generación de una regla de aprendizaje fue Donald O. Hebb, y en 1949 presentó su teoría, en la cual describe como ocurre un cambio metabólico, que permite a una neurona de entrada I que constantemente está formando parte de un proceso de excitación en una neurona O, modificarse para hacerlo con menos esfuerzo; en otras palabras, la eficiencia de la neurona I para excitar a O se ve mejorada.

Los estudios en el área para la descripción del cerebro continuaron y hacia finales de los 50 surgió una nueva idea que causó gran expectación, el concepto nació bajo el nombre de perceptrón, y su creador fue el fisiólogo Frank Rosenblatt.

En pocos años, las RNAs se habían convertido en una de las áreas de mayor interés para los investigadores, Se crearon grandes expectativas sobre sus aplicaciones, que posteriormente se tornaron en gran decepción cuando en 1969 Minsky y Papert demostraron las grandes limitaciones de esta red.

El trabajo consiste en un análisis sobre las limitaciones y las capacidades de los perceptrones. Uno de los puntos más importantes presentados en el trabajo es que los perceptrones sólo pueden diferenciar patrones linealmente separables, de tal forma que no eran capaces de llevar a cabo algunas tareas simples tales como un XOR lógico.

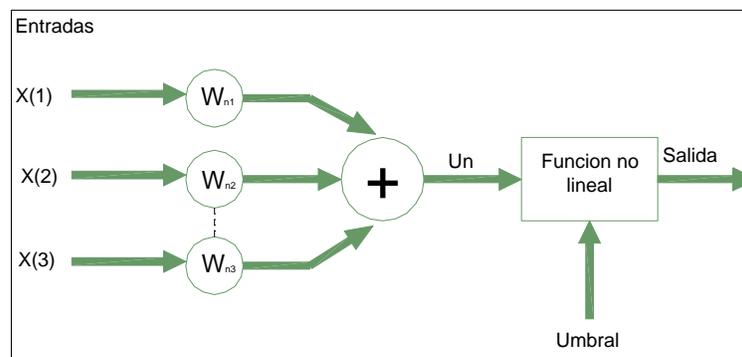
Como consecuencia del trabajo de Minsky y Papert, se detuvieron prácticamente todas las investigaciones en el área de RNAs y sólo pequeños grupos de investigadores, principalmente en Europa, pudieron continuar con sus estudios. No fue sino hasta la década de los 80's, y gracias a los esfuerzos de unos cuantos investigadores que las RNAs "resucitaron"; entre los hombres a los que más se les debe en cuanto a su resurgimiento, se encuentra John Hopfield, profesor del Instituto Tecnológico de California, que impulsó el área dando una serie de conferencias entre las cuales se cuenta *Neural networks and physical systems with emergent collective computational abilities*, y ha sido a partir de esa fecha que las RNAs volvieron a llamar la atención y se han empleado en diferentes disciplinas arrojando resultados muy satisfactorios

Modelos Neuronales

En todo modelo artificial de neurona aparecen cuatro elementos básicos:

- ✓ Un conjunto de conexiones o sinapsis que determinan el comportamiento de la neurona. Estas conexiones pueden ser excitadoras o inhibitoras.
- ✓ Un sumador que se encarga de sumar todas las entradas multiplicadas por las respectivas sinapsis.
- ✓ Una función de activación no lineal para limitar la amplitud de la salida de una neurona.
- ✓ Un umbral exterior que tiene el efecto de disminuir la entrada de la función de activación de la neurona.

Esquemáticamente quedaría representada por la siguiente figura:



Esquema de un modelo Neuronal

Matemáticamente las operaciones a realizar serían:

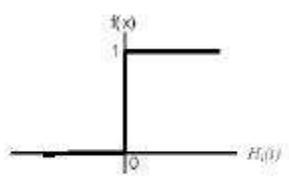
$$U_n = \sum_{j=1}^k W_{nj} \cdot x(j) \quad \text{Salida} = r(U_n - \text{umbral})$$

En cuanto a las funciones de activación existe un gran número inspiradas, todas ellas, en razones biológicas. Algunas de estas funciones son:

1. *Función escalón*
2. *Función lineal*
3. *Función Sigmoidea*
4. *Función Tangente Sigmoidea*

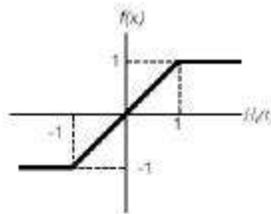
Función escalón

La función escalón se utiliza cuando la neurona tiene salidas binarias: 0, 1. La neurona se activa cuando el valor del potencial postsináptico es mayor o igual a cierto valor umbral.



Función lineal:

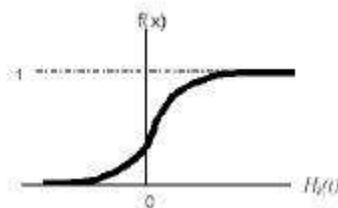
La función lineal o identidad responde a la expresión $f(x) = H_i(t)$. Una variación de la función lineal sería la función lineal a tramos donde la salida de la neurona sería la función identidad siempre y cuando el valor del potencial postsináptico estuviese dentro de un rango de valores. Al estar fuera del rango la función se torna constante.



Función Logarítmica Sigmoidea

La salida de esta función siempre será continua en el rango entre cero y uno. Con esta familia de funciones se pueden utilizar datos continuos o digitales proporcionando salidas exclusivamente continuas.

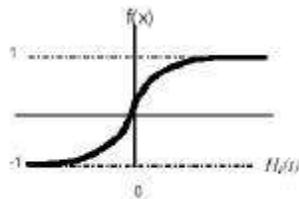
$$f(x) = \frac{1}{1 + e^{-x}}$$



Función Tangente Sigmoidea

Esta es una de las funciones más utilizadas en las redes neuronales por su flexibilidad y el amplio rango de resultados que ofrece. Las ventajas de utilizar una tangente sigmoidea frente a una sigmoidea reside en que la segunda sólo ofrece resultados en el rango positivo entre cero y uno, en cambio la tangente sigmoidea da resultados entre -1 y 1 , por lo que se amplía a los números negativos los posibles resultados. La función tiene una tipología como la siguiente:

$$f(x) = \frac{2}{1 + e^{-2x}} - 1$$



El resultado que nos ofrece cada una de estas funciones será el dato de salida de la neurona que se dirigirá bien a otra neurona o bien al resultado final.

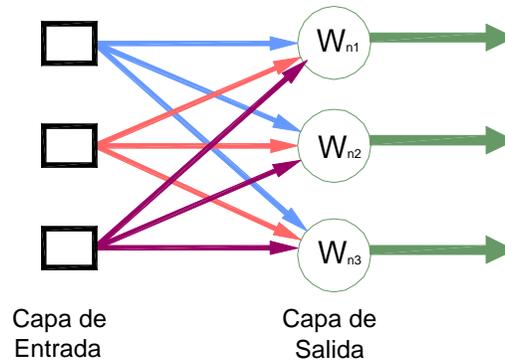
Arquitecturas Neuronales.

Una vez vistos los elementos básicos de toda red neuronal se pasará a enumerar las diferentes estructuras en las que estos elementos se pueden asociar, así se tendrán:

Redes Neuronales monocapas

Se corresponde con la red neuronal más sencilla ya que se tiene una capa de neuronas que proyectan las entradas a una capa de neuronas de salida donde se realizan diferentes cálculos. La capa de entrada, por no realizar ningún cálculo, no se cuenta de ahí el nombre de redes neuronales con una sola capa.

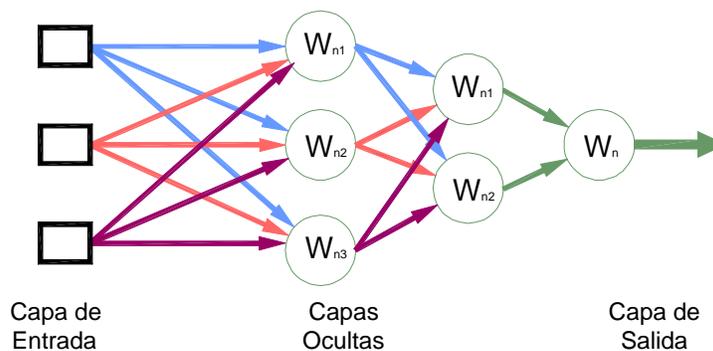
Una aplicación típica de este tipo de redes es su uso como memorias asociativas.



Red Neuronal Monocapa

Redes Neuronales Multicapa

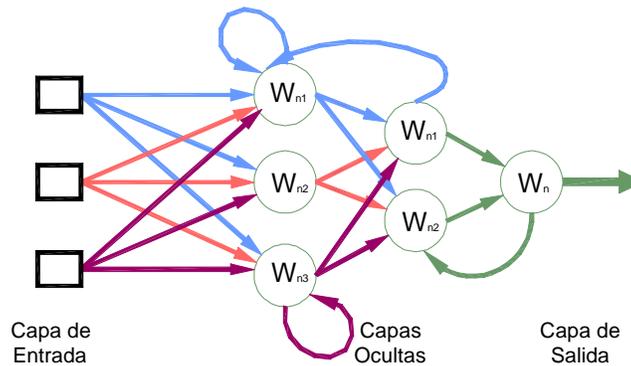
Es una generalización de la anterior existiendo un conjunto de capas intermedias entre la entrada y la salida (capas ocultas). Este tipo de red puede estar total o parcialmente conectada



Esquema de una red neuronal Multicapa.

Redes Neuronales Recurrentes

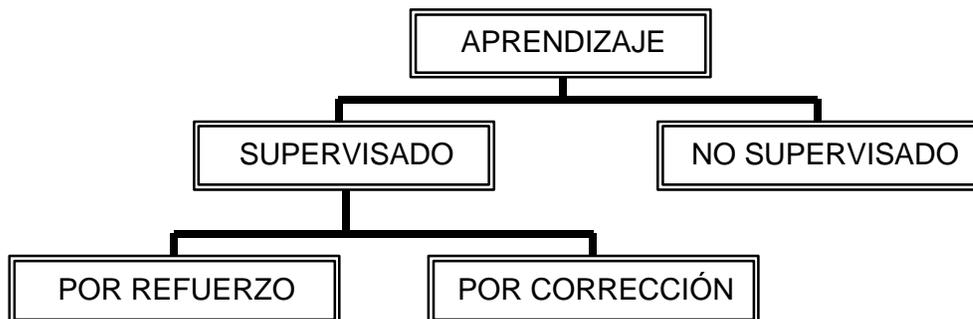
Se diferencia de las anteriores en la existencia de lazos de realimentación en la red. Estos lazos pueden ser entre neuronas de diferentes capas, neuronas de la misma capa o, más sencillamente, entre una misma neurona.



Red Neuronal Recurrente.

Métodos De Aprendizaje

En una red neuronal es necesario definir un procedimiento por el cual las conexiones del dispositivo varíen para proporcionar la salida deseada (algoritmo de aprendizaje). Los métodos de aprendizaje se puede dividir en las siguientes categorías



El aprendizaje de una red se puede dividir de las siguientes formas:

Aprendizaje supervisado

Consiste en introducir una serie de patrones de entrada a la red y a su vez mostrar la salida que se quiere tener. La red es capaz de ajustar los pesos de las neuronas de

forma que a la presentación posterior de esos patrones de entrada la red responde con salida memorizada.

- ✓ *Aprendizaje de refuerzo*: Se introducen valores de entrada, y lo único que se le indica a la red es si las salidas que ha generado son correctas o incorrectas.
- ✓ *Aprendizaje por corrección*: Al igual que en el anterior, se introducen las entradas, y se compara las salidas obtenidas por estas con las señales deseadas. Aquí se conoce la magnitud del error y ésta determina la magnitud en el cambio de los pesos.

Aprendizaje no supervisado

Se presentan los patrones de entrada a la red y ésta los clasifica en categorías según sus rasgos más sobresalientes.

Principales Arquitecturas

Dentro de las principales arquitecturas de las redes neuronales se distinguen las redes monocapa, como la red HOPFIELD y la red BRAIN-STATE-IN-A-BOX, en estas se establecen conexiones laterales entre las neuronas que pertenecen a la única capa de la red. Además pueden existir conexiones auto recurrente.

Las redes monocapa se utilizan típicamente en tareas relacionadas con lo que se conoce como auto asociación, por ejemplo para regenerar informaciones de entrada que se presentan distorsionadas o incompletas.

En las redes multicapas normalmente, todas las neuronas de una capa reciben señales de entrada de otra capa anterior, más cercana a la entrada de la red, y envían su señal de salida a una capa posterior, más cercana a la salida de la red. A estas conexiones se les denominan conexiones hacia delante o feedforward.

Sin embargo en un gran número de estas redes también existe la posibilidad de conectar las salidas de las neuronas de capas posteriores a las entradas de capas anteriores, a estas conexiones se les denomina conexiones hacia atrás o feedback

Las señales se propagan hacia adelante a través de las capas de la red, no existen conexiones hacia atrás, y normalmente tampoco auto recurrentes, ni laterales, excepto los modelos de red propuestos por Kohonen.

Las redes feedforward más conocidas son: *PERCEPTRON*, *ADALINE*, *MADALINE*, *LINEAR ADAPTATIVE MEMORY*, *DRIVE-REINFORCEMENT*, *BACKPROPAGATION*. Todas ellas son útiles en aplicaciones de reconocimiento o clasificación de patrones.

En las redes con conexiones hacia adelante y hacia atrás (feedforward/ feedback), circula información tanto hacia adelante como hacia atrás durante el funcionamiento de la red.

En general, suelen ser bicapas, existiendo por lo tanto dos conjuntos de pesos: los correspondientes a las conexiones feedforward de la primera capa (capa de entrada) hacia la segunda (capa de salida) y los de las conexiones feedback de la segunda a la primera. Los valores de los pesos de estos tipos de conexiones no tienen por qué coincidir, siendo diferentes en la mayor parte de los casos.

Los perceptrones Multicapa han sido usados con éxito para resolver diversos y difíciles problemas, usando para el entrenamiento supervisado el algoritmo conocido como algoritmo de retropropagación del error (Backpropagation).

Ventajas de las R.N.A

Debido a su constitución y a sus fundamentos, las RNA presentan un gran número de características:

- ✓ Aprendizaje Adaptativo: capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.
- ✓ Generalización: una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje. La generalización provoca la facultad de las redes neuronales de responder

apropiadamente cuando se les presentan datos o situaciones a los que no habían sido expuestas anteriormente.

- ✓ Operación en tiempo real: los cómputos neuronales pueden ser realizados en paralelo; existiendo gran cantidad de software para la implementación de las redes neuronales, por ejemplo el usado para este trabajo fue el Matlab 6.0.
- ✓ Las redes pueden aprender a reconocer patrones con ruido, distorsionados, o incompletos
- ✓ Posee la capacidad de trabajar con funciones no lineales

Desventajas de las R.N.A

Una de las desventajas de las Redes Neuronales es que requieren la definición de muchos parámetros antes de poder aplicar la metodología. Por ejemplo hay que decidir la arquitectura más apropiada, el número de capas ocultas, el número de neuronas por capa, las interconexiones, la función de transferencia, etc.

Además, se puede mencionar:

- ✓ Complejidad de aprendizaje para grandes tareas
- ✓ Tiempo de aprendizaje elevado
- ✓ Dificultad de interpretar a posteriori lo que ha aprendido la red
- ✓ Necesidad de muchos datos de entrenamiento para un correcto aprendizaje y generalización posterior.

Aplicaciones

Las redes neuronales son una tecnología computacional emergente que puede utilizarse en un gran número y variedad de aplicaciones, tanto comerciales como militares.

Hay muchos tipos diferentes de redes neuronales, cada uno de los cuales tiene una aplicación particular más apropiada. Separándolas según las distintas disciplinas algunos ejemplos de sus aplicaciones son:

- ✓ Reconocimiento de caracteres escritos.

- ✓ Identificación de candidatos para posiciones específicas.
- ✓ Optimización de plazas y horarios en líneas de vuelo.
- ✓ Explotación de bases de datos.
- ✓ Evaluación de probabilidad de formaciones geológicas y petrolíferas.
- ✓ Síntesis de voz desde texto.
- ✓ Análisis de tendencias y patrones.
- ✓ Previsión del tiempo.
- ✓ Previsión de la evolución de los precios.
- ✓ Valoración del riesgo de los créditos.
- ✓ Identificación de falsificaciones.
- ✓ Interpretación de firmas.
- ✓ Robots automatizados y sistemas de control (visión artificial y sensores de presión, temperatura, gas, etc.)
- ✓ Control de producción en líneas de proceso.
- ✓ Inspección de calidad.
- ✓ Filtrado de señales.
- ✓ Analizadores del habla para la ayuda de audición de sordos profundos.
- ✓ Diagnóstico y tratamiento a partir de síntomas y/o de datos analíticos (encefalograma, etc.).
- ✓ Clasificación de las señales de radar .
- ✓ Creación de armas inteligentes.
- ✓ Optimización del uso de recursos escasos.

BACKPROPAGATION

Antecedentes:

La regla de aprendizaje del Perceptrón monocapa y el algoritmo de LMS de Widrow y Hoff fueron diseñados para entrenar redes de una sola capa. Estas redes tienen la desventaja que solo pueden resolver problemas linealmente separables, fue esto lo que llevó al surgimiento de las redes multicapa para superar esta dificultad en las redes hasta entonces conocidas.

La Backpropagation es un tipo de red de aprendizaje supervisado, que emplea un ciclo propagación - adaptación de dos fases. Una vez que se ha aplicado un patrón a la entrada de la red como estímulo, éste se propaga desde la primera capa a través de las capas superiores de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas.

Las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta que contribuyen directamente a la salida. Sin embargo las neuronas de la capa oculta sólo reciben una fracción de la señal total del error, basándose aproximadamente en la contribución relativa que haya aportado cada neurona a la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total.

Basándose en la señal de error percibida, se actualizan los pesos de conexión de cada neurona, para hacer que la red converja hacia un estado que permita clasificar correctamente todos los patrones de entrenamiento.

La importancia de este proceso consiste en que, a medida que se entrena la red, las neuronas de las capas intermedias se organizan a sí mismas de tal modo que las distintas neuronas aprenden a reconocer distintas características del espacio total de entrada. Después del entrenamiento, cuando se les presente un patrón arbitrario de entrada que contenga ruido o que esté incompleto, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas individuales hayan aprendido a reconocer durante su entrenamiento. Y a la inversa, las unidades de las capas ocultas tienen una tendencia a inhibir su salida si el patrón de entrada no contiene la característica para reconocer, para la cual han sido entrenadas.

Varias investigaciones han demostrado que, durante el proceso de entrenamiento, la red Backpropagation tiende a desarrollar relaciones internas entre neuronas con el fin de organizar los datos de entrenamiento en clases.

Esta tendencia se puede extrapolar, para llegar a la hipótesis consistente en que todas las unidades de la capa oculta de una Backpropagation son asociadas de alguna manera a características específicas del patrón de entrada como consecuencia del entrenamiento. Lo que sea o no exactamente la asociación puede no resultar evidente para el observador humano, lo importante es que la red ha encontrado una representación interna que le permite generar las salidas deseadas cuando se le dan las entradas, en el proceso de entrenamiento. Esta misma representación interna se puede aplicar a entradas que la red no ha visto antes, y la red clasificará estas entradas según las características que compartan con los ejemplos de entrenamiento.

Regla de Aprendizaje

El algoritmo Backpropagation para redes multicapa es una generalización del algoritmo LMS, ambos algoritmos realizan su labor de actualización de pesos y ganancias con base en el error medio cuadrático. La red Backpropagation trabaja bajo aprendizaje supervisado y por tanto necesita un set de entrenamiento que le describa cada salida y su valor de salida esperado de la siguiente forma:

$$\{P_1, T_1\}, \{P_2, T_2\}, \dots, \{P_Q, T_Q\}$$

Donde P_Q es una entrada a la red y T_Q es la correspondiente salida deseada para el patrón q -ésimo. El algoritmo debe ajustar los parámetros de la red para minimizar el error medio cuadrático.

El entrenamiento de una red neuronal multicapa se realiza mediante un proceso de aprendizaje, para realizar este proceso se debe inicialmente tener definida la topología de la red esto es: número de neuronas en la capa de entrada el cual depende del número de componentes del vector de entrada, cantidad de capas ocultas y número de neuronas de cada una de ellas, número de neuronas en la capa de la salida el cual depende del número de componentes del vector de salida o patrones objetivo y funciones de transferencia requeridas en cada capa, con base en la topología escogida se asignan valores iniciales a cada uno de los parámetros que conforma la red.

Es importante recalcar que no existe una técnica para determinar el número de capas ocultas, ni el número de neuronas que debe contener cada una de ellas para un problema específico, esta elección es determinada por la experiencia del diseñador, el cual debe cumplir con las limitaciones de tipo computacional.

Cada patrón de entrenamiento se propaga a través de la red y sus parámetros para producir una respuesta en la capa de salida, la cual se compara con los patrones objetivo o salidas deseadas para calcular el error en el aprendizaje, este error marca el camino más adecuado para la actualización de los pesos y ganancias que al final del entrenamiento producirán una respuesta satisfactoria a todos los patrones de entrenamiento, esto se logra minimizando el error medio cuadrático en cada iteración del proceso de aprendizaje.

El presente algoritmo basa su corrección de los pesos por medio de la regla Delta, la cual se define como:

$$Dw_{ji}(n) = \eta \delta_j(n) y_i(n)$$

donde

η = tasa de aprendizaje

w_{ji} = Peso de la neurona i de una capa a la neurona j de la siguiente capa

δ_j = Gradiente local de la neurona j

Y_i = salida de la neurona i

n = iteración n -ésima

Si se quiere incrementar la velocidad de aprendizaje, evitando inestabilidad, es necesario modificar la regla delta incluyendo un término denominado momento, quedando:

$$Dw_{ji}(n) = \alpha Dw_{ji}(n-1) + \eta \delta_j(n) y_i(n)$$

siendo α = momento

Inconvenientes en el aprendizaje del Backpropagation

Como se mencionó anteriormente, en el entrenamiento de la red, se recalculan los pesos en cada interacción, de forma de que decrezca el error E.

Al emplear este tipo de algoritmo, pueden surgir distintos tipos de problemas:

1. Existencia de mínimos locales para el error E.
2. Presencia de múltiples mínimos globales para E
3. La posibilidad de que se den situaciones en la que , después de cada interacción se avance mínimamente hacia el mínimo global E

OVERFITTING

Uno de los problemas que ocurren durante el entrenamiento de la red neuronal es llamado *overfitting*. El error en el conjunto de entrenamiento se maneja a un valor muy pequeño, pero cuando el nuevos datos son presentados a la red el error es grande. La red tiene memorizado los ejemplos de entrenamiento, pero no ha aprendido a generalizar las nuevas situaciones.

Para evitar estos inconvenientes y la inconvergencia del algoritmo, los especialistas proponen sugerencias aplicables al algoritmo de Backpropagation:

- ✓ Elección de los pesos iniciales
- ✓ Modificación de la velocidad de entrenamiento
- ✓ Actualización de los pesos aplicando momentos
- ✓ Representación de los datos
- ✓ Elección de la cantidad de neuronas y de las capas ocultas
- ✓ implementación de validación del entrenamiento (detenimiento temprano)

REDES NEURONALES COMO MODELOS DE PREDICCIÓN

Las redes neuronales fueron elegidas como herramientas, dado que la modelización de la demanda es esencialmente multivariada, ya que inciden en la misma, parámetros

tales como: población, PBI, época del año, factores climáticos y patrones del comportamiento del pasado, etc.

Para los modelos predictivos, la arquitectura neuronal más utilizada es la del Perceptrón Multicapa entrenada con el algoritmo Backpropagation.

Basados en esto y en la amplia bibliografía existente, utilizaremos para el desarrollo del presente trabajo esta arquitectura.

DESARROLLO

En el desarrollo de los estudios, mediante la utilización de redes neuronales, definiremos una serie de pasos, con los que nos guiaremos para la implementación de las R.N.A.

Como primer paso, utilizaremos la topología de Perceptrón multicapa, en cual estará formado por dos capas ocultas de distintos números de neuronas, las cuales facilitaran a la red a la generalización y comprensión de las relaciones no lineales del problema.

Luego de elegida la estructura a utilizar (cantidad de neuronas, números de entradas), se utilizaran como vectores de entrada los datos suministrados por las dos compañías eléctricas, población, PBI.

Dichos vectores serán pre-procesados, para hacer más eficiente el entrenamiento de la red.

PRE- PROCESOS

Pre-procesamiento de la serie temporal

Antes de la modelización con las redes neuronales, debemos aplicar a las serie temporales determinados tratamientos.

Desestacionalización de la serie temporal

Este pre-procesamiento de las series temporales es uno de los más importantes, ya que mediante el mismo la serie es suavizada.

Centrado

Uno de los primeros pasos a considerar, es cuando la serie cumple con el requisito de ser estacionaria (media cero). Si bien el centrado no forma parte del modelo predictivo, mejora el rendimiento del mismo, debido a que la estructura del Perceptrón multicapa con Backpropagation tiene dificultades cuando una o mas variables de entrada se apartan del valor medio distinto de cero.

Si la serie a modelizar esta compuesta por una componente de “ continua “ creciente o decreciente, más una componente de” alterna” que varia entorno a la misma, se calcula la tendencia de la serie para luego restarla a la misma, con el fin de que los datos tengan una igualdad en el aporte del aprendizaje.

Interpolación por el Método de los splines cúbicos

Debido a que el modelado de las redes neuronales exigen una gran cantidad de datos para el entrenamiento y validación de las mismas, nos vemos en la necesidad de interpolar la serie de datos.

Entonces se requiere generar un conjunto de muestras grande a partir de un conjunto de muestras original pequeño. Esto se puede lograr como se menciono anteriormente interpolando la familia de puntos de muestra del conjunto original.

Existen muchas técnicas para interpolar una familia de puntos, tales como: Mínimos Cuadrados, Lagrange, Hermite, Splines, etc. En este trabajo utilizaremos el método de Splines cúbicos, debido a sus ventajas sobre los demás, utilizando para ello el software Matlab 6.0

Normalización

Antes de entrenar, es necesario escalar las entradas y targets (salidas de entrenamiento) para que estas caigan dentro de un determinado rango [-1, 1].

Para ello utilizaremos el programa Matlab 6.0, con el que se procede a normalizar los vectores de entrenamiento.

Una vez entrenada la red, devolverá salidas dentro del rango $[-1, 1]$, por lo que nos veremos en la necesidad de volver a tratar a la red con otro proceso, pero en este caso serán los vectores de salida, los que se llevarán nuevamente a las unidades originales.

Inicialización de los pesos

El valor de los pesos iniciales de cada neurona, antes de la primera interacción, repercute en que el error E alcance un mínimo global o local.

Es por esto que se trata de inicializar los pesos dentro de un determinado rango de valores entre -0.5 y $+0.5$ o entre -1 y 1 .

Cabe destacar que normalmente el software de simulación utiliza valores aleatorios, esto hace que la red produzca salidas muy distintas ante dos simulaciones de la misma serie.

Para solucionar estos problemas y agilizar el entrenamiento, utilizaremos el método de inicialización de Nguyen-Widrow.

MODELIZACIÓN DE LA RED PARA LA CIUDAD DE GRAL. MADARIAGA

Entrenamiento de la red Perceptrón Multicapa

En esta etapa se entrenará la red con datos históricos pre-procesados, tal cual se mencionó más arriba, para que sea capaz de predecir la demanda eléctrica.

Consideraremos para el estudio

- ✓ Algoritmo de entrenamiento: se utilizarán los algoritmos provistos por la toolbox de Matlab 6.0.^(*)

Algoritmo	Sentencia MatLab
Variable	Trainidx
Rprop	Trainrp
Gradiente conjugado escalar	Trainscg
Fletcher Powell CG	Traincgf
Polak Ribière CG	Traincgp
Powell Beale CG	Traincgb
Secante de un paso	Trainoss
Quasi Newton BFGS	Trainbfg
Levenberg Marquardt	Trainlm

- ✓ Topología de la red: la red Perceptrón Multicapa, que se utilizará estará formada por dos capas de neuronas ocultas, a las cuales se le variará la cantidad de neuronas para evaluar distintas alternativas
- ✓ Número de iteraciones: se utilizarán la cantidad de iteraciones necesarias, para asegurar que el entrenamiento no se detendrá por esta causa, para la simulación se eligió una cantidad de 5000 iteraciones.
- ✓ Elección de las entradas: se eligieron como vectores de entrada los datos suministrados por las compañías eléctricas, población y producto bruto interno.

Resumiendo, la R.N.A Perceptrón Multicapa que se elige para modelar la demanda eléctrica de la ciudad de Gral. Madariaga presenta las siguientes características

(*) NOTA: Ver en Anexo I Algoritmos de Entrenamiento.

El entrenamiento se realizará empleando la inicialización de Nguyen Widrow .
Luego también se emplearán las distintas combinaciones de los algoritmos propuestos anteriormente.

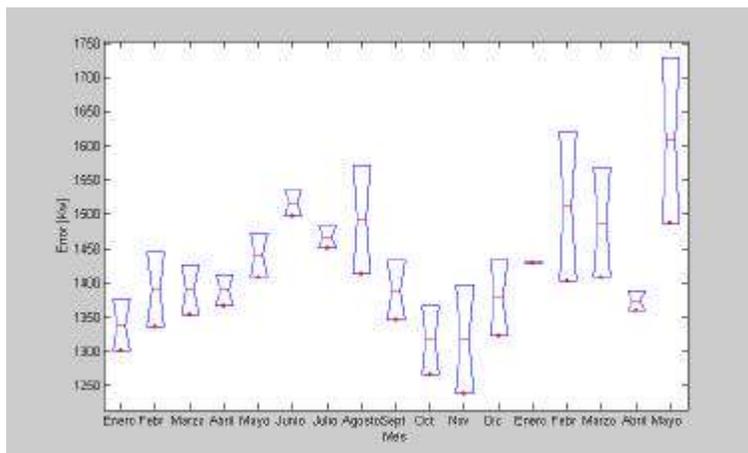
La topología de la red, es de dos capas ocultas, la primera de veinte neuronas y la segunda de dieciocho. El número de interacciones, será de 5000.

El vector de entrada contendrá seis valores históricos de consumo y la cantidad de habitantes correspondiente a dicho periodo, por lo tanto el vector estará formado por siete componentes.

Procediendo a la simulación de las redes, se obtendrán distintos resultados, para los distintos algoritmos empleados. Sobre los gráficos podemos observar el error absoluto (KWH) cometido en las estimaciones. Para llegar a ellos, la red fue entrenada con valores históricos correspondiente al período enero de 1992 a diciembre de 2001, por lo tanto el primer valor corresponde a enero de 2002.

La cantidad de valores estimados fue de 17, mostrando en la tabla los valores del error porcentual cometido (% del valor real) obtenidos a partir de la comparación con los valores reales.

Algoritmo trainrp:

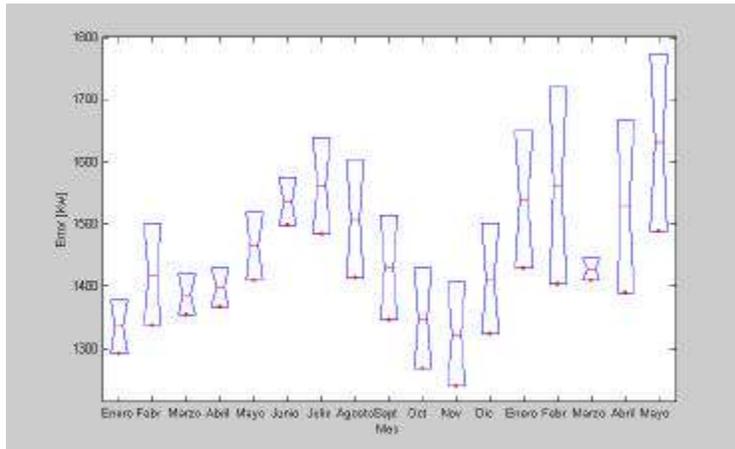


Error Absoluto

Mes	Error	Mes	Error
1	5.55	10	-7.85
2	-8.14	11	-12.73
3	-5.36	12	-8.39
4	-3.29	13	-0.13
5	-4.60	14	-15.66
6	-2.65	15	-11.36
7	2.24	16	2.09
8	-11.20	17	-16.16
9	-6.45		

Error relativo %

Algoritmo Trainingx:

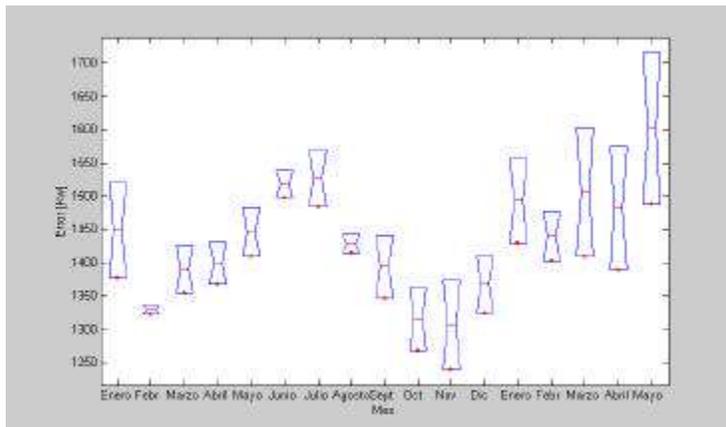


Error Absoluto

Mes	Error	Mes	Error
1	6.16	10	-12.67
2	-12.29	11	-13.37
3	-4.91	12	-13.38
4	-4.48	13	-15.38
5	-7.82	14	-22.66
6	-5.11	15	-2.57
7	-10.43	16	-19.95
8	-13.36	17	-19.20
9	-12.49		

Error relativo %

Algoritmo Trainscg:

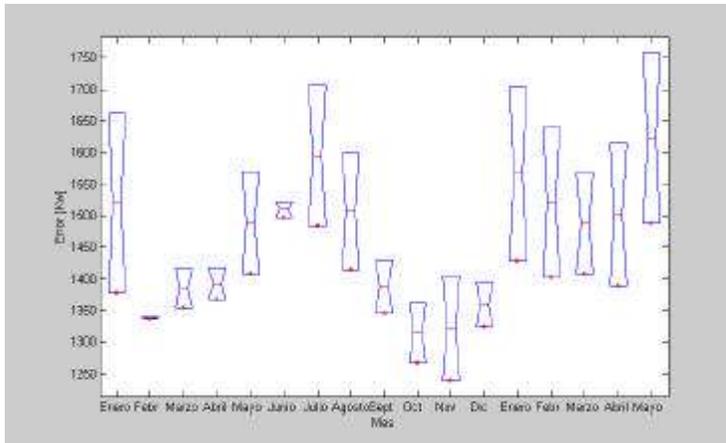


Error absoluto

Mes	Error	Mes	Error
1	-10.41	10	-7.54
2	1.02	11	-10.83
3	-5.39	12	-6.58
4	-4.59	13	-8.92
5	-5.24	14	-5.30
6	-2.77	15	-13.80
7	-5.70	16	-13.35
8	-2.00	17	-15.25
9	-7.09		

Error relativo %

Algoritmo Traicgp:

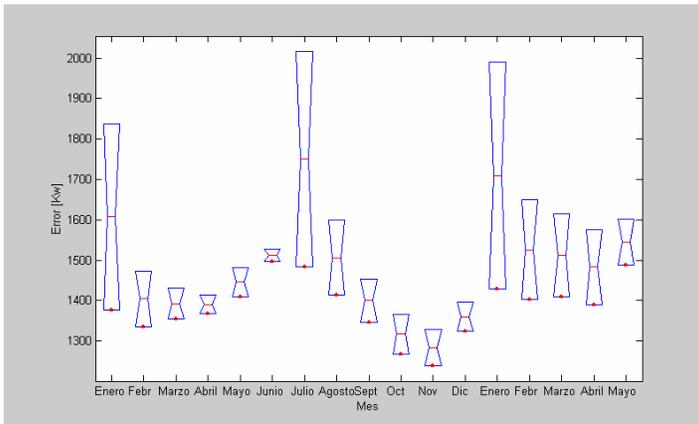


Mes	Error	Mes	Error
1	-20.72	10	-7.46
2	-0.22	11	-13.31
3	-4.64	12	-5.36
4	-3.61	13	-19.23
5	-11.40	14	-16.92
6	-1.67	15	-11.36
7	-14.94	16	-16.22
8	-13.09	17	-18.10
9	-6.28		

Error Absoluto

Error relativo %

Algoritmo Traincgb

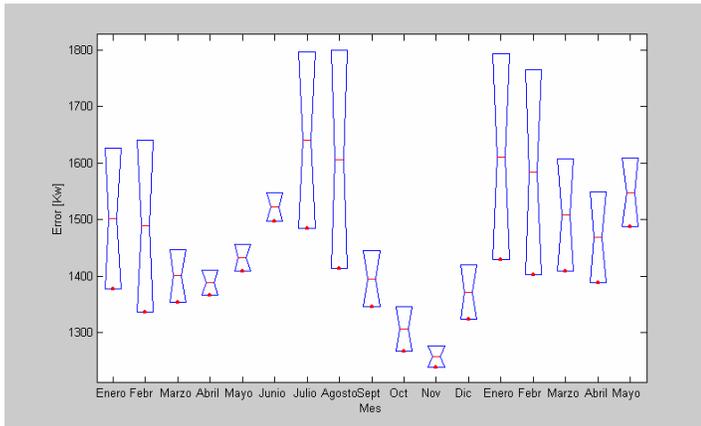


Mes	Error	Mes	Error
1	-33.40	10	-7.84
2	-10.25	11	-7.10
3	-5.67	12	-5.41
4	-3.37	13	-39.22
5	-5.23	14	-17.61
6	-2.05	15	-14.69
7	-35.81	16	-13.49
8	-13.05	17	-7.61
9	-7.99		

Error absoluto

Error relativo %

Algoritmo Trainoss

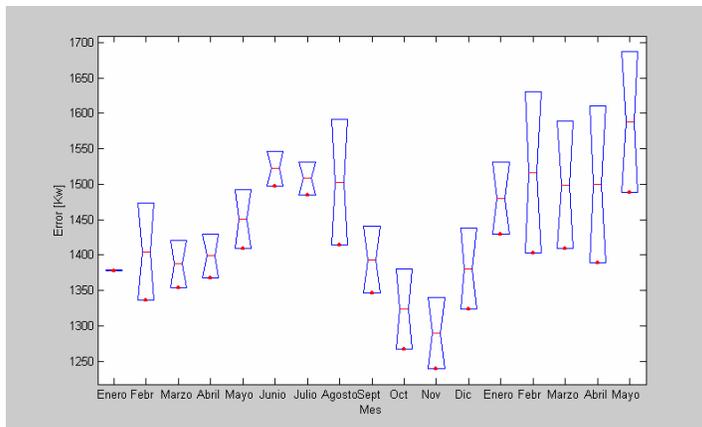


Error absoluto

Mes	Error	Mes	Error
1	-18.10	10	-6.27
2	-22.83	11	-3.05
3	-6.94	12	-7.25
4	-3.20	13	-25.49
5	-3.38	14	-25.85
6	-3.40	15	-14.12
7	-21.02	16	-11.57
8	-27.25	17	-8.10
9	-7.33		

Error relativo %

Algoritmo Trainbfg

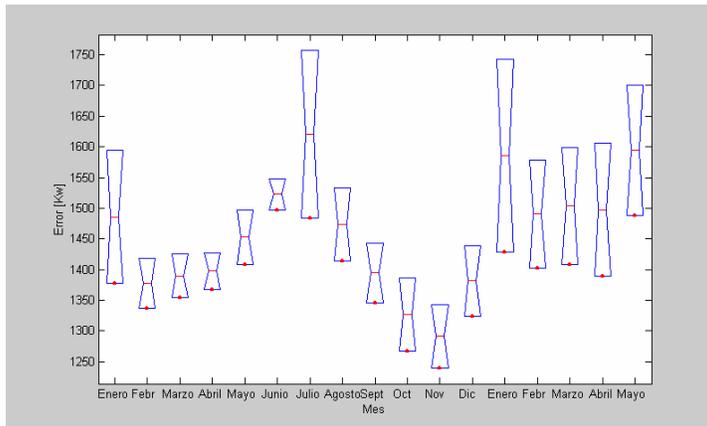


Error absoluto

Mes	Error	Mes	Error
1	-0.10	10	-8.92
2	-10.25	11	-8.10
3	-4.97	12	-8.61
4	-4.56	13	-7.10
5	-5.91	14	-16.30
6	-3.30	15	-12.79
7	-3.17	16	-15.97
8	-12.57	17	-13.37
9	-7.00		

Error relativo %

Algoritmo Trainlm



Mes	Error	Mes	Error
1	-15.71	10	-9.34
2	-6.15	11	-8.34
3	-5.28	12	-8.74
4	-4.38	13	-21.91
5	-6.25	14	-12.55
6	-3.38	15	-13.47
7	-18.36	16	-15.63
8	-8.41	17	-14.26
9	-7.24		

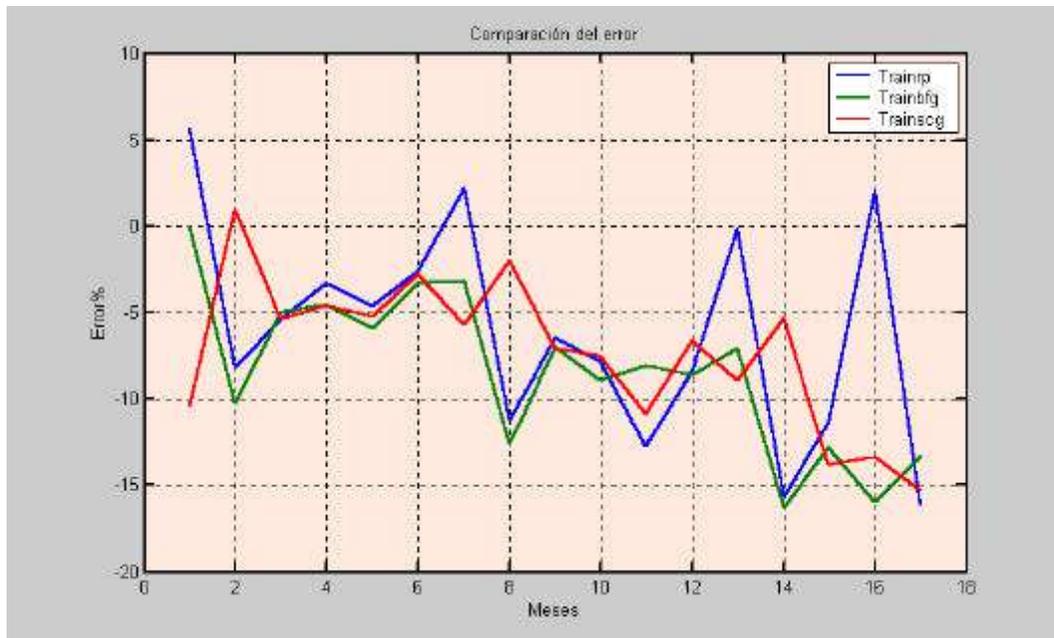
Error absoluto

Error relativo %

A continuación en la tabla resumida se comparan mes a mes los módulos de los errores relativos cometidos por cada uno de los algoritmos, destacando aquel cuya suma de estos errores sea menor:

	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP
RP	5.36	8.14	5.36	3.29	4.60	2.65	2.24	11.20	6.45
GDX	6.16	12.29	4.91	4.48	7.82	5.11	10.43	13.36	12.49
SCG	10.41	1.02	5.39	4.59	5.24	2.77	5.70	2.00	7.09
CGF	12.43	4.92	5.18	4.77	5.23	3.54	14.91	6.71	7.10
CGP	20.72	0.22	4.64	3.61	11.40	1.67	14.94	13.09	6.28
CGB	33.40	10.25	5.67	3.37	5.23	2.05	35.81	13.05	7.99
OSS	18.10	22.83	6.94	3.20	3.38	3.40	21.02	27.25	7.33
BFG	0.10	10.25	4.97	4.56	5.91	3.30	3.17	12.57	7.00
LM	15.71	6.15	5.28	4.38	6.25	3.38	18.36	8.41	7.24

	OCT	NOV	DIC	ENE	FEB	MAR	ABR	MAY	SUMA ERROR
RP	7.85	12.73	8.39	0.13	15.66	11.36	2.09	16.16	123.64
GDX	12.67	13.37	13.38	15.38	22.66	2.57	19.95	19.20	196.21
SCG	7.54	10.83	6.58	8.92	5.30	13.80	13.35	15.25	125.76
CGF	9.52	7.16	8.90	18.24	8.61	13.25	16.68	11.51	158.65
CGP	7.46	13.31	5.36	19.23	16.92	11.36	16.22	18.10	184.52
CGB	7.84	7.10	5.41	39.22	17.61	14.69	13.49	7.61	229.80
OSS	6.27	3.05	7.25	25.49	25.85	14.12	11.57	8.10	215.13
BFG	8.92	8.10	8.61	7.10	16.30	12.79	15.97	13.37	142.99
LM	9.34	8.34	8.74	21.91	12.55	13.47	15.63	14.26	179.39



En vista de los resultados mostrados, utilizaremos los dos algoritmos que mejor performance tuvieron en la etapa anterior.

Los dos algoritmos a utilizar serán el Backpropagation elástico (trainrp) y el algoritmo de gradiente conjugado escalar (trainscg).

Basándonos en estas primeras aproximaciones, procederemos al estudio de distintas alternativas utilizando estos dos últimos algoritmos.

Topología de la red

Como mencionamos anteriormente, la red Perceptrón multicapa puede tener una o varias capas ocultas, en el desarrollo de esta etapa, mostraremos distintas configuraciones y destacaremos la mejor, la cual utilizaremos para el estudio final.

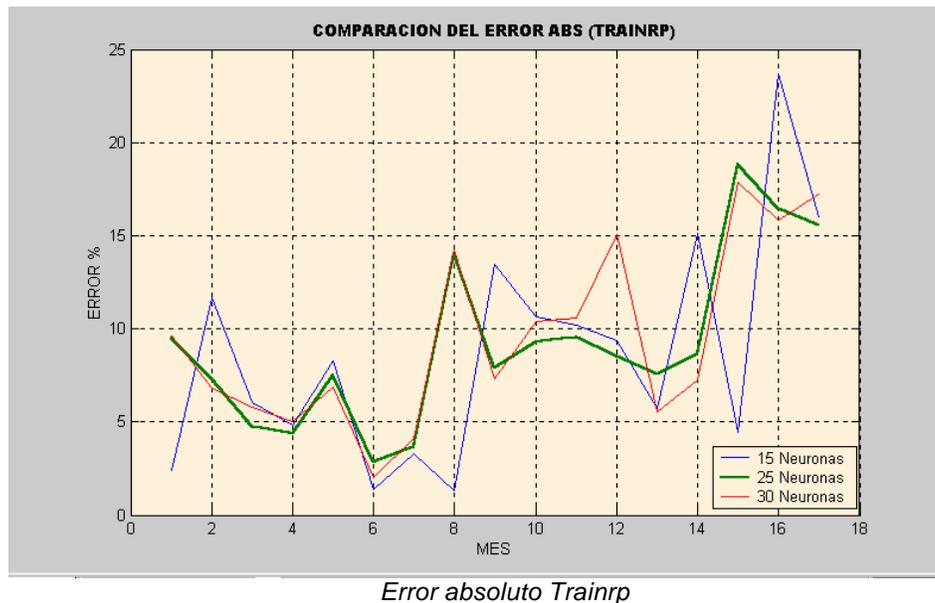
Cabe destacar que para la elección del número de neuronas y el número de capas ocultas, nos basaremos en los distintos resultados obtenidos a partir de la prueba de variadas cantidades de neuronas.

Si bien se realizaron simulaciones para 10, 15, 20, 25 Y 30 neuronas, pertenecientes a la capa oculta, en las gráficas del error, para facilitar la visualización de los resultados se incluyeron los resultados de las tres mejores simulaciones.

Tabla resumida^(**) comparativa de los errores de las 17 simulaciones utilizando el algoritmo de entrenamiento Trainrp:

Meses	15 Neuronas	25 Neuronas	30 Neuronas
1	2.37	-9.50	-9.64
2	-11.69	-7.34	-6.82
3	-6.01	-4.78	-5.80
4	-4.81	-4.41	-5.01
5	-8.26	-7.52	-6.85
6	-1.34	-2.86	-2.03
7	-3.31	-3.66	-4.10
8	-1.31	-14.06	-14.25
9	-13.47	-7.90	-7.30
10	-10.64	-9.28	-10.41
11	-10.23	-9.55	-10.61
12	-9.37	-8.54	-15.07
13	-5.71	-7.60	-5.51
14	-15.10	-8.69	-7.26
15	-4.42	-18.81	-17.86
16	-23.72	-16.44	-15.84
17	-16.02	-15.55	-17.23

Para el algoritmo trainrp, la configuración con la que se cometió menor error, fue con 25 neuronas, con un $E_{MEDIO} = 9.20\%$ y una dispersión de 4.56 %



(**) Ver en el Anexo II la totalidad de los resultados obtenidos.

Tabla resumida comparativa^(**) de los errores de las 17 simulaciones utilizando el algoritmo de entrenamiento Trainscg:

Meses	10 Neuronas	20 Neuronas	30 Neuronas
1	10.81	-22.54	-19.96
2	0.59	-31.03	-8.82
3	-0.95	-21.60	-13.22
4	-3.67	3.32	-1.95
5	-4.74	-24.13	-4.11
6	-2.64	-0.29	-2.41
7	6.10	-27.55	-22.86
8	-2.14	-35.82	-10.98
9	-1.84	-25.33	-14.58
10	-7.67	0.52	-5.79
11	-6.00	-26.52	-3.99
12	-6.89	-5.28	-6.01
13	2.69	-35.17	-27.60
14	-4.70	-41.39	-13.60
15	-6.27	-32.84	-21.16
16	-13.78	-5.65	-11.50
17	-10.07	-33.24	-4.41



Error absoluto Trainscg

Para el segundo algoritmo, el error medio absoluto cometido es de $E_{MEDIO} = 8.10\%$ con 30 neuronas en la capa oculta.

Se desarrollará, la segunda etapa del estudio, en la cual agregamos una segunda capa oculta a la topología de la red.

^(**) Ver en el Anexo II la totalidad de los resultados obtenidos.

Procedemos a variar la cantidad de neuronas que componen cada capa, obteniéndose distintos resultados, de los cuales mostraremos en una tabla resumida^(****) los que menor error cometen, para las distintas combinaciones de neuronas, utilizando primero el Algoritmo Trainrp.

Primer capa	10 Neuronas	20 Neuronas	30 Neuronas
Segunda capa	10 Neuronas	10 Neuronas	30 Neuronas
Mes			
1	4.61	8.81	15.09
2	-11.94	-6.44	0.04
3	-5.50	-9.34	-2.38
4	-5.67	-5.64	-4.34
5	-6.74	-8.33	-9.74
6	-1.72	0.26	-2.00
7	-12.68	-7.69	-4.55
8	-0.23	4.07	8.87
9	-12.18	-5.68	2.26
10	-9.24	-14.56	-5.84
11	-10.79	-10.14	-13.66
12	-6.54	-9.92	-10.93
13	-6.26	-1.84	-4.78
14	-17.47	-12.49	-11.01
15	-4.06	-14.61	-8.97
16	-19.90	-10.14	-27.48
17	-14.98	-20.09	-12.78

Error relativo %(Trainrp)

Luego de efectuado la separación de los mejores resultados, para cada combinación, compararemos gráficamente estas tres ultimas topologías, resaltando la que mejor se adecua a el problema.

En el siguiente gráfico resaltamos la curva del error de la topología 20-10 neuronas, la cual tiene un error medio de $E_{MEDIO} = 8.81\%$ con una desviación estándar menor a las otras tipologías de 4.9 unidades.

^(****)Nota: la totalidad de los resultados de las distintas combinaciones se mostraran en el Anexo I



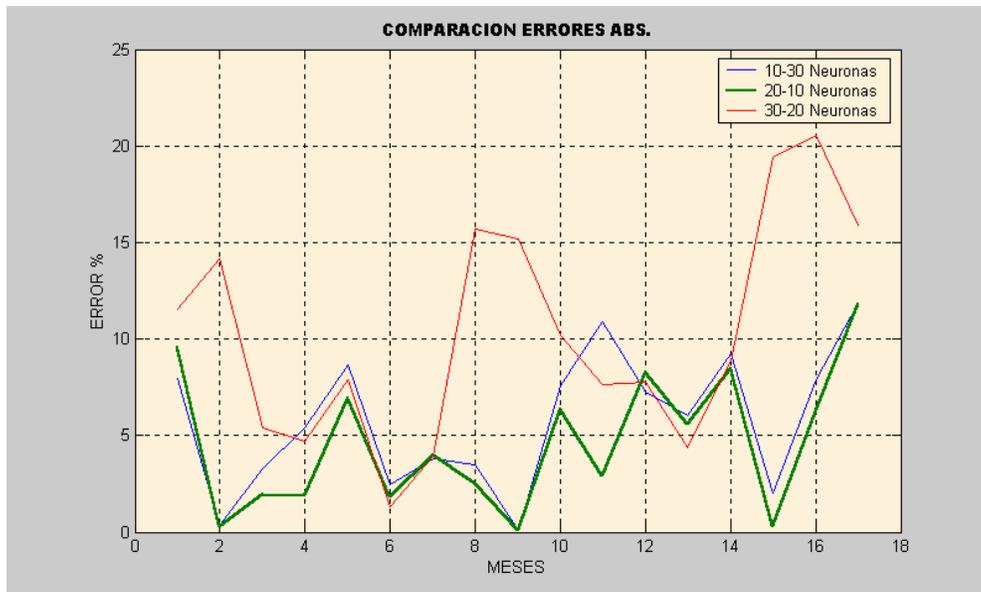
Error absoluto relativo % (Trainrp)

Procediendo de igual manera, pero para el algoritmo Trainscg, los mejores resultados obtenidos, se muestran en la siguiente tabla resumida:

Primer capa	10 Neuronas	20 Neuronas	30 Neuronas
Segunda capa	30 Neuronas	10 Neuronas	20 Neuronas
Mes			
1	7.98	9.54	-11.57
2	-0.34	0.31	-14.19
3	-3.26	-1.94	-5.37
4	-5.38	1.88	-4.71
5	-8.64	-6.97	-7.87
6	-2.45	-1.79	-1.32
7	-3.78	-4.00	-3.94
8	3.51	2.53	-15.68
9	-0.11	0.08	-15.17
10	-7.55	-6.36	-10.19
11	-10.93	-2.94	-7.63
12	-7.27	-8.26	-7.77
13	-6.07	-5.58	-4.41
14	-9.22	-8.49	-8.83
15	2.01	-0.28	-19.42
16	-7.91	-6.29	-20.58
17	-11.89	-11.81	-15.89

Errores relativos % (Trainscg)

Al graficar los errores absolutos para las tres mejores combinaciones, elegimos la que menor error posee, siendo la topología de 20-10 neuronas por capa, con un error medio de $E_{MEDIO} = 4.65\%$ y una desviación estándar de 3.60 %



Errores absolutos %(trainscg)

En base a los resultados obtenidos, el mejor algoritmo que representa el menor error, es el algoritmo Trainscg, con la configuración de 20-10 neuronas por capas. Es necesario remarcar que los errores cometidos en estas simulaciones son excesivamente grandes, ya que estos oscilan en un rango de **11.74%**.

Por consiguiente, trataremos los datos de la ciudad de Gral. Madariaga, utilizando el potencial de las redes de Kohonen⁽¹⁾. La serie temporal de la ciudad, se clasificará en base a la similitud de los datos.

Se realizaron numerosos ensayos, de los que entre los cuales se recogen los más significativos.

Una vez obtenidos los resultados de estos ensayos se tratarán por separados, según convenga. En este caso se plantea cual es el número idóneo de neuronas de salida, ya que estas darán la cantidad de conjuntos de clasificación. Es conveniente, utilizar un número pequeño de neuronas, debido a que si este es elevado, incrementará notablemente las subdivisiones.

⁽¹⁾ El comportamiento de estas redes son explicados en el Anexo II

En el estudio de clasificación de la serie de Gral. Madariaga, se obtuvieron los siguientes mapas de Kohonen, para tres y cinco neuronas de salida (clasificando los datos en 3 y 5 subconjuntos).

	1	2	3	4	5	6	7	8	9	10	11
1	-	-	-	-	-	-	1998	1999	2000	2001	2002
2	1992	1993	1994	-	-	-	-	-	-	-	-
3	-	-	-	1995	1996	1997	-	-	-	-	-

	1	2	3	4	5	6	7	8	9	10	11
1	-	-	-	-	-	-	1998	1999	2000	2001	2002
2	1992	1993	1994	-	-	-	-	-	-	-	-
3	-	-	-	-	1996	1997	-	-	-	-	-
4	-	-	-	1995	-	-	-	-	-	-	-
5	-	-	-	-	-	-	-	-	-	-	-

Mapas de Kohonen

En los mapas de las redes, se pueden observar que se han clasificado los datos en tres subconjuntos para el primer caso (tres neuronas de salida) y cuatro subconjuntos para el segundo (cinco neuronas de salida), resaltados en la figura.

Debido al potencial de la redes, podemos utilizar los últimos años para efectuar una buena predicción, ya que existe la probabilidad de que los valores de la serie correspondientes a los años 1992 hasta 1997 sean erróneos.

Por lo tanto efectuamos el ensayo, ingresando como vectores de entrada los valores correspondientes a los años 1998 hasta 2002, probando nuevamente los ensayos, la topología que mejor se adaptó a fue la de 20-20 neuronas por capas, utilizando en las simulaciones los algoritmos Trainrp y Trainscg, adaptándose mejor al problema el primero.

A continuación se muestran los errores cometidos, para cada simulación, y las sumas de los cuadrados de los estos, resaltando la mejor opción.

Primer capa	20 Neuronas	20 Neuronas
Segunda capa	10 Neuronas	10 Neuronas
Mes	Trainscg	Trainrp
1	-11.81	-5.75
2	-7.49	-5.13
3	-5.66	-4.81
4	-3.43	-2.85
5	-5.87	-6.47
6	-0.01	0.10
7	1.09	-0.70
8	-11.96	-6.14
9	-4.69	-1.87
10	-6.54	-5.34
11	-5.14	-3.75
12	-2.83	-3.63
13	0.56	1.03
14	0.30	-0.48
15	-9.22	-3.40
16	-8.16	-4.05
17	-7.17	-4.75
Suma ABS	91.95	60.26

Errores relativos % 20-10 Neuronas / capa

Basándonos en estos resultados, vemos que el error ha disminuido $E_{MEDIO}=3.54\%$ y una desviación de 2.06 %, como también el tiempo de simulación, por lo que estamos en condiciones de asegurar que el truncado de los datos no ha empeorado las condiciones del problema, sino todo lo contrario, la performance de las redes ha mejorado. Por lo tanto se efectuarán las estimaciones, utilizando la red Perceptrón multicapa, compuesta por 20-10 neuronas por capas, utilizando el algoritmo Trainrp, y como vector de entrada los datos a partir de enero de 1998 hasta mayo de 2003.

PREDICCIÓN

En base a los análisis realizados anteriormente, se procede al cálculo de la demanda de energía, siendo estas estimaciones a pequeño y mediano plazo.

Resumiremos la estructura de la red Perceptrón Multicapa que se utilizará en la predicción:

- ✓ Para el entrenamiento se utilizará el algoritmo de entrenamiento Trainrp, suministrado por la toolbox de Matlab.
- ✓ Para los pesos iniciales de la red se utilizará la inicialización de Nguyen-Widrow.
- ✓ La topología de la red es de dos capas ocultas, la primera con 20 Neuronas y la segunda con 10 Neuronas.
- ✓ Se utilizarán 65 valores históricos de consumo como salida o target.

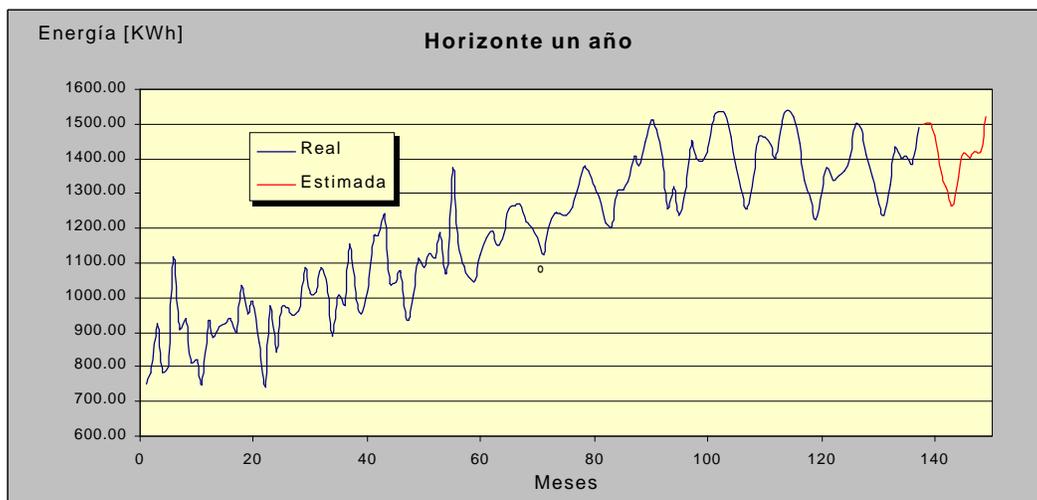
El número de vectores de entrenamiento es de 46, debido a que cada vector de entrenamiento posee once valores de consumo anteriores al de la predicción. Los resultados de los ensayos realizados para los horizontes de 1 y 5 años son presentados a continuación.

La tabla y el gráfico para la predicción del primer año correspondiente a la ciudad de Gral. Madariaga, periodo junio de 2003 a mayo de 2004, utilizando la red [MAD1], es el mostrado debajo.

MES	JUN	JUL	AGO	SEP	OCT	NOV
KWh	1500.79	1505.95	1468.7	1361.62	1318.84	1263.19

MES	DIC	ENE	FEB	MAR	ABR	MAY
KWh	1346.17	1416.2	1402.8	1422.53	1421.74	1521.7

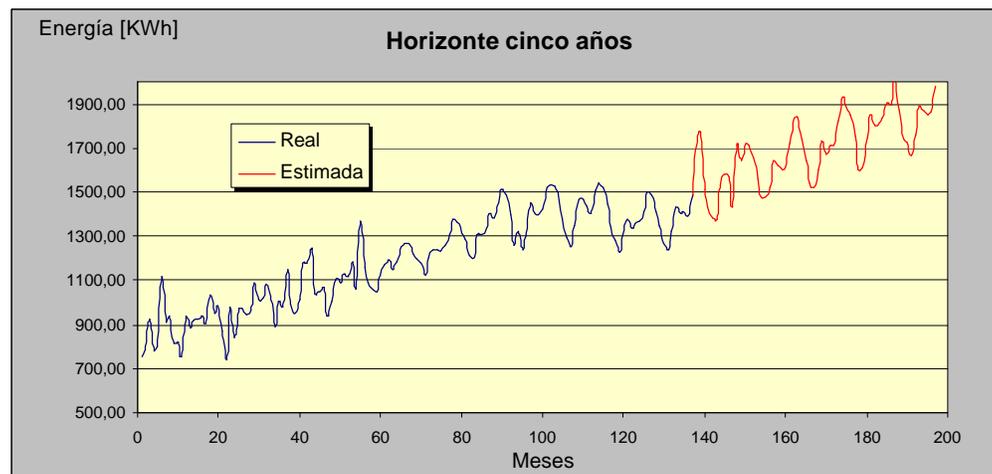
Predicción periodo un año



En la tabla y el gráfico siguiente, corresponde a la simulación de la red [MAD2], para un horizonte de cinco años, desde junio de 2003 a mayo de 2008, los valores de energía mostrados están en Kwh.

Mes	2003	2004	2005	2006	2007	2008
ENERO	-	1584.87	1646.70	1732.91	1851.90	1891.31
FEBRERO	-	1569.11	1624.26	1669.92	1803.30	1867.79
MARZO	-	1434.03	1602.56	1709.70	1817.78	1849.27
ABRIL	-	1709.00	1612.67	1713.18	1836.44	1863.48
MAYO	-	1640.63	1720.91	1824.54	1905.43	1977.83
JUNIO	1689.43	1719.15	1837.37	1934.26	1899.92	-
JULIO	1767.77	1709.85	1841.55	1890.60	2011.05	-
AGOSTO	1513.09	1656.49	1737.09	1848.83	1872.41	-
SEPTIEMBRE	1432.72	1563.92	1644.53	1750.82	1737.50	-
OCTUBRE	1385.51	1476.14	1538.76	1603.70	1726.86	-
NOVIEMBRE	1379.63	1482.32	1523.81	1608.97	1665.23	-
DICIEMBRE	1533.97	1521.31	1604.79	1748.80	1758.46	-

Predicción periodo 5 años



Del anterior análisis se puede observar que la máxima energía para el primer año será en el mes de Mayo de 2004, con un valor de 1521.7 KWh.

Para el horizonte de cinco años, el máximo consumo se producirá en Julio de 2007 con 2011.15 KWh.

MODELIZACIÓN DE LA RED PARA LA CIUDAD DE PINAMAR

Entrenamiento de la red Perceptrón Multicapa

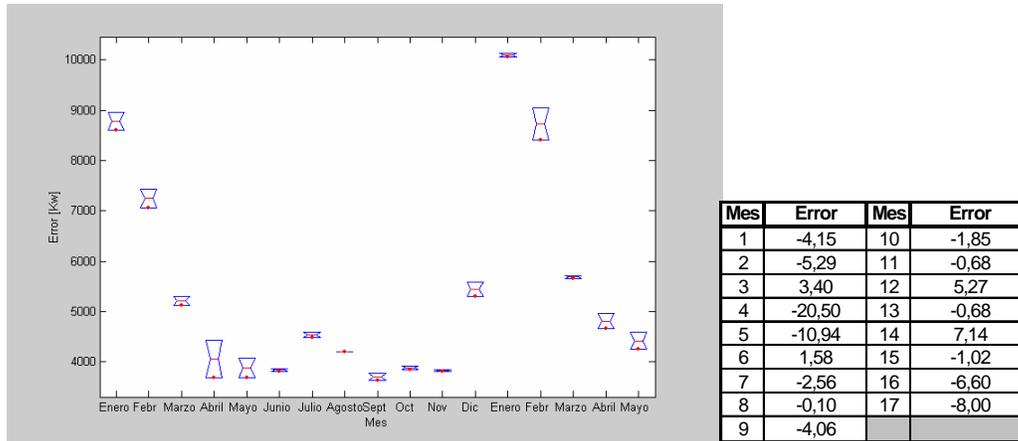
Procediendo de igual manera que en el estudio realizado en la ciudad de Gral. Madariaga, se realizan las simulaciones para los distintos algoritmos detallados con anterioridad utilizando el software Matlab 6.0

Modelización de la red para la ciudad de Pinamar

Entrenamiento de la red Perceptrón Multicapa

Procediendo de igual manera que en el estudio realizado en la ciudad de Gral. Madariaga, se realizan las simulaciones para los distintos algoritmos detallados con anterioridad utilizando el software Matlab 6.0

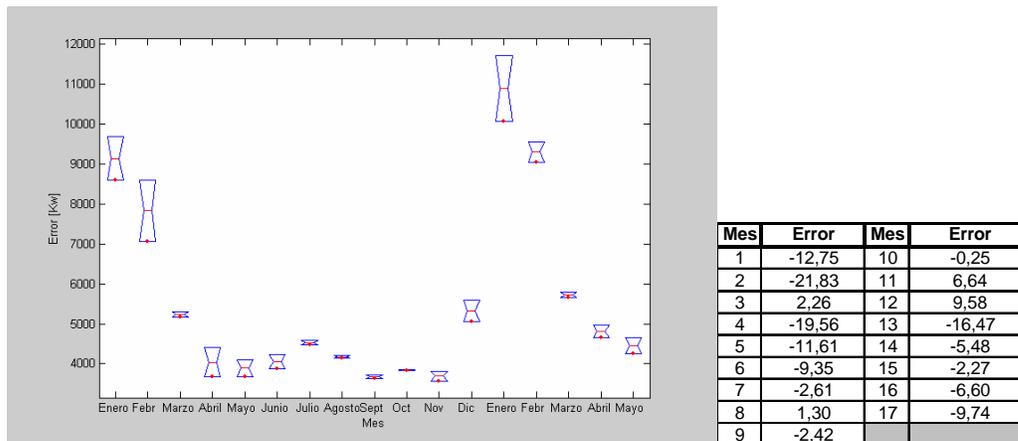
Algoritmo Trainrp



Error absoluto

Error relativo %

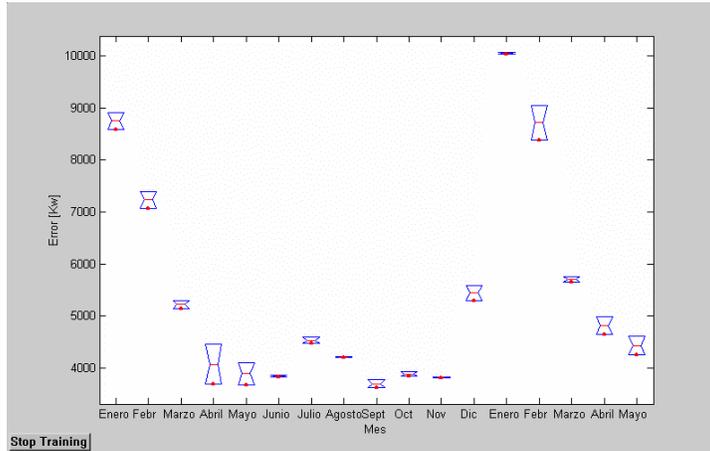
Algoritmo Traingdx



Error absoluto

Error relativo %

Algoritmo Trainscg

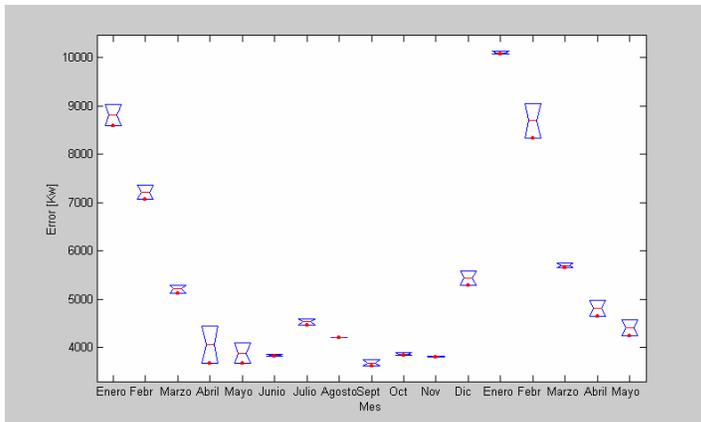


Error absoluto

Mes	Error	Mes	Error
1	-3,65	10	-2,24
2	-4,75	11	-0,15
3	2,95	12	5,21
4	-20,85	13	0,32
5	-11,43	14	7,48
6	1,27	15	-1,76
7	-2,50	16	-7,04
8	-0,18	17	-8,40
9	-3,84		

Error relativo %

Algoritmo Traincgf

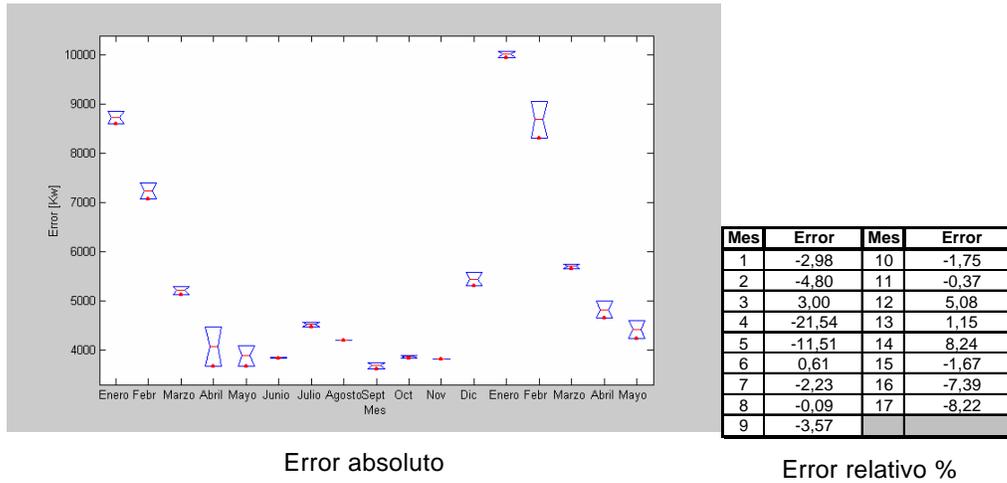


Error absoluto

Mes	Error	Mes	Error
1	-5,09	10	-1,72
2	-4,29	11	-0,28
3	3,33	12	5,37
4	-20,93	13	-0,59
5	-11,22	14	8,00
6	1,29	15	-1,53
7	-2,49	16	-7,11
8	-0,21	17	-7,67
9	-3,27		

Error relativo %

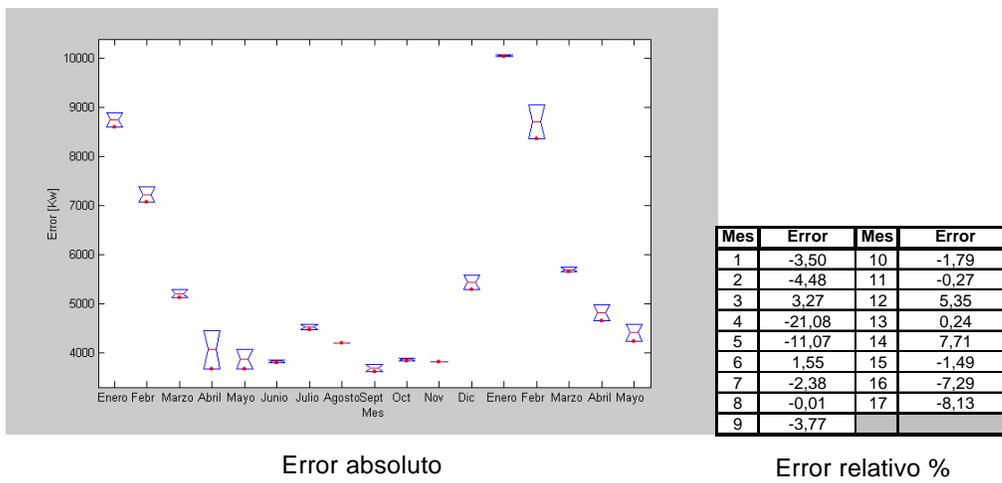
Algoritmo Traincgp:



Error absoluto

Error relativo %

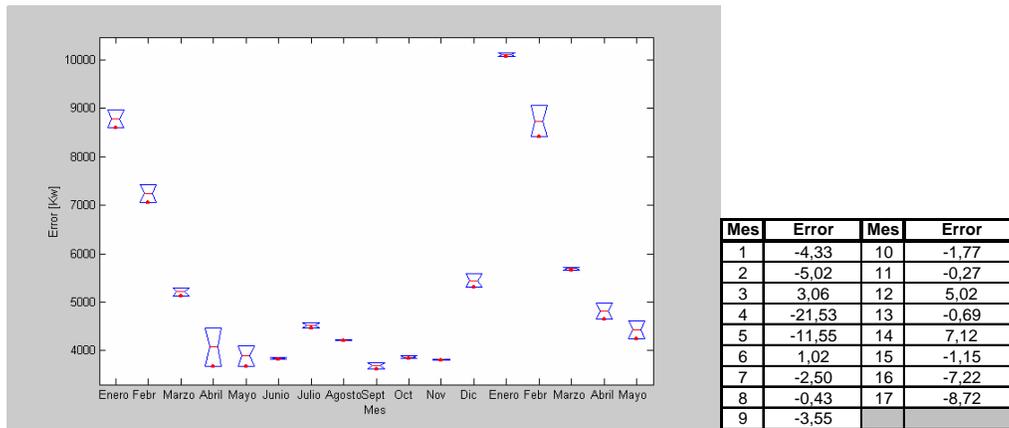
Algoritmo Traincgb



Error absoluto

Error relativo %

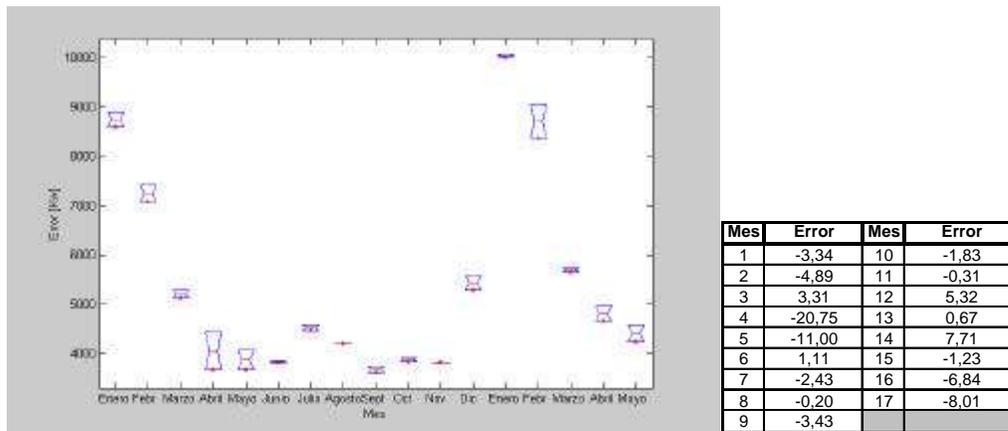
Algoritmo Trainoss



Error absoluto

Error relativo %

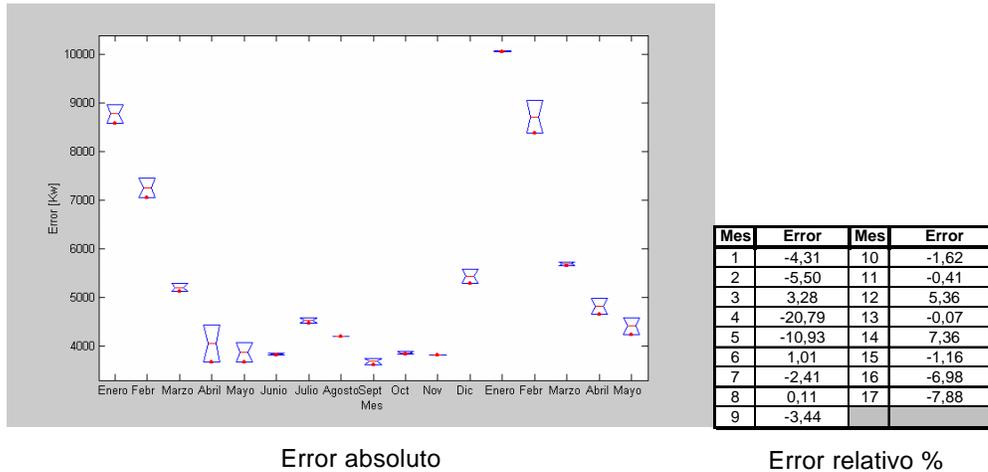
Algoritmo Trainbfg



Error absoluto

Error relativo %

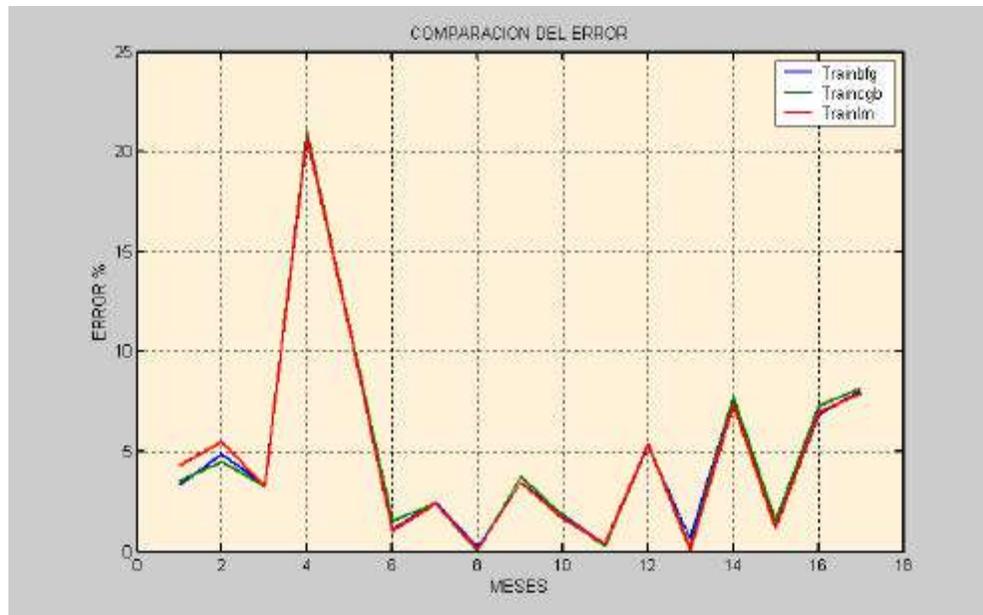
Algoritmo Trainlm



A continuación en la tabla resumida se comparan mes a mes los módulos de los errores relativos cometidos por cada uno de los algoritmos, destacando aquel cuya suma de estos errores sea menor:

	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP
RP	4.154	5.29	3.4	20.5	10.94	1.579	2.557	0.098	4.062
GDX	12.75	21.83	2.26	19.56	11.61	9.35	2.61	1.30	2.42
SCG	3.65	4.75	2.95	20.85	11.43	1.27	2.50	0.18	3.84
CGF	5.09	4.29	3.33	20.93	11.22	1.29	2.49	0.21	3.27
CGP	2.98	4.80	3.00	21.54	11.51	0.61	2.23	0.09	3.57
CGB	3.50	4.48	3.27	21.08	11.07	1.55	2.38	0.01	3.77
OSS	4.33	5.02	3.06	21.53	11.55	1.02	2.50	0.43	3.55
BFG	3.34	4.89	3.31	20.75	11.00	1.11	2.43	0.20	3.43
LM	4.31	5.50	3.28	20.79	10.93	1.01	2.41	0.11	3.44

	OCT	NOV	DIC	ENE	FEB	MAR	ABR	SUMA ERROR
RP	1.85	0.68	5.27	0.68	7.14	1.02	6.60	83.82
GDX	0.25	6.64	9.58	16.47	5.48	2.27	6.60	140.73
SCG	2.24	0.15	5.21	0.32	7.48	1.76	7.04	84.02
CGF	1.72	0.28	5.37	0.59	8.00	1.53	7.11	84.39
CGP	1.75	0.37	5.08	1.15	8.24	1.67	7.39	84.16
CGB	1.79	0.27	5.35	0.24	7.71	1.49	7.29	83.38
OSS	1.77	0.27	5.02	0.69	7.12	1.15	7.22	84.95
BFG	1.83	0.31	5.32	0.67	7.71	1.23	6.84	82.37
LM	1.62	0.41	5.36	0.07	7.36	1.16	6.98	82.63



Error absoluto relativo %

En este caso, los mejores resultados fueron obtenidos al utilizar los algoritmos de gradiente conjugada de Fletcher-Powell (Traincgb), el BFGS Quasi-Newton (Trainbfg) y el Levenberg-Marquardt (Trainlm).

Sin embargo, como los errores no tienen grandes diferencias entre sí, y teniendo en cuenta que los algoritmos Trainrp y Trainscg son más rápidos que los algoritmos de gradiente conjugada de Fletcher-Powell (Traincgb), el BFGS Quasi-Newton (Trainbfg) y el Levenberg-Marquardt (Trainlm), utilizaremos los algoritmos Trainrp y Trainscg.

Basándonos en estas primeras aproximaciones, procederemos al estudio de distintas alternativas utilizando estos dos algoritmos.

Topología de la red

De la misma manera que para el estudio de la ciudad de Gral. Madariaga, se mostrará una tabla resumida^(*) comparativa de las tres mejores configuraciones de la red, en este caso para el algoritmo de entrenamiento Trainrp.

(*) Ver la totalidad de los ensayos en Anexo II

Meses	10 Neuronas	20 Neuronas	25 Neuronas
1	-4,20	-3,48	-5,12
2	-5,47	-4,81	-4,89
3	3,76	3,78	3,01
4	-20,76	-20,66	-20,46
5	-11,04	-10,81	-10,77
6	1,36	0,92	0,96
7	-1,79	-2,42	-2,81
8	-0,50	-0,54	-0,34
9	-2,45	-3,50	-3,53
10	-0,69	-2,10	-1,59
11	0,64	-0,34	-0,18
12	5,32	5,34	6,36
13	-0,17	-0,34	-1,17
14	7,62	7,28	9,50
15	-0,92	-0,71	-0,81
16	-6,96	-7,47	-6,49
17	-8,58	-8,31	-7,93

Error relativo %(Trainrp)



Error

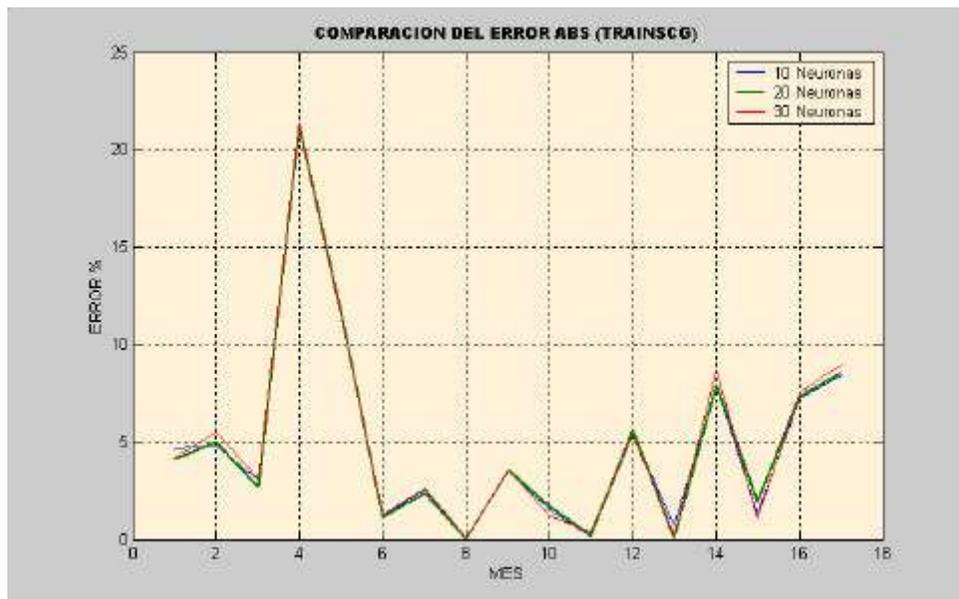
absoluto Trainrp

Tabla comparativa^(*) de los errores de las 17 simulaciones utilizando el algoritmo de entrenamiento Trainscg

^(*) Ver la totalidad de los ensayos en Anexo II

Meses	10 Neuronas	20 Neuronas	30 Neuronas
1	-4,67	-4,12	-4,11
2	-4,78	-4,97	-4,74
3	3,08	2,67	3,04
4	-21,17	-21,15	-21,24
5	-11,33	-11,49	-11,42
6	1,21	1,17	0,65
7	-2,55	-2,36	-2,08
8	-0,02	0,03	0,16
9	-3,51	-3,60	-3,80
10	-1,53	-1,73	-1,65
11	0,14	0,24	-0,05
12	5,40	5,60	5,43
13	-0,70	0,07	-0,01
14	7,85	7,90	9,73
15	-1,36	-1,92	-1,65
16	-7,22	-7,37	-7,41
17	-8,39	-8,50	-8,74

Error relativo %(Trainscg)



Error absoluto Trainscg

Para el primer algoritmo, la configuración con la que se cometió menor error medio absoluto, fue con 10 neuronas, con un $E_{MEDIO}= 4.83 \%$

En cambio para el segundo algoritmo, el error medio absoluto cometido es de $E_{MEDIO}= 4.993 \%$ con 20 neuronas en la capa oculta.

Es importante recalcar que el error es realmente muy similar para las distintas combinaciones de capas ocultas.

Desarrollaremos ahora, la segunda etapa del estudio, en la cual agregamos una segunda capa oculta a la topología de la red.

Procederemos a variar la cantidad de neuronas que componen cada capa, obteniéndose distintos resultados, de los cuales mostraremos en una tabla resumida^(**) los que menor error cometen, para las distintas combinaciones de neuronas, utilizando el Algoritmo Trainrp.

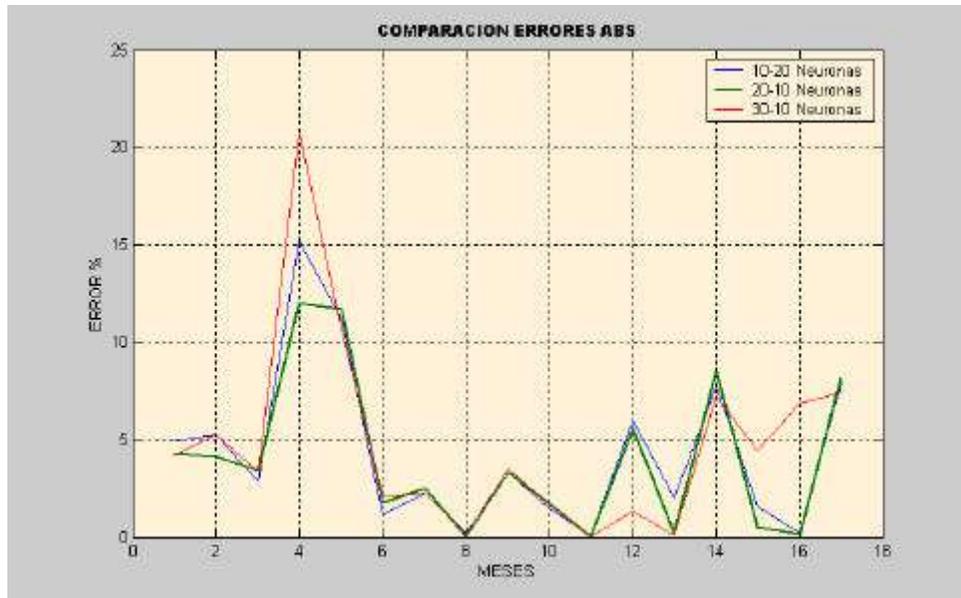
Primer capa	10 Neuronas	20 Neuronas	30 Neuronas
Segunda capa	20 Neuronas	10 Neuronas	10 Neuronas
Mes			
1	-4,93	-4,30	-4,22
2	-5,26	-4,10	-5,25
3	2,90	3,46	3,39
4	-15,17	-11,98	-20,71
5	-11,21	-11,72	-10,62
6	1,12	1,75	2,07
7	-2,24	-2,50	-2,26
8	-0,23	-0,05	0,16
9	-3,31	-3,29	-3,52
10	-1,47	-1,73	-1,67
11	-0,09	0,05	-0,05
12	6,00	5,54	1,34
13	-2,03	-0,19	0,11
14	7,71	8,55	7,25
15	-1,56	-0,51	-4,46
16	-0,21	-0,14	-6,82
17	-7,85	-8,15	-7,40

Error relativo %(Trainrp)

Compararemos gráficamente estas tres últimas topologías, resaltando la que mejor se adecua al problema.

En gráfico resaltamos la curva del error de la topología 20-10 neuronas, la cual tiene un error medio de $E_{MEDIO} = 3.99 \%$ con una desviación estándar menor a las otras tipologías de 3.95 unidades.

(**) Ver la totalidad de los resultados en Anexo II



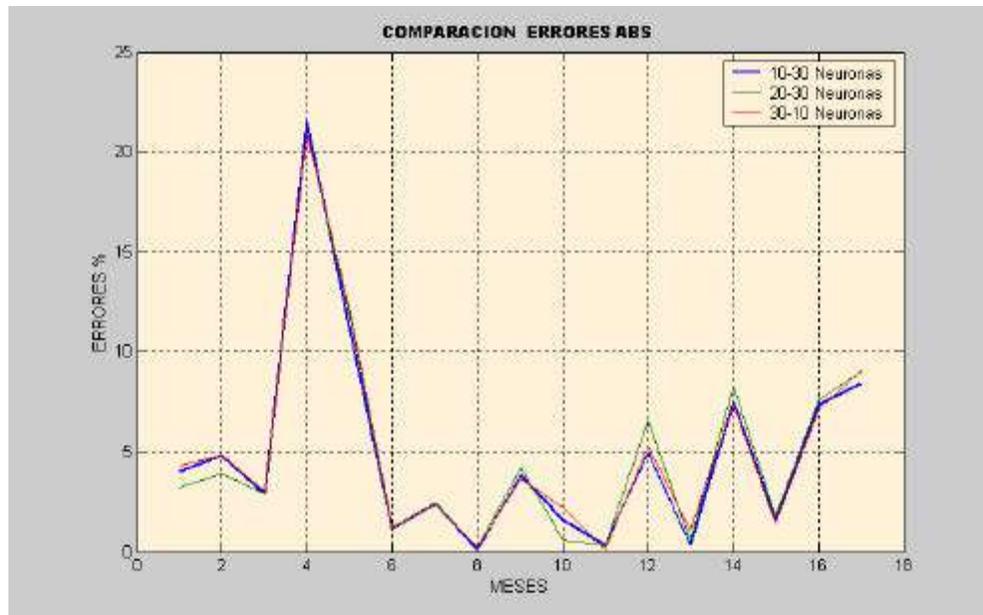
Error absoluto relativo %(Trainrp)

De la misma manera., pero para el algoritmo Trainscg, los mejores resultados obtenidos, se muestran en la siguiente tabla resumida^(**):

Primer capa	10 Neuronas	20 Neuronas	30 Neuronas
Segunda capa	30 Neuronas	30 Neuronas	10 Neuronas
Mes			
1	-3,97	-3,20	-4,30
2	-4,81	-3,86	-4,83
3	2,90	2,91	2,99
4	-21,50	-20,96	-20,95
5	-10,98	-11,71	-11,97
6	1,16	1,16	1,22
7	-2,41	-2,38	-2,32
8	-0,10	-0,22	-0,22
9	-3,79	-4,19	-3,66
10	-1,56	-0,57	-2,19
11	-0,31	-0,27	-0,08
12	4,94	6,53	5,23
13	-0,34	0,54	-1,06
14	7,48	8,27	7,38
15	-1,57	-1,79	-1,43
16	-7,36	-7,59	-7,13
17	-8,39	-8,99	-9,02

Error relativo %(Trainscg)

^(**) Ver la totalidad de los resultados en Anexo II



Error absoluto relativo %(Trainscg)

En este caso la configuración con la que mejor resultado se obtuvo, fue la 10-30 Neuronas en las capas ocultas, con un $E_{MEDIO} = 4.91\%$ con una desviación estándar menor a las otras tipologías de 3.78 unidades.

De la observación de las dos configuraciones, se llega a la conclusión que la configuración que menor error comete en la predicción de la serie temporal para la ciudad de Pinamar, es el Perceptrón multicapa, con algoritmo Backpropagation elástico (trainrp), con dos capas ocultas. La primera con 20 Neuronas y la segunda con 10 Neuronas. Con esta red, estimaremos la serie temporal para la ciudad de Pinamar.

PREDICCIÓN

Resumiremos la estructura de la red Perceptrón Multicapa que se utilizará en la predicción:

- ✓ Para el entrenamiento se utilizará el algoritmo de entrenamiento Trainrp, suministrado por la toolbox de Matlab.
- ✓ Para los pesos iniciales de la red se utilizará la inicialización de Nguyen-Widrow.
- ✓ La topología de la red es de dos capas ocultas, la primera con 20 Neuronas y la segunda con 10 Neuronas.

- ✓ Se utilizarán 137 valores históricos de consumo como salida o target.
- ✓ El número de vectores de entrenamiento es de 110, debido a que cada vector de entrenamiento posee once valores de consumo anteriores al de la predicción.

Para la predicción de la demanda, se utilizarán dos redes distintas para los dos distintos horizontes de predicción.

Para el horizonte de un año, se utilizará la red [PIN1], que tiene la característica de calcular luego cada predicción, la nueva tendencia de la serie.

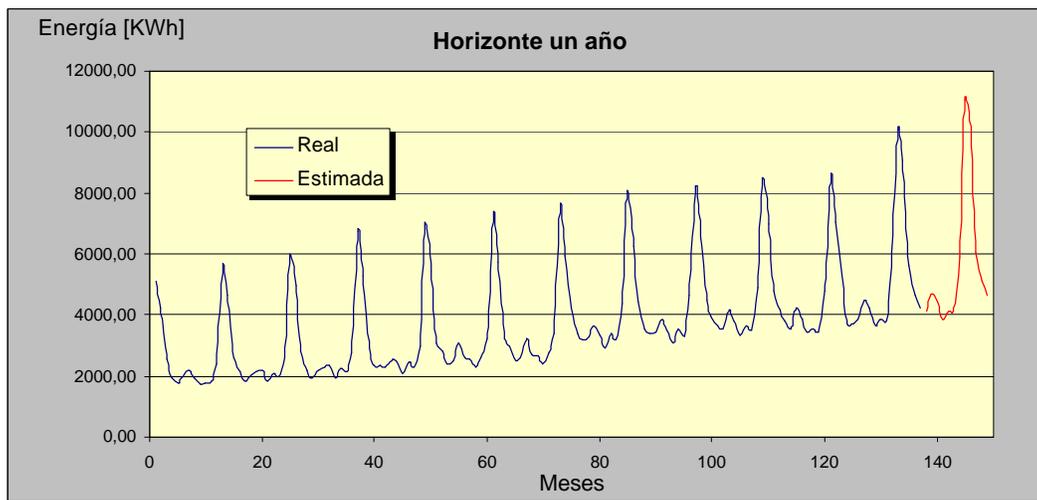
Para el horizonte de cinco años, se utilizará la red [PIN2], que tiene la característica de no calcular la tendencia de la serie, sino que una vez finalizada las 60 predicciones (los cinco años), se le suma la tendencia calculada para la serie real.

Presentamos aquí, la tabla y el gráfico para la predicción del primer año correspondiente a la ciudad de Pinamar, periodo junio de 2003 hasta mayo 2004.

MES	JUN	JUL	AGO	SEP	OCT	NOV
<i>KWh</i>	4096.80	4681.03	4412.75	3872.05	4120.94	4113.47

MES	DIC	ENE	FEB	MAR	ABR	MAY
<i>KWh</i>	5899.29	11083.42	9911.68	6073.85	5125.04	4628.13

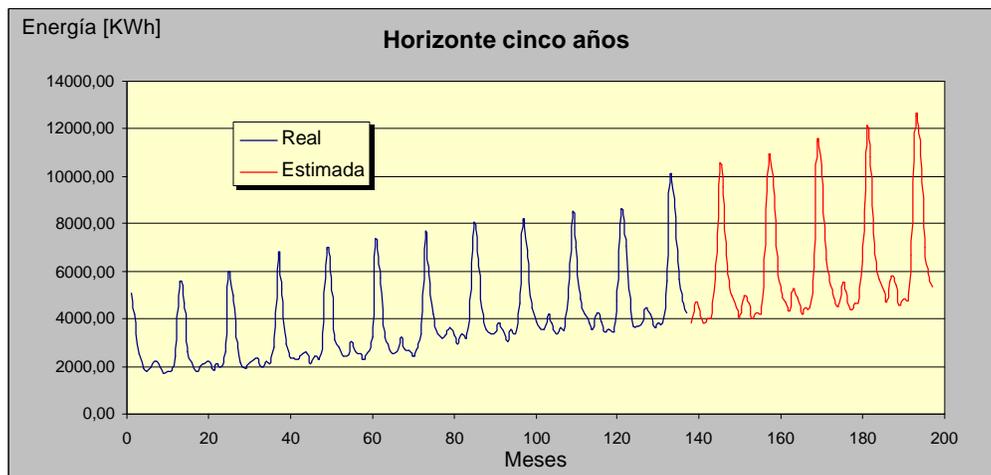
Predicción periodo de un año



A continuación se presenta la tabla y el gráfico correspondiente a la simulación de la red [PIN2], para un horizonte de cinco años (periodo junio de 2003 a mayo 2008), en Kwh.

Mes	2003	2004	2005	2006	2007	2008
ENERO	-	10499.53	10909.04	11460.49	12051.02	12557.29
FEBRERO	-	9573.79	10003.19	10455.92	10810.38	11267.55
MARZO	-	5916.52	6211.39	6466.88	6749.65	6997.31
ABRIL	-	4942.21	5205.09	5427.60	5668.96	5893.52
MAYO	-	4463.12	4714.15	4921.02	5144.92	5343.57
JUNIO	3832.55	4062.30	4312.46	4522.59	4709.65	-
JULIO	4724.55	4983.95	5253.02	5511.04	5777.44	-
AGOSTO	4463.50	4673.66	4907.37	5143.18	5389.93	-
SEPTIEMBRE	3801.17	3993.83	4203.88	4395.03	4584.64	-
OCTUBRE	4023.02	4235.97	4432.64	4618.38	4805.75	-
NOVIEMBRE	3999.65	4209.82	4429.97	4618.18	4780.81	-
DICIEMBRE	5713.39	5971.56	6192.43	6419.65	6673.56	-

Predicción periodo de 5 años.



Del anterior análisis se puede observar que la máxima energía para el primer año será en el mes de enero, con un valor de 11083.42 KWh.

Para el horizonte de cinco años, el máximo consumo se producirá en enero de 2008 con 12557.29 KWh.

RESUMEN DEL CAPÍTULO TULO

En el desarrollo de este capítulo, se explicó y analizó el modelado predictivo basado en las Redes Neuronales Artificiales, siendo los resultados obtenidos óptimos.

De los análisis efectuados a la muestra correspondiente a la ciudad de Gral. Madariaga, se observó que las redes neuronales no respondían satisfactoriamente

cuando se la entrenaba con la totalidad de los valores históricos. Se observa en la gráfica de la serie temporal de Gral. Madariaga una diferencia notoria en la representación de los datos históricos.

Por ello, se clasificaron los datos utilizando una red competitiva (Kohonen). Esta red clasificó los valores con los cuales se procedió a realizar la estimación de los valores de consumo.

En el estudio de la muestra perteneciente a la ciudad de Pinamar, se observa en la representación de la serie temporal, picos muy pronunciados en los meses de verano, algo previsible dado la característica turística de la ciudad.

A pesar de esto, la red utilizada se adaptó, con algunas modificaciones en su topología con respecto a Gral. Madariaga, satisfactoriamente.

En resumen, el modelado predictivo basado en RNA, se adapta a distintas características de las series temporales, siendo el resultado predictivo satisfactorio.

Las predicciones para las dos muestras, dieron los siguientes resultados relevantes:

Pinamar

- ✓ Máximo consumo en el primer año estimado, se observa en el periodo estival, con un valor de 10499,55 MWh correspondiente al mes de enero de 2004.
- ✓ En el desarrollo predictivo, para los cinco años estimados, los máximos consumos anuales, corresponden a los meses de verano, igual a lo predicho por el modelo tradicional.
- ✓ Máximo consumo, para los cinco años se observa para enero de 2008, con un valor de 12547,29 MWh.

Gral. Madariaga



- ✓ Máximo consumo en el primer año estimado, se observa en el periodo invernal, con un valor de 11767,77 MWh correspondiente al mes de julio de 2003.
- ✓ En el desarrollo predictivo, para los cinco años estimados, los máximos consumos anuales, corresponden a los meses de invierno.
- ✓ Máximo consumo, para los cinco años se observa para julio de 2007, con un valor de 2011,05 MWh.

CAPÍTULO 4: ANÁLISIS COMPARATIVO

En este capítulo, expondremos las conclusiones a las cuales hemos arribado luego de la comparación de las distintas alternativas planteadas. Basados en éstas conclusiones representaremos sobre una plataforma de información Geo-referencial los datos estimados.

EVALUACIÓN DE LOS RESULTADOS

Aplicación a un caso real

Para demostrar las bondades de la preedición de la demanda, utilizaremos Redes Neuronales Artificiales y el modelado tradicional, para el cálculo de potencia pico y fuera de pico de la ciudad de General Madariaga. Luego, haremos el cálculo económico del desempeño de la compañía utilizando las potencias pico y fuera de pico calculadas por cada método.

Todos los años, los clientes en media tensión deben realizar el llamado contrato de potencia. En este contrato, se compra una potencia que será pagada todos los meses aunque la empresa no la necesite.

Además, si la empresa se excediera de la potencia contratada, cada Kw de más debe ser pagado un 50 % más del precio de la potencia contratada.

Es por esto, que para el cálculo de las potencias con Redes Neuronales, se utilizaron las redes [PICO], [RESTO] y [VALLE]⁽¹⁾. Las redes fueron entrenadas con datos correspondientes al periodo Enero de 1992 a Diciembre de 2001, y se estimó el consumo de estas potencias para el año 2002.

A continuación, presentamos una tabla donde se resumen los resultados de predicción para cada uno de los métodos.

⁽¹⁾ Ver Anexo III, archivos M

Mes	TRADICIONAL		RED NEURONAL	
	P. PICO [Kw]	P. FUE PICO [Kw]	P. PICO [Kw]	P. FUE PICO [Kw]
ENERO	3806,67	3292,04	3588,76	2742,30
FEBRERO	3539,55	2982,16	3364,60	2426,60
MARZO	3749,70	3158,88	3513,54	2573,20
ABRIL	3772,83	3069,62	3583,98	2546,80
MAYO	4012,06	3284,77	3707,11	2915,40
JUNIO	4040,23	3445,04	3530,12	2629,70
JULIO	3946,35	3316,47	3452,88	2754,70
AGOSTO	3782,55	3218,01	3425,70	2704,10
SEPTIEMBRE	3672,61	3032,29	3478,71	2324,70
OCTUBRE	3558,87	2877,09	3257,34	2167,40
NOVIEMBRE	3669,29	2948,14	3299,63	2067,30
DICIEMBRE	3724,18	3017,95	3418,30	2210,40

En base a estos resultados, calculamos las potencias pico y fuera de pico que minimicen el precio pagado por la compañía y son los siguientes:

TRADICIONAL		RED NEURONAL	
P. PICO [Kw]	P. FUE PICO [Kw]	P. PICO [Kw]	P. FUE PICO [Kw]
3700,00	3000,00	3400,00	2400,00

Luego, con estas potencias calculadas y teniendo en cuenta la potencia real consumida, calculamos el gasto en concepto de energía que deberá pagar la compañía.

TRADICIONAL		RED NEURONAL		REAL	
P. PICO [\$]	P. F. PICO [\$]	P. PICO [\$]	P. F. PICO [\$]	P. PICO [\$]	P. F. PICO [\$]
398268.00	139119.00	373134.00	133148.00	369030.00	130116.00
TOTAL [\$]	537387.00	TOTAL [\$]	506282.00	TOTAL (\$)	499146.00

Como se puede observar en la tabla, utilizando las Redes Neuronales la compañía pago un sobrepago de **\$ 7.136,00** debido a los errores cometidos en la estimación de la potencia necesaria.

Sin embargo, si se utilizan los datos estimados por el método tradicional, el sobrepago se eleva a **\$ 38.241,00** es decir **\$ 31.105,00** más en concepto de potencia disponible.

ANÁLISIS DE RNA Y TÉCNICA TRADICIONAL

Debido a que existen numerosas técnicas para modelar el comportamiento de las demandas, diferenciándose entre ellas en aspectos tales como, información necesaria para su empleo, el modelo matemático que representa a esa técnica y las herramientas de cálculos necesarias para obtener los resultados buscados, hemos elegido dos técnicas distintas. Siendo estas, el modelado predictivo tradicional y el modelado de redes neuronales.

Por lo tanto basándonos en los resultados obtenidos por medio de los ensayos y cálculos efectuados a lo largo del trabajo, podemos discriminar que método se adapta mejor a la predicción de la demanda eléctrica de los dos tipos de muestras.

Es necesario aclarar que si bien existen, como se mencionó con anterioridad, diversos métodos predictivos de la demanda de consumo eléctrico, no utilizamos en este trabajo el modelo ARIMA, debido a la complejidad del método (modelo estocástico). Por lo tanto los modelos predictivos sujetos al estudio, en este proyecto, son los mencionados en los capítulos 2 y 3.

Seguidamente, mostraremos los errores obtenidos en los ensayos, para cada uno de los métodos aplicados, en cada muestra:

- ✓ Para realizar la comparación, se tomaron para ambos modelos, los datos correspondientes al periodo Enero de 1992 a Diciembre de 2001, reservando los últimos 17 valores para comparar el error cometido.
- ✓ En el ajuste de la línea de tendencia, se utilizaron dos curvas, la lineal y la cuadrática.
- ✓ Para el modelado RNA, se utilizaron las dos mejores topologías, con el algoritmo de entrenamiento Trainrp.

		METODO TRADICIONAL		METODO R.N.A	
MES		Error-lineal %	Error-cuadrática %	Error %20N-20N	Error %20N-10N
1	ENERO	0.52	2.86	-3.08	-5.75
2	FEBRERO	-1.54	1.05	-9.20	-5.13
3	MARZO	-0.13	2.63	-3.75	-4.81
4	ABRIL	0.23	3.19	-4.30	-2.85
5	MAYO	-3.50	-0.21	-6.26	-6.47
6	JUNIO	0.54	3.92	-0.71	0.10
7	JULIO	-13.12	-9.02	-1.16	-0.70
8	AGOSTO	-14.45	-10.06	-4.03	-6.14
9	SEPTIEMBRE	-12.19	-7.63	-6.99	-1.87
10	OCTUBRE	-13.84	-8.96	-4.12	-5.34
11	NOVIEMBRE	-15.38	-10.17	-5.41	-3.75
12	DICIEMBRE	-14.24	-8.81	-3.07	-3.63
13	ENERO	0.33	5.30	-0.34	1.03
14	FEBRERO	-0.57	4.68	-1.05	-0.48
15	MARZO	-0.01	5.45	-1.80	-3.40
16	ABRIL	-2.10	3.72	-9.16	-4.05
17	MAYO	-1.84	4.21	-3.45	-4.75
SUMA E ABS.		94.539	91.879	67.898	60.261

Errores Obtenidos en estimación para Gral. Madariaga

		METODO TRADICIONAL		MÉTODO R.N.A	
MES		Error-lineal %	Error-cuadrática %	Error %10N-20N	Error %20N-10N
1	ENERO	-18.24	-18.81	-4.93	-4.30
2	FEBRERO	-15.48	-16.11	-5.26	-4.10
3	MARZO	5.45	4.87	2.90	3.46
4	ABRIL	-14.73	-15.52	-15.17	-11.98
5	MAYO	-4.28	-5.07	-11.21	-11.72
6	JUNIO	-1.80	-2.64	1.12	1.75
7	JULIO	0.75	-0.14	-2.24	-2.50
8	AGOSTO	2.71	1.77	-0.23	-0.05
9	SEPTIEMBRE	0.64	-0.39	-3.31	-3.29
10	OCTUBRE	-1.32	-2.45	-1.47	-1.73
11	NOVIEMBRE	-0.52	-1.71	-0.09	0.05
12	DICIEMBRE	9.58	8.44	6.00	5.54
13	ENERO	-6.58	-8.01	-2.03	-0.19
14	FEBRERO	4.92	3.57	7.71	8.55
15	MARZO	6.60	5.21	-1.56	-0.51
16	ABRIL	4.20	2.70	-0.21	-0.14
17	MAYO	4.73	3.16	-7.85	-8.15
SUMA E ABS.		102.537	100.559	73.284	67.982

Errores Obtenidos en estimación para Pinamar

De los resultados obtenidos se desprende, que el modelo basado en redes neuronales artificiales, es ampliamente superior al modelo tradicional, para los dos distintos tipos de curvas estudiados. La suma de los errores absolutos, refleja lo antes expresado.



Los valores obtenidos de los modelos tradicionales sobre la ciudad de Gral. Madariaga, fluctúan en un **máximo del 10.17% y un mínimo de 0.21% y entre 18.81% y 0.14%** para Pinamar, en el mejor de los casos.

En cambio, en el modelo basado en redes neuronales, no solo la suma de los errores absolutos fueron menores, sino también su dispersión.

CAPÍTULO 5: REPRESENTACIÓN DE LOS RESULTADOS

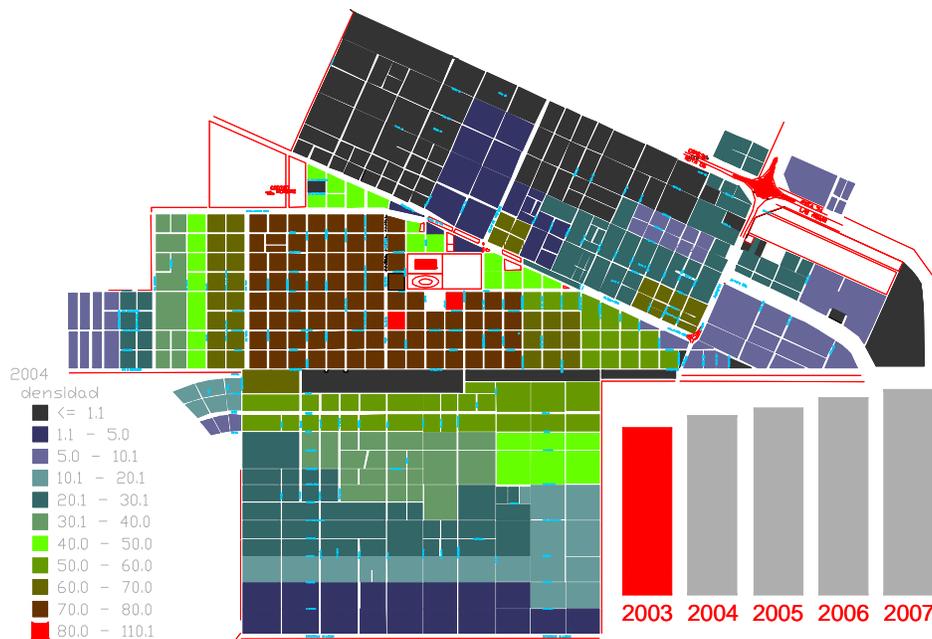
En esta sección del trabajo se representaran los resultados obtenidos por medio de mapas temáticos, utilizando un software de información geográfica.

Una vez obtenidos los datos de consumo para ambas ciudades, se volcaron sobre una base de datos para poder implementar los mapas temáticos mediante el software Autodesk Map de información geográfica, con el objetivo de visualizarlos a través del tiempo.

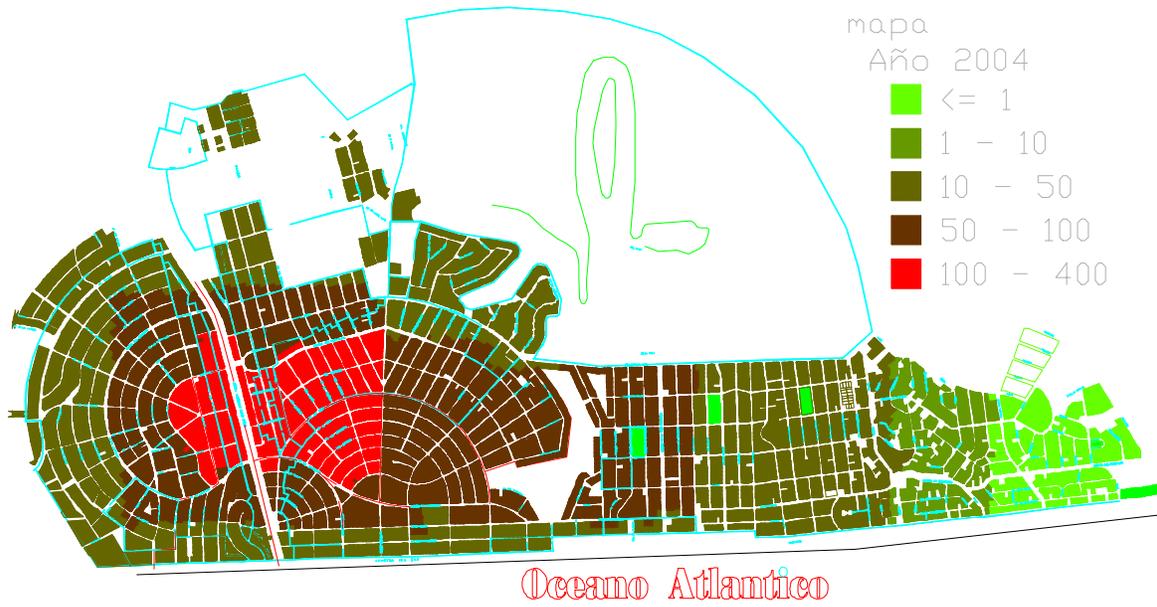
Sobre el mapa de la ciudad de Gral. Madariaga y de Pinamar, se distribuyó la densidad de población a través de los cinco años de estudio, y para estos el consumo energético.

Gracias a esta herramientas, se puede observar gráficamente, la dinámica de los consumos para ambas ciudades; siendo esta presentación de fácil comprensión para personas no conocedoras del tema.

En la carpeta *Mapas* del CD adjunto, se entregan el resto de los mapas temáticos.



Mapa temático correspondiente a la ciudad de Gral. Madariaga



Mapa temático correspondiente a la ciudad de Pinamar

CONCLUSIONES

Modelo Tradicional.

En cuanto al método tradicional, se observa en ambos casos, que la línea de tendencia ajustada por la curva hiperbólica cuadrática, es levemente superior a la lineal. A pesar de esto, este tipo de ajuste tiene inconvenientes en la predicción de la serie temporal en el mediano y largo plazo, puesto que la ecuación que la describe, tiende a aumentar el error. Por este motivo, en este trabajo se utilizó la curva lineal en el ajuste por mínimos cuadrados de la línea de tendencia.

Este método posee una importante desventaja, la estimación no toma en cuenta la componente cíclica e irregular, ya que esta última no es posible modelarla matemáticamente. Tampoco permite, considerar el aporte de otras variables distintas a los datos de consumo históricos.

Pero tiene como ventaja su fácil implementación, ya que basta con solo armar una planilla de cálculo.

Modelo Neuronal

En la aplicación de este modelo en el análisis predictivo de la serie temporal, podemos concluir:

- ✓ Es una técnica nueva, con múltiples aplicaciones en diversas áreas, en particular la estimación y predicción de demandas, el cual fue tema de estudio en este trabajo.
- ✓ En la elección de la estructura de la red, no existe un criterio establecido, para decidir su arquitectura final. De los distintos ensayos de prueba y error, concluimos que la adición de dos capas ocultas en una red multicapa, provoca que el error disminuya, pero más capas, no mejoran el error y extienden el tiempo de entrenamiento.
- ✓ En nuestro caso, utilizamos la inicialización Nguyen-Widrow de los pesos neuronales, debido a que inicializando los pesos en forma aleatoria la red no tenía la misma performance.

- ✓ De los distintos algoritmos utilizados, de los que mejores resultados se obtuvieron fueron el Rprop (Trainrp) y el gradiente conjugado escalar (Trainscg).
- ✓ La cantidad de valores históricos que componen a los vectores de entrenamiento, no siguen un criterio determinado, sino que es el resultado de distintos ensayos según el problema. Así, para la ciudad de Madariaga, la cantidad óptima de valores históricos fue de seis; mientras que para la ciudad de Pinamar fue de once.
- ✓ El modelo R.N.A, permite considerar variables exógenas a la red, como cantidad de habitantes, factores climáticos y económicos.
- ✓ Permiten trabajar con menor cantidad de datos históricos que los modelos tradicionales.
- ✓ Capacidad de filtrar datos, que perjudiquen el aprendizaje de las redes.
- ✓ Requiere mayores recursos en cuanto a su implementación, ya que se necesitó un software específico (Matlab 6.0) para su entrenamiento y posterior simulación.
- ✓ Los algoritmos Powell Beale CG (Traincgb) y Levenberg Marquardt (Trainlm), tiene una performance buena con respecto al error, pero son excesivamente lentos en su ejecución.

Del análisis comparativo de las dos muestras, se desprende que el modelo RNA es superior frente al modelo tradicional tanto en el corto como en el largo plazo en las dos ciudades de características de consumo tan dispares.

De los valores comparados, el modelo RNA no solo posee un error menor, sino que la dispersión del error es menor.

Es de destacar la importancia de la estimación y cuan precisa sea esta, ya que es una herramienta de vital importancia en el mundo actual; cuanto mejor prediga el futuro, mejor se estará preparado para él.



Finalmente, podemos intuir que el modelo basado en RNA, es una poderosa herramienta que con el paso del tiempo desplazará a los métodos tradicionales en el cálculo predictivo.

FUTURO DE LAS RNA EN LA INGENIERIA ELÉCTRICA



Como se mencionó a lo largo de este trabajo, la principal ventaja de las redes neuronales es su capacidad para aprender de su experiencia, de generalizar, de extraer características esenciales a partir de datos aparentemente irrelevantes.

Debido a que es una técnica nueva, presenta limitaciones; pero su fácil implementación y la calidad de sus respuestas son un motivo más que suficiente para que se continúe investigando y desarrollando esta técnica.

Por lo tanto, que se profundice en el tema y su aplicación en la ingeniería eléctrica mediante la inserción de la teoría de redes neuronales y posterior dictado en el programa de la carrera.

Posibles aplicaciones serían, la estimación diaria de demanda de energía, flujo de carga, predicción de fallas de aislación, control de inyección de armónicos, como también la continuación de este trabajo en el campo del desarrollo de un GIS.

BIBLIOGRAFÍA

Biran, A.; Breiner, M.; *Matlab for engineers*; Addison-Wesley Publishing Company; U.S.A.1999.

Piegel, Murray R; Teoría y problemas de probabilidad y estadística; McGraw-Hill;

Toranzos, Fausto I.; Teoría estadísticas y aplicaciones; editorial Kapeluz S.A, 1971

Levin, Richar I & Rubin, David S.; Estadística para administradores; Prentice-Hall Hispanoamericana S.A, 1996

Freman, James A. & Skapura, David M.; Redes Neuronales; Ediciones Días de Santos S.A.

Haykin, Simon ; Neural Networks: A comprehensive foundation; 1993

Hilera, José R. & Martinez, Victor J.;Redes neuronales artificiales; Alfaomega S.A, 2000

Harper, Gilberto E.; V2, Líneas de transmisión y redes de distribución de potencia eléctrica ; Editorial Limusa, 1978

Autodesk ; Autocad Map 2000 ; Autodesk, Inc 1999

Prado, Pedro O; Agüero, Carlos; Passoni, Isabel; Clara, Fernando ; Paper Third Latin-American Congress, Propuesta de utilización de las redes neuronales para la predicción de la demanda eléctrica en un sistema de distribución.

Valiente, Stella M. & Passoni, Isabel; Apuntes de cátedra “Tecnologías emergentes” para la toma de decisiones.

Di Menna; Romeo; Anaut ; Apunte de cátedra “Sistema eléctrico de potencia”.

Recopilación de trabajos; 3^{ra} convención y exposición sobre la distribución de energía eléctrica 1982 A.E.A.

Paginas web

<http://www.lawebdelprogramador.com>; Tutorial de Matlab

<http://www.gc.ssr.upm.es/inves/neural/ann2/anntutorial.html> Tutorial R.N.A

http://www.infor.uva.es/biometria/Documentos/informes_uva/EstadoArte/EstadoArte/EstadoArte.html Tutorial series Temporales R.N.A

<http://www.aern.net/cas/downloads.htm> Tutorial R.N.A



ANEXOS