



ESCUELA SUPERIOR DE INGENIEROS

MÁSTER EN SISTEMAS DE ENERGÍA ELÉCTRICA

**"PREDICCIÓN DE LA DEMANDA
ELÉCTRICA: COMPARATIVA
ARIMA – REDES NEURONALES
MEDIANTE SOFTWARE SPSS"**

AUTOR

FRANCISCO MANUEL REYES LORA

TUTOR

JESÚS M. RIQUELME SANTOS

FECHA

JUNIO 2016

ÍNDICE

CAPÍTULO I: ESTADO DEL ARTE

1.- INTRODUCCIÓN.....	1
2.- NECESIDAD DE PREDECIR LA DEMANDA	2
3.- CARACTERÍSTICAS GENERALES DE LA DEMANDA	4
4.- DIFICULTADES EN LA PREDICCIÓN DE DEMANDA	4
4.1.- Proceso de estimación y variables significativas	5
4.2.- Uso de los modelos.....	6
5.- MODELOS Y TÉCNICAS DE PREDICCIÓN	6
5.1.- Regresión múltiple	7
5.2.- Alisado exponencial	9
5.3.- Series de tiempo estocásticas	9
5.3.1.- Modelo AR.....	9
5.3.2.- Modelo ARMA	10
5.3.3.- Modelo ARIMA	10
5.4.- Modelado ARMAX basado en algoritmos genéticos.....	10
5.5.- Lógica difusa	10
5.6.- Redes neuronales	11
5.7.- Sistemas expertos.....	12
6.- COMPARACIÓN DE TÉCNICAS	12
7.- CONCLUSIONES.....	13

CAPÍTULO II: TEORÍA

SERIES TEMPORALES	15
1.- INTRODUCCIÓN.....	15
2.- ESTUDIO DE LAS SERIES TEMPORALES.....	16
2.1.- Modelado clásico de series temporales	16
2.2.- Enfoque actual de las series temporales: Modelos ARIMA	18
2.2.1.- Procesos no estacionarios homogéneos	21
2.2.2.- Corrección de variaciones estacionales	22
2.2.3.- La función de autocorrelación parcial (FACP)	23
2.2.4.- Tipos de procesos de series temporales	23
REDES NEURONALES	26
1.- INTRODUCCIÓN.....	26
2.- CONCEPTOS BÁSICOS DE LAS REDES NEURONALES	26
3.- CLASIFICACIÓN DE LAS REDES NEURONALES.....	30
3.1.- Según el número de capas	31

3.2.- Según la forma de conexión	32
3.3.- Según la forma de asociación.....	32
3.4.- Según la dinámica de actuación	33
4.- DEFINICIÓN DE PARÁMETROS	33
4.1.- Arquitectura de red.....	33
4.2.- Proceso de aprendizaje	34
4.3.- Criterios de normalización y parada.....	36
5.- EL PERCEPTRÓN MULTICAPA	40
6.- LA REGLA DE APRENDIZAJE BACKPROPAGATION.....	41
7.- PREDICCIÓN DE DEMANDA MEDIANTE REDES NEURONALES.....	42

CAPÍTULO III: DESARROLLO

1.- ORIGEN Y ESTRUCTURA DE LOS DATOS	46
2.- METODOLOGÍA.....	48
3.- MODELO ARIMA.....	49
3.1.- Procedimiento	49
3.2.- Conjuntos de datos históricos y de validación	50
3.3.- Análisis de la serie temporal	51
3.3.1.- Gráfico de secuencia	51
3.3.2.- Estacionalidad.....	52
3.4.- Desarrollo del modelo	53
3.4.1.- Preparación del modelo	53
3.4.2.- Validación.....	60
4.- REDES NEURONALES	64
4.1.- Procedimiento	65
4.2.- Desarrollo del modelo	66
4.2.1.- Pre-procesamiento de los datos	66
4.2.2.- Diseño de la red neuronal	67
4.2.2.1.- Arquitectura de la red.....	67
4.2.2.2.- Topología de la red neuronal	69
4.2.3.- Implementación de la red neuronal artificial	71
4.2.3.1.- Conjuntos de entrenamiento y prueba	71
4.2.3.2.- Resumen del modelo	72
4.2.4.- Validación.....	73

CAPÍTULO IV: RESULTADOS Y CONCLUSIONES

1.- INTRODUCCIÓN.....	75
2.- ARIMA	76
2.1.- Caso 1 – Punta de demanda (Miércoles 4-2-2015).....	76
2.2.- Caso 2 – Laborable (Martes 12-5-2015).....	78
2.3.- Caso 3 – Fin de semana (Sábado 3-10-2015).....	81

3.- REDES NEURONALES	83
3.1.- Caso 1 – Punta de demanda (Miércoles 4-2-2015)	83
3.2.- Caso 2 – Laborable (Martes 12-5-2015)	85
3.3.- Caso 3 – Fin de semana (Sábado 3-10-2015).....	88
4.- COMPARATIVA DE RESULTADOS. ERROR MAPE	90
4.1.- Caso 1 – Punta de demanda (Miércoles 4-2-2015)	90
4.2.- Caso 2 – Laborable (Martes 12-5-2015)	92
4.3.- Caso 3 – Fin de semana (Sábado 3-10-2015).....	94
5.- VENTAJAS E INCONVENIENTES. TABLA RESUMEN	96
6.- CONCLUSIONES.....	97

CAPÍTULO V: BIBLIOGRAFÍA

1.- BIBLIOGRAFÍA.....	99
-----------------------	----

CAPÍTULO VI: ANEXOS

1.- ARIMA	102
1.1.- Caso 1	102
1.2.- Caso 2	104
1.3.- Caso 3	106
2.- REDES NEURONALES	108
2.1.- Caso 1	108
2.2.- Caso 2	109
2.3.- Caso 3	110

ÍNDICE DE FIGURAS

1.- Representación de una serie temporal	16
2.- Serie temporal con tendencia.....	17
3.- Descomposición de una serie temporal en sus componentes.....	18
4.- Proceso estocástico estacionario.....	19
5.- Función de autocorrelación parcial	20
6.- Modelo esquemático de una neurona artificial	27
7.- Representación esquemática y matricial de una capa de neuronas	29
8.- Ejemplo de una red neuronal de 3 capas	29
9.- Representación matricial de una red de 3 capas.....	30
10.- Red monocapa	31
11.- Red multicapa	31
12.- Red neuronal recurrente	32
13.- Algoritmos y paradigmas de aprendizaje	34
14.- Ejemplo del concepto de generalización.....	37
15.- Regla de detención temprana basada en validación cruzada	39
16.- Disposición de una red ejemplo de 3 capas	42
17.- Estructura típica de una red neuronal para predicción de demanda	44
18.- Seguimiento de la demanda de energía para un día determinado.....	46
19.- Valores de las curvas de demanda	47
20.- Datos importadas a Excel y clasificados de acuerdo a diferentes criterios	47
21.- Gráfico de secuencia para la Hora 12 del Caso 1	52
22.- Datos importados a SPSS.....	53
23.- Definición de periodicidad	54
24.- Períodos de estimación y predicción.....	55
25.- Coeficientes del modelo ARIMA	56
26.- Gráfica FAC para la Hora 12 del Caso 1	58
27.- Gráfica FACP para la Hora 12 del Caso 1	59
28.- Selección de estadísticos.....	61
29.- Selección de gráficos	61
30.- Gráfica de error absoluto porcentual medio.....	62
31.- Selección de escalado de entradas	67
32.- Esquema general de la Red Neuronal	68
33.- Definición de la topología de la red	69
34.- Red neuronal para la Hora 12 del Caso 1.....	70
35.- Definición de conjuntos de entrenamiento y prueba.....	72
36.- Curvas de demanda. ARIMA – Caso 1	77
37.- Curvas de demanda. ARIMA – Caso 2	79

38.- Curvas de demanda. ARIMA – Caso 3	82
39.- Curvas de demanda. REDES NEURONALES – Caso 1	84
40.- Curvas de demanda. REDES NEURONALES – Caso 2	86
41.- Curvas de demanda. REDES NEURONALES – Caso 3	89
42.- Comparativa de curvas de demanda. Caso 1	91
43.- Comparativa de curvas de demanda. Caso 2	93
44.- Comparativa de curvas de demanda. Caso 3	95
45.- Gráfica de error absoluto porcentual promedio – Caso 1	103
46.- Gráfica de error absoluto porcentual promedio – Caso 2	105
47.- Gráfica de error absoluto porcentual promedio – Caso 3	107

ÍNDICE DE TABLAS

1.- Identificación de modelos.....	25
2.- Estadísticos descriptivos para la Hora 12 del Caso 1	51
3.- Coeficientes del modelo ARIMA para la Hora 12 del Caso 1	60
4.- Estadísticos del modelo ARIMA para la Hora 12 del Caso 1.....	63
5.- Datos de la red neuronal implementada para la Hora 12 del Caso 1	72
6.- Información de arquitectura y magnitud de los errores para la Hora 12 del Caso 1	73
7.- Resultados ARIMA – Caso 1	76
8.- Resultados ARIMA – Caso 2	78
9.- Diferencias entre curva real y estimada – Caso 2	80
10.- Resultados ARIMA – Caso 3	81
11.- Resultados Redes Neuronales – Caso 1	83
12.- Resultados Redes Neuronales – Caso 2	85
13.- Diferencias entre curva real y estimada – Caso 2	87
14.- Resultados Redes Neuronales – Caso 3	88
15.- Comparativa MAPE – Caso 1	90
16.- Comparativa MAPE – Caso 2	92
17.- Comparativa MAPE – Caso 3	94
18.- Ventajas e inconvenientes de los métodos estudiados	96
19.- Coeficientes de los modelos ARIMA para el Caso 1	102
20.- Estadísticos para cada modelo del Caso 1	103
21.- Coeficientes de los modelos ARIMA para el Caso 2	104
22.- Estadísticos para cada modelo del Caso 2	105
23.- Coeficientes de los modelos ARIMA para el Caso 3	106
24.- Estadísticos para cada modelo del Caso 3	107
25.- Información de la red neuronal desarrollada para el Caso 1	108
26.- Información de la red neuronal desarrollada para el Caso 2	109
27.- Información de la red neuronal desarrollada para el Caso 3	110

CAPÍTULO I:
ESTADO
DEL
ARTE



ESTADO DEL ARTE

1.- INTRODUCCIÓN

La predicción de la demanda es un problema de gran importancia para el sector eléctrico, ya que, a partir de sus resultados, los agentes del mercado de energía toman las decisiones más adecuadas para su labor. Dicha predicción es un proceso central e integral en la planificación y operación de las instalaciones eléctricas. Implica una adecuada predicción tanto de las magnitudes como de la localización de la carga a lo largo de diferentes períodos de tiempo del horizonte estudiado. La variable más interesante en este tipo de predicción suele ser la carga horaria total del sistema. Puede resultar útil clasificar la predicción de carga en función del horizonte de estudios: hasta un día para predicciones a corto plazo (STLF), de un día a un año para predicciones a medio plazo (MTLF) y entre uno y diez años para predicciones a largo plazo (LTLF).

La precisión en la estimación de carga conlleva un considerable potencial de ahorro para las compañías generadoras, este ahorro se da cuando la predicción de carga se utiliza para controlar las operaciones y los despachos de energía, el unit commitment, las transferencias de combustible y el análisis de la red. La exactitud en la precisión tiene un impacto significativo en la operación de los sistemas de potencia debido a que la economía de operaciones y el control de dichos sistemas pueden ser muy sensibles a errores en la predicción. De los estudios realizados se deduce que errores (tanto positivos como negativos) han resultado en incrementos en el coste de operación. Algunos análisis han cuantificado el valor en euros de una mejora en la STLF para un generador típico; una reducción del 1% del error medio de la estimación puede llegar a suponer un ahorro de millones de euros.

La liberalización del mercado y las integraciones energéticas regionales han causado una incertidumbre aún mayor sobre la evolución de los precios debido a la gran cantidad de factores que intervienen en el mercado, los cuales también han aumentado la incertidumbre inherente al crecimiento de la demanda.



Por tanto, queda claro que la predicción de la demanda de electricidad es una herramienta fundamental para la toma de decisiones operativas y estratégicas, cuya falta de precisión puede traer altos costos económicos.

En esta sección se presenta un análisis de las técnicas y modelos más usados en el pronóstico de la demanda de electricidad y la problemática o dificultades a las que se enfrentan los investigadores al momento de realizar un pronóstico. La carga del sistema es un proceso aleatorio continuo, compuesto de miles de componentes individuales e influenciado por un gran número de factores que pueden clasificarse en: factores económicos, hora, día, estación, tiempo y efectos aleatorios.

Con objeto de mejorar la precisión de la estimación de carga se ha propuesto una amplia variedad de modelos, variables en complejidad, funcionamiento o procedimiento de estimación. El objeto de esta parte del proyecto consiste en listar y clasificar las técnicas de predicción de demanda eléctrica que se han venido llevando a cabo en los últimos años, reflejando además las tendencias más recientes en investigación.

La gran cantidad de publicaciones realizadas en los últimos años son una evidencia de los grandes esfuerzos que ha realizado la comunidad académica por desarrollar nuevos y mejores métodos para el pronóstico de la demanda de electricidad. Otro objetivo de esta introducción es presentar una visión panorámica de las metodologías utilizadas y de los casos de aplicación abordados que ayude a identificar, organizar, clasificar y caracterizar la diversidad de aproximaciones existentes. Dado que las técnicas de predicción se han clasificado en siete categorías, después de un breve estudio sobre la demanda se dedicarán las siguientes secciones al estudio de cada una de ellas, proporcionando una breve descripción de la técnica y de la principal literatura existente sobre ella.

2.- NECESIDAD DE PREDECIR LA DEMANDA

Como se ha comentado anteriormente, la predicción de la demanda de electricidad se realiza para horizontes de corto, medio y largo plazo. El corto plazo corresponde a la predicción en tiempo real para la hora siguiente y con un horizonte de hasta una



semana hacia delante; el pronóstico se basa en los datos históricos de demanda diaria y factores climáticos. El medio plazo corresponde al pronóstico mensual con un horizonte de hasta un año a partir de la demanda histórica de electricidad, y la predicción de algunas variables explicativas como el crecimiento de la economía o el clima. Finalmente, el largo plazo abarca un horizonte de uno hasta diez años; la predicción de la demanda en el largo plazo es usada para la planificación y expansión de la generación y el transporte; los datos usados para este pronóstico son la demanda anual, el precio de la electricidad, la evolución demográfica e indicadores económicos, entre otros.

Dependiendo del tipo de agente del mercado, la predicción de la demanda se justifica por las razones enunciadas a continuación:

- **Para los generadores:** La predicción de demanda en el corto plazo permite definir la cantidad de energía a generar (ofertar) para el día siguiente, programar la operación de unidades y fijar el precio de oferta de la electricidad en el mercado. En el medio plazo es un elemento fundamental para la definición de planes de mercado, contratos de venta y análisis de la evolución del mercado. En el largo plazo, permite detectar los periodos para los cuales existen excesos y carencias de capacidad de generación con el fin de planificar las inversiones en la expansión del sistema de generación y adoptar medidas de conservación de la energía; en el largo plazo, este es un problema fundamental debido a que la construcción de una nueva planta generadora puede tardar varios años, afectando a la fiabilidad del suministro de energía eléctrica.
- **Para los distribuidores y transportistas:** A corto plazo, permite realizar el seguimiento del comportamiento de la red con el fin de identificar puntos críticos que en el futuro pueden ocasionar problemas. Se utiliza en el medio plazo para la planificación de los mantenimientos del sistema. Es un elemento fundamental para definir el programa de expansión del sistema de transporte a largo plazo.
- **Para los comercializadores:** En el medio y largo plazo, es un elemento fundamental para el análisis del comportamiento del mercado y la definición de los planes estratégicos y operativos para la comercialización de la energía eléctrica.



- **Para el operador del mercado:** En el corto plazo es un elemento fundamental para la programación y operación de las unidades de generación, minimizando los ajustes del programa de operación en tiempo real, con el fin de evitar los sobrecostes en la producción de electricidad.

3.- CARACTERÍSTICAS GENERALES DE LA DEMANDA

Las series de demanda de electricidad presentan características particulares que se han identificado en diferentes estudios:

- Las series de demanda presentan fuertes patrones cíclicos de periodicidad anual, mensual, semanal, diaria y horaria; además, se ve afectada por la presencia de días festivos.
- El consumo de electricidad varía de acuerdo con la estación del año, el día de la semana y la hora del día. Los mayores consumos se presentan durante los días laborales y en las horas punta como son las 12:00 h y 19:00 h.
- Su evolución en el corto, medio y largo plazo está influenciada por eventos climáticos extremos y por factores económicos como el crecimiento del PIB, los precios de la energía o el crecimiento de la población.

4.- DIFICULTADES EN LA PREDICCIÓN DE LA DEMANDA

El pronóstico de la serie de demanda es una tarea difícil. Primero, porque las series de demanda son complejas y presentan diferentes niveles de estacionalidad. Segundo, porque hay muchas variables exógenas importantes que deben ser consideradas, especialmente las relacionadas con el clima. Una desviación grande en la predicción de demanda puede implicar grandes costos de operación, por lo cual se debe tener especial cuidado con el uso de los modelos.



En las siguientes subsecciones se exponen las principales dificultades que se han encontrado los expertos relacionadas con el proceso de estimación, selección de variables significativas y uso de los modelos.

4.1.- Proceso de estimación y variables significativas

Los mercados eléctricos son complejos debido al alto número de factores físicos, tecnológicos y sociales que influyen en su comportamiento. Las variables físicas como las condiciones climáticas tienen un comportamiento poco predecible a medio y largo plazo, al igual que los cambios tecnológicos y sociales tales como innovaciones en la generación de electricidad o cambios en los patrones de consumo.

En áreas de rápido crecimiento, una dificultad para la predicción de la demanda es que la base de datos es corta e insuficiente, no se tiene experiencia con la cual se pueda comparar y las técnicas de predicción son incapaces de modelar adecuadamente factores relacionados con los ciclos y los eventos dinámicos tales como los cambios de temperatura.

Es necesario contar con herramientas que permitan analizar la información histórica para validar hipótesis sobre las condiciones del mercado y para construir pronósticos usándolas. Además, es importante validar si los ajustes basados en la experiencia son de valor para mejorar la precisión de los pronósticos.

Los pronósticos basados en juicios son más creíbles que aquellos basados en sofisticados modelos matemáticos; sin embargo, la calidad del pronóstico se ve afectada por el hecho de que no se basa en un proceso sistemático de razonamiento, tal que ellos no son fácilmente defendibles, argumentables y sustentables en las evidencias, y resulta difícil documentar cómo fueron obtenidas las predicciones. Por esta razón, no es posible realizar procesos de realimentación y revisión con el ánimo de mejorar las prácticas y corregir las desviaciones y errores sistemáticos.

Las desviaciones y los errores sistemáticos degradan ostensiblemente la precisión y la calidad de las estimaciones. Las técnicas de modelado matemático ofrecen modelos



sofisticados capaces de manejar cantidades considerables de información, sin embargo es difícil incorporar el conocimiento subjetivo a esta aproximación.

4.2.- Uso de los modelos

El uso de modelos no lineales para el estudio del pronóstico de la demanda aún no ha sido completamente estudiado, ya que no se ha agotado la lista de los modelos posibles para su uso.

Velásquez, en su estudio sobre pronóstico de precios de electricidad, menciona algunos problemas teóricos, metodológicos y empíricos sobre el uso de modelos no lineales, los cuales son válidos para el pronóstico de la demanda. Estos problemas se detallan a continuación:

- No existen razones empíricas, metodológicas o teóricas para preferir un modelo específico entre varias alternativas.
- Falta claridad sobre cuáles son los procedimientos más adecuados para la estimación y la prueba de cada modelo particular.

5.- MODELOS Y TÉCNICAS DE PREDICCIÓN

Una gran cantidad de modelos han sido aplicados a diferentes series de demanda de acuerdo a las necesidades de cada estudio. Estos métodos se pueden clasificar a grandes rasgos en tres grupos:

El primer grupo se basa en modelos estadísticos (regresión, series de tiempo y/o econométricos), los cuales modelan la serie de demanda en función sus valores pasados o en función de algunas variables exógenas como el tiempo o factores socio-económicos.

El segundo grupo reúne los modelos basados en inteligencia artificial. Esta técnica ha sido usada en los últimos años y se han elaborado estudios donde se comparan los



resultados con métodos tradicionales como el caso de Taylor, en el cual se predice la serie horaria de demanda de Rio de Janeiro, Inglaterra y Gales mediante un modelo de redes neuronales artificiales y se comparan los resultados con modelos estadísticos (ARIMA, Alisado exponencial, componentes principales). Dentro de las técnicas usadas se encuentran las redes neuronales artificiales, modelos neurodifusos y modelos híbridos.

El tercer grupo son modelos empíricos que dependen del juicio y la intuición humana.

A continuación se presenta un repaso de las diferentes técnicas de predicción de demanda eléctrica existentes. Dichas técnicas se clasifican en siete categorías:

- 1) Regresión múltiple.
- 2) Alisado exponencial.
- 3) Series temporales estocásticas.
- 4) Modelos ARMAX basados en algoritmos genéticos.
- 5) Lógica difusa.
- 6) Redes Neuronales.
- 7) Sistemas expertos.

Para cada categoría se describe brevemente la metodología utilizada, se discuten sus ventajas y desventajas y se repasa la literatura existente.

5.1.- REGRESIÓN MÚLTIPLE

El análisis por regresión múltiple utiliza la técnica de estimación por mínimos cuadrados ponderados. Basándose en este análisis se pueden calcular tanto la relación estadística entre la carga total y las condiciones meteorológicas como la influencia del tipo de día. Los coeficientes de regresión se calculan utilizando una estimación igual o exponencial de mínimos cuadrados ponderados de acuerdo un histórico de datos. Mbamalu y El-Hawary detallan el siguiente algoritmo para la aplicación de este tipo de análisis: El programa de análisis de datos permite la selección del grado de influencia polinomial de las variables desde 1 a 5. En muchos casos, la dependencia lineal arroja los mejores resultados. El modelo desarrollado por Papalexopulos y Hesterberg produce una



predicción inicial del pico de demanda que utiliza entonces para calcular unas predicciones horarias iniciales. En el paso siguiente utiliza la máxima de las predicciones horarias iniciales, el error más reciente de la predicción pico inicial y los errores alisados exponencialmente como variables para un modelo de regresión que arrojará una predicción pico ajustada.

Haida y Muto presentaron un método que incluía técnicas basada en la transformación. Dicho método utiliza una regresión para predecir la carga nominal y un método de aprendizaje para predecir la carga residual. Varadan y Makran utilizaron un modelo de mínimos cuadrados para identificar y cuantificar los diferentes tipos de carga en líneas y subestaciones.

Hyde y Hodnett presentaron un modelo basado en el tiempo para predecir la carga en el Sistema eléctrico irlandés. Para incluir el efecto del tiempo, el modelo se desarrolló utilizando análisis de regresión de los histórico de carga y tiempo. Los mismos autores desarrollaron posteriormente un modelo de regresión adaptable para predicciones a un día vista, el cual identifica componentes sensibles al tiempo o a la carga. Se utiliza una regresión lineal de los datos históricos para estimar los parámetros de los dos componentes.

Al-Garni y otros desarrollaron un modelo de regresión para el consumo de energía eléctrica en Arabia Saudí en función del clima, radiación solar, población y renta per cápita. La selección de variables se lleva a cabo usando el método de regresión escalonada.

Alfares y Nazeeruddin presentaron un modelo regresivo de estimación de demanda pico diaria para un año entero incluyendo vacaciones. Para estimar la carga de forma precisa para un año se tomaron en cuenta diferentes factores estacionales que afectan a la carga de forma diferente a lo largo del año. Durante el período invernal se introduce un factor adicional que representa la “sensación térmica” para complementar los factores usados en estaciones más cálidas. Para los períodos vacacionales se deduce una cantidad de carga a la estimación calculada en caso de ser un día laborable.

5.2.- ALISADO EXPONENCIAL

El alisado exponencial es uno de los métodos clásicos utilizados para la predicción de demanda eléctrica. Se basa en crear un modelo a partir de la carga recogida en los datos históricos para, posteriormente predecir la carga futura utilizando dicho modelo.

El método de Winter es uno de los métodos de alisado exponencial que pueden analizar series de tiempo estacionales directamente. Este método se basa en tres constantes de alisado, las cuales tienen en cuenta la estacionariedad, tendencia y estacionalidad. El-Keib y otros presentaron una aproximación híbrida donde el alisado exponencial se aumentaba mediante el análisis del espectro de potencia y un modelado autorregresivo. Una tendencia en auge consiste en el cálculo del alisado óptimo.

5.3.- SERIES DE TIEMPO ESTOCÁSTICAS

Anteriormente se ha mencionado la dificultad para analizar y predecir patrones de demanda pertenecientes a áreas de rápido crecimiento mediante métodos de series temporales. Sin embargo, dichos métodos continúan estando entre los más utilizados para el cálculo de predicciones a corto plazo. Para emplear esta técnica se elabora un modelo basado en datos históricos para, posteriormente, calcular la carga futura basándose en dicho modelo. En el resto de la sección se detallan alguno de los modelos de series temporales utilizados.

5.3.1.- Modelo AR

Si se asume que la carga es una combinación lineal de cargas previas, entonces el modelo autorregresivo (AR) puede utilizarse para modelar el perfil de carga. El algoritmo presentado por El-Keib incluye una técnica de modelado autorregresivo complementada con un análisis de autocorrelación parcial. Huang propone un algoritmo capaz de determinar el número mínimo de parámetros necesarios para determinar el componente aleatorio, eliminando el juicio subjetivo y mejorando la precisión de la estimación.

5.3.2.- Modelo ARMA

La identificación de parámetros para un modelo ARMA general puede hacerse a través de una técnica recursiva o de máxima similitud, que consiste básicamente en un algoritmo de regresión no lineal. Fan y McDonald utilizaron el algoritmo recursivo de mínimos cuadrados ponderados (WRLS) para actualizar los parámetros de su modelo ARMA. Chen y otros desarrollaron un modelo ARMA donde los errores de predicción se utilizaban para actualizar el modelo. Al usar el mínimo error cuadrático medio para calcular los coeficientes este modelo superaba al modelo ARMA convencional.

5.3.3.- Modelo ARIMA

Si el proceso es no estacionario, la serie ha de ser transformada primero a un modelo estacionario. El procedimiento propuesto por Elrazaz y Mazi usaba la componente de tendencia para predecir el incremento en la carga del sistema, los parámetros climáticos para predecir el componente sensible de la carga y, finalmente, el modelo ARIMA para calcular el componente cíclico no climático del pico de carga semanal. Barakat y otros utilizaron un modelo ARIMA estacional basado en datos históricos para predecir la carga con variaciones según la estación del año. Juberias desarrolló un modelo ARIMA en tiempo real que incluye la influencia meteorológica como una variable.

5.4.- MODELADO ARMAX BASADO EN ALGORITMOS GENÉTICOS

La técnica de algoritmos genéticos (GA) se utiliza para identificar el modelo ARMAX en predicciones de carga. Mediante la simulación de un proceso evolutivo natural, el algoritmo evalúa muchos puntos dentro del espacio de búsqueda y asume que dicho espacio es diferenciable, convergiendo hacia una solución óptima y mejorando la eficacia del modelo.

5.5.- LÓGICA DIFUSA

Los sistemas de lógica difusa pueden identificar y aproximar cualquier sistema dinámico desconocido, en este caso demanda, a un sistema compacto y de precisión



determinada. Por tanto, la lógica difusa posee una gran capacidad para extraer similitudes a partir de ingentes volúmenes de datos.

La predicción a través de la lógica difusa consta de dos etapas: entrenamiento y predicción en línea. En la etapa de entrenamiento se utilizan los datos históricos para entrenar un estimador de $2m$ entradas y $2n$ salidas de forma que genere patrones dentro de los datos disponibles. Después del suficiente entrenamiento, se une dicho estimador a un controlador para predecir, en línea, los cambios de demanda.

Se han desarrollado diferentes técnicas para representar modelos de demanda mediante sentencias condicionales de lógica difusa. Liang y Hsu formularon un modelo de programación lineal difusa del programa de generación de energía, representando incertidumbres en la predicción y los datos de entradas usando lógica difusa. Para manipular grandes cantidades de datos se utilizan redes neuronales. Srinivasan utilizó un modelo híbrido difuso-neuronal para predecir la demanda. Este modelo híbrido puede predecir con precisión la carga en días laborales, festivos y días antes y después de estos últimos.

5.6.- REDES NEURONALES

Las redes neuronales o redes neuronales artificiales tienen una amplia variedad de aplicaciones debido a su capacidad de aprendizaje. Existen muchos tipos: redes de perceptrón multicapa, redes autoorganizadas, etc. Cada red está conformada por varias capas que, a su vez, están integradas por muchas neuronas, estas son multiplicadas por unos pesos y sumadas para formar un producto llamado función neta.

La mayor ventaja radica en que, de todos los métodos de predicción tratados en esta sección, el modelado por redes neuronales no necesita un modelo de carga. Por contra, el entrenamiento requiere de mucho tiempo.

La metodología propuesta por Liu utiliza redes totalmente conectadas de neuronas tipo feedforward. Las salidas de esta red son funciones lineales de los pesos que conectan



entradas y unidades ocultas con las unidades de salida. Por lo tanto, las ecuaciones lineales se pueden resolver utilizando estos pesos de salida.

5.7.- SISTEMAS EXPERTOS

Los sistemas expertos han surgido a consecuencia de los avances en inteligencia artificial. Se basan en un programa informático que tiene la capacidad de razonar, explicar y aumentar su base de conocimiento según recibe nueva información. Para construir el modelo se extraen datos de predicción en forma de sentencias IF-THEN y consistentes en relaciones entre los cambios en la demanda del sistema y los cambios naturales o artificiales que afectan el consumo de electricidad. Esta base de reglas se utiliza para hacer la predicción, algunas no cambian con el tiempo mientras que otras han de ser actualizadas continuamente.

Las relaciones lógicas y sintácticas entre las variables que afectan a la demanda han sido ampliamente estudiadas con objeto de desarrollar diferentes reglas para diferentes enfoques.

Las variables típicas son: estación considerada, día de la semana y temperatura. Ejemplos de este modelo pueden encontrarse en los estudios de Rahman y Ho.

Algunas metodologías híbridas combinan los sistemas expertos con otras técnicas de predicción. Dash desarrolló un modelo donde se aplicaba la lógica difusa a un sistema experto. Kim utilizó una estrategia en dos etapas para predecir la carga en la red de Corea del Sur. En primer lugar se entrena una red neuronal para obtener una predicción inicial, a continuación, un sistema experto modifica la predicción para tener en cuenta los cambios de temperatura y los días festivos.

6.- COMPARACIÓN DE TÉCNICAS

Además de clasificar las diferentes técnicas de predicción, es importante comparar las diferentes categorías. A lo largo de los años se ha intentado comparar empíricamente alguno de los métodos utilizados en la predicción de demanda. Uno de los primeros



estudios fue realizado por Willis y Northcote-Green, dicho estudio llevaba a cabo una comparativa del rendimiento proporcionado por 14 métodos de predicción diferentes. Atlas realizó una comparativa de diferentes estructuras de redes neuronales frente a modelos de regresión. Girgis utilizó datos reales para comparar los errores de estimación para predicciones a una hora y a un día asociadas a tres técnicas de predicción distintas: Filtro de Kalman, redes neuronales y sistemas expertos.

Existen otros estudios comparativos de un enfoque más limitado, proporcionado a menudo por los investigadores para demostrar la superioridad de un determinado método sobre las técnicas previamente publicadas. Por ejemplo, Mbamalu y El-Hawary compararon su modelo autorregresivo con el método Box-Jenkins. Srinivasan comparó su modelo híbrido de redes neuronales y lógica difusa frente a un modelo regresivo, demostrando una notable mejora en la predicción. La necesidad de comparativas exhaustivas actualizadas presenta un interesante campo de investigación, dada la amplia variedad de objetivos y enfoques y las ilimitadas posibilidades de mezcla de diferentes componentes de varios métodos.

7.- CONCLUSIONES

El pronóstico de la demanda es un elemento importante para la operación, planificación y expansión de los sistemas eléctricos de potencia; ya que puede ser un factor determinante para la toma de decisiones en el mercado eléctrico.

Las características principales de la serie de demanda son la tendencia, estacionalidad, ciclos y la irregularidad, además dicha serie tiene una fuerte influencia de variables económicas y climáticas.

La literatura analiza distintos casos de los cuales no se pueden obtener conclusiones generales, es decir, presenta diferentes tipos de modelos para diferentes series y escalas de tiempo; adicionalmente, algunos modelos involucran variables exógenas que hacen más complejo el mismo modelo e involucran los errores asociados a los pronósticos de estas variables, agregando más incertidumbre en los resultados del modelo.



Se han aplicado diferentes técnicas a la predicción de demanda. En esta sección se han estudiado siete de ellas: 1) Regresión múltiple, 2) Alisado exponencial, 3) Series temporales estocásticas, 4) Modelos ARMAX basados en algoritmos genéticos, 5) Lógica difusa, 6) Redes neuronales y 7) Sistemas expertos.

De la revisión de la literatura realizada, se deduce que la técnica de pronóstico más usada son las redes neuronales artificiales, como segunda opción se tienen los modelos estadísticos de series de tiempo, siendo el modelo ARIMA el más utilizado, usualmente como modelo de comparación frente a técnicas más complejas. Se resalta además el uso de modelos híbridos los cuales combinan técnicas de redes neuronales, lógica difusa, algoritmos genéticos y las técnicas tradicionales de serie de tiempo y regresión.

Con los años, el foco de la investigación ha variado, reemplazando antiguas técnicas con modelos más nuevos y eficientes. Debido a su aparentemente limitado éxito un determinado número de modelos parece en desuso hoy día. Dichos métodos son la predicción en línea y la estimación por reconocimiento de patrones. Además ha disminuido considerablemente el énfasis puesto en técnicas como los mínimos cuadrados ponderados.

Las series temporales siguen siendo ampliamente usadas. La creciente velocidad a la que los ordenadores aumentan su capacidad está haciendo posible aplicar soluciones cada vez más complicadas. El futuro de la predicción de demanda parece ir de la mano de la lógica difusa, los algoritmos genéticos y las redes neuronales, siendo esta última técnica la que se encuentra más en boga durante los últimos años.

A modo de cierre, cabe destacar que el análisis realizado muestra que el tema de la predicción de la demanda de energía eléctrica está de actualidad; esta afirmación se basa en primer lugar en que la mayor parte de las investigaciones son realizadas utilizando redes neuronales y, en segundo lugar, en que para la mayoría de las series, existen pocos estudios que permitan realizar una comparación clara entre modelos; más aún, existe muy poca información y una gran variedad de casos de aplicación, lo que no permite aún concluir sobre cuales tipos de modelos podrían ser más adecuados para predecir este tipo de series de tiempo.

CAPÍTULO II:

TEORÍA

TEORÍA - SERIES TEMPORALES

1.- INTRODUCCIÓN

Cuando hablamos de una secuencia de valores observados a lo largo del tiempo, y por tanto ordenados cronológicamente, la denominamos, en un sentido amplio, serie temporal. Resulta difícil imaginar una rama de la ciencia en la que no aparezcan datos que puedan ser considerados como series temporales.

Si, conocidos los valores pasados de la serie, fuera posible predecir con un razonable grado de certeza el próximo valor de la variable, decimos que la serie es determinista, aun cuando posea una cierta componente aleatoria, y lógicamente es de éstas de las que se ocupan las técnicas denominadas "análisis de series temporales" y a las que vamos a dedicar esta breve introducción.

El análisis estadístico de series temporales se usa hoy día con profusión en muchas áreas de la ciencia, fundamentalmente en física, ingeniería y en economía. Los objetivos del análisis de series temporales son diversos, pudiendo destacar la predicción, el control de un proceso, la simulación de procesos, y la generación de nuevas teorías físicas o biológicas, entendiendo por predicción o inferencia a la estimación de valores futuros de la variable en función del comportamiento pasado de la serie u otros valores o variables que afecten a la misma.

En la teoría de control de procesos, se trata de seguir la evolución de una variable determinada con el fin de regular su resultado. La simulación se emplea en investigación aplicada, cuando el proceso es muy complejo para ser estudiado de forma analítica. Evidentemente aunque el valor futuro de una serie temporal no sea predecible con total exactitud, para que tenga interés su estudio, el resultado tampoco puede ser completamente aleatorio, existiendo alguna regularidad en cuanto a su comportamiento en el tiempo, lo que hará posible su modelado y por ende, en su caso, la predicción.

Por lo tanto, si podemos encontrar patrones de regularidad en diferentes secciones de una serie temporal, podremos también describirlas mediante modelos basados en distribuciones de probabilidad. Todo el análisis de series temporales se suele abordar desde una teoría más amplia conocida como Análisis de Procesos Estocásticos. Así, se denomina proceso estocástico a la secuencia ordenada de variables aleatorias $X(t)$ (o X_i) cuya distribución de probabilidad asociada en cada instante se supone conocida. Un proceso estocástico es por tanto el modelo matemático para una serie temporal.

2.- ESTUDIO DE LAS SERIES TEMPORALES

2.1.- Modelado clásico de series temporales

El primer paso obligatorio para analizar una serie temporal es presentar un gráfico de la evolución de la variable a lo largo del tiempo, como puede ser el de la siguiente figura:




Fig. 1: Representación de una serie temporal

El siguiente paso consistirá en determinar si la secuencia de valores es completamente aleatoria o si, por el contrario, se puede encontrar algún patrón a lo largo del tiempo, pues sólo en este caso podremos seguir con el análisis.

La metodología tradicional para el estudio de series temporales es bastante sencilla de comprender, y fundamentalmente se basa en descomponer las series en varias partes: tendencia, variación estacional o periódica, y otras fluctuaciones irregulares.

- Tendencia: Es la dirección general de la variable en el periodo de observación, es decir el cambio a largo plazo de la media de la serie.
- Estacionalidad: Corresponde a fluctuaciones periódicas de la variable, en periodos relativamente cortos de tiempo.
- Otras fluctuaciones irregulares: Después de extraer de la serie la tendencia y variaciones cíclicas, nos quedará una serie de valores residuales, que pueden ser o no totalmente aleatorios.

Volvemos a estar como en el punto de partida, pues ahora también nos interesa determinar si esa secuencia temporal de valores residuales puede o no ser considerada como aleatoria pura.

En la figura 2 vemos un ejemplo de una serie temporal en la que se aprecia la existencia de las distintas componentes comentadas y en la figura 3 podemos observar cada una de las tres componentes mencionadas.




Fig. 2: Serie temporal con tendencia

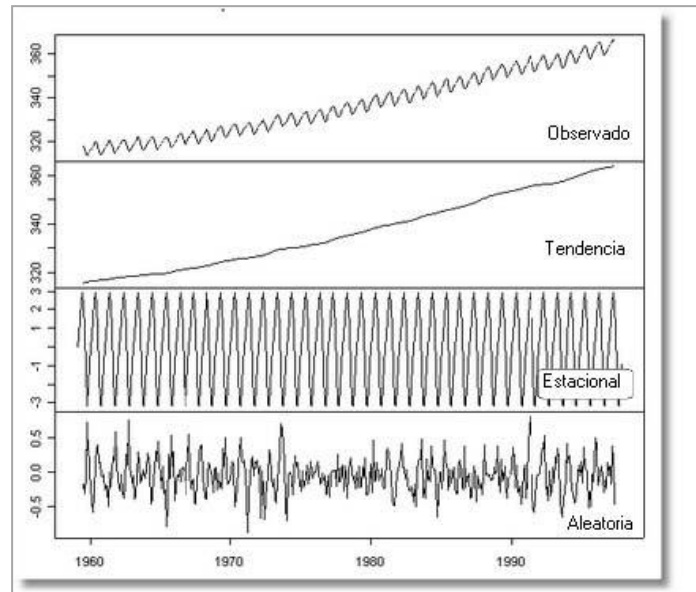


Fig. 3: Descomposición de una serie temporal en sus componentes

2.2.- Enfoque actual de las series temporales: Modelos ARIMA

A comienzo de los años 70, G. Box, profesor de Estadística de la Universidad de Wisconsin, y G. Jenkins, profesor de Ingeniería de Sistemas de la Universidad de Lancaster, introdujeron una pequeña revolución en el enfoque del análisis de series temporales, en sus trabajos sobre el comportamiento de la contaminación en la bahía de San Francisco, con el propósito de establecer mejores mecanismos de predicción y control. El libro en el que describen la metodología, se convirtió rápidamente en un clásico, y sus procedimientos se utilizan ampliamente desde entonces en diferentes ramas de la ciencia, conociéndose como modelos ARIMA y también como modelos Box–Jenkins. Para explicar dicho modelo se hace necesario conocer ciertas definiciones:

- **Proceso estocástico:** Llamamos proceso estocástico a una sucesión de variables aleatorias $\{x_t\}$ donde $t = \dots, -1, 0, 1, 2, \dots$
- **Ruido blanco:** Se llama ruido blanco a una sucesión de variables aleatorias con esperanza cero, igual varianza e independientes en el tiempo $\{\varepsilon_t\}$
- **Paseo aleatorio:** Llamamos paseo aleatorio a un proceso estocástico $\{x_t\}$ cuyas primeras diferencias forman un proceso ruido blanco.

$$x_t - x_{t-1} = z_t \rightarrow \Delta x_t = z_t$$

- Un proceso estocástico es estacionario en sentido estricto si para toda m-tupla (t_1, \dots, t_m) y todo entero k , el vector de variables $(x_{t_1}, \dots, x_{t_m})$ tiene la misma distribución de probabilidad conjunta que el vector $(x_{t_1+k}, \dots, x_{t_m+k})$.

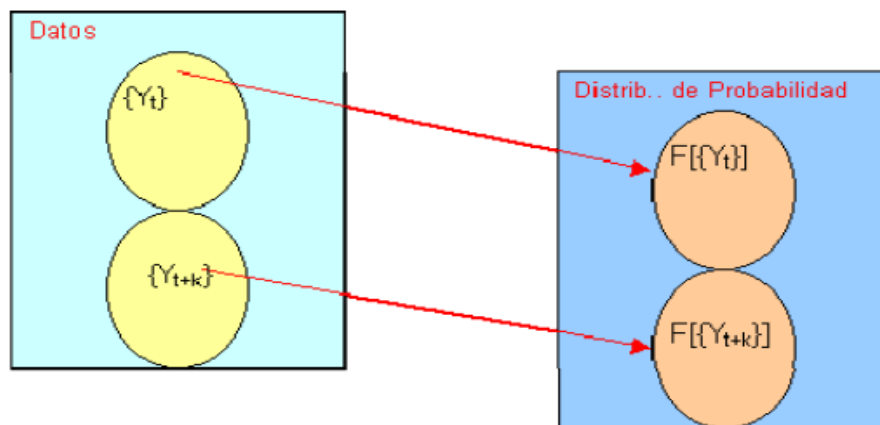


Fig. 4: Proceso estocástico estacionario

Otros conceptos a tener en cuenta a la hora de analizar series de tiempo son los siguientes:

- La función de autocorrelación: La función de autocorrelación mide la correlación entre los valores de la serie distanciados un lapso de tiempo k y se emplea para analizar la estacionalidad de una serie. La fórmula del coeficiente de correlación simple, dados N pares de observaciones y, x es la siguiente:

$$\rho = \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum (y_i - \bar{y})^2 \sum (x_i - \bar{x})^2}}$$

La función de autocorrelación es el conjunto de coeficientes de autocorrelación rk desde 1 hasta un máximo que no puede exceder la mitad de los valores observados, y es de gran importancia para estudiar la estacionalidad de la serie, ya que si ésta existe, los valores separados entre sí por intervalos iguales al periodo estacional deben estar correlacionados de alguna forma. Es decir que el coeficiente de autocorrelación para un retardo igual al periodo estacional debe ser significativamente diferente de 0.

Relacionada con la función de autocorrelación nos encontramos con la función de autocorrelación parcial. En el coeficiente de autocorrelación parcial de orden k , se calcula la correlación entre parejas de valores separados esa distancia pero eliminando el efecto debido a la correlación producida por retardos anteriores a k . En la figura 5 vemos una gráfica típica de la función de autocorrelación parcial, en la que se marcan los intervalos de confianza para ayudar a detectar los valores significativos y cuya posición en el eje X nos indicará la probable presencia de un factor de estacionalidad para ese valor de retardo.




Fig. 5: Función de autocorrelación parcial

Otro concepto importante en este tipo de estudios es el siguiente:

- **Ergodicidad:** las series temporales que se manejan en econometría están constituidas por observaciones históricas, es decir, no proceden de la experimentación y por tanto, son irrepetibles. Una serie temporal puede contemplarse como una sola prueba de un experimento aleatorio multivariable y constituye lo que se denomina una realización del proceso.

Para hacer inferencias estadísticas en problemas donde interviene una sola variable aleatoria es necesario recurrir a la repetición de experimentos. Si esta repetición de pruebas fuese necesaria con todos los procesos estocásticos surgirían problemas de inferencia estadística inabordables.



Afortunadamente, esto no es así. Se puede demostrar que, cuando un proceso estocástico cumple ciertas condiciones, es posible estimar consistentemente sus características a partir de una realización del mismo. Los procesos que cumplen tales condiciones se denominan ergódicos.

2.2.1.- Procesos no estacionarios homogéneos

A las series con las que vamos a trabajar les vamos a exigir que sean estacionarias en sentido débil (la estacionalidad en sentido débil o de segundo orden se produce cuando los momentos de primer y de segundo orden del proceso estocástico son invariantes en el tiempo).

A las series que presentan una tendencia lineal se les suele someter a la siguiente transformación:

$$x_t - (x_{t-1}) = \Delta x_t = y_t$$

El símbolo Δ denota incremento, es un operador, que también lo podemos escribir en función del operador de retardos como:

$$\Delta = 1 - L ; \text{ donde } L \text{ es el operador de retardos.}$$

Para no confundirnos, Δ lo único que hace es sobre los datos de una serie, a cada dato le resta el inmediatamente anterior. Se suele decir que se ha aplicado una primera diferencia sobre la serie original.

Si x_t muestra una tendencia lineal, la primera diferencia de la serie, y_t , ya no incorporará tendencia. En tal caso se dice que x_t es una serie temporal homogénea de primer orden.

Análogamente, si x_t presenta una tendencia exponencial, para eliminarla, se halla primero el logaritmo de la serie y luego la primera diferencia de la serie así calculada. Es decir si x_t presenta una tendencia exponencial:

$$\ln(x_t) - \ln(x_{t-1}) = y_t, \text{ donde } y_t \text{ tendrá la tendencia eliminada.}$$

En general, un proceso no estacionario que se convierte en estacionario después de h operaciones de diferencia, se denomina homogéneo de orden h o integrado de orden h .

Hay que señalar que, en la práctica, es difícil determinar si se han realizado el número de diferencias adecuado para transformar la serie en estacionaria. Es posible quedarse corto, o por el contrario, llegar a una “sobrediferenciación” de la serie.

El instrumento que suele utilizarse para detectar el número adecuado de diferencias, es simplemente la inspección visual del gráfico de la serie y de su correlograma.

2.2.2.- Corrección de variaciones estacionales

La eliminación de las variaciones estacionales, para inducir la estacionariedad, suele hacerse mediante un procedimiento de autoajuste, del mismo modo que el comentado para tendencia, denominado “diferenciación estacional”.

Lo primero que conviene hacer es eliminar la tendencia de la serie, ya que, de otra forma, la diferencia entre los datos relativos al mismo mes (o fracción del año) sería significativa, sin que esto implique evidencia de variaciones estacionales.

Si los datos son mensuales, la diferenciación estacional, consiste en calcular: $y_t = x_t - x_{t-12}$, mientras que con datos trimestrales: $y_t = x_t - x_{t-4}$

Si después de efectuar esta transformación, la serie sigue presentando evidencia de variaciones estacionales, es posible aplicar de nuevo el procedimiento, es decir, calcular las diferencias de segundo orden y así sucesivamente.

Ya hemos visto la función de autocorrelación simple, y su estimación a través de la función de autocorrelación muestral. Ahora vamos a introducir una nueva función, fundamental para el análisis de series temporales.

2.2.3.- La función de autocorrelación parcial (FACP)

La función de autocorrelación de un proceso estocástico $\{x_t\}$ es una función que para cada instante t y cada entero k , toma un valor igual a la correlación entre x_t y x_{t-k} ajustada por el efecto de los retardos intermedios $x_{t-1}, \dots, x_{t-k-1}$

El interés en que el proceso sea estacionario es que las FAC y las FACP son independientes del tiempo, lo que es fundamental para calcular los coeficientes de ambas funciones.

2.2.4.- Tipos de Procesos de Series Temporales

Hemos hablado antes de “procesos autorregresivos” como aquellos en los que los valores actuales de la serie dependen de la historia de la misma, pero no siempre se tiene esta dependencia. En este sentido vamos a distinguir tres tipos de procesos:

- Procesos Autorregresivos (AR)
- Procesos de Medias Móviles (MA) esto es por el inglés “moving averages”
- Procesos Autorregresivos y de Medias Móviles (ARMA)

- Procesos Autorregresivos AR(p)

Se define un modelo AR de orden p , también escrito AR(p), como:

$$x_t = \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} + \varepsilon_t, \text{ donde } \varepsilon_t \text{ es ruido blanco}$$

Es decir, escribimos x_t en función de los valores pasados de la propia serie, e incluimos en la expresión un término de perturbación o error, ε_t , que suponemos se comporta como ruido blanco.



Un proceso autorregresivo de orden p , también podemos expresarlo en función del operador de retardos.

$$\text{Si } \Phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p \text{ donde } L^p x_t = x_{t-p}$$

De modo que un modelo AR(p) en forma compacta, se puede escribir como:

$$\Phi(L)x_t = \varepsilon_t$$

- Procesos de Medias Móviles MA(q)

Pasamos a definir ahora los ya conocidos “procesos de medias móviles”. Un proceso de medias móviles de orden q , tiene la forma general:

$$x_t = \varepsilon_t + \phi_1 \varepsilon_{t-1} + \phi_2 \varepsilon_{t-2} + \phi_3 \varepsilon_{t-3} + \dots + \phi_q \varepsilon_{t-q} \text{ donde } \varepsilon_t \text{ es ruido blanco.}$$

Definiendo el operador $\phi(L)$ como:

$$\phi(L) = 1 + \phi_1 L + \phi_2 L^2 + \phi_3 L^3 + \dots + \phi_q L^q \text{ donde } L \text{ es el operador de retardos.}$$

Podemos expresar un modelo MA(q) en forma compacta como:

$$x_t = \phi(L) \varepsilon_t$$

Es decir, en un proceso MA(q) cada componente de la serie analizada x_t se explica en función del ε_t de otra serie y de los q anteriores.

- Procesos ARMA (p,q)

El proceso que nos queda por definir es el tipo ARMA (p,q), que consiste en un proceso que combina las características de los dos modelos vistos anteriormente, Así formalmente un proceso ARMA (p,q) se podrá escribir como:

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + \varepsilon_t + \phi_1 \varepsilon_{t-1} + \phi_2 \varepsilon_{t-2} + \phi_3 \varepsilon_{t-3} + \dots + \phi_q \varepsilon_{t-q}$$

Y en forma compacta se puede escribir como:

$$\varphi(L)X_t = \phi(L)\varepsilon_t, \text{ donde } L \text{ es el operador de retardos visto anteriormente.}$$

- Identificación de los procesos AR, MA y ARMA

A partir de las figuras de las FAC y de las FACP, tendremos que intentar identificar el proceso generador de la serie. Para ello podemos hacer uso de la siguiente tabla:

MODELO	FAC	FACP
AP(q)	Decrecimiento rápido de tipo geométrico puro, y geométrico con alternancia de signos, sinusoidal o mezcla de varios tipos.	Se anula para retardos superiores a p
MA(q)	Se anula para retardos superiores a q.	Decrecimiento rápido de tipo exponencial y/o sinusoidal
ARMA (p,q)	Los primeros valores iniciales no tienen patrón fijo y van seguidos de una mezcla de oscilaciones sinusoidales y/o exponenciales amortiguadas	Los primeros valores iniciales no tienen patrón fijo y van seguidos de una mezcla de oscilaciones sinusoidales y/o exponenciales amortiguadas.

Tabla 1: Identificación de modelos

TEORÍA - REDES NEURONALES

1.- INTRODUCCIÓN

Las redes neuronales artificiales hacen referencia a una clase de modelos basada en los sistemas nerviosos biológicos. Estos modelos están compuestos de muchos elementos de información, denominados neuronas, trabajando en paralelo y conectadas a través de pesos sinápticos que se adaptan a través de un proceso de aprendizaje. Se puede decir que una red neuronal artificial es una máquina adaptable que puede guardar el conocimiento a través del proceso de aprendizaje.

La investigación en el campo de las redes neuronales tiene ya una historia de algunas décadas, comenzando en 1943 con McCulloch (neurólogo) y Pitts (matemático), quienes desarrollaron una teoría acerca de la forma de trabajar de las neuronas biológicas, modelando el comportamiento de una neurona mediante circuitos eléctricos. Hoy, las redes neuronales tienen muchas aplicaciones, de las cuales se destacan el reconocimiento de patrones, el control de procesos y la predicción de series temporales.

2.- CONCEPTOS BÁSICOS DE LAS REDES NEURONALES

Podría definirse a una red neuronal artificial como una estructura de proceso de información, paralela y distribuida, formada por elementos de procesamiento (EP) o neuronas, interconectados a través de canales unidireccionales llamados conexiones sinápticas. Cada EP tiene una salida única que se distribuye sobre un número de conexiones bilaterales. El proceso de información interno en cada EP puede definirse de forma arbitraria, pero ha de ser totalmente local, es decir, depende solamente de los valores almacenados en su memoria local. En la figura 6 se muestra una representación esquemática del modelo matemático de una neurona.




Fig. 6: Modelo esquemático de una neurona artificial

Cada neurona puede poseer muchas entradas provenientes de otras unidades o de las entradas del sistema, pero una única salida, la cual se puede conectar a otras neuronas o ser una salida del sistema.

Del modelo anterior hay que tener en cuenta dos aspectos clave. En primer lugar, las estructuras matriciales que se dan en la unidad de procesamiento y en segundo lugar la naturaleza no-lineal de la salida de la neurona, al ser afectada por la función de activación f .

Estas unidades de procesamiento poseen las siguientes partes:

- Un **conjunto de conexiones sinápticas**, las cuales están caracterizadas por un peso o intensidad de conexión w que multiplica los valores de las R entradas p . Estos pesos, son las únicas variables que se modifican durante el proceso de entrenamiento de la red, una vez ha sido definida su arquitectura.
- Un **sumador**, el cual se encarga de sumar todas las entradas ponderadas en sus respectivas sinapsis. Esta operación es una simple combinación lineal de las variables de entrada a la neurona.
- Una **función de activación** para limitar la amplitud de la salida de la neurona. Esta función de activación es un parámetro que se escoge antes del entrenamiento de la red. Existen diferentes tipos de función de activación. En la figura 6 se muestran algunas de las comúnmente usadas.

- Un **umbral exterior b** que determina el valor por encima del cual la neurona se activa.

A un grupo de neuronas idénticas que están al mismo nivel de procesamiento de la información, se le conoce como “capa” de neuronas. Por lo general, una red neuronal posee una capa de entrada, una capa de salida, y n capas “ocultas” intermedias. Aunque las funciones de activación de cada neurona de la red pueden ser diferentes, se acostumbra a mantener la misma función de activación en las neuronas de una misma capa y en la mayoría de los casos se emplean funciones de activación diferentes entre capas.

La formulación matemática presente por capa puede ser extraída del esquema de red presentado en la figura 7. En esa red, cada elemento del vector de entrada p se conecta a cada neurona a través de la matriz de pesos W . La i -ésima neurona tiene un sumador que recoge sus entradas pesadas y el factor de sesgo b , para formar su propia salida escalar $n(i)$. Varios $n(i)$ forman el vector n de S elementos. Finalmente, las salidas de cada neurona forman un vector columna a , el cual se calcula según la expresión mostrada en la parte inferior de la figura 7.

En cuanto a la notación empleada, es conveniente resaltar que el número de entradas a una capa R puede ser diferente del número de neuronas por capa S , de tal forma que no se restringe el número de neuronas de una capa al número de entradas de la misma.

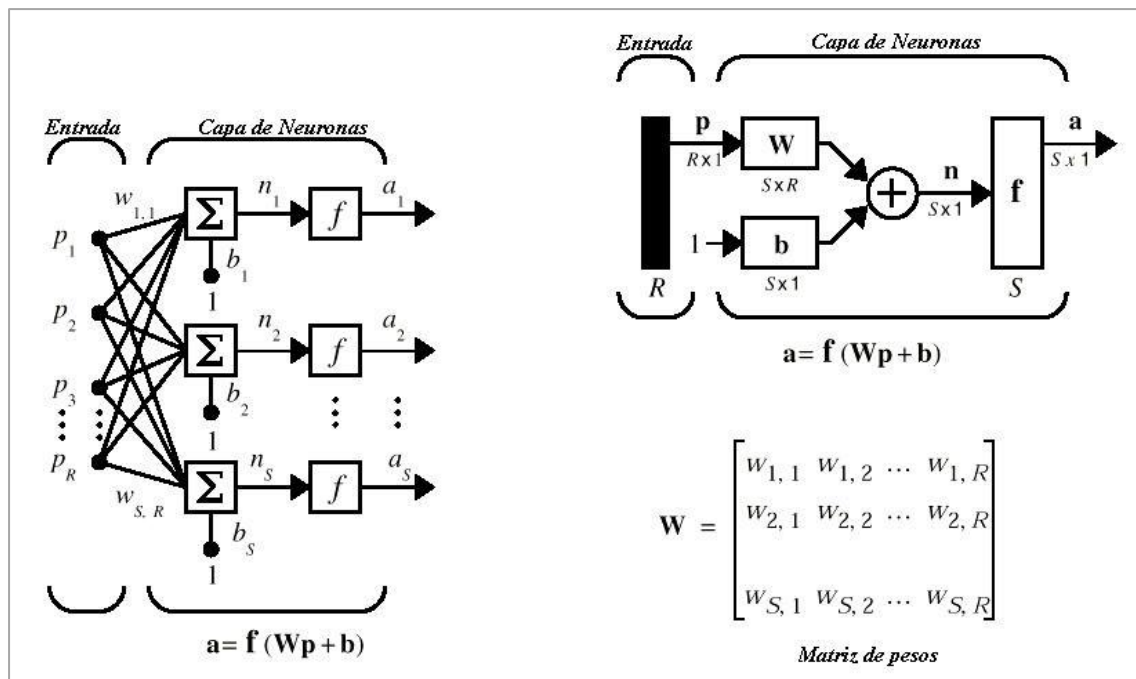


Fig. 7: Representación esquemática y matricial de una capa de neuronas

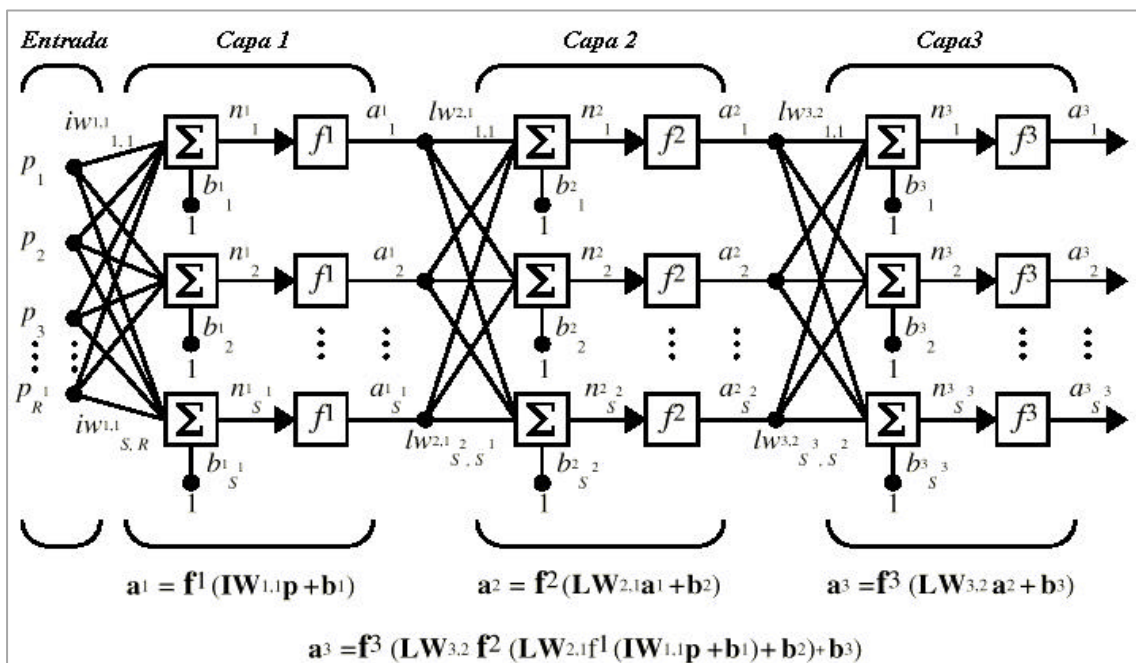


Fig. 8: Ejemplo de una red neuronal de 3 capas

Dentro de una red neuronal, los elementos de procesamiento se encuentran agrupados por capas; una capa es una colección de neuronas, que de acuerdo a su ubicación recibe diferentes nombres: Se denomina capa de entrada a aquella que recibe las señales de entrada. Capas ocultas a aquellas que no tienen contacto con los datos exteriores, sus elementos pueden poseer diferentes formas conexión, determinando de esta manera la topología de la red y capa de salida, a aquella que recibe la información de las capas ocultas y la transmite al medio exterior.

Cuando se tienen varias capas en una red neuronal, cada capa tiene una matriz de pesos W , un vector de factores de sesgo b y un vector de salida a . En la figura 8, se muestra el esquema de una red de tres capas (una capa de entrada, una capa de salida y una capa oculta) y en la parte inferior la ecuación resultante para el vector de salida.

Para distinguir entre las matrices de pesos, las salidas, las funciones de activación etc., de cada capa, se coloca un superíndice en la variable. En la figura 9 se muestra la red de tres capas de la figura 8, como una representación matricial.

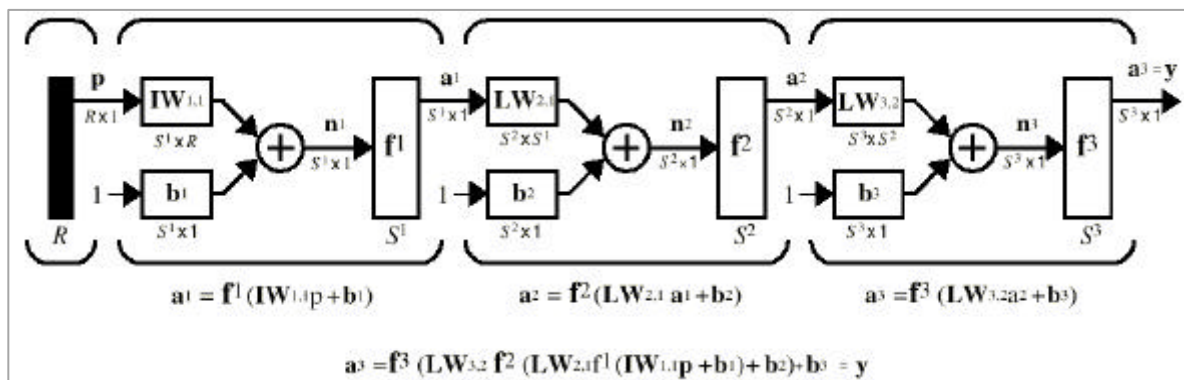


Fig. 9: Representación matricial de una red de 3 capas

3.- CLASIFICACIÓN DE LAS REDES NEURONALES

Los elementos básicos comentados anteriormente se pueden conectar entre sí para dar lugar a las estructuras neuronales o modelos de conexión, los cuales podrían ser clasificados de diferentes formas según el criterio usado. De esta manera se podrían tener redes neuronales de los siguientes tipos:

3.1.- Según el número de capas

Las redes neuronales pueden ser clasificadas como redes neuronales monocapa, que se corresponden a la red neuronal más sencilla, en donde una capa de neuronas proyecta las entradas a una capa de salida donde se realizan diferentes cálculos; por no realizarse ningún cálculo en la capa de entrada, se consideran estas redes como una sola capa. Una aplicación típica de este tipo de redes es como memorias asociativas.




Fig. 10: Red monocapa

La otra clasificación la conforman las redes neuronales multicapa, que serían 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.




Fig. 11: Red multicapa

3.2.- Según la forma de conexión

Las redes neuronales también pueden ser clasificadas, según su conexión, como redes neuronales unidireccionales (feed-forward), donde la propagación de las señales se produce en un sentido solamente, no existiendo la posibilidad de realimentaciones. Como ejemplo puede observarse la figura 10.

Otro tipo sería el integrado por las redes neuronales recurrentes, las cuales se caracterizan por la existencia de lazos de realimentación. Estos lazos pueden ser entre neuronas de diferentes capas, neuronas de la misma capa o, más sencillamente, entre una misma neurona. Esta estructura recurrente la hace especialmente adecuada para estudiar la dinámica de sistemas no lineales. En la figura 12 se representa el esquema de una red recurrente.

3.3.- Según la forma de asociación

Pueden ser clasificadas como redes heteroasociativas, cuando asocian un patrón de entrada A con otro diferente B a la salida; y redes autoasociativas, cuando asocian un patrón de entrada A (posiblemente perturbado por ruido) consigo mismo a la salida.




Fig. 12: Red neuronal recurrente



3.4.- Según la dinámica de actualización

Pueden ser sub-clasificadas como redes síncronas, cuando los estados se actualizan en función de un cierto reloj común a todas las neuronas, las cuales se van actualizando por capas, empezando por las de entrada y prosiguiendo hacia la salida. El caso contrario a las anteriores son las redes asíncronas, es decir, no hay reloj, y entonces las neuronas actualizan su estado independientemente de las demás.

Por otro lado, las redes estocásticas generan una componente aleatoria tanto en el instante de actualización como en el valor del estado.

4.- DEFINICIÓN DE PARÁMETROS

Además de la selección de la función de activación en cada una de las neuronas, el usuario deberá definir otros parámetros de la red neuronal en conjunto, antes de iniciar el proceso de entrenamiento. Estos parámetros son: arquitectura de red, proceso de aprendizaje, criterio de normalización y criterio de parada. A continuación se presenta una descripción de cada uno de ellos.

4.1.- Arquitectura de red

Es la forma como se conectan las neuronas que conforman la red; la arquitectura o topología de red está definida por el número de capas, número de neuronas por capa y forma de conexión. En cuanto a esta última característica se dice que la red es alimentada hacia adelante (feed-forward) cuando las neuronas se conectan sólo hacia capas posteriores o recurrente cuando una o varias salidas de las neuronas de una capa se emplean como realimentación de sí mismas o de otras neuronas de una capa anterior.

4.2.- Proceso de Aprendizaje

Es el orden de operaciones a realizar para modificar los valores de los pesos a través de toda la red neuronal, a fin de obtener una salida deseada, partiendo de sus correspondientes entradas a la red.

Los pesos de una red neuronal son los responsables de que dos redes con arquitecturas idénticas resuelvan problemas totalmente diferentes y, por lo tanto, estos representan la experiencia de la red sobre un problema particular. Es por ello que, además de la estructura, la red neuronal necesita utilizar un mecanismo que le permita establecer las intensidades de cada conexión sináptica o pesos de manera eficiente. Son muchas las variantes en cuanto a procesos para conseguir el aprendizaje de la red. Sin embargo, se pueden diferenciar dentro del proceso unas reglas o algoritmos de aprendizaje y unos paradigmas de aprendizaje.

Los algoritmos de aprendizaje, son metodologías planteadas para lograr el aprendizaje de la red mediante alguna técnica matemática específica. Los paradigmas de aprendizaje, se refieren al modo en que la red se relaciona con su ambiente de aprendizaje. En la figura 13 se muestra un esquema de los principales algoritmos y paradigmas de aprendizaje.

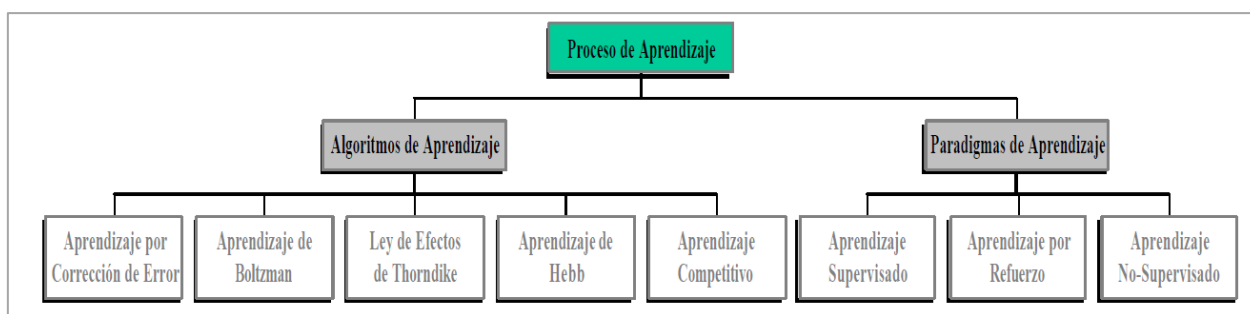


Fig. 13: Algoritmos y paradigmas de aprendizaje

Entre los algoritmos de aprendizaje, el de corrección de error es el más comúnmente usado en todas sus variantes, se fundamenta simplemente en minimizar una función basada en el error entre la respuesta objetivo y la respuesta de la red en la simulación.



La función de error se plantea a partir de un criterio estadístico, el más comúnmente usado es el error MSE o error cuadrático medio.

El aprendizaje de Boltzman es un algoritmo estocástico derivado de la teoría termodinámica y la mecánica estadística. En este caso, la salida de las unidades de procesamiento es una función estocástica de las entradas, en vez de ser una función determinista como en el algoritmo de corrección de error. Con respecto a las neuronas de la red, sus salidas se calculan usando probabilidades en vez de una función umbral o una función de salida. La función a minimizar en este caso es la energía y se emplea la distribución de Boltzman para encontrar las probabilidades de los estados energéticos. Este mismo planteamiento se emplea en otra técnica de optimización conocida como simulated annealing o temple simulado.

En cuanto a los paradigmas de aprendizaje, éstos se clasifican como aprendizaje supervisado, aprendizaje por refuerzo y aprendizaje no-supervisado. Los supervisados requieren que cada que ha de ser utilizada en el entrenamiento, esté acompañada de la respuesta o salida que la red debe producir ante ella. En este aprendizaje, también conocido como aprendizaje por corrección de error, se conoce la magnitud del error y ésta determina la magnitud en el cambio de los pesos. Es la forma más común de aprendizaje empleada.

En el aprendizaje por refuerzo sólo se conoce si la salida de la red corresponde o no con la señal deseada, es decir, la información es de tipo booleana (verdadero o falso), y se basan en la ley de efectos de Thorndike, la cual es a su vez, un algoritmo de entrenamiento. Este algoritmo se basa en que si un sistema responde satisfactoriamente a una acción, este proceso es reforzado.

Los paradigmas de aprendizaje no-supervisados, generalmente utilizados en clasificación, requieren a cambio de la respuesta deseada, asignar valores a un conjunto de parámetros que regulan el aprendizaje.



4.3.- Criterios de Normalización y Parada

La selección de estos dos aspectos manipula en cierta forma la información de entrada y las respuestas a la salida de la red. La normalización de la información (convertir datos a valores en el rango de 0 a 1) de entrada, es necesaria si se considera el uso de funciones de activación cuyos valores estén en rangos de 0 a 1. Una normalización común de un dato a ser introducido a la red, puede ser realizada empleando los valores máximos y mínimos de los datos disponibles, por ejemplo:

$$\text{Dato Normalizado} = (\text{Dato} - \text{Valor Mín}) / (\text{Valor Máx} - \text{Valor Mín})$$

El criterio de normalización depende de los requerimientos del usuario en las funciones de activación que empleará en la red.

En cuanto al criterio de parada, un sistema que se considere inteligente deberá prever mecanismos para detener su proceso de aprendizaje cuando las metas en cuanto al error (diferencia entre la respuesta real del sistema y la obtenida por la red) han sido alcanzadas o para dar por terminado el proceso cuando parezca que no se van a poder alcanzar tales metas, evitando un gasto de procesamiento inútil. Existen diferentes formas de contabilizar el error entre una respuesta de la red y la respuesta real objetivo. Estos errores provienen de la teoría estadística, y entre ellos los más comúnmente usados son: error residual, desviación media absoluta, error cuadrático medio, porcentaje de error medio absoluto y porcentaje medio de error.

El criterio de parada es de vital importancia en todo algoritmo de optimización a nivel general y en este caso concreto en todo algoritmo de entrenamiento de un sistema de aprendizaje basado en ejemplos. Sus funciones principales son:

1) Reducir el tiempo de aprendizaje: Es frecuente al utilizar ciertos métodos de optimización en los que la llegada al mínimo sea muy lenta, por lo que es aconsejable parar antes de llegar a éste, obteniendo aún buenos resultados.

2) Asegurar que el sistema de aprendizaje tenga una buena generalización: Se entiende por generalización, cuando la red es capaz de dar una respuesta correcta, cuando se le muestran entradas diferentes a aquella con las cuales ha sido entrenada. En la figura 14 se muestra un esquema del concepto de generalización.

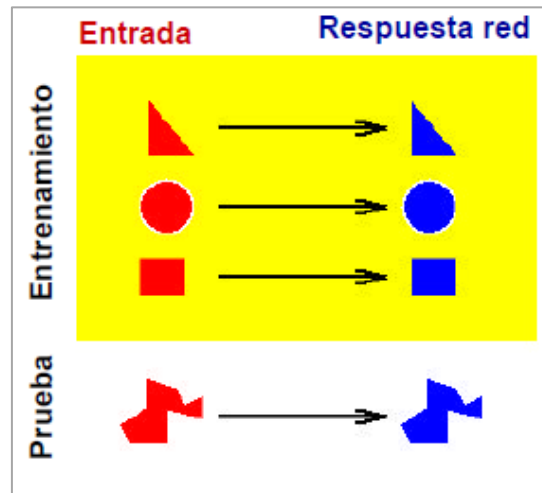


Fig. 14: Ejemplo del concepto de generalización

La topología de una red neuronal, es decir, el número de nodos y la ubicación y el número de conexiones entre ellos, tiene un impacto significativo en el rendimiento de la red y su habilidad para generalizar. La densidad de conexiones en una red neuronal determina su habilidad para almacenar información. Si una red no tiene suficientes conexiones entre nodos, el algoritmo de entrenamiento puede no converger nunca ya que la red neuronal no es capaz de aproximar la función. Por otro lado, en una red densamente conectada, puede darse el sobreajuste (overfitting), el cual es un problema de los modelos estadísticos donde se presentan demasiados parámetros. Esta es una situación negativa porque, en lugar de aprender a aproximar la función presente en los datos, la red simplemente puede memorizar cada ejemplo de entrenamiento. El ruido en los datos de entrenamiento se aprende entonces como parte de la función, a menudo destruyendo la habilidad de la red para generalizar.

El criterio de parada no implica en sí la ecuación o el tipo de error empleado, sino el criterio utilizado por el algoritmo de entrenamiento de la red para detener el proceso. Este criterio puede estar basado en los objetivos error de entrenamiento y/o de validación.



Se puede considerar el problema de selección de la red como una elección, dentro del conjunto de modelos de estructuras candidatas, de la mejor estructura de acuerdo a un cierto criterio. En este contexto, una herramienta estándar en estadística conocida como validación cruzada puede resultar útil. En ella, el conjunto de entrenamiento se divide aleatoriamente en dos subconjuntos:

- El subconjunto de estimación, usado para seleccionar el modelo (también llamado set de entrenamiento).
- El subconjunto de validación, usado para evaluar o validar el modelo.

El objetivo es validar el modelo sobre un conjunto de datos diferente de aquel utilizado para la estimación de los parámetros. De este modo se puede usar el conjunto de entrenamiento para evaluar el rendimiento de varios modelos candidatos, y así elegir el mejor.

Comúnmente, un perceptrón multicapa entrenado con el algoritmo de backpropagation aprende en etapas, moviéndose desde la realización de funciones de mapeo bastante simples a más complejas a medida que progresa la sesión de entrenamiento. Esto se ejemplifica por el hecho de que en una situación típica, el error cuadrático medio disminuye con el incremento del número de repeticiones durante el entrenamiento: comienza con un valor grande, decrece rápidamente, y luego continúa disminuyendo lentamente mientras la red converge hacia un mínimo local sobre la superficie de error. Teniendo como meta una buena generalización, es muy difícil darse cuenta de cuándo es el mejor momento de detener el entrenamiento si solamente se está mirando a la curva de aprendizaje para dicho entrenamiento.

En particular, como se mencionó anteriormente, es posible que la red termine sobreajustándose a los datos de entrenamiento si la sesión de entrenamiento no se detiene en el momento correcto. Sin embargo, se puede identificar el comienzo del sobreajuste a través del uso de la validación cruzada, para lo cual los ejemplos de entrenamiento se separan en un subconjunto de estimación y un subconjunto de validación. El de estimación se utiliza para entrenar a la red en el modo usual, excepto

por una modificación menor: la sesión de entrenamiento se detiene periódicamente (cada tantas repeticiones), y se evalúa la red con el conjunto de validación después de cada período de entrenamiento. Más específicamente, el proceso periódico de estimación seguida de validación procede de la siguiente manera:

1) Después del período de estimación (entrenamiento), se fijan todos los pesos y los umbrales del perceptrón multicapa, y la red opera en su modo hacia delante. El error de validación se mide así para cada ejemplo en el conjunto de validación.

2) Cuando la fase de validación se completa, la estimación (entrenamiento) se reanuda para otro período y el proceso se repite.

Este procedimiento se denomina método de entrenamiento con detención temprana o "early stopping". En la figura 15 se muestran las formas de dos curvas de aprendizaje, una perteneciente a las medidas sobre el subconjunto de estimación y la otra sobre el de validación.

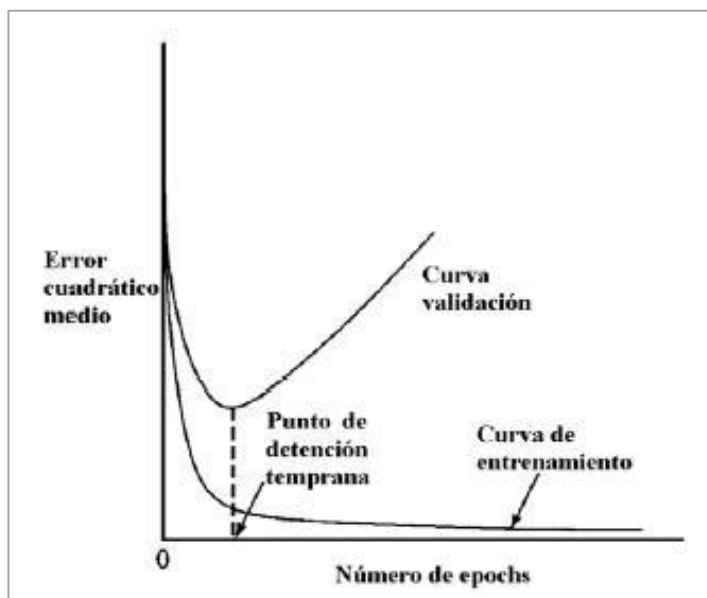


Fig. 15: Regla de detención temprana basada en validación cruzada

Normalmente, el modelo no trabaja tan bien sobre el subconjunto de validación como lo hace sobre el de estimación, en el cual se basó su diseño. La curva de aprendizaje de estimación decrece monótonamente para un número creciente de repeticiones.



En contraste, la curva de aprendizaje de validación decrece monótonamente hasta un mínimo, entonces empieza a incrementarse mientras continúe el entrenamiento. Al observar la curva de aprendizaje independientemente se podría pensar que después del punto señalado como detección, se podría mejorar aún más; en realidad, lo que la red está aprendiendo más allá de ese punto es esencialmente ruido contenido en el conjunto de entrenamiento, lo cual también produce efectos no deseados en la respuesta de la red. A este problema se le conoce como sobreentrenamiento, sugiriendo la heurística que el punto mínimo sobre la curva de aprendizaje de validación sea utilizado como un criterio para detener la sesión de entrenamiento.

5.- EL PERCEPTRÓN MULTICAPA

El perceptrón multicapa es la red neuronal artificial más conocida y de mayor número de aplicaciones dentro del estado del arte de las redes neuronales artificiales.

Su historia comienza en 1958 cuando Rosenblatt publica los primeros trabajos sobre un modelo neuronal y su algoritmo de aprendizaje.

El perceptrón está formado por una única neurona, por lo que su utilización está limitada a la clasificación de patrones en dos clases. Si se expande esta capa de salida con más de una neurona se ampliará el número de clases posibles aunque con la limitación demostrada por Minsky y Papert, consistente en que estas clases deben ser linealmente separables.

Esta limitación imposibilita al perceptrón para resolver problemas tan sencillos como el de una función lógica XOR de 2 entradas, lo cual produjo un estancamiento en el desarrollo en torno a las RNA.

La separación de clases no linealmente separables se consigue introduciendo al menos una capa de neuronas entre la salida y la entrada. A este tipo de red se le denominó como "perceptrón multicapa" y nació básicamente con la intención de dar solución a las limitaciones del perceptrón clásico o monocapa.

El problema de este tipo de perceptrón está en su entrenamiento, ya que es difícil modificar correctamente los pesos de la capa oculta. Aparece entonces el problema de asignar un “error” durante el proceso de aprendizaje a estas neuronas; este problema es conocido en la teoría como el problema de la "asignación de crédito". El cual fue resuelto por una serie de investigadores de forma independiente, lo cual dio luz verde para lo que posteriormente se conoció como la regla de aprendizaje "Backpropagation", que tal como su nombre indica tiene la función de ir propagando los errores producidos en la capa de salida hacia atrás.

6.- LA REGLA DE APRENDIZAJE BACKPROPAGATION

El algoritmo backpropagation para redes multicapa realiza su labor de actualización de pesos y ganancias mediante el error cuadrático medio. La red con backpropagation trabaja bajo aprendizaje supervisado y, por tanto, necesita un conjunto de entrenamiento que le describa cada salida y su valor de salida esperado de la forma $\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\}$. Donde p_Q es una entrada de la red y t_Q es la correspondiente salida deseada para el patrón q-ésimo.

El entrenamiento de una red neuronal multicapa se realiza mediante un proceso de aprendizaje, en el cual se debe inicialmente tener definida la topología de la red, es decir: el número de neuronas en la capa de entrada el cual depende del número de elementos del vector de entrada, cantidad de capas ocultas y número de neuronas de cada una de ellas, número de neuronas en la capa de 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.

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 cuadrático medio en cada iteración

del proceso de aprendizaje. En la figura 16 se muestra una red de 3 capas con sus correspondientes neuronas y sus pesos ponderados w .

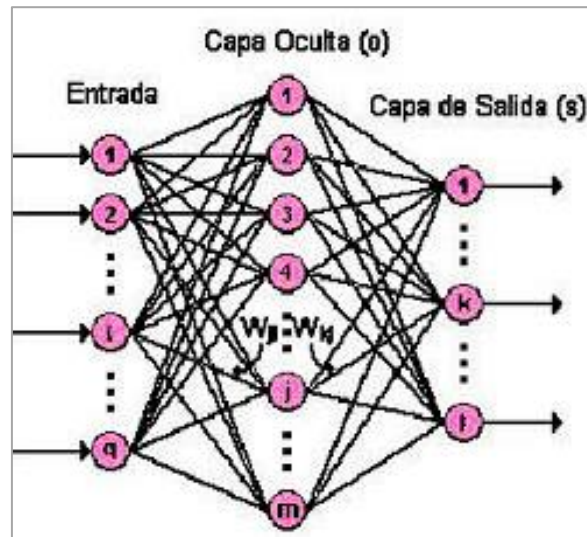


Fig. 16: Disposición de una red ejemplo de 3 capas

7.- PREDICCIÓN DE DEMANDA MEDIANTE REDES NEURONALES

La idea detrás del uso de modelos basados en redes neuronales para la predicción de parámetros relacionados con el consumo de energía es simple: No se requiere conocer una ecuación o función matemática que represente el comportamiento del consumo de energía, simplemente se requiere un sistema que a partir de un conjunto de datos históricos, determine el comportamiento futuro del consumo de energía. En otras palabras, se requiere de un modelo tipo "caja negra", en el cual no es de interés la ecuación matemática que modela el comportamiento, sino que respuesta da el sistema ante una entrada en particular.

Otro de los aspectos importantes dentro de los esquemas de predicción, es la suposición de que la carga futura es dependiente en la carga del pasado y algunos factores externos como variables económicas, climáticas y culturales, que tuvieron también relación con ella, empleándose la RNA para aproximar esta dependencia.

Los factores económicos de influencia en la demanda tienen una mayor cabida en el pronóstico a largo plazo. Se deben principalmente a cambios en factores productivos



como crecimiento en la industria, recesión económica y programas de gestión de la demanda, entre otros.

Los factores climáticos están más relacionados con el pronóstico de la demanda de corto plazo. Algunos esquemas de predicción consideran efectos en la demanda tales como: temperatura, humedad, velocidad del viento, luz solar y efectos estacionales (épocas de tormentas, nieve, etc.,...).

Desafortunadamente, las condiciones climáticas son bastante específicas de una región y se requiere información actualizada específica de la zona de demanda, lo que imposibilita la aplicación de estas variables explicativas en modelo de predicción de la demanda con mayor grado de agregación, sin contar el problema de la disponibilidad de los datos.

Los factores culturales, están asociados principalmente al calendario laboral (días laborables, fines de semana y festivos). No obstante, algunos esquemas de predicción consideran efectos no comunes, como eventos deportivos, periodos vacacionales, cambio de horario por estaciones, programas de televisión de gran impacto, entre otros. Una posible arquitectura que solucione el problema, se muestra a continuación.

En la figura 17 se presenta una arquitectura de red común a la mayoría de esquemas de predicción encontrados en el estado del arte. En este esquema se distinguen tres tipos de datos en los que se subdivide la capa de entrada: Datos de demanda históricos, información del calendario e información climática.

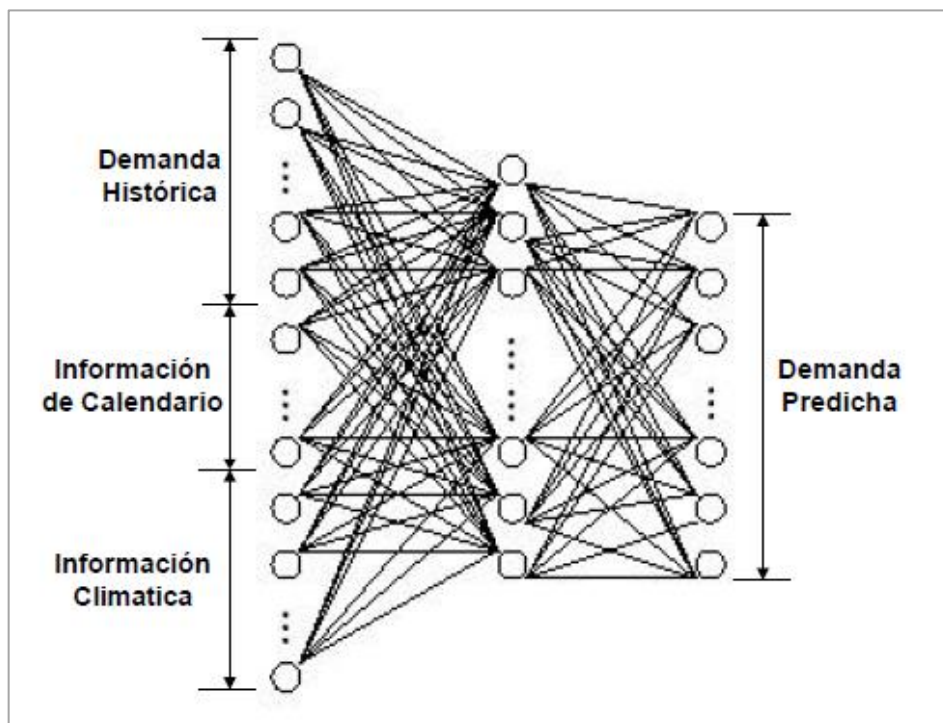


Fig. 17: Estructura típica de una red neuronal para predicción de demanda

Por las características del problema, se considera la construcción de un modelo de predicción de demanda como un problema de identificación de sistemas no lineales. No obstante, a diferencia de las metodologías clásicas de identificación de sistemas como ARIMA, el trabajo con redes neuronales adolece de procedimientos generales para construir los modelos, siendo por lo general seleccionados de manera heurística.

Existen dos fases en toda aplicación de las redes neuronales: la fase de aprendizaje o entrenamiento y la fase de prueba. En la fase de entrenamiento, se usa un conjunto de datos o patrones de entrenamiento para determinar los pesos (parámetros de diseño) que definen el modelo neuronal. Por lo general el conjunto de datos empleado en la fase de entrenamiento se divide en un conjunto para el entrenamiento propiamente dicho y otro a efectos de validar el modelo durante el entrenamiento, incluidos dentro del algoritmo de aprendizaje.

Una vez entrenado este modelo, se usará en la llamada fase de prueba o funcionamiento directo, en la que se procesan los patrones de prueba que constituyen



la entrada habitual de la red, analizándose de esta manera las prestaciones definitivas de la red.

Una revisión del estado del arte muestra que la mayoría de trabajos en torno al tema han usado un perceptrón multicapa feedforward como un estimador de una relación no lineal desconocida, pero con aspectos diferenciadores en el uso de los datos de tiempo, las otras variables de entrada, la arquitectura de la red, el algoritmo de entrenamiento, la selección y tratamiento de los datos de entrenamiento.

No obstante, se observan muchos tipos de esquemas para la solución del problema, como aquellos que aplican modelos híbridos con combinaciones de técnicas que emplean inteligencia artificial y/o técnicas convencionales de predicción, y dentro de aquellas que usan redes neuronales, es también común encontrar modelos que usan aprendizaje y redes recurrentes, por mencionar algunos ejemplos.

Un acercamiento común entre los esquemas de predicción encontrados en el estado del arte, es la creación de un sistema modular dónde se concentran las tareas específicas del proceso de predicción, como por ejemplo el tratamiento de los datos de entrada o la realimentación de errores en un sistema dinámico de predicción.

CAPÍTULO III:

DESARROLLO

DESARROLLO

1.- ORIGEN Y ESTRUCTURA DE LOS DATOS

Los datos utilizados para el estudio son los proporcionados por REE, dichos datos se encuentran disponibles para el público a través de su página web (<https://demanda.ree.es/movil/peninsula/demanda/total>), en el caso que nos ocupa se seleccionará la demanda peninsular exclusivamente. La estructura de los datos se ilustra en la figura 18 y es la siguiente: Se nos presenta la curva de carga perteneciente al día seleccionado, dicha curva se muestra por triplicado para representar los valores reales, previstos y programados. Además, se muestran datos referentes al tipo de generación y emisiones de CO₂.



Fig. 18: Seguimiento de la demanda de energía para un día determinado

No obstante, para el objeto de este proyecto, resulta más conveniente obtener dichos valores directamente en formato de tabla, con objeto de trasladarlos de forma sencilla y precisa a los programas estadísticos. Para ello se nos presenta la opción de recopilar los valores a intervalos de 10 minutos, dicha disposición de los datos se muestra en la figura 19. Con objeto de reducir la carga computacional de la predicción, se eliminarán

los valores tomados cada diez minutos, quedándonos solamente con los valores pertenecientes a horas en punto, reduciendo ampliamente tanto el tamaño del fichero de datos como el tiempo necesario para obtener una estimación.

Seguimiento de la demanda de energía eléctrica (MW)			
Hora	Real	Prevista	Programada
2016-03-16 21:00	36199	36429	35540
2016-03-16 21:10	36174	36195	35540
2016-03-16 21:20	36212	35923	35540
2016-03-16 21:30	35640	35613	35540
2016-03-16 21:40	35216	35266	35540
2016-03-16 21:50	34810	34882	35540
2016-03-16 22:00	34086	34459	33025
2016-03-16 22:10	33988	34008	33025
2016-03-16 22:20	33777	33539	33025
2016-03-16 22:30	32978	33050	33025
2016-03-16 22:40	32892	32542	33025
2016-03-16 22:50	32211	32015	33025
2016-03-16 23:00	31466	31467	29980
2016-03-16 23:10	30992	30930	29980
2016-03-16 23:20	30683	30429	29980
2016-03-16 23:30	30210	29966	29980

Fig. 19: Valores de las curvas de demanda

Partiendo de los datos en este formato, podemos proceder a la importación de los mismos a una hoja de cálculo para su posterior análisis, quedando el resultado final tal como se puede observar en la figura 20.

	A	B	C	D	E	F	G	H
1	FECHA - HORA	REAL	PREVISTA	FILTRO HORA	FILTRO FECHA	FILTRO DÍA	FILTRO MES	FILTRO AÑO
2	01/01/2012 0:00	25422	25489	0:00	1	domingo	enero	2012
3	01/01/2012 1:00	24775	24093	1:00	1	domingo	enero	2012
4	01/01/2012 2:00	23194	23204	2:00	1	domingo	enero	2012
5	01/01/2012 3:00	21480	21711	3:00	1	domingo	enero	2012
6	01/01/2012 4:00	20289	20061	4:00	1	domingo	enero	2012
7	01/01/2012 5:00	19605	19393	5:00	1	domingo	enero	2012
8	01/01/2012 6:00	19467	19468	6:00	1	domingo	enero	2012
9	01/01/2012 7:00	19429	19400	7:00	1	domingo	enero	2012
10	01/01/2012 8:00	19587	19796	8:00	1	domingo	enero	2012
11	01/01/2012 9:00	18850	19572	9:00	1	domingo	enero	2012
12	01/01/2012 10:00	19973	19821	10:00	1	domingo	enero	2012
13	01/01/2012 11:00	21241	21409	11:00	1	domingo	enero	2012
14	01/01/2012 12:00	22463	22368	12:00	1	domingo	enero	2012
15	01/01/2012 13:00	23015	22953	13:00	1	domingo	enero	2012
16	01/01/2012 14:00	23466	23347	14:00	1	domingo	enero	2012
17	01/01/2012 15:00	22581	22643	15:00	1	domingo	enero	2012
18	01/01/2012 16:00	21717	21446	16:00	1	domingo	enero	2012
19	01/01/2012 17:00	22044	21917	17:00	1	domingo	enero	2012
20	01/01/2012 18:00	24244	24728	18:00	1	domineo	enero	2012

Fig. 20: Datos importados a Excel y clasificados de acuerdo a diferentes criterios

2.- METODOLOGÍA

Una vez definidos tanto el origen como el formato de los datos, es preciso determinar el horizonte horario de la predicción a realizar. En nuestro estudio se realizará una **estimación a 24 horas de un día de 2015**, lo cual la engloba en el terreno de las predicciones a corto plazo.

En este caso se utilizarán los **años 2014 y 2015** (obviamente, de 2015 sólo se tomarán los valores **anteriores** al día a predecir) como **datos históricos** a partir de los que realizar las predicciones, asimismo, se tomará un **subconjunto** de los datos para la **validación** de dichas estimaciones.

Para llevar a cabo la predicción **dividiremos el día en sus 24 horas correspondientes y realizaremos un modelo para estimar cada una de ellas por separado, empezando por las 00:00 horas y acabando en las 23:00 del día en cuestión.**

Con objeto de probar los modelos para distintas condiciones y épocas del año, se estudiarán tres casos:

- 1) **Día de máxima potencia instantánea (4/2/2015)**
- 2) **Día laborable (12/5/2015)**
- 3) **Sábado (3/10/2015)**

Nuestro estudio se dividirá en dos partes según la técnica predictiva empleada, esto es, ARIMA o Redes Neuronales. Para cada metodología se desarrollará el proceso según los parámetros anteriormente mencionados indicando, si fuera necesario, las variaciones introducidas.

Posteriormente se compararán los resultados con los datos reales de ese día y la estimación realizada por REE con objeto de extraer las correspondientes conclusiones acerca del ajuste de nuestros modelos.



3.- MODELO ARIMA

A continuación se detalla el procedimiento utilizado para realizar la predicción de acuerdo a la metodología Box-Jenkins. **Dado que dicho procedimiento será análogo para las 24 horas de los 3 días objeto de estudio, se utilizará una de las horas correspondientes al caso 1 (punta de demanda anual) como ejemplo para ilustrar el proceso de estimación. En concreto, utilizaremos la Hora 12.**

3.1.- Procedimiento

Con objeto de exponer de forma concisa el procedimiento a seguir para lograr nuestra estimación con un nivel de ajuste adecuado, en este apartado se detallarán brevemente los pasos que seguiremos en los epígrafes posteriores.

- 1) Se clasifican por horas los datos de demanda obtenidos de REE.
- 2) Para la hora estudiada se realiza la división del conjunto de datos en dos subconjuntos, uno de datos históricos y otro de validación.
- 3) Hacemos un análisis de la serie temporal compuesta por los datos históricos con objeto de obtener el máximo de información previa para nuestro modelo.
- 4) Dentro del software SPSS, analizamos las funciones de autocorrelación de nuestra serie temporal.
- 5) Estudiando las gráficas de las autocorrelaciones y, comparándolas con los patrones presentes en la bibliografía, se aplican unos valores a los coeficientes p , d y q .
- 6) El modelo ARIMA creado a partir de estos coeficientes se aplica al conjunto de validación. Se obtienen varios estadísticos relevantes a la hora de valorar la bondad del ajuste.



- 7) Se realiza una comparativa entre los estadísticos (errores) obtenidos y los valores de referencia presentes en la bibliografía.
- 8) Si los errores se encuentran dentro de unos parámetros aceptables se detiene la iteración y se dan los coeficientes por buenos. En caso contrario se continúa el método iterativo volviendo al paso 4.
- 9) Una vez obtenidos unos coeficientes definitivos se pasa a calcular el modelo ARIMA para la siguiente hora hasta completar las 24 horas del día a predecir.

3.2.- Conjuntos de datos históricos y de validación

En primer lugar es necesario estudiar la división del conjunto de casos en los respectivos subconjuntos de datos históricos y de validación, mediante este paso definiremos la cantidad de información que destinaremos, por un lado a la creación de nuestro modelo ARIMA y por el otro a la comprobación de la bondad del ajuste de dicho modelo. Considerando que, para el Caso 1 (4/2/2015), nuestros datos comenzarán el 1/1/2014 y terminarán el 3/2/2015 nos encontramos con 400 días aproximadamente que dividiremos de acuerdo al siguiente criterio:

- **Conjunto de Datos Históricos**: Es el conjunto de datos que utilizamos para ajustar los coeficientes del modelo ARIMA. En nuestro caso utilizaremos los **valores de la hora a predecir que se hayan dado en todos los casos anteriores (sólo días laborables) a la fecha objeto de la estimación menos los destinados al conjunto de validación**. En este caso, tomaremos 360 días como conjunto de datos históricos.

- **Conjunto de Validación**: Es el conjunto de datos encargados de evaluar la capacidad de predicción y precisión del modelo ARIMA. En nuestro caso se utilizará la **validación cruzada, tomando para ello varios días laborables extraídos de diferentes semanas y meses**. Tomaremos 40 días (10%) como conjunto de validación.

3.3- Análisis de la serie temporal

El análisis preliminar de una serie constituye el primer paso a seguir a la hora de estudiar una serie temporal. Esta fase nos permite detectar las características más importantes de una serie, tales como su tendencia (creciente o decreciente), la existencia de ciclos, presencia de valores atípicos, etc.

En primer lugar se calculan algunos de los valores más relevantes de la serie temporal creada a partir de los datos históricos de la hora a predecir. La tabla 2 refleja el resultado del cálculo de los valores máximo, mínimo y la media para la hora 12.

ESTADÍSTICOS DESCRIPTIVOS	
<i>Observaciones</i>	360
<i>Mínimo</i>	19247
<i>Máximo</i>	36573
<i>Media</i>	27910

Tabla 2: Estadísticos descriptivos para la Hora 12 del Caso 1

3.3.1.- Gráfico de secuencia

La forma más sencilla de comenzar el análisis de una serie temporal es mediante su representación gráfica. El gráfico que se emplea para representar las series temporales es el gráfico de secuencia. Los gráficos de secuencia son diagramas de líneas en los cuales el tiempo se representa en el eje de abscisas (x), y la variable cuya evolución en el tiempo estudiamos en el eje de ordenadas (y).

En primer lugar, **se representará gráficamente la serie temporal correspondiente a la hora 12 en todos los casos históricos disponibles**, con ello, tendremos una idea de la evolución general de la variable (hora) a lo largo de un periodo estimado de más 12 meses. Por tanto, a modo de ejemplo, en la figura 21 se mostrarán los valores de potencia para la hora 12 a lo largo del conjunto de datos históricos.




Fig. 21: Gráfico de secuencia para la Hora 12 del Caso 1

Estudiando la evolución de la variable en dicho período, se observa que **presenta un período inicial de crecimiento invernal seguido de un descenso que se ve interrumpido en los meses cálidos del año por un crecimiento moderado y un descenso paulatino hacia el otoño para, ya al final del año, volver a la senda del crecimiento.**

3.3.2.- Estacionalidad

Una serie es estacional cuando podemos observar en ella un patrón sistemático que se repite periódicamente (cada año, cada mes, etc., dependiendo de las unidades de tiempo en que vengan recogidos los datos).

Existen muchos ejemplos de series con comportamiento estacional. El hecho de que las vacaciones laborales se concentren en los meses de verano condiciona los valores de muchas series. La pauta sistemática que caracteriza la estacionalidad no tiene por qué ser anual, algunas series tienen una estacionalidad cuyo periodo es de un mes, una semana o incluso un día.

Obviamente, en el estudio de la demanda de energía eléctrica era esperable encontrar una **fuerte estacionalidad que, como se ha visto en la figura 21 del apartado anterior está fuertemente ligada a la época del año.**

3.4.- Desarrollo del modelo

En el Capítulo III se hizo la descripción de la metodología Box-Jenkins para modelos ARIMA. A continuación se detallarán las sucesivas etapas que nos permitirán determinar el modelo que mejor se ajusta al comportamiento de la serie de datos.

3.4.1.- Preparación del modelo

En primer lugar abrimos en SPSS el conjunto de datos del problema, además se renombran las columnas (variables) según la hora del día correspondiente. En la figura 22 puede apreciarse la disposición que adoptan los datos en el software SPSS, con las horas distribuidas en columnas y los casos en filas, el último caso de cada columna será el valor a predecir.

	Hora_0	Hora_1	Hora_2	Hora_3	Hora_4	Hora_5	Hora_6	Hora_7	Hora_8	Hora_9	Hora_10	Hora_11	Hora_12	Hora_13	Hora_14	Hora_15	Hora_16	Hora_17	Hora
1	25422	24775	23194	21480	20289	19605	19487	19429	19587	18850	19973	21241	22463	23015	23466	22581	21717	22044	
2	24748	21782	20195	18834	18615	18520	19677	23111	25908	28532	30952	32032	31891	31935	31551	30466	30196	30081	
3	28702	25604	23414	22566	21932	21993	23167	26196	29627	32385	34297	34735	34535	34170	33534	31957	32076	32242	
4	29412	26962	24553	23581	23059	23190	23909	26826	30246	33397	35054	35248	34698	34458	33585	32102	32098	32386	
5	30031	26947	24742	23679	23166	23324	23919	27009	29844	32708	34570	34675	34172	33874	33103	31232	30749	30705	
6	29096	26441	24151	22446	21480	21386	21131	22043	22022	22974	24580	25597	25776	25910	25877	24496	23705	23808	
7	27392	24901	22747	21684	21165	20830	21213	22476	24020	25097	27576	28541	28383	28775	28998	27977	27129	27148	
8	27559	25538	23070	21960	21450	21203	21447	21978	22796	23323	25213	26282	27058	27414	28132	27014	26015	26056	
9	28021	24799	23015	22246	21917	21958	24065	27958	33810	36036	36813	36836	36137	35968	34797	33723	33620	34054	
10	30251	27215	25456	24529	24246	24502	25848	29370	34661	37025	38024	37986	37283	36721	35708	34612	34361	34637	
11	31203	28148	26292	25236	24695	25108	26178	30328	34764	37385	38269	38421	37912	37435	35946	34782	35110	35245	
12	31002	27858	26084	24925	24814	25045	26250	29926	35136	37269	38552	38603	38205	37838	36673	35897	35966	36088	
13	31470	28282	26062	25420	24888	25249	26001	30314	35294	37604	39104	39237	38613	38090	36657	35655	35361	35358	
14	32089	29404	26666	25143	24351	24227	24205	24935	26966	28693	32138	33473	32973	32484	32650	31386	30641	30287	
15	29792	27082	24833	23255	22738	22122	22781	23203	24012	24356	27145	29325	29957	30050	31186	30174	29508	28800	
16	29005	26034	24178	23415	23010	23083	24589	29440	34635	37066	39041	39580	39642	39642	38604	37309	37275	37066	
17	31086	27937	25958	24721	24550	24340	25661	29834	35141	37296	38286	38644	38368	37909	36967	36055	35568	35697	
18	31421	28338	26439	25240	24853	25097	26373	30204	35689	37880	38387	38442	37794	37374	36230	35015	34803	35199	
19	31821	28239	25927	24889	24902	24713	25812	30205	35017	37490	38696	37956	37466	36744	35588	34711	34403	34889	
20	30834	27837	25805	24843	24547	24679	25690	29789	34256	36507	37367	37427	36883	36056	34685	33263	32864	32991	
21	31095	28603	26286	24942	24067	23692	23434	24711	26267	28179	31105	31918	31498	30708	30595	29511	28459	27955	
22	29357	26644	24641	23082	22502	22022	22337	22876	23341	23880	26207	28066	27828	27771	28080	27109	26059	25613	
23	28047	25173	23448	22511	22079	22585	24087	28827	33849	36194	36935	36958	36278	35886	34591	33699	33399	33601	
24	29958	27278	25448	24521	24215	24119	25137	29406	34421	36131	36986	36838	36199	35971	34763	33506	33435	33599	
25	30248	27197	25331	24548	24172	24501	25871	29717	34847	36851	37582	37446	36881	36504	35049	33773	33980	33884	
26	31186	28359	25492	24507	24270	24697	25780	29688	34622	36594	37773	37913	37833	37119	35791	34440	34488	34671	
27	30441	27430	25381	24282	23894	24242	25137	28950	33890	36070	38100	38276	38114	37632	36782	35339	35054	35056	
28	31066	28032	25632	24362	23510	23189	23321	24272	25888	28037	31569	33022	32644	32656	32412	31067	30191	29844	
29	30393	27049	24539	23106	22334	22172	21926	22733	23227	23962	26009	28105	28370	28298	29353	28312	27243	26837	
30	28754	25483	23722	22744	22408	22907	24409	29006	34319	36872	37802	38137	37653	37283	36106	34818	34546	34387	

Fig. 22: Datos importados a SPSS

Ahora se hace uso del paquete predictivo incluido con SPSS y se realiza la estimación, para ello seleccionaremos la opción de *analizar*, dentro de esta *previsiones* y *crear modelo*. De este modo iremos determinando los distintos coeficientes que definen el modelo ARIMA.

Antes de realizar el análisis establecemos una periodicidad semanal de los datos, con cada entrada correspondiente a un día. En la figura 23 podemos observar las distintas periodicidades que nos permite asignar el programa y, en amarillo, la utilizada para nuestro estudio.

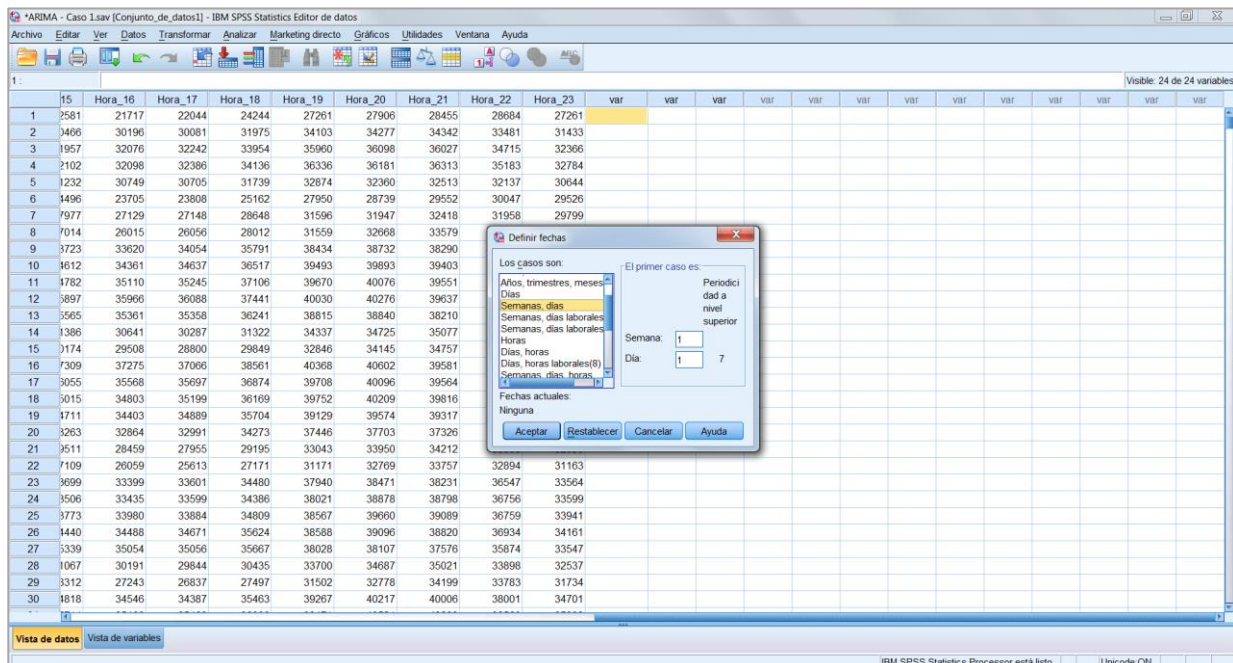


Fig. 23: Definición de periodicidad

A continuación, establecemos los períodos de estimación (del primer caso al último de los datos históricos) y previsión (caso inmediatamente posterior al último valor histórico). En la figura 24 podemos observar como asignamos la hora estudiada como variable dependiente y la periodicidad como variable independiente.

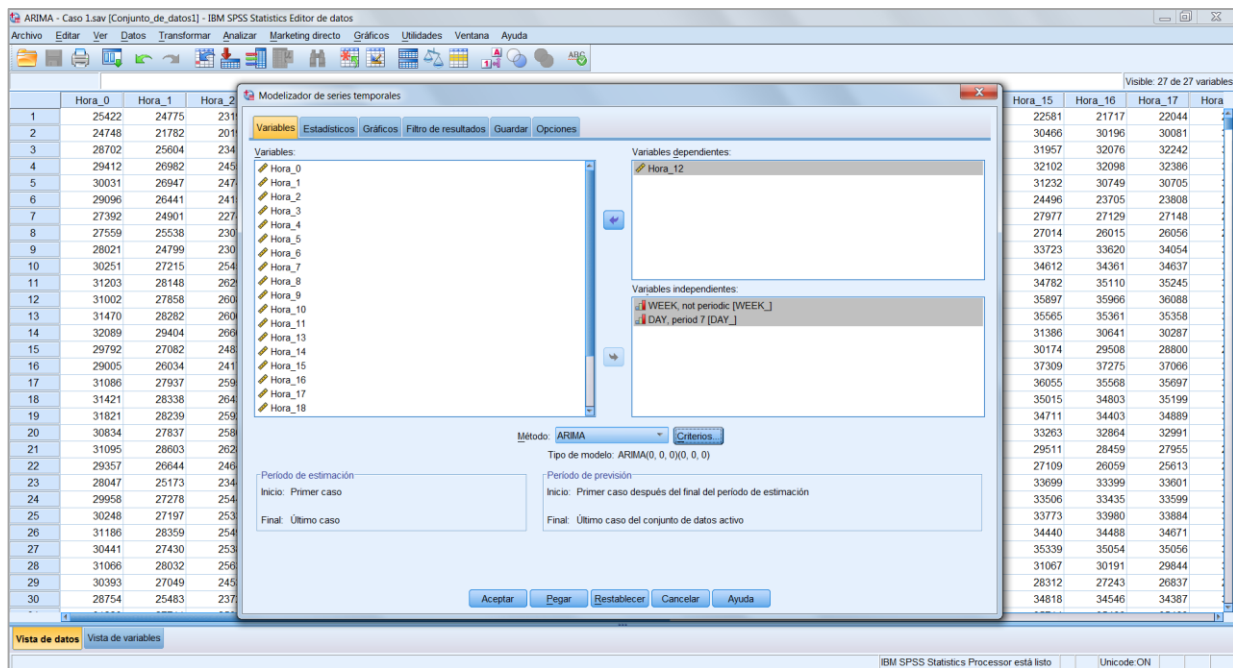


Fig. 24: Períodos de estimación y predicción

Ahora habría que definir los coeficientes para nuestro modelo ARIMA, con objeto de obtener una previsión lo más precisa posible, **se implementará en este punto un método iterativo que nos lleve a afinar los resultados, quedándonos para nuestro modelo con aquellos coeficientes que nos proporcionen un mejor ajuste, dicho ajuste se valorará según vayamos observando el comportamiento de los errores presentes en el conjunto de validación.** En la figura 25 se observa el modo de introducir los coeficientes que irán definiendo los sucesivos modelos.

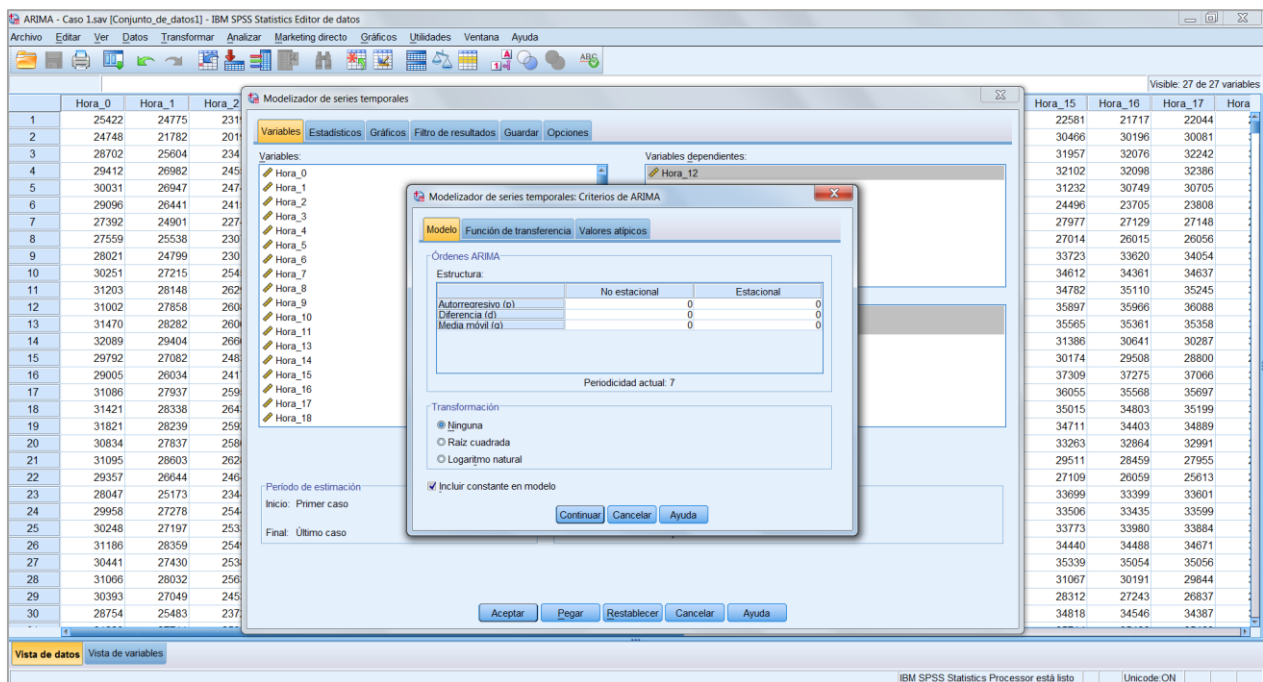


Fig. 25: Coeficientes del modelo ARIMA

Para este tipo de modelos, el primer paso consiste en convertir nuestra serie de observaciones en una serie estacionaria, que es aquella en la que ni la media, ni la varianza, ni las autocorrelaciones dependen del tiempo. Según sean los motivos por los que la serie no sea estacionaria, será necesario aplicar uno de los siguientes procedimientos hasta hacerla estacionaria.

- a) Si tiene tendencia: Tomaremos diferencias regulares hasta que desaparezca. Normalmente el orden de la diferencia será 1, y raramente será mayor a 3.
- b) Si es heterocedástica, es decir, no tiene varianza constante, habrá que transformar la serie.
- c) Si es estacional: Tomaremos diferencias estacionales hasta que desaparezca el patrón que se repite.

Una vez "estabilizada" la serie mediante las transformaciones adecuadas, se procede a estudiar la presencia de regularidades en la serie, para identificar un posible modelo matemático.

Para ello se calculan y representan la función de autocorrelación simple y parcial, y se compara su forma con un catálogo de patrones gráficos, que son típicos de los diferentes modelos propuestos, seleccionando el modelo que más se adecue a la forma de las funciones de autocorrelación que hemos obtenido con nuestros datos, de modo que podemos intentar deducir su estructura observando la FAC y la FACP, teniendo en cuenta que:

a) El decrecimiento de la autocorrelación en el tiempo (expresada en la altura de las barras) debe ser exponencial. También suelen aparecer una alternancia de los signos o una forma sinusoidal.

b) Una de las dos funciones de autocorrelación va a mostrar una estructura como la descrita en a), mientras que la otra mostrará algunos valores que salen de la banda de confianza.

c) La FAC y la FACP de un ruido blanco (serie de datos procedentes de variables sin ninguna estructura común, es decir, independientes entre sí) tiene todos los coeficientes nulos en teoría, o no significativos en nuestras gráficas.

d) Hay que tener en cuenta que las bandas de confianza que aparecen en las gráficas de las funciones de autocorrelación suelen determinar una zona del 95%, es decir, el coeficiente que sobresale se puede considerar no nulo con un 95% de seguridad.

Observando las gráficas anteriores podemos hacernos una idea de qué modelo subyace a nuestra serie, o al menos de cuáles son los primeros candidatos que debemos probar. Para comprobar analíticamente un modelo, vamos a intentar ajustar un modelo ARIMA(p,d,q) y donde el valor de “d” es el número de diferencias regulares que hayamos tenido que tomar para hacer la serie estacionaria, “p” es el orden de la parte AR y “q” el de la parte MA.

Puesto que no hay un único modelo correcto (que explique suficientemente bien los datos), de la misma manera que no hay una única función que pase por varios puntos

que tracemos en un sistema de ejes XY, algunos criterios que se pueden seguir para elegir un modelo satisfactorio son:

- Debe verificar las condiciones gráficas y numéricas necesarias.
- Sus residuos después de ajustar el modelo deben ser ruido. Un valor próximo a los límites de confianza en los retardos iniciales debe considerarse un indicio claro de que el modelo es inadecuado.
- Entre los que verifican las mismas condiciones numéricas más o menos, queremos tomar el más sencillo posible, es decir, el que necesite menos parámetros.
- En último término, la elección del modelo final debe ser un equilibrio entre simplicidad y eficacia.

En las figuras 26 y 27 se ilustran las gráficas de la función de autocorrelación y la función de autocorrelación parcial para la Hora 12 del Caso 1, a partir de la información que nos proporcionan podemos hacer una primera aproximación de los coeficientes de nuestro modelo.




Fig. 26: Gráfica FAC para la Hora 12 del Caso 1




Fig. 27: Gráfica FACP para la Hora 12 del Caso 1

Una vez obtenidos los correlogramas se procede a analizar su comportamiento y si es necesaria la diferenciación de la serie para transformarla en una serie estacionaria.

Cuando se tiene la FAC y FACP de la serie estacionaria se procede a estimar los valores p , d , q ; recordemos que d es las veces que se diferencia la serie para transformarla en una serie estacionaria. Una vez cumple esta condición los correlogramas resultantes se comparan con funciones FAC y FACP teóricas, para estimar el modelo.

En resumen, la metodología a seguir se basará en asignar, a partir de las gráficas de FAC y FACP, unos valores iniciales a los coeficientes que definen los modelos ARIMA para, a continuación, ejecutar este y comprobar los resultados obtenidos sobre el conjunto de validación, mediante el análisis de los errores aparecidos en dicho conjunto se irán ajustando progresivamente los modelos hasta lograr una predicción lo más precisa posible.

Tras la realización del método iterativo anteriormente descrito, se proponen en la tabla 3 los coeficientes para realizar la estimación de la hora 12.

HORA	MODELO (p,d,q)
12:00	ARIMA (1,1,2)

Tabla 3: Coeficientes del modelo ARIMA para la Hora 12 del Caso 1

Con objeto de justificar los coeficientes que se detallan en la tabla, se ilustrará a continuación el proceso de validación, detallando las diferentes magnitudes analizadas a la hora de continuar o, finalmente, detener nuestro proceso iterativo.

3.4.2.- Validación

Procedemos ahora a estimar el valor de la variable de acuerdo al modelo elegido, para ello **aplicaremos dicho modelo ARIMA a nuestro conjunto de validación que, tal como se definió anteriormente, está compuesto por un 10% de los datos disponibles, es decir, unos 40 días laborables anteriores al día a estimar.** Como paso previo es necesario definir los estadísticos y gráficos que vamos a usar en la fase de validación de la previsión. En la figura 28 se pueden observar los diferentes parámetros a aplicar al análisis de nuestro modelo, sería computacionalmente costoso marcar todos los estadísticos posibles, por tanto, marcamos sólo los más relevantes, tales como R^2 , R^2 estacionario y error absoluto porcentual promedio.

Para cada estadístico se realizará un breve comentario, proporcionando una explicación de la relevancia del mismo y una comparación con los parámetros en los que debe estar para avalar la bondad del ajuste del modelo.

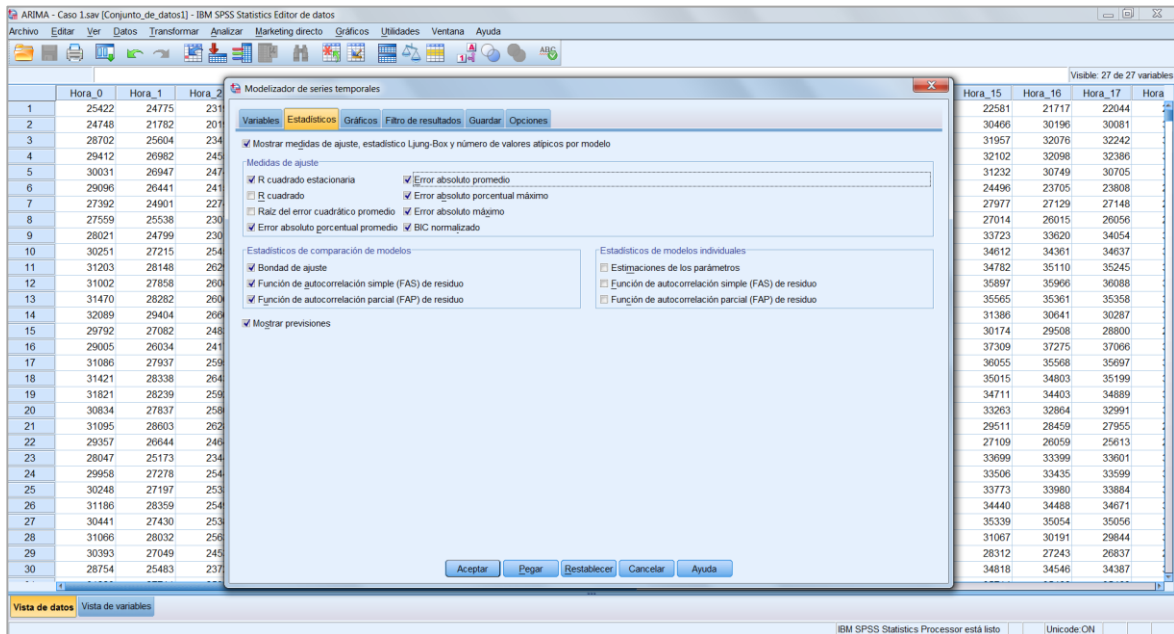


Fig. 28: Selección de estadísticos

En la figura 29 se ilustra el proceso de selección de los gráficos a mostrar, de nuevo guiaremos por consideraciones de economía y sencillez y mostraremos sólo aquellos gráficos cuyo análisis tenga una mayor importancia, especialmente el error absoluto porcentual promedio.

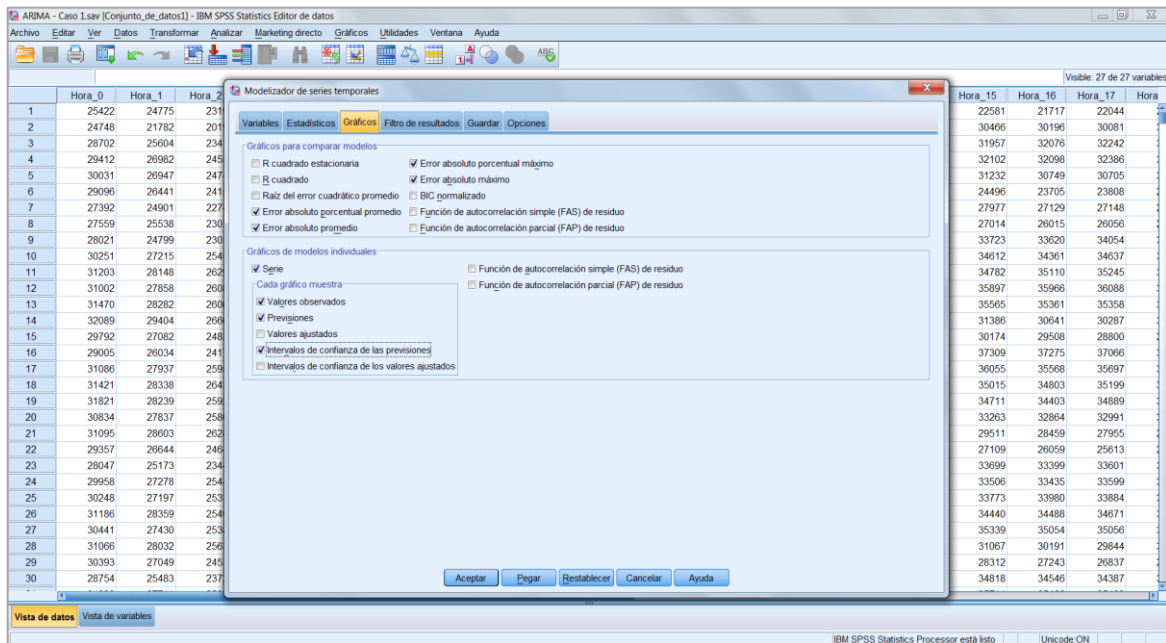


Fig. 29: Selección de gráficos

Una vez obtenidos los estadísticos y los gráficos que definen nuestro modelo, pasamos a la fase de validación, basada en el estudio de los datos anteriormente mencionados. Como parámetros de validación se estudiarán las medidas de bondad de ajuste utilizadas en el modelado de series temporales.

En la gráfica 30 se representa el Error absoluto porcentual promedio (MAPE). Medida de la desviación de la serie dependiente del nivel pronosticado por el modelo. Es independiente de las unidades utilizadas y se puede utilizar para comparar series con distintas unidades. **Considerando un valor de MAPE igual a 0 un ajuste perfecto, en nuestro modelo obtenemos un error en torno al 2.8% (ver tabla 9), por tanto, podemos darlo por bueno.**




Fig. 30: Gráfica de error absoluto porcentual promedio

La tabla 4 está compuesta por los valores numéricos que dan forma a los estadísticos analizados. Dado el valor del MAPE se ha analizado en conjunción con su gráfica, se explican a continuación el resto de errores.

ESTADÍSTICOS DEL MODELO			
Hora	R ² estacionaria	R ²	MAPE
Hora_12	,574	,831	2,878

Tabla 4: Estadísticos del modelo ARIMA para la Hora 12 del Caso 1

- **R-cuadrado estacionaria:** Una medida que compara la parte estacionaria del modelo con un modelo de promedio simple. Los valores negativos significan que el modelo estudiado es peor que el modelo base. Los valores positivos significan que el modelo estudiado es mejor que el modelo base. **En nuestro modelo el valor es positivo.**

- **R cuadrado:** Una estimación de la proporción de la varianza total en la serie que explica el modelo. Los valores negativos significan que el modelo estudiado es peor que el modelo base. Los valores positivos significan que el modelo estudiado es mejor que el modelo base. **En nuestro modelo el valor es positivo.**

Tras el estudio de los parámetros de validación se concluye que el modelo calculado puede ser satisfactorio. El resto de modelos horarios para los tres casos estudiados así como sus estadísticos de validación pueden consultarse en los anexos. Una vez desarrollados dichos modelos, pasaríamos a exponer los resultados de la estimación y obtener las conclusiones pertinentes en el Capítulo IV.



4.- REDES NEURONALES

En esta sección se aplicará el método de las redes neuronales artificiales para predecir valores futuros de la serie de demanda de energía eléctrica para los tres casos estudiados. Para ello será necesario construir, entrenar y probar una red neuronal.

En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa y el tipo y número de conexiones entre neuronas. Luego de conformar el esquema de la red neuronal, se procede a la etapa de aprendizaje de la red. Por lo general las redes neuronales aprenden por medio de ejemplos, los cuales comúnmente se presentan a la red en patrones de entrada y salida.

En la etapa de aprendizaje o entrenamiento, se procura que la red asimile todos los ejemplos, logrando que generalice los patrones, es decir, que a unas entradas determinadas, la red neuronal responda con valores lógicos esperados y no que solo memorice los ejemplos, dando respuestas aleatorias o erróneas.

En la mayoría de la literatura científica, los autores proponen el uso de redes perceptrón multicapa, para problemas relacionados con predicción, debido a que estas redes asimilan fácilmente el comportamiento no lineal de un sistema.

Los criterios de diseño más comúnmente usados puede sintetizarse en el esquema que se presenta a continuación, en él se detallan cuatro tareas que pueden generalizar el proceso de diseño de una red neuronal artificial:

- Preprocesamiento de los datos
- Diseño de la red neuronal
- Implementación
- Validación



4.1.- Procedimiento

Se detallan a continuación los pasos más relevantes a la hora de diseñar, entrenar y aplicar las redes neuronales para la predicción de demanda en los tres casos analizados. Cabe recordar que se utilizará una red neuronal para cada una de las 24 horas que componen el día a predecir.

- 1) Se clasifican por horas los datos de demanda obtenidos de REE.
- 2) Para la hora estudiada se realiza la división del conjunto de datos en dos subconjuntos, entrenamiento y prueba.
- 3) Realizamos un preprocesamiento de los datos con objeto de homogeneizar los valores de entrada, facilitando así el aprendizaje de la red.
- 4) Basándonos en la bibliografía, proponemos un modelo de red neuronal, definiendo su arquitectura y topología.
- 5) Entrenamos la red con el conjunto de datos.
- 6) Aplicamos la red al conjunto de prueba y obtenemos diferentes estadísticos para la posterior validación del resultado.
- 7) Comparamos los estadísticos obtenidos con los valores de referencia presentes en la bibliografía.
- 8) Si los errores se encuentran dentro de unos parámetros aceptables se detiene la iteración y se da por buena la red neuronal propuesta. En caso contrario se continúa el método iterativo volviendo al paso 4.
- 9) Una vez obtenidos unos resultados satisfactorios sobre el conjunto de prueba, se pasa a desarrollar la red neuronal para la siguiente hora hasta completar las 24 horas del día a predecir.

4.2.- Desarrollo del modelo

En el Capítulo III se describió el modelo teórico de las redes neuronales artificiales y su aplicación a la predicción de demanda eléctrica. A continuación se detallarán las sucesivas etapas que nos permitirán determinar el modelo e implementarlo mediante el paquete de Redes Neuronales Artificiales contenido en SPSS. Como en el modelo ARIMA realizado anteriormente ejemplificaremos el desarrollo para Hora 12 del Caso 1.

4.2.1.- Preprocesamiento de los datos

El preprocesamiento de los datos es fundamental porque reduce el conjunto de entrada, ya que la complejidad de la red tiene un comportamiento exponencial de acuerdo a la dimensión del vector de entrada. Adicionalmente, el pre-procesamiento limpia el conjunto de datos de entrada de elementos anómalos, o sea, datos irregulares cuya presencia puede afectar al correcto funcionamiento de la red.

Uno de los aspectos más relevantes en el éxito de cualquier modelo neuronal es el conjunto de datos empleado en su entrenamiento. Incluso el más simple de los modelos puede ofrecer buenos resultados si es alimentado con datos que, tras ser preprocesados adecuadamente, revelan de forma clara y precisa la información relevante. Asimismo, el mejor de los modelos fracasará si es entrenado con datos de baja calidad. Es por tanto necesario llevar a cabo un preprocesado de la información muestral para de este modo aumentar la capacidad de aprendizaje de la red. El preprocesado utilizado para nuestro modelo consistirá en un **cambio de escala**. Mediante dicho proceso, todas las variables consideradas en el modelo serán linealmente escaladas entre 0 y 1. Este procedimiento consiste simplemente en modificar la escala de las variables atendiendo a su valor mínimo y máximo. Como resultado obtendremos nuevas series de datos más homogéneas, las cuales oscilarán entre 0 y 1. En la figura 31 podemos observar la ventana de selección de variables y, concretamente, la pestaña del cambio de escala de covariables.

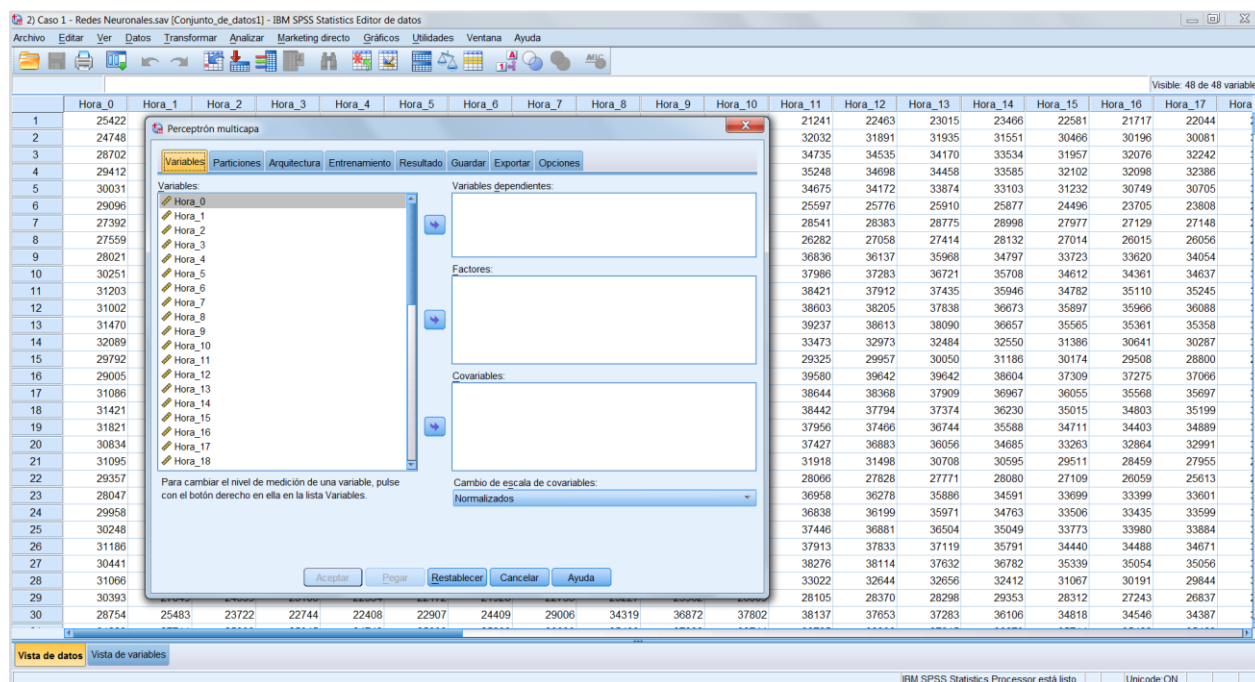


Fig. 31: Selección de escalado de entradas

4.2.2.- Diseño de la red neuronal

A la hora de escoger el modelo de red neuronal se ha optado por la utilización de la red perceptrón multicapa. Pasamos a continuación a determinar la red en sí misma a través de su arquitectura.

4.2.2.1.- Arquitectura de la red

Antes de profundizar con detalle en la elección de los elementos de la red neuronal modelada, cosa que se hará en el punto siguiente, es conveniente esbozar aquí la arquitectura prevista para nuestro modelo. La red que proponemos estará compuesta por tres capas: Una de entrada, una oculta y una de salida. En lo referente a la capa de entrada, ubicaremos en la misma **dos neuronas que contendrán la información, para todos los días anteriores a la estimación, de los valores anterior y posterior a la hora a predecir**. La capa de salida solo contará con una unidad, la cual indicará el valor de la carga eléctrica en la hora estimada. Finalmente la capa oculta contará con un número de neuronas entre 1 y 6. Esquemáticamente nuestro modelo de red neuronal artificial para la curva de carga tendría la siguiente forma:




Fig. 32: Esquema general de la Red Neuronal. Se puede apreciar la capa de entrada con dos neuronas; la capa oculta, con un número variable de ellas y, finalmente, la capa de salida con una neurona

La determinación del número óptimo de neuronas de la capa oculta se ha llevado a cabo mediante un proceso de ensayo y error en el que jugamos con el número de neuronas y el máximo error admisible. En todo caso, nuestro objetivo será dotar a la red de un número adecuado de neuronas en la capa oculta para que sea capaz de aprender las características de las posibles relaciones existentes entre los datos de la muestra.

Demasiadas neuronas podrían llevarnos a un sobreajuste, la red memorizaría el conjunto de datos de entrenamiento y para valores pertenecientes al mismo su precisión sería casi absoluta. Sin embargo si le presentamos valores desconocidos fallaría estrepitosamente, dado que como consecuencia del sobre-ajuste sería incapaz de generalizar. Por otra parte si el número de neuronas en la capa oculta es reducido podremos llegar a una situación de subajuste, en la cual la red no sería capaz de aprender ciertas relaciones existentes entre las variables.

4.2.2.2.- Topología de la red neuronal

1) **Número de Neuronas de Entrada = 2**. Corresponde a las mediciones horarias de demanda de energía eléctrica en el período que va desde el 1/1/2014 hasta el día anterior al día a predecir según el caso y, más concretamente a los valores anterior y posterior a la hora a estimar. Es decir, si queremos realizar la previsión para la hora 20, nuestras neuronas de entrada serán la hora 19 y la 21 de todos los casos que conforman el conjunto de datos históricos y, por tanto, anteriores al día para el que se realiza la estimación. En la figura 33 se ilustran las diferentes opciones proporcionadas por SPSS a la hora de configurar la topología de la red neuronal.

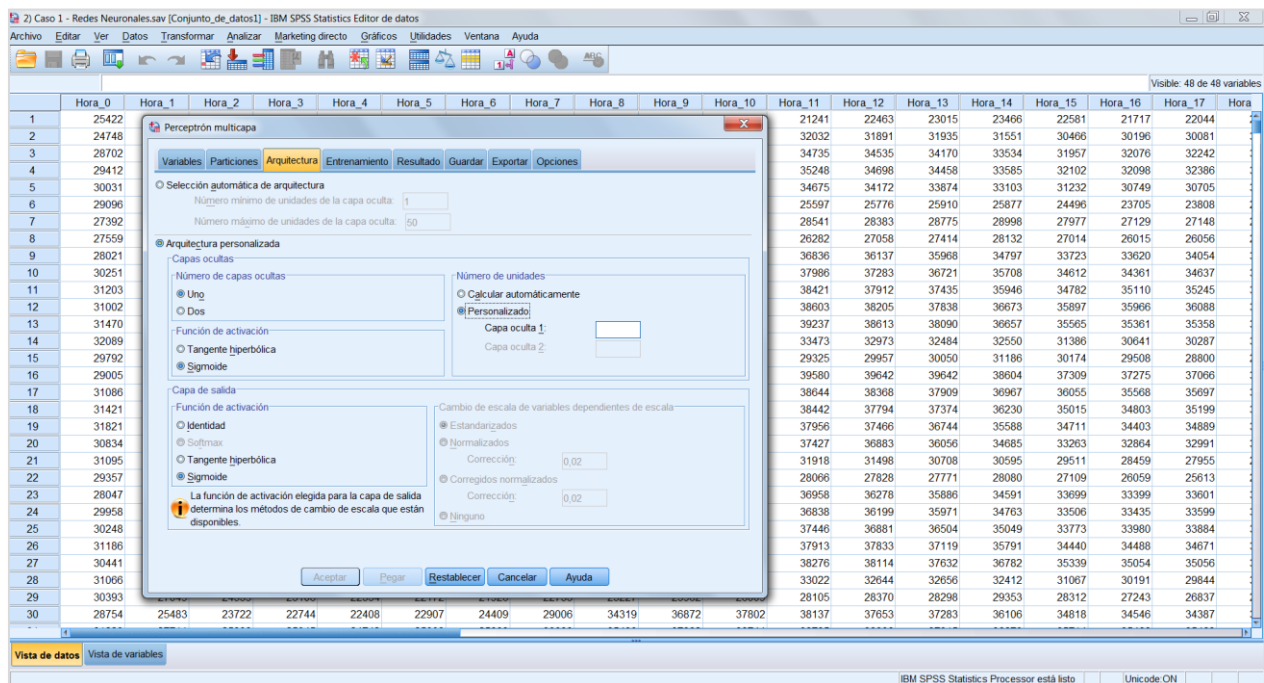


Fig. 33: Definición de la topología de la red

2) **Número de Capas Ocultas = 1**. Encargada de brindarle a la red la capacidad de generalizar, el incremento en número de capas incrementa el tiempo de procesamiento y la dificultad sobre el ajuste lo que conduce a un pobre rendimiento en la predicción fuera de la muestra. En nuestro caso se opta por una sola capa oculta la cual es suficiente para asegurar la capacidad de generalización de nuestra red dada la relativa cantidad de datos con los que contamos.

3) **Número de Neuronas Ocultas = 1-6**. El número de neuronas de nuestra capa oculta irá variando en función de la hora predecir y del ajuste que cada modelo vaya arrojando. Se establecerá, por tanto, un proceso iterativo para determinar el número óptimo de neuronas en la capa oculta, no obstante, se marcarán unos límites superior e inferior respectivamente de 1 y 6 neuronas ocultas.

4) **Número de Neuronas de Salida = 1**. Las redes neuronales con múltiples salidas producen, normalmente, resultados inferiores en comparación con una red con una única salida. Lo recomendable es tener una red especializada para cada una de las salidas deseadas en cada estimación. El número de neuronas de la capa de salida de nuestra red es una ya que contendrá el valor de la hora a predecir.

5) **Función de Transferencia = Sigmoidal**. El propósito de esta función es prevenir a las salidas de alcanzar valores muy elevados que puedan paralizar la red y detener el entrenamiento de la misma. Como función de transferencia se utiliza la función Sigmoidal (rango de salida entre -1 y +1).

A modo de resumen, se presenta en la figura 34 el modelo de red neuronal elegido para nuestro ejemplo, es decir, para la hora 12 del caso 1. Podemos ver la capa de entrada con 2 neuronas, correspondientes a la hora anterior y posterior a la hora a predecir; una capa oculta con 2 neuronas en este caso y una capa de salida con el valor estimado.

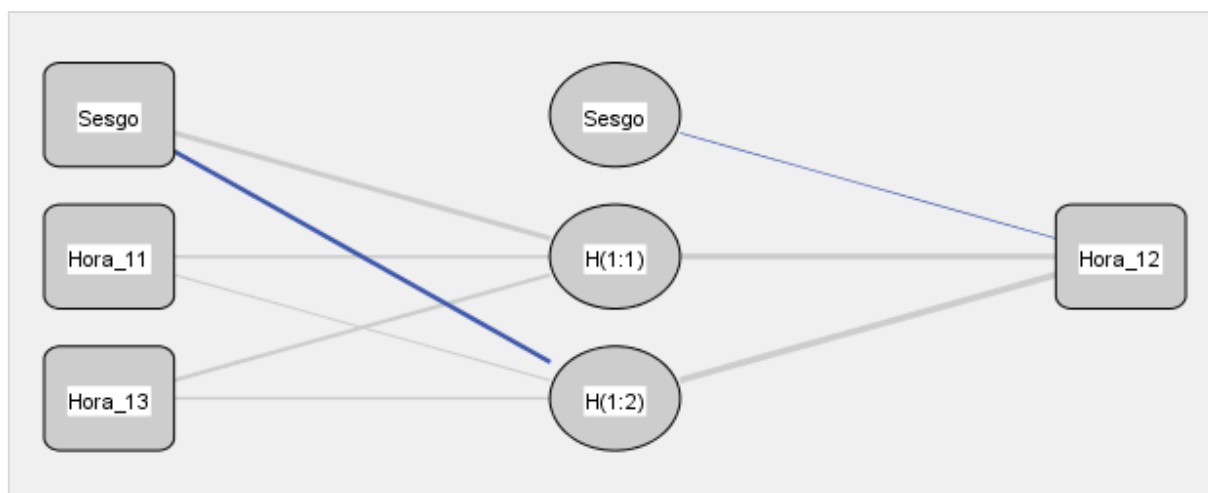


Fig. 34: Red neuronal para la Hora 12 del Caso 1



4.2.3.- Implementación de la red neuronal artificial

Una vez desarrolladas tanto la arquitectura como la topología de la red neuronal artificial es el momento de generar la implementación más adecuada a través del entrenamiento y la validación del rendimiento de dicha red.

4.2.3.1.- Conjuntos de entrenamiento y prueba

- **Conjunto de Entrenamiento**: Es el conjunto de datos que utiliza la red neuronal para aprender los patrones presentes en los datos. En nuestro caso utilizaremos los **valores de la hora a predecir que se hayan dado en todos los casos anteriores al día objeto de la estimación**. En porcentaje, los datos utilizados para el entrenamiento de la red neuronal corresponden al 70 % de los datos de la serie.

- **Conjunto de Prueba**: Es el conjunto de datos encargados de evaluar la capacidad de predicción y precisión de la red, En nuestro caso se utilizará el 30% restante de los datos del conjunto de entrenamiento para validar la red.

En la figura 35 puede observarse el método empleado en SPSS para definir los conjuntos de entrenamiento y prueba, pudiendo definirse estos tanto a través de un valor numérico concreto como a partir de un porcentaje de los datos disponibles.

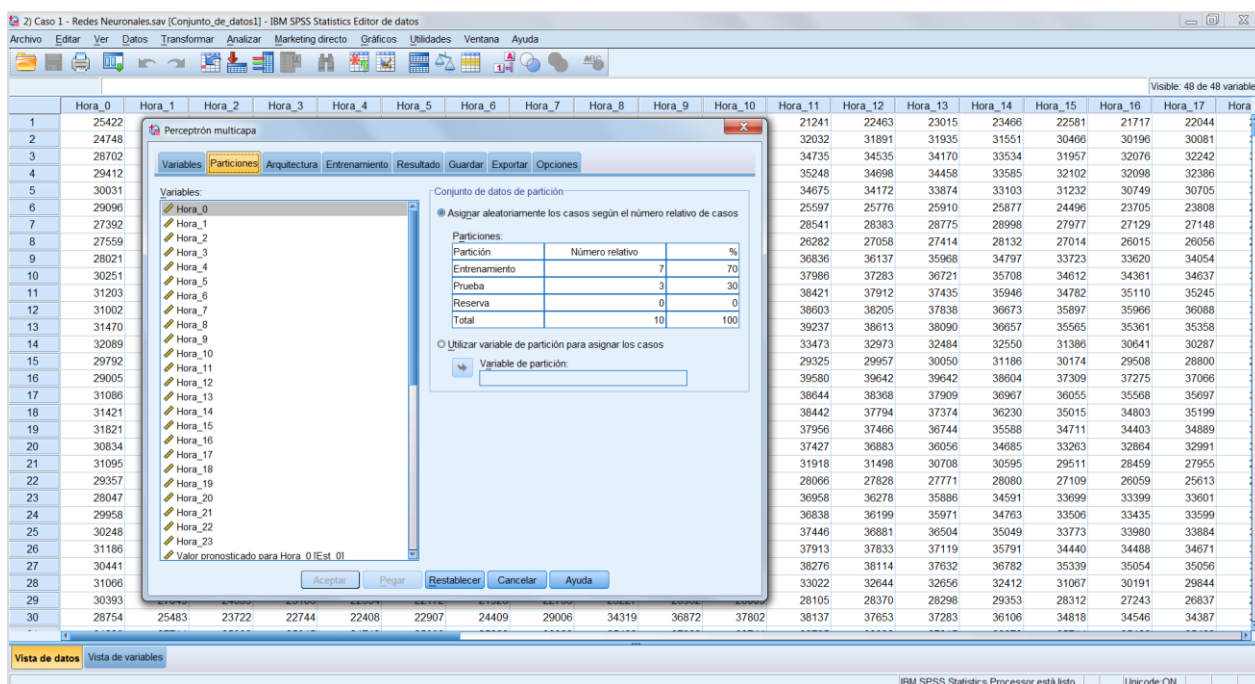


Fig. 35: Definición de conjuntos de entrenamiento y prueba

4.2.3.2.- Resumen del modelo

Una vez diseñada la red neuronal y, antes de proceder a la validación, se resumen en la tabla 5 las características de dicha red para la predicción de demanda de energía eléctrica:

INFORMACIÓN DE LA RED NEURONAL	
Tipo de red	Perceptrón multicapa
Número de entradas	1 capa con 2 neuronas
Número de capas ocultas	1 capa con 2 neuronas
Número de salidas	1
% de datos de entrenamiento	70%
% de datos de prueba	30%
Función de activación	Sigmoidal

Tabla 5: Datos de la red neuronal implementada para la Hora 12 del Caso 1

4.2.4.- Validación

Para la validación de las redes neuronales se utilizarán dos criterios, el error cuadrático medio y el error relativo, a través de las magnitudes de estos podremos determinar si el rendimiento predictivo de nuestra red se mueve dentro de los parámetros adecuados.

En la tabla 6 se muestra un resumen de toda la información disponible para nuestra red ejemplo: topología y errores utilizados en la fase de validación. Además, se han incluido dos topologías adicionales, variando el número de neuronas ocultas para ilustrar nuestra elección (en verde).

HORA	RED			ERRORES	
	Entradas	Ocultas	Salida	Cuadrático medio	Relativo
12:00	2	1	1	0,871	0,016
	2	2	1	0,369	0,002
	2	3	1	0,415	0,09

Tabla 6: Información de arquitectura y magnitud de los errores correspondientes a la red neuronal desarrollada para la estimación de la Hora 12 del Caso 1.

A partir de los valores de error obtenidos podemos pasar a valorar el ajuste de nuestro modelo de red neuronal:

- **Error cuadrático medio:** En este caso, con dos neuronas en la capa oculta nos encontramos con un valor de **0,369**. De acuerdo a la bibliografía, con valores en torno a 5 la red consigue entrenarse dando buenos resultados, por tanto, desde el punto de vista del ECM, **la estimación es significativa**. Con una y tres neuronas en la capa oculta los resultados son también válidos, sin embargo, el punto que minimiza ambos errores se alcanza con dos neuronas.

- **Error relativo:** El error relativo de la red con dos neuronas en la capa oculta se sitúa en un valor del **0,002**, por lo que también validaría la **bondad del ajuste de nuestra red neuronal**. En este caso, los errores relativos de las tipologías descartadas se encuentran muy próximos y serían igualmente aceptables.



Tras el estudio de los parámetros de validación se concluye que la red neuronal desarrollada puede ser satisfactoria. El resto de redes neuronales para los tres casos estudiados así como sus estadísticos de validación pueden consultarse en los anexos. Una vez desarrolladas dichas redes, pasaríamos a exponer los resultados de la estimación y obtener las conclusiones pertinentes en el Capítulo IV.

CAPÍTULO IV:

RESULTADOS Y CONCLUSIONES

RESULTADOS Y CONCLUSIONES

1.- INTRODUCCIÓN

Se procederá a continuación a exponer los resultados arrojados por los dos métodos de predicción para cada uno de los tres casos considerados. Se reflejarán los valores obtenidos para cada una de las 24 horas del día a predecir y se compararán los resultados tanto con los valores reales obtenidos de REE como con la predicción que dicho organismo realizó para el día en cuestión, de este modo podrá juzgarse el ajuste de los diferentes modelos a los datos reales de demanda y, además, se cuantificará la desviación de nuestros modelos con respecto al utilizado por REE.

Para cada caso se presentará una tabla con la siguiente información:

- **Fecha – Hora**
- **Prevista:** Demanda pronosticada según el modelo predictivo.
- **Real:** Demanda registrada según los datos de REE.
- **Prevista (REE):** Estimación realizada por REE.
- **% Error vs. Real:** Porcentaje de desviación de la estimación frente al valor real.
- **% Error vs. REE:** Desviación de la estimación frente a la calculada por REE.
- **% Error REE vs. Real:** Desviación de la estimación de REE frente al valor real.
- **% Error Medio:** Porcentaje de error medio de las columnas anteriores.

Además, se marcarán en **verde** y **rojo** los mejores y peores casos respectivamente de cada estimación.

Una vez expresados los datos en formato tabla se desarrollará un gráfico con la demanda para el día en cuestión representada a través de las curvas pronosticada, real y estimada por REE donde se pondrán claramente de manifiesto las cualidades del modelo predictivo.

2.- ARIMA

Tras la aplicación de los modelos ARIMA horarios las previsiones obtenidas son las siguientes.

2.1.- Caso 1 – Punta de demanda (Miércoles 4-2-2015)

FECHA - HORA	PREVISTA (ARIMA)	REAL	PREVISTA (REE)	% ERROR vs. REAL	% ERROR vs. REE	% ERROR REE vs. REAL
04/02/2015 0:00	29874	30671	30855	2,60	3,18	0,60
04/02/2015 1:00	27773	28636	28466	3,01	2,43	0,60
04/02/2015 2:00	25862	26701	26526	3,14	2,50	0,66
04/02/2015 3:00	25067	25619	25683	2,15	2,40	0,25
04/02/2015 4:00	24355	25207	25343	3,38	3,90	0,54
04/02/2015 5:00	24843	25224	25437	1,51	2,34	0,84
04/02/2015 6:00	25867	26442	26879	2,17	3,77	1,63
04/02/2015 7:00	29368	30378	31012	3,32	5,30	2,04
04/02/2015 8:00	34218	35103	35507	2,52	3,63	1,14
04/02/2015 9:00	35677	36695	37691	2,77	5,34	2,64
04/02/2015 10:00	36417	38546	38641	5,52	5,76	0,25
04/02/2015 11:00	37515	38690	39058	3,04	3,95	0,94
04/02/2015 12:00	37175	38573	38657	3,62	3,83	0,22
04/02/2015 13:00	37515	38627	38491	2,88	2,54	0,35
04/02/2015 14:00	35724	37650	37907	5,12	5,76	0,68
04/02/2015 15:00	34708	36721	36815	5,48	5,72	0,26
04/02/2015 16:00	34459	36498	36770	5,59	6,29	0,74
04/02/2015 17:00	34645	36625	36499	5,41	5,08	0,35
04/02/2015 18:00	35555	36807	37093	3,40	4,15	0,77
04/02/2015 19:00	38158	39578	39594	3,59	3,63	0,04
04/02/2015 20:00	39140	40579	40500	3,55	3,36	0,20
04/02/2015 21:00	38384	39840	39890	3,65	3,78	0,13
04/02/2015 22:00	36211	37720	38082	4,00	4,91	0,95
04/02/2015 23:00	33421	34691	34505	3,66	3,14	0,54
				3,55	4,03	0,72
				% ERROR MEDIO		

Tabla 7: Resultados ARIMA – Caso 1

Como puede observarse en la tabla 7, el error medio entre nuestros cálculos y los valores reales se sitúa en el **3,55%**, alcanzando un máximo del 5,59% y un mínimo del

1,51%. Las fuentes bibliográficas sitúan el margen para una predicción aceptable en valores en torno al 5%, por lo tanto, podemos dar por válida nuestra estimación. Hay que considerar también que para cada valor horario nuestra estimación se queda “corta”, es decir, predice unos valores de potencia menores a la demanda real, lo cual puede estar íntimamente relacionado con el caso estudiado que, recordemos, se corresponde con la punta de demanda anual. Ligado a este razonamiento es destacable el hecho de que nuestra curva de demanda se ajusta mejor en los valores de horas valle y se separa de la realidad conforme avanza el día y aumenta el consumo. Considerando el ajuste de la predicción realizada por REE se puede deducir que su modelo está mejor preparado para afrontar este tipo de días de carga máxima, ya sea por la formulación matemática que lo defina o por una mayor abundancia de datos históricos a partir de los cuales realizar la estimación.

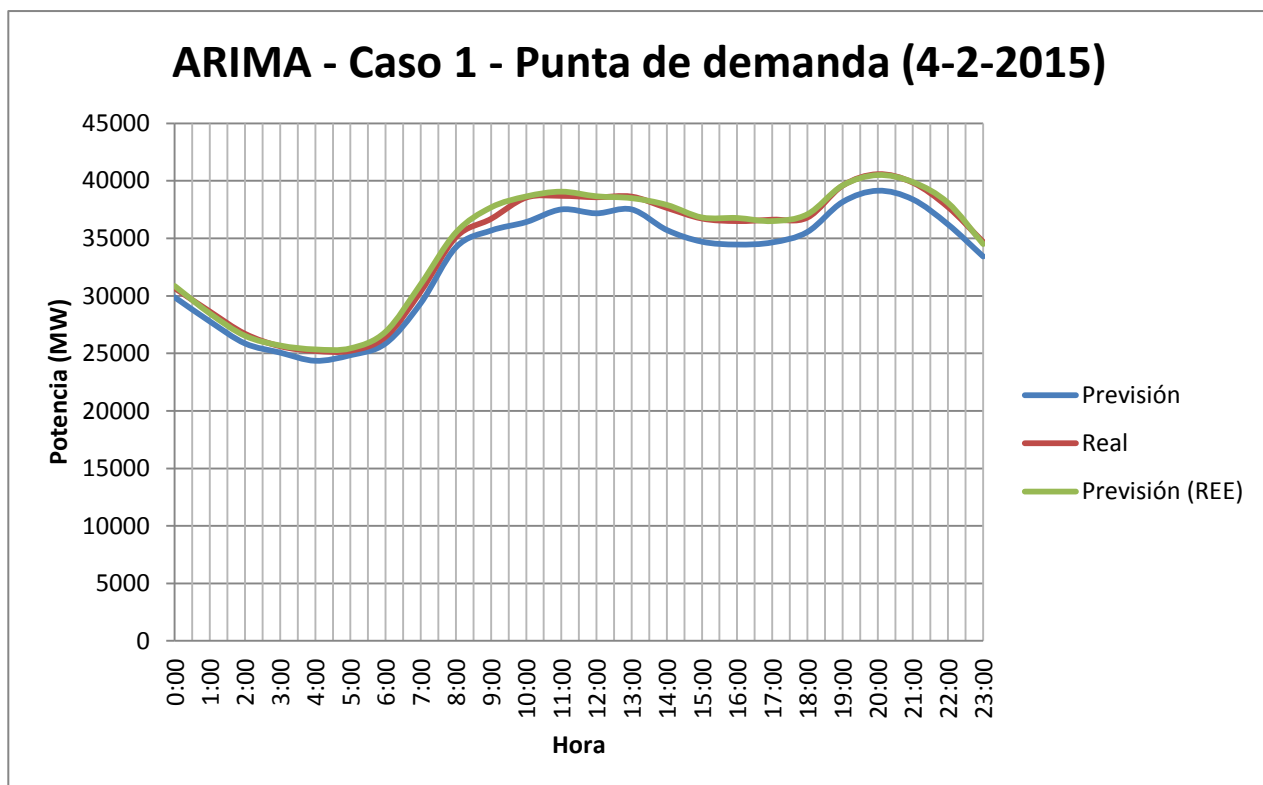


Fig. 36: Curvas de demanda. ARIMA – Caso 1

Como se ha comentado anteriormente, en la figura 36 puede observarse como nuestra predicción se sitúa siempre por debajo de los valores reales. Cabe destacar también

que la estimación realizada por REE se sitúa por encima de la carga real durante las primeras horas de la mañana.

2.2.- Caso 2 – Laborable (Martes 12-5-2015)

FECHA - HORA	PREVISTA (ARIMA)	REAL	PREVISTA (REE)	% ERROR vs. REAL	% ERROR vs. REE	% ERROR REE vs. REAL
12/05/2015 0:00	25709	25846	26403	0,53	2,63	2,11
12/05/2015 1:00	24413	24621	24896	0,84	1,94	1,10
12/05/2015 2:00	23389	23426	23506	0,16	0,50	0,34
12/05/2015 3:00	22742	22693	22983	0,22	1,05	1,26
12/05/2015 4:00	22174	22567	22723	1,74	2,42	0,69
12/05/2015 5:00	22558	22596	22629	0,17	0,31	0,15
12/05/2015 6:00	23204	23465	22989	1,11	0,94	2,07
12/05/2015 7:00	25782	25464	25356	1,25	1,68	0,43
12/05/2015 8:00	27479	28077	28438	2,13	3,37	1,27
12/05/2015 9:00	29454	29848	30047	1,32	1,97	0,66
12/05/2015 10:00	30273	30950	31158	2,19	2,84	0,67
12/05/2015 11:00	30991	31854	31756	2,71	2,41	0,31
12/05/2015 12:00	31581	32331	32194	2,32	1,90	0,43
12/05/2015 13:00	32039	32950	32823	2,76	2,39	0,39
12/05/2015 14:00	31499	32187	32383	2,14	2,73	0,61
12/05/2015 15:00	30460	31281	31494	2,62	3,28	0,68
12/05/2015 16:00	30560	31205	31419	2,07	2,73	0,68
12/05/2015 17:00	30658	31395	31674	2,35	3,21	0,88
12/05/2015 18:00	30086	31390	31372	4,15	4,10	0,06
12/05/2015 19:00	29920	31090	30898	3,76	3,17	0,62
12/05/2015 20:00	30047	30607	30506	1,83	1,50	0,33
12/05/2015 21:00	30319	31021	31160	2,26	2,70	0,45
12/05/2015 22:00	31337	31409	31406	0,23	0,22	0,01
12/05/2015 23:00	28426	28551	28944	0,44	1,79	1,36
				1,72	2,16	0,73
				% ERROR MEDIO		

Tabla 8: Resultados ARIMA – Caso 2

En esta ocasión, observamos un incremento drástico en el rendimiento de nuestra predicción, proporcionando un valor medio de error del **1,72%** frente al 0,73% que proporciona la estimación realizada por REE. Por tanto, para este caso podemos

concluir que el ajuste es altamente satisfactorio proporcionando unos valores muy cercanos a la realidad del día estudiado.




Fig. 37: Curvas de demanda. ARIMA – Caso 2

En la figura 37 puede observarse como las tres curvas se solapan hasta, aproximadamente, la hora de comienzo de la jornada laboral donde nuestra estimación comienza a quedar un poco por debajo tanto de los valores reales como de la predicción de REE hasta las 22:00 horas aproximadamente donde las tres curvas vuelven a coincidir. En la tabla 9 se muestran los valores de potencia estimados y reales desde las 8:00 hasta las 22:00 para ilustrar y cuantificar este hecho.



HORA	PREVISTA (ARIMA)	REAL	DIFERENCIA (MW)	DIFERENCIA (%)
8:00	27479	28077	598	2,13
9:00	29454	29848	394	1,32
10:00	30273	30950	677	2,19
11:00	30991	31854	863	2,71
12:00	31581	32331	750	2,32
13:00	32039	32950	911	2,76
14:00	31499	32187	688	2,14
15:00	30460	31281	821	2,62
16:00	30560	31205	645	2,07
17:00	30658	31395	737	2,35
18:00	30086	31390	1304	4,15
19:00	29920	31090	1170	3,76
20:00	30047	30607	560	1,83
21:00	30319	31021	702	2,26
22:00	31337	31409	72	0,23

Tabla 9: Diferencias entre curva real y estimada – Caso 2

Como puede apreciarse en los valores de la tabla, la mayor separación entre curvas se da entre las 17 y las 19 horas de la tarde, con una desviación en torno al 4%. Conforme va acabando la jornada laboral las diferencias descienden drásticamente

2.3.- Caso 3 – Fin de semana (Sábado 3-10-2015)

FECHA - HORA	PREVISTA (ARIMA)	REAL	PREVISTA (REE)	% ERROR vs. REAL	% ERROR vs. REE	% ERROR REE vs. REAL
03/10/2015 0:00	25358	25237	25379	0,48	0,08	0,56
03/10/2015 1:00	24355	24003	24286	1,47	0,28	1,17
03/10/2015 2:00	23016	22644	22993	1,64	0,10	1,52
03/10/2015 3:00	22203	21837	22031	1,68	0,78	0,88
03/10/2015 4:00	21739	21260	21493	2,25	1,14	1,08
03/10/2015 5:00	21419	21148	21287	1,28	0,62	0,65
03/10/2015 6:00	21454	21283	21261	0,80	0,91	0,10
03/10/2015 7:00	22122	22268	22193	0,66	0,32	0,34
03/10/2015 8:00	22922	22862	23129	0,26	0,89	1,15
03/10/2015 9:00	24706	24727	24466	0,08	0,98	1,07
03/10/2015 10:00	26900	26802	26648	0,37	0,95	0,58
03/10/2015 11:00	27799	27329	27627	1,72	0,62	1,08
03/10/2015 12:00	28113	28034	27723	0,28	1,41	1,12
03/10/2015 13:00	28271	27731	27893	1,95	1,36	0,58
03/10/2015 14:00	27898	27886	27610	0,04	1,04	1,00
03/10/2015 15:00	26517	26424	26424	0,35	0,35	0,00
03/10/2015 16:00	25487	25234	25424	1,00	0,25	0,75
03/10/2015 17:00	25169	24823	25010	1,39	0,64	0,75
03/10/2015 18:00	24956	24888	24919	0,27	0,15	0,12
03/10/2015 19:00	24938	24846	24966	0,37	0,11	0,48
03/10/2015 20:00	26293	26524	26647	0,87	1,33	0,46
03/10/2015 21:00	28934	28351	28504	2,06	1,51	0,54
03/10/2015 22:00	26799	27134	27151	1,23	1,30	0,06
03/10/2015 23:00	25131	24909	25060	0,89	0,28	0,60
				0,98	0,73	0,69
				% ERROR MEDIO		

Tabla 10: Resultados ARIMA – Caso 3

En el último de los casos estudiados podemos encontrar el mejor ajuste de nuestra estimación, con un error del **0,98%** frente a la demanda real y de sólo un 0,73% con respecto a la estimación realizada por REE. De este último valor se puede deducir que nuestro modelo predictivo se ha ajustado de forma casi perfecta al modelo utilizado por REE, el cual podemos asumir como límite teórico de la mejor predicción posible.




Fig. 38: Curvas de demanda. ARIMA – Caso 3

En la figura 38 podemos observar como las curvas siguen una evolución prácticamente idéntica con determinados intervalos donde se ajusta mejor nuestro modelo y otros donde los valores proporcionados por REE son más exactos. Entre las 21 y las 22 horas se produce una ligera separación de las curvas dado que nuestro modelo estima un consumo mayor al real.

3.- REDES NEURONALES

Tras la aplicación de los modelos de Redes Neuronales, las previsiones obtenidas son las siguientes.

3.1.- Caso 1 – Punta de demanda (Miércoles 4-2-2015)

FECHA - HORA	PREVISTA (ARIMA)	REAL	PREVISTA (REE)	% ERROR vs. REAL	% ERROR vs. REE	% ERROR REE vs. REAL
04/02/2015 0:00	30667	30671	30855	0,01	0,61	0,60
04/02/2015 1:00	27707	28636	28466	3,24	2,67	0,60
04/02/2015 2:00	26028	26701	26526	2,52	1,88	0,66
04/02/2015 3:00	25102	25619	25683	2,02	2,26	0,25
04/02/2015 4:00	24768	25207	25343	1,74	2,27	0,54
04/02/2015 5:00	24836	25224	25437	1,54	2,36	0,84
04/02/2015 6:00	26012	26442	26879	1,63	3,23	1,63
04/02/2015 7:00	29813	30378	31012	1,86	3,87	2,04
04/02/2015 8:00	34327	35103	35507	2,21	3,32	1,14
04/02/2015 9:00	36526	36695	37691	0,46	3,09	2,64
04/02/2015 10:00	37559	38546	38641	2,56	2,80	0,25
04/02/2015 11:00	37572	38690	39058	2,89	3,80	0,94
04/02/2015 12:00	37690	38573	38657	2,29	2,50	0,22
04/02/2015 13:00	37698	38627	38491	2,41	2,06	0,35
04/02/2015 14:00	36735	37650	37907	2,43	3,09	0,68
04/02/2015 15:00	35654	36721	36815	2,91	3,15	0,26
04/02/2015 16:00	35705	36498	36770	2,17	2,90	0,74
04/02/2015 17:00	35507	36625	36499	3,05	2,72	0,35
04/02/2015 18:00	36759	36807	37093	0,13	0,90	0,77
04/02/2015 19:00	38599	39578	39594	2,47	2,51	0,04
04/02/2015 20:00	39469	40579	40500	2,74	2,55	0,20
04/02/2015 21:00	38867	39840	39890	2,44	2,56	0,13
04/02/2015 22:00	36649	37720	38082	2,84	3,76	0,95
04/02/2015 23:00	33886	34691	34505	2,32	1,79	0,54
				2,12	2,61	0,72
				% ERROR MEDIO		

Tabla 11: Resultados REDES NEURONALES – Caso 1

Como puede observarse en la tabla 11, el error medio entre nuestros cálculos y los valores reales se sitúa en el **2,12%**, alcanzando un máximo del 3,24% y un mínimo del

0,01%. Cabe destacar el hecho de que, aproximadamente durante el transcurso de la jornada laboral, nuestro modelo arroja siempre valores menores que la demanda real, por tanto, podemos inferir que nuestra red sufre un descenso en su rendimiento predictivo conforme aumenta la carga del sistema.




Fig. 39: Curvas de demanda. REDES NEURONALES – Caso 1

Como se ha comentado anteriormente, en el gráfico puede observarse como, durante el transcurso de la jornada laboral, nuestra predicción se sitúa siempre por debajo de los valores reales, comenzando a converger de nuevo con la curva real en las últimas horas del día.

3.2.- Caso 2 – Laborable (Martes 12-5-2015)

FECHA - HORA	PREVISTA (ARIMA)	REAL	PREVISTA (REE)	% ERROR vs. REAL	% ERROR vs. REE	% ERROR REE vs. REAL
12/05/2015 0:00	25976	25846	26403	0,50	1,62	2,11
12/05/2015 1:00	24830	24621	24896	0,85	0,27	1,10
12/05/2015 2:00	23200	23426	23506	0,96	1,30	0,34
12/05/2015 3:00	22594	22693	22983	0,44	1,69	1,26
12/05/2015 4:00	22041	22567	22723	2,33	3,00	0,69
12/05/2015 5:00	21908	22596	22629	3,04	3,19	0,15
12/05/2015 6:00	22628	23465	22989	3,57	1,57	2,07
12/05/2015 7:00	25664	25464	25356	0,79	1,21	0,43
12/05/2015 8:00	27525	28077	28438	1,97	3,21	1,27
12/05/2015 9:00	29170	29848	30047	2,27	2,92	0,66
12/05/2015 10:00	31020	30950	31158	0,23	0,44	0,67
12/05/2015 11:00	32115	31854	31756	0,82	1,13	0,31
12/05/2015 12:00	31667	32331	32194	2,05	1,64	0,43
12/05/2015 13:00	31807	32950	32823	3,47	3,10	0,39
12/05/2015 14:00	31205	32187	32383	3,05	3,64	0,61
12/05/2015 15:00	30796	31281	31494	1,55	2,22	0,68
12/05/2015 16:00	31298	31205	31419	0,30	0,39	0,68
12/05/2015 17:00	30117	31395	31674	4,07	4,92	0,88
12/05/2015 18:00	29605	31390	31372	5,69	5,63	0,06
12/05/2015 19:00	30008	31090	30898	3,48	2,88	0,62
12/05/2015 20:00	31563	30607	30506	3,12	3,46	0,33
12/05/2015 21:00	31305	31021	31160	0,92	0,47	0,45
12/05/2015 22:00	31354	31409	31406	0,18	0,17	0,01
12/05/2015 23:00	29257	28551	28944	2,47	1,08	1,36
				2,00	2,13	0,73
				% ERROR MEDIO		

Tabla 12: Resultados REDES NEURONALES – Caso 2

El segundo caso arroja unos porcentajes relativamente similares a la estimación del primero, proporcionando un valor medio de error del **2,00%**. Sin embargo, en este caso nuestras estimaciones no siguen una tendencia uniforme a la alza o a la baja con respecto a los valores reales de demanda. Por contra, se producen una serie de oscilaciones en nuestra curva prevista que se hacen especialmente acusadas durante el transcurso de la jornada laboral.




Fig. 40: Curvas de demanda. REDES NEURONALES – Caso 2

Observando la figura 40 queda patente la oscilación que presenta la curva de demanda estimada, presentando períodos en los que, sin motivo aparente, subestima o sobreestima los valores reales y, sólo al final del día consigue converger con la curva real.

En la tabla 13 se cuantifican las oscilaciones anteriormente mencionadas para el período en que se dan con mayor frecuencia, es decir, de las 11 hasta las 21 horas.



HORA	PREVISTA (REDES)	REAL	DIFERENCIA (MW)	DIFERENCIA (%)
11:00	32115	31854	-261	0,82
12:00	31667	32331	664	2,05
13:00	31807	32950	1143	3,47
14:00	31205	32187	982	3,05
15:00	30796	31281	485	1,55
16:00	31298	31205	-93	0,30
17:00	30117	31395	1278	4,07
18:00	29605	31390	1785	5,69
19:00	30008	31090	1082	3,48
20:00	31563	30607	-956	3,12
21:00	31305	31021	-284	0,92

Tabla 13: Diferencias entre curva real y estimada – Caso 2

Como puede observarse por los valores de la tabla, las mayores oscilaciones se dan entre las 17 y las 21 horas con estimaciones que, o bien subestiman la demanda real en torno al 4% o la superan con un valor del 3% aproximadamente.

3.3.- Caso 3 – Fin de semana (Sábado 3-10-2015)

FECHA - HORA	PREVISTA (ARIMA)	REAL	PREVISTA (REE)	% ERROR vs. REAL	% ERROR vs. REE	% ERROR REE vs. REAL
03/10/2015 0:00	25349	25237	25379	0,44	0,12	0,56
03/10/2015 1:00	24537	24003	24286	2,22	1,03	1,17
03/10/2015 2:00	22908	22644	22993	1,17	0,37	1,52
03/10/2015 3:00	22359	21837	22031	2,39	1,49	0,88
03/10/2015 4:00	22006	21260	21493	3,51	2,39	1,08
03/10/2015 5:00	21566	21148	21287	1,98	1,31	0,65
03/10/2015 6:00	21480	21283	21261	0,93	1,03	0,10
03/10/2015 7:00	22214	22268	22193	0,24	0,09	0,34
03/10/2015 8:00	23015	22862	23129	0,67	0,49	1,15
03/10/2015 9:00	24591	24727	24466	0,55	0,51	1,07
03/10/2015 10:00	26770	26802	26648	0,12	0,46	0,58
03/10/2015 11:00	27604	27329	27627	1,01	0,08	1,08
03/10/2015 12:00	27536	28034	27723	1,78	0,67	1,12
03/10/2015 13:00	27693	27731	27893	0,14	0,72	0,58
03/10/2015 14:00	27668	27886	27610	0,78	0,21	1,00
03/10/2015 15:00	26597	26424	26424	0,65	0,65	0,00
03/10/2015 16:00	25334	25234	25424	0,40	0,35	0,75
03/10/2015 17:00	25148	24823	25010	1,31	0,55	0,75
03/10/2015 18:00	24988	24888	24919	0,40	0,28	0,12
03/10/2015 19:00	25036	24846	24966	0,76	0,28	0,48
03/10/2015 20:00	26112	26524	26647	1,55	2,01	0,46
03/10/2015 21:00	28497	28351	28504	0,51	0,02	0,54
03/10/2015 22:00	27361	27134	27151	0,84	0,77	0,06
03/10/2015 23:00	25419	24909	25060	2,05	1,43	0,60
				1,10	0,72	0,69
				% ERROR MEDIO		

Tabla 14: Resultados REDES NEURONALES – Caso 3

En el caso del fin de semana nos encontramos con el mejor ajuste de entre los casos estudiados, con un error del **1,10%** frente a la demanda real y de sólo un 0,69% con respecto a la estimación realizada por REE. Además, los porcentajes de error correspondiente a las horas con una mejor estimación son realmente bajos, normalmente por debajo del 1% por lo que podemos concluir que la estimación ha sido muy satisfactoria.




Fig. 41: Curvas de demanda. REDES NEURONALES – Caso 3

En el gráfico podemos observar como las tres curvas siguen una evolución prácticamente idéntica con determinados intervalos donde incluso se solapan, esto da una idea de, hasta qué punto, la estimación ha resultado acertada.

4.- COMPARATIVA DE RESULTADOS. ERROR MAPE

Con objeto de proporcionar una forma rápida de comparar el rendimiento predictivo de las dos aproximaciones, se mostrará a continuación una tabla donde se indicará el MAPE asociado a cada estimación, de esta manera, tendremos un indicador fiable sobre el que basar nuestras conclusiones.

4.1.- Caso 1 – Punta de demanda (Miércoles 4-2-2015)

FECHA - HORA	PREVISTA (ARIMA)	PREVISTA (REDES)	REAL	PREVISTA (REE)	MAPE ARIMA	MAPE REDES
04/02/2015 0:00	29874	30667	30671	30855	2,60	0,01
04/02/2015 1:00	27773	27707	28636	28466	3,01	3,24
04/02/2015 2:00	25862	26028	26701	26526	3,14	2,52
04/02/2015 3:00	25067	25102	25619	25683	2,15	2,02
04/02/2015 4:00	24355	24768	25207	25343	3,38	1,74
04/02/2015 5:00	24843	24836	25224	25437	1,51	1,54
04/02/2015 6:00	25867	26012	26442	26879	2,17	1,63
04/02/2015 7:00	29368	29813	30378	31012	3,32	1,86
04/02/2015 8:00	34218	34327	35103	35507	2,52	2,21
04/02/2015 9:00	35677	36526	36695	37691	2,77	0,46
04/02/2015 10:00	36417	37559	38546	38641	5,52	2,56
04/02/2015 11:00	37515	37572	38690	39058	3,04	2,89
04/02/2015 12:00	37175	37690	38573	38657	3,62	2,29
04/02/2015 13:00	37515	37698	38627	38491	2,88	2,41
04/02/2015 14:00	35724	36735	37650	37907	5,12	2,43
04/02/2015 15:00	34708	35654	36721	36815	5,48	2,91
04/02/2015 16:00	34459	35705	36498	36770	5,59	2,17
04/02/2015 17:00	34645	35507	36625	36499	5,41	3,05
04/02/2015 18:00	35555	36759	36807	37093	3,40	0,13
04/02/2015 19:00	38158	38599	39578	39594	3,59	2,47
04/02/2015 20:00	39140	39469	40579	40500	3,55	2,74
04/02/2015 21:00	38384	38867	39840	39890	3,65	2,44
04/02/2015 22:00	36211	36649	37720	38082	4,00	2,84
04/02/2015 23:00	33421	33886	34691	34505	3,66	2,32
					3,55	2,12
					MAPE	

Tabla 15: Comparativa MAPE – Caso 1

Como podemos observar, el MAPE de ambas predicciones es relativamente bueno, avalando la bondad de nuestro ajuste. Cabe destacar que la predicción mediante redes neuronales es capaz de mejorar en más de un punto porcentual el rendimiento del método ARIMA para este caso.




Fig. 42: Comparativa de curvas de demanda. Caso 1

En la figura 42 podemos observar claramente el mejor ajuste proporcionado por las redes neuronales con valores que, aun estando por debajo de la demanda real, consiguen minimizar el descenso de rendimiento predictivo acusado por el método ARIMA durante las horas de jornada laboral.

4.2.- Caso 2 – Laborable (Martes 12-5-2015)

FECHA - HORA	PREVISTA (ARIMA)	PREVISTA (REDES)	REAL	PREVISTA (REE)	MAPE ARIMA	MAPE REDES
12/05/2015 0:00	25709	25976	25846	26403	0,53	0,50
12/05/2015 1:00	24413	24830	24621	24896	0,84	0,85
12/05/2015 2:00	23389	23200	23426	23506	0,16	0,96
12/05/2015 3:00	22742	22594	22693	22983	0,22	0,44
12/05/2015 4:00	22174	22041	22567	22723	1,74	2,33
12/05/2015 5:00	22558	21908	22596	22629	0,17	3,04
12/05/2015 6:00	23204	22628	23465	22989	1,11	3,57
12/05/2015 7:00	25782	25664	25464	25356	1,25	0,79
12/05/2015 8:00	27479	27525	28077	28438	2,13	1,97
12/05/2015 9:00	29454	29170	29848	30047	1,32	2,27
12/05/2015 10:00	30273	31020	30950	31158	2,19	0,23
12/05/2015 11:00	30991	32115	31854	31756	2,71	0,82
12/05/2015 12:00	31581	31667	32331	32194	2,32	2,05
12/05/2015 13:00	32039	31807	32950	32823	2,76	3,47
12/05/2015 14:00	31499	31205	32187	32383	2,14	3,05
12/05/2015 15:00	30460	30796	31281	31494	2,62	1,55
12/05/2015 16:00	30560	31298	31205	31419	2,07	0,30
12/05/2015 17:00	30658	30117	31395	31674	2,35	4,07
12/05/2015 18:00	30086	29605	31390	31372	4,15	5,69
12/05/2015 19:00	29920	30008	31090	30898	3,76	3,48
12/05/2015 20:00	30047	31563	30607	30506	1,83	3,12
12/05/2015 21:00	30319	31305	31021	31160	2,26	0,92
12/05/2015 22:00	31337	31354	31409	31406	0,23	0,18
12/05/2015 23:00	28426	29257	28551	28944	0,44	2,47
					1,72	2,00
					MAPE	

Tabla 16: Comparativa MAPE – Caso 2

En este caso, la estimación mediante el modelo ARIMA arroja unos resultados excelentes con un MAPE en torno al 1,7%, la predicción mediante redes está levemente por detrás en este caso aunque, con un MAPE de sólo el 2% también puede darse por buena.




Fig. 43: Comparativa de curvas de demanda. Caso 2

En la figura 43 queda patente el mayor problema encontrado en el método de las redes neuronales para el caso que nos ocupa y no es otro que las oscilaciones presentadas por la curva prevista durante las horas de jornada laboral, no consiguiendo ajustarse a la tendencia establecida por la demanda real hasta las últimas horas del día. En consonancia con el caso 1, la estimación mediante modelos ARIMA vuelve a quedarse por debajo de los valores de potencia real durante las horas de jornada laboral.

4.3.- Caso 3 – Fin de semana (Sábado 3-10-2015)

FECHA - HORA	PREVISTA (ARIMA)	PREVISTA (REDES)	REAL	PREVISTA (REE)	MAPE ARIMA	MAPE REDES
03/10/2015 0:00	25358	25349	25237	25379	0,48	0,44
03/10/2015 1:00	24355	24537	24003	24286	1,47	2,22
03/10/2015 2:00	23016	22908	22644	22993	1,64	1,17
03/10/2015 3:00	22203	22359	21837	22031	1,68	2,39
03/10/2015 4:00	21739	22006	21260	21493	2,25	3,51
03/10/2015 5:00	21419	21566	21148	21287	1,28	1,98
03/10/2015 6:00	21454	21480	21283	21261	0,80	0,93
03/10/2015 7:00	22122	22214	22268	22193	0,66	0,24
03/10/2015 8:00	22922	23015	22862	23129	0,26	0,67
03/10/2015 9:00	24706	24591	24727	24466	0,08	0,55
03/10/2015 10:00	26900	26770	26802	26648	0,37	0,12
03/10/2015 11:00	27799	27604	27329	27627	1,72	1,01
03/10/2015 12:00	28113	27536	28034	27723	0,28	1,78
03/10/2015 13:00	28271	27693	27731	27893	1,95	0,14
03/10/2015 14:00	27898	27668	27886	27610	0,04	0,78
03/10/2015 15:00	26517	26597	26424	26424	0,35	0,65
03/10/2015 16:00	25487	25334	25234	25424	1,00	0,40
03/10/2015 17:00	25169	25148	24823	25010	1,39	1,31
03/10/2015 18:00	24956	24988	24888	24919	0,27	0,40
03/10/2015 19:00	24938	25036	24846	24966	0,37	0,76
03/10/2015 20:00	26293	26112	26524	26647	0,87	1,55
03/10/2015 21:00	28934	28497	28351	28504	2,06	0,51
03/10/2015 22:00	26799	27361	27134	27151	1,23	0,84
03/10/2015 23:00	25131	25419	24909	25060	0,89	2,05
					0,98	1,10
					MAPE	

Tabla 17: Comparativa MAPE – Caso 3

En el último caso encontramos un rendimiento prácticamente idéntico en ambos modelos, con unos MAPE en torno al 1% que otorgan una gran credibilidad a las estimaciones realizadas.




Fig. 44: Comparativa de curvas de demanda. Caso 3

Observando la figura 44 queda patente el excelente ajuste de las estimaciones realizadas mediante ambos métodos, con períodos donde se solapan perfectamente con la curva de demanda real.

5.- VENTAJAS E INCONVENIENTES. TABLA RESUMEN

Se exponen a continuación una serie de hechos encontrados durante las estimaciones realizadas y que resaltan algunos puntos importantes a la hora de afrontar una predicción mediante cualquiera de los dos métodos estudiados.

MÉTODO	VENTAJAS	INCONVENIENTES	HORIZONTE
ARIMA	El ajuste los valores estimados se acerca mucho al comportamiento de la curva de demanda con un margen de error mínimo	Análisis previo complejo	Corto, medio y largo plazo
	Es capaz de mantener una tendencia uniforme para la gráfica estimada y que se aproxima bastante a la real		

MÉTODO	VENTAJAS	INCONVENIENTES	HORIZONTE
REDES NEURONALES	No requieren formulaciones matemáticas complejas o correlación entre entradas y salidas.	La programación de la red tediosa	Corto, medio y largo plazo
	Modelos sencillos y que permiten obtener bajos errores en el pronóstico	Pueden producirse oscilaciones en los valores estimados	

Tabla 18: Ventajas e inconvenientes de los métodos estudiados



6.- CONCLUSIONES

En el presente trabajo se realiza una comparación entre dos métodos de probada eficacia para la estimación de la demanda de energía eléctrica, modelado ARIMA y Redes Neuronales. Para ello, se procede a realizar la predicción para tres casos correspondientes al año 2015, tomando como datos históricos para nuestros modelos los días a partir del 1/1/2014 y hasta la fecha anterior al día a predecir según cada supuesto (punta de demanda invernal, laborable y fin de semana). De esta forma, contamos con los datos correspondientes a los consumos de energía en cada hora del día a lo largo de más de 600 casos, formando un período total de, aproximadamente, dos años de datos históricos.

Es posible modelar los consumos de energía eléctrica utilizando los métodos ARIMA, dado que el comportamiento de estas series no es completamente aleatorio y se pueden describir como series de tiempo con una alta probabilidad de éxito en el modelado a través de dicha metodología.

Los valores arrojados por este modelo se ajustan con relativa precisión a los valores reales presentes en los casos estudiados y, lo que es más importante, son similares a los valores previstos por el operador de la red, lo que permite confiar en la bondad del ajuste de nuestro modelo.

El modelado mediante redes neuronales ha arrojado también unos valores relativamente precisos, incluso ofreciendo resultados virtualmente idénticos a los proporcionados por el modelo ARIMA. No obstante, la presencia de ciertas oscilaciones en las estimaciones nos hace recordar la “desconexión” existente entre la red neuronal y la realidad, comportándose dicha red como una caja negra sin una base formal que la una a la curva de demanda real. Sin embargo, la flexibilidad de este método hace que sus posibilidades de mejora sean prácticamente ilimitadas ya que mediante la aplicación de una arquitectura distinta se pueden obtener diferentes niveles de precisión.



Cabe destacar también el hecho de que ambas metodologías se apoyan fuertemente en el criterio del operador, quedando por tanto, como un “arte” en el que la experiencia previa supone un factor que, aun no pudiendo ser cuantificado formalmente, juega un importante papel en el resultado final de la estimación.

Para ambos casos se han obtenido unos valores relativamente cercanos a la predicción realizada por Red Eléctrica de España, asumiendo que dicho organismo posee una base de datos históricos prácticamente ilimitada y que realiza la predicción mediante software especializado creado específicamente para el propósito de la estimación de demanda podemos calificar los resultados obtenidos como muy satisfactorios ya que se mantienen dentro de unos valores coherentes y cercanos a la realidad de la demanda en la España peninsular.

Por tanto, se concluye que podemos estimar el comportamiento de la curva de demanda de energía eléctrica mediante modelos ARIMA o Redes Neuronales creados a partir de software estadístico disponible a nivel comercial a un coste relativamente bajo y con resultados adecuados y razonablemente precisos.

CAPÍTULO V:

BIBLIOGRAFÍA



BIBLIOGRAFÍA

1.- BIBLIOGRAFÍA

- **Al-Garni, A. Ahmed, Z. & Al-Nassar, Y.** Model for electric energy consumption in Eastern Saudi Arabia. *Energy Sources*, Vol. 19 (1997)
- **Al-Saba, T & El-Amin, I.** Artificial neural networks as applied to long-term demand forecasting. *Artificial Intelligence in Engineering*, Vol. 13 (1999)
- **Alfares, H. & Nazeeruddin, M.** Regression-based methodology for daily peak load forecasting. *Proceedings of the 2nd International Conference on Operations and Quantitative Management*, Ahmedabad, India (1999)
- **Alkhathami, M.** Introduction to Electric Load Forecasting Methods. *Journal of Advanced Electrical and Computer Engineering*, Vol. 2, (2015)
- **Brockwell, P. & Davis, R.** *Introduction to Time Series and Forecasting*. Ed. Springer.
- **Chatfield, C.** *The analysis of time series. An introduction*. Ed. Chapman and Hall.
- **Contreras, J. & Riquelme, J.** Short-term Demand and Energy Price Forecasting. *IEEE MELECON* (2006)
- **Ediger, V. & Tatlidil, H.** Forecasting the primary energy demand in turkey and analysis of cyclic patterns. *Energy Conversion and Management*, Vol. 43 (2002)
- **El-Keib, A. & Ma, H.** Advancement of statistical based modeling for short-term load forecasting. *Electric Power Systems Research*, Vol. 35 (1995)
- **Hahn, H. Pickl S.** Electric load forecasting methods: Tools for decision making. *European Journal of Operational Research*. Vol. 199 (2009)



- **Haida, T. Muto, S. & Takahashi, Y.** Peak load forecasting using multiple-year data with trend data processing techniques. *Electrical Engineering in Japan*, Vol. 124 (1998)
- **Hong, T.** Load Forecasting Case Study. Easter Interconnection States Planning Council (2015)
- **Huang, S.** Short-term load forecasting using threshold autoregressive models. *IEE Proceedings: Generation, Transmission, and Distribution*, Vol. 144 (1997)
- **Hyde, O. & Hodnett, P.** Modeling the effect of weather in short-term electricity load forecasting. *Mathematical Engineering in Industry*, Vol. 6 (1997)
- **Juberias, G. Yunta, R. & Garcia, J.** A new ARIMA model for hourly load forecasting. *IEEE Transmission and Distribution Conference Proceedings*, Vol. 1 (1999)
- **Liang, R. & Hsu, Y.** Fuzzy linear programming: an application to hydroelectric generation scheduling. *IEE Proceedings: Generation, Transmission and Distribution*, Vol. 141 (1994)
- **Mbamalu, G. & El-Hawary, M.** Load forecasting via suboptimal seasonal autoregressive models and iteratively reweighted least squares estimation. *IEEE Transactions on Power Systems*, Vol. 8 (1992)
- **Mishra, G. & Singh, A.** Application of Box-Jenkins method and artificial neural network procedure for time series forecasting of prices. *Statistics in transition*, Vol. 16 (2015)
- **Moturi, C. & Kioko, F.** Use of Artificial Neural Networks for Short-Term Electricity Load Forecasting of Kenya National Grid Power System. *International Journal of Computer Applications*, Vol. 2 (2013)



- **Murillos, J. Trejos, A. & Carvajal, P.** Estudio del pronóstico de la demanda de energía eléctrica utilizando modelos de series de tiempo. *Sciencia et Technica* Año IX, Nº. 23 (2003)
- **Pai, P. & Hong, W.** Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms. *Electric Power Systems Research*, Vol. 74 (2005)
- **Senabre, C. Valero, S. Gabaldón, A. Ortiz, M. & González M.** Predicción de la Demanda Total de Energía Eléctrica Española utilizando Mapas Auto-organizados como Modelo de Red Neuronal. *Escuela Técnica Superior de Ingeniería Industrial. Universidad Politécnica de Cartagena* (2004)
- **Senjyu, T. Takara, H. Uezato, K. & Funabashi, T.** One-hour-ahead load forecasting using neural network. *IEEE Transactions on Power Systems*, Vol. 17 (2002)
- **Taylor, J. & McSharry, P.** Short-Term Load Forecasting Methods: An Evaluation Based on European Data. *IEEE Transactions on Power Systems*, Vol. 22 (2008)
- **Taylor, J. Menezes, L. & McSharry, P.** A comparison of univariate methods for forecasting electricity demand up to a day ahead. *International Journal of Forecasting*, Vol. 22 (2006)
- **Smith, M.** Modeling and short-term forecasting of New South Wales electricity system load. *Journal of Business and Economic Statistics*, Vol. 18 (2000)
- **Uriel, E.** Análisis de series temporales. Modelos ARIMA. Ed. Paraninfo.
- **Weron, R.** Modelling and Forecasting Electricity Loads and Prices. A Statistical Approach. Ed. Wiley & Sons.
- **Yalcinoz, T. & Eminoglu, U.** Short term and medium term power distribution load forecasting by neural networks. *Energy Conversion and Management*, Vol. 46 (2005)

CAPÍTULO VI:

ANEXOS

ANEXOS

1.- ARIMA

1.1.- Caso 1

COEFICIENTES DEL MODELO	
HORA	MODELO (p,d,q)
0:00	ARIMA (0,1,6)
1:00	ARIMA (0,1,6)
2:00	ARIMA (0,1,2)
3:00	ARIMA (0,1,6)
4:00	ARIMA (1,0,2)
5:00	ARIMA (0,1,6)
6:00	ARIMA (0,0,7)
7:00	ARIMA (1,0,3)
8:00	ARIMA (1,1,0)
9:00	ARIMA (1,1,3)
10:00	ARIMA (1,1,2)
11:00	ARIMA (1,1,2)
12:00	ARIMA (1,1,2)
13:00	ARIMA (3,0,0)
14:00	ARIMA (1,0,2)
15:00	ARIMA (1,0,2)
16:00	ARIMA (3,0,0)
17:00	ARIMA (3,0,0)
18:00	ARIMA (1,1,2)
19:00	ARIMA (1,1,5)
20:00	ARIMA (1,1,5)
21:00	ARIMA (3,1,3)
22:00	ARIMA (3,1,4)
23:00	ARIMA (1,1,4)

Tabla 19: Coeficientes de los modelos ARIMA para el Caso 1




Fig. 45: Gráfica de error absoluto porcentual promedio – Caso 1

ESTADÍSTICOS DEL MODELO			
Hora	R ² estacionaria	R ²	MAPE
Hora_0	,472	,711	3,178
Hora_1	,535	,634	3,238
Hora_2	,518	,584	3,241
Hora_3	,488	,565	3,392
Hora_4	,467	,580	3,360
Hora_5	,429	,594	3,342
Hora_6	,659	,659	3,060
Hora_7	,686	,686	3,268
Hora_8	,118	,667	4,166
Hora_9	,168	,568	4,348
Hora_10	,190	,558	3,994
Hora_11	,182	,567	3,666
Hora_12	,158	,553	3,499
Hora_13	,555	,555	3,320
Hora_14	,578	,578	3,075
Hora_15	,595	,595	3,214
Hora_16	,572	,572	3,584
Hora_17	,572	,572	3,727
Hora_18	,128	,623	3,846
Hora_19	,126	,787	3,555
Hora_20	,105	,820	3,296
Hora_21	,154	,811	2,992
Hora_22	,183	,784	2,496
Hora_23	,132	,841	2,114

Tabla 20: Estadísticos para cada modelo del Caso 1



1.2.- Caso 2

COEFICIENTES DEL MODELO	
HORA	MODELO (p,d,q)
0:00	ARIMA (1,0,0)
1:00	ARIMA (1,0,3)
2:00	ARIMA (2,0,4)
3:00	ARIMA (1,0,0)
4:00	ARIMA (1,0,3)
5:00	ARIMA (1,0,0)
6:00	ARIMA (1,0,0)
7:00	ARIMA (0,1,2)
8:00	ARIMA (0,1,2)
9:00	ARIMA (1,0,2)
10:00	ARIMA (0,1,2)
11:00	ARIMA (0,1,2)
12:00	ARIMA (1,0,2)
13:00	ARIMA (1,0,2)
14:00	ARIMA (1,0,2)
15:00	ARIMA (1,0,2)
16:00	ARIMA (1,0,2)
17:00	ARIMA (1,0,2)
18:00	ARIMA (0,1,2)
19:00	ARIMA (0,1,2)
20:00	ARIMA (0,1,2)
21:00	ARIMA (0,1,2)
22:00	ARIMA (1,0,2)
23:00	ARIMA (1,1,2)

Tabla 21: Coeficientes de los modelos ARIMA para el Caso 2




Fig. 46: Gráfica de error absoluto porcentual promedio – Caso 2

ESTADÍSTICOS DEL MODELO			
Hora	R ² estacionaria	R ²	MAPE
Hora_0	,570	,823	2,176
Hora_1	,555	,802	2,187
Hora_2	,562	,772	2,109
Hora_3	,585	,757	2,220
Hora_4	,048	,396	3,448
Hora_5	,635	,756	2,253
Hora_6	,653	,728	2,357
Hora_7	,430	,666	3,172
Hora_8	,106	,666	3,906
Hora_9	,579	,579	4,031
Hora_10	,144	,562	3,783
Hora_11	,136	,572	3,489
Hora_12	,571	,571	3,310
Hora_13	,555	,555	3,249
Hora_14	,586	,586	3,011
Hora_15	,597	,597	3,150
Hora_16	,576	,576	3,434
Hora_17	,576	,576	3,571
Hora_18	,133	,635	3,671
Hora_19	,126	,800	3,368
Hora_20	,128	,837	3,094
Hora_21	,184	,823	2,769
Hora_22	,793	,793	2,292
Hora_23	,058	,846	1,995

Tabla 22: Estadísticos para cada modelo del Caso 2

1.3.- Caso 3

COEFICIENTES DEL MODELO	
HORA	MODELO (p,d,q)
0:00	ARIMA (1,1,3)
1:00	ARIMA (1,1,3)
2:00	ARIMA (1,1,2)
3:00	ARIMA (1,1,2)
4:00	ARIMA (1,1,2)
5:00	ARIMA (1,1,2)
6:00	ARIMA (1,1,3)
7:00	ARIMA (1,1,3)
8:00	ARIMA (1,1,2)
9:00	ARIMA (2,0,2)
10:00	ARIMA (2,0,2)
11:00	ARIMA (2,0,2)
12:00	ARIMA (2,0,1)
13:00	ARIMA (2,0,1)
14:00	ARIMA (2,1,6)
15:00	ARIMA (1,1,4)
16:00	ARIMA (1,1,4)
17:00	ARIMA (1,1,2)
18:00	ARIMA (1,1,2)
19:00	ARIMA (1,1,1)
20:00	ARIMA (1,1,1)
21:00	ARIMA (2,0,1)
22:00	ARIMA (0,1,6)
23:00	ARIMA (1,1,6)

Tabla 23: Coeficientes de los modelos ARIMA para el Caso 3




Fig. 47: Gráfica de error absoluto porcentual promedio – Caso 3

ESTADÍSTICOS DEL MODELO			
Hora	R ² estacionaria	R ²	MAPE
Hora_0	,722	,767	2,666
Hora_1	,781	,738	2,688
Hora_2	,786	,718	2,683
Hora_3	,797	,695	2,631
Hora_4	,813	,717	2,469
Hora_5	,818	,716	2,456
Hora_6	,829	,750	2,217
Hora_7	,879	,796	2,281
Hora_8	,917	,834	2,434
Hora_9	,858	,858	2,357
Hora_10	,865	,865	2,447
Hora_11	,849	,849	2,564
Hora_12	,820	,820	2,728
Hora_13	,785	,785	2,817
Hora_14	,822	,693	3,180
Hora_15	,799	,719	2,983
Hora_16	,791	,735	3,022
Hora_17	,788	,737	3,117
Hora_18	,784	,788	3,067
Hora_19	,714	,862	3,037
Hora_20	,626	,880	2,900
Hora_21	,872	,872	2,639
Hora_22	,066	,798	2,281
Hora_23	,049	,826	2,248

Tabla 24: Estadísticos para cada modelo del Caso 3

2.- REDES NEURONALES

2.1.- Caso 1

HORA	RED			ERRORES	
	Entradas	Ocultas	Salida	Cuadrático medio	Relativo
0:00	2	3	1	5,824	0,037
1:00	2	1	1	2,419	0,014
2:00	2	2	1	1,967	0,012
3:00	2	3	1	2,354	0,012
4:00	2	6	1	2,018	0,013
5:00	2	2	1	1,778	0,012
6:00	2	4	1	2,778	0,015
7:00	2	2	1	2,996	0,017
8:00	2	2	1	2,631	0,016
9:00	2	2	1	0,911	0,006
10:00	2	1	1	0,792	0,005
11:00	2	1	1	1,124	0,008
12:00	2	2	1	0,369	0,002
13:00	2	2	1	0,865	0,004
14:00	2	2	1	0,91	0,006
15:00	2	2	1	0,967	0,006
16:00	2	2	1	0,438	0,003
17:00	2	1	1	0,891	0,005
18:00	2	4	1	2,393	0,013
19:00	2	2	1	5,095	0,037
20:00	2	3	1	5,646	0,030
21:00	2	1	1	10,537	0,055
22:00	2	3	1	4,017	0,025
23:00	2	3	1	5,474	0,033

Tabla 25: Información de la red neuronal desarrollada para el Caso 1

2.2.- Caso 2

HORA	RED			ERRORES	
	Entradas	Ocultas	Salida	Cuadrático medio	Relativo
0:00	2	4	1	4,264	0,057
1:00	2	3	1	2,326	0,036
2:00	2	2	1	2,964	0,023
3:00	2	2	1	2,438	0,045
4:00	2	1	1	1,918	0,039
5:00	2	3	1	1,852	0,024
6:00	2	1	1	3,010	0,031
7:00	2	4	1	3,254	0,035
8:00	2	1	1	2,316	0,045
9:00	2	1	1	0,810	0,009
10:00	2	4	1	1,659	0,027
11:00	2	1	1	2,378	0,006
12:00	2	1	1	0,560	0,004
13:00	2	2	1	0,926	0,005
14:00	2	1	1	1,025	0,007
15:00	2	3	1	1,048	0,007
16:00	2	5	1	0,530	0,005
17:00	2	2	1	0,910	0,008
18:00	2	1	1	3,124	0,016
19:00	2	4	1	4,830	0,042
20:00	2	1	1	5,210	0,037
21:00	2	2	1	7,261	0,061
22:00	2	1	1	3,908	0,029
23:00	2	1	1	6,018	0,030

Tabla 26: Información de la red neuronal desarrollada para el Caso 2

2.3.- Caso 3

HORA	RED			ERRORES	
	Entradas	Ocultas	Salida	Cuadrático medio	Relativo
0:00	2	3	1	1,250	0,044
1:00	2	3	1	0,269	0,013
2:00	2	5	1	0,397	0,013
3:00	2	2	1	0,400	0,012
4:00	2	4	1	0,457	0,016
5:00	2	2	1	0,449	0,027
6:00	2	4	1	0,798	0,030
7:00	2	4	1	3,868	0,069
8:00	2	2	1	1,669	0,051
9:00	2	1	1	0,783	0,037
10:00	2	2	1	0,377	0,014
11:00	2	1	1	0,316	0,009
12:00	2	2	1	0,233	0,009
13:00	2	2	1	0,367	0,010
14:00	2	1	1	0,366	0,016
15:00	2	1	1	0,600	0,017
16:00	2	2	1	0,429	0,011
17:00	2	3	1	0,244	0,009
18:00	2	3	1	0,945	0,028
19:00	2	2	1	0,707	0,019
20:00	2	4	1	1,258	0,040
21:00	2	5	1	1,977	0,084
22:00	2	2	1	0,798	0,040
23:00	2	5	1	0,733	0,029

Tabla 27: Información de la red neuronal desarrollada para el Caso 3