



UNIVERSIDAD DE JAÉN
Escuela Politécnica Superior de Linares

Trabajo Fin de Grado

**DISEÑO DE RED NEURONAL PARA
LA PREDICCIÓN DEL
CONSUMO DE ENERGÍA
ELÉCTRICA: CASO PRÁCTICO**

Alumno: Rubén Sánchez Castro

Tutor: Gómez González, Manuel
Depto.: Ingeniería Eléctrica

Febrero, 2018



UNIVERSIDAD DE JAÉN
Escuela Politécnica Superior de Linares

Trabajo Fin de Grado

UNIVERSIDAD DE JAÉN
Escuela Politécnica Superior de Linares

DISEÑO DE RED NEURONAL PARA LA PREDICCIÓN DEL CONSUMO DE ENERGÍA ELÉCTRICA: CASO PRÁCTICO

Alumno: Rubén Sánchez Castro

Tutor: Gómez González, Manuel
Depto.: Ingeniería Eléctrica

Febrero, 2018

ÍNDICE DE CONTENIDO

1. INTRODUCCIÓN	7
1.1. SISTEMA ELÉCTRICO ESPAÑOL	7
1.2. DEMANDA DE ENERGÍA	8
1.3. IMPORTANCIA DE LA DEMANDA PARA LA DISTRIBUIDORA	8
1.4. ASPECTOS SOCIO-ECONÓMICOS EN LA DEMANDA DE ENERGÍA	9
1.5. PREDICCIÓN DE LA DEMANDA Y CONSUMO ELÉCTRICO	10
1.6. MUNICIPIO DE CANENA	11
1.7. CALIDAD DEL SERVICIO	12
1.8. MÉTODO CLÁSICO DE PREVISIÓN	13
1.9. MÉTODOS PARAMÉTRICOS	13
1.10. DESREGULARIZACIÓN DEL SECTOR	13
2. REDES NEURONALES	14
2.1. FUNDAMENTOS BIOLÓGICOS	14
2.2. INTRODUCCIÓN A LAS REDES NEURONALES ARTIFICIALES Y SU HISTORIA	14
2.3. ELEMENTOS DE UNA RED NEURONAL	17
2.3.1. Unidades de proceso	17
2.3.2. Estado de activación	17
2.3.3. Función de salida	18
2.4. TOPOLOGÍA	19
2.5. PERCEPTRÓN MULTICAPA	19
2.6. MECANISMOS DE APRENDIZAJE	20
2.6.1. Redes Neuronales con aprendizaje supervisado	20
2.6.2. Redes Neuronales con aprendizaje no supervisado	20
2.7. SOBREENTRENAMIENTO DE LA RED	20
2.8. VENTAJAS DE LAS REDES NEURONALES	20
3. METODOLOGÍA	22
3.1. OBTENCIÓN Y PREPROCESAMIENTO DE DATOS	22
3.1.1. División de los datos	26
3.2. CREACIÓN DE LA RED NEURONAL	26
3.3. ENTRENAMIENTO DE LA RED	31
3.3.1 Limitaciones y precauciones con Levenberg-Marquardt	38
3.3.2 Generalizaciones	38

4. RESULTADOS.....	39
5. CONCLUSIONES	88
6. BIBLIOGRAFÍA Y REFERENCIAS.....	90

RESUMEN

En el presente trabajo fin de grado se pretende realizar una predicción del consumo de energía eléctrica. El método de predicción llevado a cabo es mediante el uso de Redes Neuronales Artificiales. Con una buena predicción se logra un gran equilibrio entre la energía generada y la energía consumida. Si no se logra un equilibrio se tendrían problemas por los cuales no se generaría la energía suficiente para abastecer a los consumidores, lo cual conlleva cortes de suministro o bien por el desperdicio de energía eléctrica, ya que esta no se puede almacenar en grandes cantidades ni durante un periodo de tiempo elevado.

Para este caso práctico se han utilizado datos históricos meteorológicos y de consumo pertenecientes al Municipio de Canena situado en la provincia de Jaén y los cuáles se obtuvieron gracias a Electra La Loma S.L.

1. INTRODUCCIÓN

1.1. Sistema Eléctrico Español

El sistema eléctrico español se asegura que la energía sea transportada hasta las redes de distribución con las condiciones de calidad exigibles de la normativa vigente.

La Ley 17/2007, de 4 de julio, confirmó la condición de Red Eléctrica como gestor de la red de transporte y le atribuyó la función de transportista único, en régimen de exclusividad. En cumplimiento de esta ley Red Eléctrica adquirió, en 2010, los activos de Baleares y Canarias y el resto de los activos peninsulares pendientes de transferir de las empresas eléctricas. Esta compra supuso la consolidación definitiva del modelo de transportista único y operador del sistema.

Los principales grupos del sistema son:

- Generadores: Son los responsables de la energía eléctrica en sus plantas e inyectarla a la de red de transporte.
- Transportista: Es la encargada de transportar la energía en alta tensión. Para ello debe de mantener, gestionar y reparar las infraestructuras en caso de ser necesario. Como se ha indicado anteriormente la empresa encargada de realizar dicha tarea en España es Red Eléctrica de España (REE).
- Distribuidoras: Transportan y gestionan la energía desde el punto de distribución hasta el punto de suministro. Mantienen las redes de baja y media tensión garantizando la calidad y su perfecto funcionamiento de suministro.
- Comercializadoras: Son las responsables de la compra de energía para el consumidor. Cada ciudadano puede elegir a que comercializadora quiere comprarle la energía debido a la liberación del sistema eléctrico.

A continuación, se muestra un esquema del sistema eléctrico:



Figura 1.1: Esquema del sistema eléctrico

1.2. Demanda de energía

Nunca es constante y cambia continuamente. La demanda total de energía en el nivel de transporte varía de forma más o menos predecible y depende de: estación del año, condiciones climáticas, modo de vida de una sociedad en particular. Las variaciones de demanda en el nivel generación suelen ser pequeñas y se conocen como fluctuaciones de carga [1].

1.3. Importancia de la demanda para la Distribuidora

El grupo Electra La Loma S.L. está formado por tres empresas que son: Electra La Loma S.L. como distribuidora, Electra La Loma Escuadras Uno S.L. Electra La Loma Escuadras Dos S.L. y Electra La Loma Losilla Tres S.L. como generadores de energía eléctrica a través de las energías renovables y para ser más exactos energía solar fotovoltaica y por último Electra La Loma Comercializadora como su nombre indica para la venta de energía a la población.

Electra La Loma S.L. tiene como finalidad suministrar electricidad a los usuarios de la manera más segura y económica posible, de forma continua. Las empresas generadoras y distribuidoras trabajan de forma enlazada para conseguir un suministro de energía óptimo, obteniéndose así mejoras en los rendimientos económicos y operacionales.

La capacidad de generar un pronóstico del consumo próximo de energía eléctrica permite la favorable operatividad de los sistemas. Para conseguir unos objetivos de calidad y confiabilidad del servicio, la predicción de la demanda de energía es indispensable. Si se generan unas deficiencias en la distribución de energía eléctrica pueden crear una serie de limitaciones a los usuarios, debido a que existe un progresivo aumento de dependencia de la electricidad.

El pronóstico de la demanda es una actividad fundamental para Electra La Loma S.L. como para cualquier empresa que suministra energía eléctrica. Tiene una gran importancia a la hora de determinar, por parte de la empresa distribuidora, qué cantidad y cuando se producirá la mayor demanda por parte de los consumidores. Cuando las previsiones realizadas son lo más parecidas a la realidad, tiene como consecuencia la toma de una serie de decisiones eficaces en la planificación, con lo cual, se previenen riesgos de excesos o defectos de energía. Por el contrario, si el pronóstico se aleja de la realidad, se toman decisiones menos acertadas que ocasionan pérdidas de capital.

La previsión del consumo permite obtener una correcta percepción de las necesidades futuras de generación de electricidad. Si se pronostica que no se va a disponer de una extensión suficiente de energía se podrían tomar medidas como la generación de más energía o aplicación de métodos de preservación de la energía. Tanto un exceso como un defecto de energía, pueden generar costes considerablemente elevados, además, el cliente puede tener la percepción de una calidad baja del servicio.

1.4. Aspectos socio-económicos en la demanda de energía

Consecuentemente, puede asegurarse que existe una relación muy estrecha entre el consumo de energía y el bienestar económico de un país.

Ya desde tiempos remotos, el hombre ha sabido utilizar, además de su propio esfuerzo físico, el de algunos animales domésticos para obtener energía mecánica; a ello unirá después la fuerza del viento (eólica) y la de las corrientes de agua. Además, obtenía calor de la combustión para sus hogares, y las actividades fabriles.

La correspondencia entre el nivel de vida y el consumo energético de un país puede apreciarse también desde la perspectiva histórica. Así, cuando un país

comienza a desarrollarse, su estructura económica está caracterizada por un predominio de las actividades del sector primario.

En el proceso de crecimiento económico, la industria va aumentando en importancia, lo mismo que el sector transportes, y estas actividades consumen importantes cantidades de energía. A ello se va uniendo la creciente mecanización de las actividades económicas y el aumento del uso de energía en el sector doméstico [1].

1.5. Predicción de la demanda y consumo eléctrico

Una gestión óptima de la energía necesita mayor conocimiento de las variables que entran en juego a la hora del consumo. Por ello, los métodos de predicción de consumo y demanda de energía son cada vez más importantes porque obteniendo un sistema de predicción muy eficiente, se puede obtener un equilibrio entre la demanda y el consumo en el cual los consumidores no tendrán cortes de suministro debido a las malas gestiones y predicciones de consumo.

El principal problema en el sistema eléctrico es almacenar la energía eléctrica que se genera. No puede almacenarse, ni en grandes cantidades ni de forma económicamente rentable, por lo que en cada instante debe generarse lo que se consume.

La potencia eléctrica demandada varía de un día a otro y a lo largo del día, por lo que la generación debe seguir esa misma variación temporal, manteniendo el valor nominal de la frecuencia del sistema, 50 Hz, y otras condiciones que definen el estado de funcionamiento normal del sistema eléctrico.

Se pueden diferenciar las predicciones en tres tipos: a largo, corto plazo y medio plazo [2].

- A largo plazo: consiste en desarrollar un pronóstico de la demanda de energía eléctrica existente generalmente desde 5 a 25 años. Esta previsión tiene una gran relevancia para llevar a cabo la planificación a la hora de originar otras empresas generadoras de energía, como también redes de transmisión de la electricidad. Es difícil tener una buena exactitud en las predicciones con periodos de tanto tiempo. Esta predicción se necesita para la planificación del sistema generador y sistema de transporte, ya que una predicción lo más

exacta posible, otorgará mayor probabilidad para satisfacer los picos de carga y mejorar el factor de carga.

- A corto plazo: consiste en hacer una previsión de la demanda con el objetivo de proporcionar electricidad en el intervalo de horas, días y también semanas.

Existen variaciones en la demanda ocasionadas por diversos factores:

- Condiciones sociales y económicas: no tienen tanta importancia en este tipo de pronóstico.
- Condiciones meteorológicas: representan una gran influencia a la hora de desarrollar este pronóstico. Podemos encontrar que el patrón del consumo de energía al día se corresponde con la línea de temperatura diaria. Esto quiere decir que la energía máxima demandada en el día coincide aproximadamente cuando la temperatura es máxima o mínima, en función de si la energía eléctrica se necesita para calentar o refrescar. De igual modo, existen diferencias en el consumo entre los días laborales y los días del fin de semana, así como también entre los días que son festivos y los que no lo son.

- A medio plazo: se trata de llevar a cabo una previsión de la demanda en tiempos comprendidos por semanas, meses o hasta 5 años, con la finalidad de suministrar energía eléctrica en esos intervalos. Con esta predicción se establece el calendario de mantenimiento de las plantas generadoras y del sistema de transporte de energía.

1.6. Municipio de Canena

Es un municipio español de la provincia de Jaén (Andalucía), situado en la comarca de La Loma. Cuenta con una población aproximadamente de 2.000 habitantes.

El medio de vida de la población es la agricultura dedicándose concretamente al cultivo del olivo. La temporada de recogida de este cultivo está comprendida entre Diciembre y Febrero por lo que las almazaras en esta región y precisamente en el pueblo funcionarán a pleno rendimiento conllevando a una elevación del consumo durante estos meses debido a dicho cultivo.

1.7. Calidad del servicio

En España, el suministro de energía eléctrica está garantizado, la atención se centra cada vez más en la calidad. El consumo y los consumidores se han vuelto más exigentes y las autoridades normativas del sector eléctricos incluyen estándares de calidad en las leyes y reglamentos [3].

La calidad del servicio se caracteriza por los siguientes factores:

- Cortes en el suministro: las interrupciones pueden tener graves consecuencias de cara al consumidor. Pueden ser cortes largos o cortos (microcortes) y el daño causado aumenta de forma no lineal con la duración de la interrupción.
- Caídas de tensión: las reducciones de la tensión en el suministro ya sean causadas por cortocircuitos o fallos del sistema, perduran hasta que el defecto se elimina.
- Armónicos de tensión: las desviaciones de la onda de tensión sobre la frecuencia fundamental debido a la saturación de los materiales ferromagnéticos, pueden también tener efectos adversos en los aparatos de consumo.
- Efecto Flicker: son fluctuaciones en la amplitud de la tensión a baja frecuencia debidas a ciertos tipos de cargas. La solución a este problema es compleja, ya que depende del proveedor y de las cargas del sistema.
- Sobretensión: el incremento del valor de la tensión provocado por un cortocircuito, avería, descargas atmosféricas o cualquier otro hecho, causa daños graves a los consumidores.

Por último, cabe añadir que el consumo de energía eléctrica puede variar con la temperatura o las contingencias. Se debe tener en cuenta, como se mencionó anteriormente, que esta demanda se debe satisfacer de forma instantánea y, por lo tanto, el sistema de suministro de energía eléctrica, las centrales eléctricas, el transporte y la distribución, deben diseñarse para ser capaces de detectar y responder inmediatamente a tales variaciones.

1.8. Método clásico de previsión

La suavización exponencial (SE) es uno de los principales métodos clásicos de previsión cuantitativa, es sencillo, robusto y ampliamente utilizado para la previsión de la demanda [4]. Los valores pasados de la serie de tiempo son ponderados y desvalorizados en relación a los más recientes. Ese proceso se realiza en función de parámetros de atenuación que varían en el intervalo $[0,1]$. De esta manera, con la atenuación de los valores extremos de la serie, es posible definir el patrón básico de la demanda.

Por un lado, los valores de demanda cero en la serie temporal, y por otro, la variabilidad del tamaño de la demanda y del patrón de comportamiento de los datos, dificultan la aplicación de los modelos clásicos de previsión.

1.9. Métodos paramétricos

Son los encargados de obtener a partir del análisis estadístico y matemático los valores reales de las variables, los valores que tendrían los parámetros de los modelos en donde intervienen esas variables como comprobar el grado de validez.

1.10. Desregularización del sector

La desregularización dentro del sector de la electricidad hace que el adecuado pronóstico de la demanda de la energía eléctrica sea un requisito relevante por parte de las empresas suministradoras. En la mayoría de los países industrializados, la desregularización en este sector supone un factor de dubitación, esto hace que el precio de la energía eléctrica esté determinado por el mercado, teniendo como consecuencia que este precio influya directamente sobre el consumo de electricidad.

2. REDES NEURONALES

2.1. Fundamentos biológicos

El cerebro consta de un gran número de neuronas (aproximadamente 10^{11}) altamente interconectadas (aproximadamente 10^4 conexiones por neurona). Tres son los elementos de las neuronas:

- Soma o cuerpo celular: Cuerpo o parte principal de las neuronas. Es donde reside su núcleo.
- Axones: Se trata de una fibra nerviosa que permite enviar las señales eléctricas a otras neuronas. En su extremo más lejano al soma, posee muchas terminaciones nerviosas que se conectan con muchas neuronas a la vez.
- Dendritas: Prolongaciones de la neurona en forma de ramitas, a través de las cuales, la neurona recibe información procedente de otra neurona.




Figura 2.1: Neurona biológica.

La forma que tienen las neuronas de comunicarse (enviar y recibir información de otras neuronas) es a través de la Sinapsis. Se trata de un proceso que ocurre cuando el axón de una neurona manda información a las dendritas de otra neurona (el canal entre ambas partes de las neuronas es conocido como “espacio intersináptico”).

2.2. Introducción a las redes neuronales artificiales y su historia.

Las redes neuronales surgen por el afán del ser humano de crear máquinas que puedan pensar por sí solas, en otras palabras, que sean capaz de procesar, aprender y por lo tanto tener un comportamiento similar a las neuronas del ser humano.

¿Cómo puede tomar decisiones en base a la experiencia con perspectiva y fiabilidad una máquina con IA? Todo depende del problema, de la información que se disponga y de la forma en que esa información sea procesada. Lo que se trata es de buscar patrones o tendencias para generar una “máquina” que nos permita predecir o reproducir comportamientos con un grado de incertidumbre asociado.

La historia de las redes neuronales empezó a estudiarse a principios del siglo XX y que han sido señalados por Damián Jorge Matich [5]:

1936 - Alan Turing fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación. Sin embargo, los primeros teóricos que concibieron los fundamentos de la computación neuronal fueron Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, quienes, en 1943, lanzaron “Un Cálculo Lógico de la Inminente Idea de la Actividad Nerviosa - Boletín de Matemática Biofísica 5: 115-133”. Ellos crearon una red neuronal simple con circuitos eléctricos.

1949 - Donald Hebb escribió un importante libro: “La organización del comportamiento”, en el que se establece una conexión entre psicología y fisiología. Su idea fue que el aprendizaje ocurría cuando ciertos cambios en una neurona eran activados. También intentó encontrar semejanzas entre el aprendizaje y la actividad nerviosa. Los trabajos de Hebb formaron las bases de la Teoría de las Redes Neuronales.

1950 - Karl Lashley. En sus series de ensayos, encontró que la información no era almacenada en forma centralizada en el cerebro, sino que era distribuida encima de él.

1956 - Congreso de Dartmouth. Este Congreso frecuentemente se menciona para indicar el nacimiento de la inteligencia artificial.

1957 - Frank Rosenblatt comenzó el desarrollo del Perceptrón. Esta es la red neuronal más antigua; utilizándose hoy en día para aplicación como reconocedor de patrones. Sin embargo, es incapaz de clasificar clases no separables linealmente.

1960 - Bernard Widrow/Marcial Hoff desarrollaron el modelo Adaline (ADaptative LINear Elements). Esta fue la primera red neuronal aplicada a un problema real (filtros

adaptativos para eliminar ecos en las líneas telefónicas) que se ha utilizado comercialmente durante varias décadas.

1961 - Karl Steinbeck: Die Lernmatrix. Red neuronal para simples realizaciones técnicas (memoria asociativa).

1967 - Stephen Grossberg realizó una red: Avalancha, que consistía en elementos discretos con actividad que varían en el tiempo y que satisfacen ecuaciones diferenciales continuas, para resolver actividades como reconocimiento continuo de habla y aprendizaje de los brazos de un robot.

1969 - Marvin Minsky/Seymour Papert. En este año surgieron críticas que frenaron, hasta 1982, el crecimiento que estaban experimentando las investigaciones sobre redes neuronales. Minsky y Papert, del Instituto Tecnológico de Massachussets (MIT) probaron (matemáticamente) que el Perceptrón era muy débil. A pesar de ello James Anderson desarrolló un modelo lineal, llamado Asociador Lineal, que consistía en unos elementos integradores lineales (neuronas) que sumaban sus entradas.

1974 - Paul Werbos desarrolló la idea básica del algoritmo de aprendizaje de propagación hacia atrás (backpropagation); cuyo significado quedó definitivamente aclarado en 1985.

1977 - Stephen Grossberg. Teoría de Resonancia Adaptada (TRA), que simula otras habilidades del cerebro: memoria a largo y corto plazo.

1980 - Kunihiro Fukushima desarrolló un modelo neuronal para el reconocimiento de patrones visuales.

1985 - John Hopfield provocó el renacimiento de las redes neuronales con su libro: "Computación neuronal de decisiones en problemas de optimización".

1986 - David Rumelhart/G. Hinton redescubrieron el algoritmo de aprendizaje de propagación hacia atrás (backpropagation). A partir de 1986, el panorama fue alentador con respecto a las investigaciones y el desarrollo de las redes neuronales. En la actualidad, son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen (sobre todo en el área de control) y las empresas que

lanzan al mercado productos nuevos, tanto hardware como software (sobre todo para simulación).

2.3. Elementos de una red neuronal

2.3.1. Unidades de proceso

En todas las redes neuronales se pueden caracterizar tres tipos de unidades: entradas, salidas y ocultas.

Las entradas son las que reciben las señales del entorno (a su vez son entradas a la red).

Las salidas son las que envían los datos obtenidos fuera de la red.

Las ocultas se encuentran en el interior del sistema entre las entradas y las salidas por lo que no tienen contacto con el exterior [6].




Figura 2.2: Neurona Artificial.

2.3.2. Estado de activación

Las neuronas dentro del sistema se encuentran en un estado. Dicho estado puede ser reposo o excitado a los cuales se les denomina globalmente como estados de activación.

2.3.3. Función de salida

Entre las neuronas de una red artificial existen conexiones que unen a unas con otras. Cada neurona manda una señal a aquellas que se encuentran en su salida. Hay cuatro tipos de funciones de salida o transferencia.




Figura 2.3: Función escalón [6].




Figura 2.4: Función lineal y mixta [6].




Figura 2.5: Función Sigmoidal [6].




Figura 2.6: Función Gaussiana [6].

2.4. Topología

Según el número de capas que forman las redes neuronales se pueden diferenciar dos tipos: monocapa y multicapa. Las monocapa están compuestas por las entradas y una única salida mientras que si son multicapa están formadas por las capas ocultas, las de entrada y las de salida.

2.5. Perceptrón multicapa

Es una red hacia adelante (feed forward). En estas redes se usa el algoritmo backpropagation para llevar a cabo el entrenamiento que consiste en modificar los pesos de la red hasta que la salida deseada (target) sea la salida obtenida.




Figura 2.7: Perceptrón multicapa

2.6. Mecanismos de aprendizaje

2.6.1. Redes Neuronales con aprendizaje supervisado

El aprendizaje es controlado por un agente externo lo que permite cambiar los pesos en caso de que haya un error en la salida. Este aprendizaje puede ser por corrección de error, estocástico o refuerzo.

2.6.2. Redes Neuronales con aprendizaje no supervisado

La corrección de los pesos no depende de un agente externo como ocurre en el aprendizaje supervisado.

2.7. Sobreentrenamiento de la red

Si la red se entrena demasiado y con muchos datos puede llegar un momento en el que la red no sea capaz de generalizar los datos nuevos con el consiguiente defecto de no aprender debido a que el error de validación se incrementa.

Cuanto mayor es la red, las funciones serán más complejas, sin embargo, si se usa una red pequeña no tendrá los suficientes datos como para sobreentrenar los datos [7].

2.8. Ventajas de las redes neuronales

Debido a su constitución y a sus fundamentos, las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro.

Las principales ventajas son [6]:

- Aprendizaje adaptivo. Capacidad de aprender a realizar tareas que se basan en un entrenamiento o una experiencia inicial.
- Autoorganización. Una red neuronal puede crear su propia organización o representación de la información mediante una etapa de aprendizaje como hemos señalado anteriormente.
- Tolerancia a fallos. En el caso de que suceda algún error con la consiguiente degradación de la red neuronal, esta podrá retener algunas capacidades pese haber sufrido un daño.

- Operación en tiempo real. Los computadores neuronales pueden ser realizados en paralelo y máquinas con especial hardware se diseñan y fabrican para obtener esta capacidad.
- Fácil inserción dentro de la tecnología existente. Se pueden mejorar sus capacidades en ciertas tareas gracias a chips especializados.

3. METODOLOGÍA

3.1. Obtención y preprocesamiento de datos

La obtención de los datos sobre el consumo eléctrico de uno de los puntos frontera del municipio de Canena ha sido gracias a la Distribuidora Electra La Loma, S.L. como se dijo en el resumen. Estos son los datos de la curva de carga de energía horaria del 1 de Enero de 2015 hasta el 31 de Diciembre de 2015. El consumo de energía ha sido procesado para que se ofrezcan dichos consumos en una frecuencia diaria pasando de tener un fichero con 8760 a 365 (esto puede empeorar la predicción de la red neuronal).

A continuación, se puede ver gráficamente el consumo después del procesado y partiendo de los datos iniciales:




Figura 3.1: Consumo promedio diario

Estos valores de consumo promedio si los multiplicamos con los días correspondientes que tiene cada mes obtendremos el promedio mensual.




Figura 3.2: Consumo promedio mensual

Además, en la siguiente imagen se puede mostrar el consumo promedio en horas.

	Promedio de Consumo (kW)											
	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
0:00	561,84	531,46	718,13	1.215,40	1.807,68	1.667,57	1.570,87	1.684,00	1.955,77	1.206,26	259,83	45,16
1:00	489,90	460,89	642,74	1.145,00	1.748,84	1.632,23	1.583,71	1.668,81	1.921,47	1.194,06	318,40	60,16
2:00	442,68	410,07	604,16	1.156,27	1.779,81	1.622,60	1.604,23	1.647,81	1.890,50	1.201,19	334,50	58,52
3:00	409,74	382,68	605,68	1.109,60	1.754,19	1.601,60	1.598,97	1.617,48	1.846,90	1.201,13	325,73	58,77
4:00	396,84	375,29	600,10	1.032,03	1.726,87	1.574,43	1.593,39	1.622,42	1.853,33	1.168,26	334,93	57,74
5:00	400,48	378,46	614,68	1.018,17	1.731,19	1.579,50	1.589,13	1.621,84	1.829,57	1.126,58	288,10	70,32
6:00	431,84	411,04	635,06	1.017,87	1.733,58	1.470,60	1.478,35	1.666,00	1.781,13	1.055,32	263,23	82,71
7:00	542,74	516,04	683,77	726,63	1.361,94	1.103,93	1.041,39	1.487,65	1.559,33	860,74	216,97	56,48
8:00	595,84	551,18	596,42	789,03	1.320,42	1.091,60	935,74	1.385,71	1.470,23	773,87	137,67	21,23
9:00	606,90	568,96	595,97	716,23	1.050,26	819,27	717,94	1.070,68	1.092,50	539,68	104,43	7,71
10:00	603,39	561,64	527,61	494,53	610,68	336,40	245,42	560,55	522,17	295,10	106,70	3,58
11:00	527,29	494,32	419,00	429,57	579,23	311,33	247,23	531,68	498,33	273,42	92,37	2,32
12:00	448,39	432,89	390,45	408,77	567,81	316,17	240,06	511,71	503,30	287,10	119,40	1,16
13:00	471,03	460,71	385,84	421,47	587,65	335,03	251,74	566,32	622,90	360,06	111,87	2,03
14:00	534,03	512,39	446,35	495,07	792,87	648,60	655,32	982,39	903,70	510,97	110,63	2,81
15:00	512,39	484,43	414,68	517,73	883,84	706,23	689,39	1.075,23	986,40	539,52	96,40	3,94
16:00	531,68	494,11	449,39	580,27	977,26	777,80	745,32	1.123,84	1.167,53	623,26	102,63	6,52
17:00	586,48	522,11	491,03	649,60	1.196,23	933,57	813,45	1.185,68	1.323,80	676,61	106,00	19,45
18:00	712,90	609,86	512,45	672,87	1.284,45	1.021,67	911,48	1.336,00	1.462,43	703,52	92,63	25,32
19:00	779,81	728,96	626,06	751,93	1.341,03	1.052,13	1.003,65	1.513,68	1.601,97	703,39	58,23	25,94
20:00	799,13	768,46	708,52	853,83	1.404,68	1.110,80	1.035,19	1.533,68	1.679,27	717,32	62,13	26,19
21:00	823,32	797,64	732,45	845,13	1.428,13	1.163,10	1.053,97	1.542,71	1.648,83	720,16	52,73	25,61
22:00	770,77	743,89	711,68	803,00	1.391,74	1.091,47	1.056,94	1.547,55	1.604,43	743,97	96,63	25,35
23:00	667,52	647,29	695,16	1.205,60	1.751,81	1.505,37	1.399,35	1.673,26	1.878,87	996,97	104,67	25,19

Tabla 3.1: Promedio de consumo horario

Como se puede observar en la figura 3.3 se puede ver claramente la hora y el mes en los cuales se tiene mayor consumo. El periodo del año de mayor consumo está comprendido entre Mayo y Septiembre en un horario comprendido de 19:00 a

7:00 de la mañana. Esta franja horaria de consumo se debe a la población, para estas fechas tienen la mayor parte del tiempo el aire acondicionado activado en sus casas.

El período de invierno es algo bajo y puede ser debido a algún error en la lectura del consumo por parte de la distribuidora o sea debido al sector primario (agricultura dedicada precisamente a la oliva y cuya temporada empieza a final de año).

La variable más importante que como consecuencia altera el consumo aumentando o disminuyendo es la temperatura. Habría que destacar sus máximas y mínimas registradas en función de la fecha:

CARACTERÍSTICA	Tempratura °C	FECHA
Temperatura máxima más alta registrada	42	06/07/2015
Temperatura máxima más baja registrada	3,2	21/01/2015
Temperatura mínima más alta registrada	26,4	07/08/2015
Temperatura mínima más baja registrada	-2,1	01/01/2015

Tabla 3.2: Promedio de consumo horario

La última variable que es la encargada de registrar las precipitaciones ha sido obtenida a través de AEMET (Agencia Estatal de Meteorología) teniendo un fichero con las muestras correspondientes al año 2015.

Una vez realizada nuestra base datos, hay que procesar la información para que la red neuronal funcione correctamente con el algoritmo a utilizar siendo el más adecuado para una red multicapa feed forward backpropagation indica que se debe de elegir un algoritmo de tipo backpropagation. De todos los algoritmos para trabajar con redes neuronales el más adecuado para este tipo es el algoritmo de Levenberg-Marquardt siendo el más rápido respecto las demás opciones disponibles [8]. Este algoritmo mezcla el algoritmo de gradiente descendiente y el Gauss-Newton mediante el proceso de entrenamiento.

Para normalizar los datos de nuestro problema, ha consistido en dejar los valores entre 0 y 1 y para ello se ha utilizado un método que se conoce como normalización lineal uniforme. Este método de normalización es muy sensible a valores anómalos y esto podría tener efectos negativos a la hora de predicción de nuestra red. La fórmula para conseguir este tipo de normalización es la siguiente donde v' corresponde al valor real de la variable;

$$v' = \frac{v - \min}{\max - \min} \quad (1)$$

También se usó la función seno y coseno para procesar los datos de los días del año y para llegar a ese procesamiento se utilizó las siguientes fórmulas obteniendo valores entre -1 y 1:

$$p' = \sin\left(\left(\frac{2 * \Pi}{365}\right) * p\right) \quad (2)$$

$$q' = \sin\left(\left(\frac{2 * \Pi}{365}\right) * q\right) \quad (3)$$

Se muestra una porción de datos sin normalizar y otra porción con dichos datos normalizados.

T.max	T.min	Viento	Precipitaciones	Consumo	Fecha
17,4	-1,7	10	0	859	02/01/2015
21,3	1	9	0	755	03/01/2015
21,4	0,9	9	0	695	04/01/2015
17,8	0	7	0	664	05/01/2015
13,6	0	6	0	638	06/01/2015
15,3	1,3	9	0	616	07/01/2015
15,7	3,3	9	0	590	08/01/2015
18,1	2,5	12	0	448	09/01/2015
24,1	3,3	10	0	410	10/01/2015
19	1	8	0	426	11/01/2015
17,8	8,6	12	0	452	12/01/2015
19,7	5,4	7	0	412	13/01/2015
19,4	2,7	6	0	427	14/01/2015

Tabla 3.3: Porción datos sin normalizar

T.max	T.min	Viento	Precipitación	Consumo	Fecha Sen	Fecha Cos
0,2608	0	0,24	0	0,28720324	0,01720463	0,99985199
0,3595	0	0,16	0	0,3188229	0,03440417	0,999408
0,4582	0,0375	0,12	0	0,25963686	0,05159352	0,99866817
0,4608	0,0337	0,12	0	0,39347754	0,0687676	0,99763271
0,3696	0,0337	0,04	0	0,35914881	0,08592133	0,99630193
0,2633	0,0337	0	0	0,28070974	0,10304962	0,99467622
0,3063	0,0489	0,12	0	0,29020184	0,1201474	0,99275606
0,3165	0,1247	0,12	0	0,28728596	0,13720962	0,99054203
0,3772	0,0944	0,24	0	0,26199438	0,15423122	0,98803478
0,5291	0,1247	0,16	0	0,23897758	0,17120716	0,98523505
0,4	0,0375	0,08	0	0,23186368	0,18813243	0,98214367
0,3696	0,3255	0,24	0	0,24853172	0,205002	0,97876155
0,4177	0,2042	0,04	0	0,23651667	0,22181089	0,9750897
0,4101	0,1019	0	0	0,24569857	0,23855412	0,9711292
0,2962	0,1626	0,28	0	0,24032178	0,25522673	0,96688123
0,1519	0,1322	0,36	0,137724551	0,25905782	0,27182379	0,96234704
0,1519	0,1322	0,36	0,005988024	0,2416453	0,28834038	0,95752798

Tabla 3.4: Porción datos normalizados

3.1.1. División de los datos

En una red neuronal actúan tres subconjuntos de datos: el % de datos destinados al entrenamiento, el conjunto de validación, y el conjunto de prueba.

El conjunto de entrenamiento calcula la pendiente del gradiente y se recalculan las bias o pesos sinápticos de la red.

El conjunto de datos de validación evalúa el entrenamiento desde el momento que comienza la primera iteración. Su objetivo principal es minimizar el sobreajuste del modelo para que no haya un sobre entrenamiento.

El conjunto de prueba verifica la validez de la red una vez finalizado el entrenamiento. Si el error es parecido al error de validación podría significar que la división o elección de las variables no ha sido el correcto.

3.2. Creación de la red neuronal

El software elegido para realizar este proyecto de predicción de consumo eléctrico en el municipio de Canena ha sido el Matlab R2017a [9].

Matlab es capaz de crear un modelo de red neuronal bastante sencillo si se utiliza algunas herramientas de ayuda de las que dispone el programa como nnstart el cual despliega un menú con varios ejemplos (nftool, nprtool, nctool, ntstool).




Figura 3.3: Menú de Matlab con comando nnstart

La realización de redes neuronales con Matlab es gracias a que dispone de una librería que se llama Neural Network Toolbox con la que se puede crear, entrenar, simular una gran variedad de modelos para diferentes tipos según la solución que se quiera obtener.

En este trabajo fin de grado se ha usado el comando nntool para la creación de la red. Ejecutar el comando nntool muestra la siguiente interfaz de Matlab. Una vez iniciado el programa de matlab nos aparece la ventana de comandos donde insertaremos nntool.

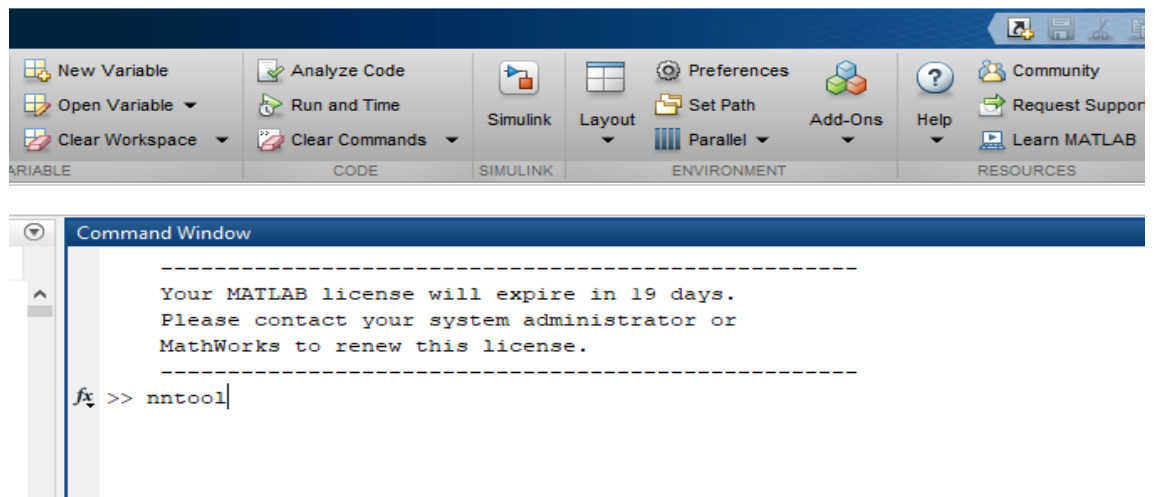


Figura 3.4: Comando nntool

Una vez ejecutado el comando aparece la siguiente interfaz:




Figura 3.5: Interfaz principal del comando nntool

Como se ha visto en la imagen anterior, se visualiza una interfaz donde aparecerán las entradas, las salidas, las salidas obtenidas una vez entrenada la red y el error.

Para importar los valores del workspace o cualquier otro lugar, se pulsa el comando importar dando acceso a la siguiente interfaz.




Figura 3.6: Interfaz de importación

Una vez importados los datos de entrada y salida, seleccionamos la pestaña “New”.





Figura 3.7: Interfaz de creación de red

En esta interfaz hay varios parámetros que se deben de explicar:


- Name: Nombre que se le otorga a la red neuronal que se pretende crear para llevar a cabo el entrenamiento y su consiguiente simulación.
- Network type: El tipo de red elegida para entrenar el perceptrón multicapa debe ser una propagación hacia adelante y la mejor para esta situación es feed-forward backpropagation.
- Input data: Se seleccionan los datos que se requieren como entrada para llevar a cabo el entrenamiento. El fichero hace referencia a la temperatura máxima, temperatura mínima, precipitaciones y la fecha.



	1	2	3	4
1	0.2608	0.3595	0.4582	0.4608
2	0	0	0.0375	0.0337
3	0	0	0	0
4	0	0.0027	0.0055	0.0082

Figura 3.8: Muestra datos de entrada normalizados

- Target data: Se seleccionan los datos de la base de datos con los que se quiere llevar a cabo el entrenamiento. Hay una única salida que representa el consumo de energía diario.



	1	2	3	4
1	0.2872	0.3188	0.2596	0.3935

Figura 3.9: Muestra datos de salida normalizados

- Training function: La función elegida es TRAINLM. Esta función se refiere al logaritmo de entrenamiento de Levenberg-Marquardt, siendo el mejor para este tipo de redes, pero con el consiguiente problema de que requiere un gran uso de memoria.

- Adaption learning function: La función elegida es LEARNNGDM. Utiliza el gradiente descendiente con momentum para el aprendizaje de los pesos, lo que acelera la convergencia.
- Performance function: La función elegida es MSE. Calcula el error cuadrático medio entre la salida de la red y la salida deseada.
- Number of layers: Es el número de capas que forman la red neuronal. La capa número uno es la capa de salida por lo que el mínimo número de capas para la creación de una red neuronal es uno. En este caso se ha optado por la opción de dos capas formando la red con una capa de salida y una capa oculta ocasionando la mayor predicción posible.
- Properties for layer 1: En las propiedades de la capa uno se selecciona el número de neuronas de las que estará formada la red. En este caso se ha optado por la opción de 8 neuronas ya que aportaba una mejor solución al problema en cuestión y esto ha sido verificado después de probar diferentes números de capas y neuronas. Además, la función de activación o transferencia que mejor se ha acoplado al sistema es la función tangencial hiperbólica.
- Properties for layer 2: En las propiedades de la segunda capa no se puede elegir el número de neuronas porque pertenece a la capa de salida. La función de activación ha sido la función pureline.

3.3. Entrenamiento de la red

Una vez creada la red, habrá que realizar su entrenamiento.




Figura 3.10: Visualización de la red

Aunque ya estén insertados las entradas y las salidas cuando se creó la red, se debe de volver a seleccionar en la pestaña training info y además se podrá cambiar el nombre de los resultados del entrenamiento de la salida como del error.





Figura 3.11: Inserción de entradas y salidas

Se podrán variar parámetros referentes al algoritmo de entrenamiento de Levenberg-Marquart:

- Epochs: El código que permite controlar el número de épocas (iteraciones de entrenamiento).
- Time: Permite introducir el tiempo máximo en segundos que se desea que dure el entrenamiento. La abreviación "Inf" hace referencia a la palabra infinito.
- Goal: Es el máximo error permitido para finalizar el entrenamiento, por defecto está impuesto en cero, pero es bastante improbable llegar a ese valor.

- Min_grad: Es el gradiente mínimo que debe alcanzar para detener el entrenamiento



Training Parameters			
showWindow	true	mu	0.01
showCommandLine	false	mu_dec	0.1
show	25	mu_inc	10
epochs	10000	mu_max	10000000000
time	Inf		
goal	0		
min_grad	1e-07		
max_fail	6		

Train Network

Figura 3.12: Parámetros entrenamiento

Una vez terminado de variar los parámetros, la red puede comenzar a entrenarse pulsando Train Network y aparecerá la siguiente interfaz de entrenamiento.




Figura 3.13: Visualización del entrenamiento

Una vez finalizado el entrenamiento se puede observar que hay 6 iteraciones, transcurrido los cuatro segundos, donde el error de validación no ha disminuido dando por finalizado el entrenamiento.

Se pueden dibujar tres gráficas:

- Performance: Muestra el error cuadrático medio en función del número de iteraciones que para este caso fueron cero iteraciones con un Mean Squared Error (mse) de 0,0068019.




Figura 3.14: Mean Squared Error (mse) vs número de iteraciones

En la gráfica siguiente se muestra el gradiente, μ y la validación de fallo en función de las iteraciones.




Figura 3.15: Val fail, Mu y Gradient vs iteraciones

En la siguiente gráfica se observa la recta de regresión lineal durante el entrenamiento, la validación y el testeo. Cuanto mayor sea la aproximación a uno, la correlación tendrá mayor dependencia entre salida y la salida deseada. Esto quiere decir que la red estará obteniendo una mayor predicción cuanto más cercano a uno esté el coeficiente de correlación R. Se puede ver en la siguiente figura:




Figura 3.16: Regresión lineal

Si dos neuronas tienen exactamente los mismos pesos, siempre tendrán el mismo gradiente por lo que no serán capaces de aprender características diferentes aunque en este caso directamente ese peso no influirá en la red al tener los dos pesos el mismo valor.

Se rompe la simetría inicializando los pesos con valores aleatorios pequeños [10]. En este caso debido al comando para crear la red, inicializar los pesos se realiza en la subpestaña de la interfaz de entrenamiento “Reinitialize Weights” y se pulsa sobre Initialize Weights para obtener los nuevos valores de los pesos sinápticos.




Figura 3.17: Inicializar pesos

3.3.1 Limitaciones y precauciones con Levenberg-Marquardt

Utilizar este algoritmo tiene una serie de limitaciones y precauciones ya que únicamente es bueno para redes pequeñas y medianas. En el momento que la red sea de una estructura bastante amplia se deberá de optar por otros algoritmos como son `trainscg` o `trainrp`.

3.3.2 Generalizaciones

El perceptrón multicapa tiende a dar una respuesta razonable cuando se aportan entradas que no habían sido entrenadas por la red. Esto se debe a la nueva entrada que conduce a una salida más exacta. Por ello, es posible entrenar una red con valores representativos de entrada y salida y obtener buenos resultados debido a la buena generalización de la red [9].

4. RESULTADOS

Una vez entrenado las diferentes redes con distintos números de neurona, se expone gráficamente el resultado de cada una de ellas para las redes neuronales con una, dos, cuatro, seis, ocho, diez, quince, treinta, sesenta, ciento veinte, dos cientos cuarenta, quinientos y mil neuronas. De esta manera se puede sacar una comparativa y decidir que red después de ser entrenada es la mejor para nuestro sistema y ya se procederá a la simulación de la misma con los nuevos valores de entrada.

Resultados para red neuronal con una neurona




Figura 4.1.a: Entrenamiento 1 neurona




Figura 4.1.b: Entrenamiento 1 neurona




Figura 4.1.c: Entrenamiento 1 neurona

Resultados para red neuronal con dos neuronas

Create Network or Data

Network **Data**

Name
network2neuronas

Network Properties

Network Type: Feed-forward backprop

Input data: ENTRADAS2

Target data: TARGETS2

Training function: TRAINLM

Adaption learning function: LEARNGDM

Performance function: MSE

Number of layers: 2

Properties for: Layer 1

Number of neurons: 2

Transfer Function: TANSIG

View Restore Defaults

Help Create Close

Figura 4.2.a: Entrenamiento 2 neuronas




Figura 4.2.b: Entrenamiento 2 neuronas




Figura 4.2.c: Entrenamiento 2 neuronas




Figura 4.2.d: Entrenamiento 2 neuronas

Resultados para red neuronal con cuatro neuronas




Figura 4.3.a: Entrenamiento 4 neuronas




Figura 4.3.b: Entrenamiento 4 neuronas




Figura 4.3.c: Entrenamiento 4 neuronas

Resultados para red neuronal con seis neuronas




Figura 4.4.a: Entrenamiento 6 neuronas




Figura 4.4.b: Entrenamiento 6 neuronas




Figura 4.4.c: Entrenamiento 6 neuronas

Resultados para red neuronal con ocho neuronas




Figura 4.5.a: Entrenamiento 8 neuronas




Figura 4.5.b: Entrenamiento 8 neuronas




Figura 4.5.c: Entrenamiento 8 neuronas

Resultados para red neuronal con diez neuronas




Figura 4.6.a: Entrenamiento 10 neuronas




Figura 4.6.b: Entrenamiento 10 neuronas




Figura 4.6.c: Entrenamiento 10 neuronas

Resultados para red neuronal con quince neuronas




Figura 4.7.a: Entrenamiento 15 neuronas




Figura 4.7.b: Entrenamiento 15 neuronas




Figura 4.7.c: Entrenamiento 15 neuronas

Resultados para red neuronal con treinta neuronas




Figura 4.8.a: Entrenamiento 30 neuronas




Figura 4.8.b: Entrenamiento 30 neuronas




Figura 4.8.c: Entrenamiento 30 neuronas

Resultados para red neuronal con sesenta neuronas




Figura 4.9.a: Entrenamiento 60 neuronas




Figura 4.9.b: Entrenamiento 60 neuronas




Figura 4.9.c: Entrenamiento 60 neuronas

Resultados para red neuronal con ciento veinte neuronas




Figura 4.10.a: Entrenamiento 120 neuronas




Figura 4.10.b: Entrenamiento 120 neuronas




Figura 4.10.c: Entrenamiento 120 neuronas

Resultados para red neuronal con doscientos cuarenta neuronas




Figura 4.11.a: Entrenamiento 240 neuronas




Figura 4.11.b: Entrenamiento 240 neuronas




Figura 4.11.c: Entrenamiento 240 neuronas

Resultados para red neuronal con quinientas neuronas




Figura 4.12.a: Entrenamiento 500 neuronas




Figura 4.12.b: Entrenamiento 500 neuronas




Figura 4.12.c: Entrenamiento 500 neuronas

Resultados para red neuronal con mil neuronas




Figura 4.13.a: Entrenamiento 1000 neuronas




Figura 4.13.b: Entrenamiento 1000 neuronas




Figura 4.13.c: Entrenamiento 1000 neuronas

Se puede observar que la red cuando se le ha aumentado con un valor de neuronas superior a 240, su regresión lineal ha decaído drásticamente y esto es debido a que le cuesta generalizar al haber una gran cantidad de neuronas.

Después de haber creado, entrenado y analizado qué tipo de red es la mejor, con cuantas capas ocultas y establecido el número de neuronas, se han obtenido las siguientes predicciones y sus respectivos errores entre los targets y salidas obtenidas de los diferentes entrenamientos con los diferentes números de neuronas como se muestra en la figura de a continuación:

Nº Neuronas	Salidas	Entradas	%Error_MAX	%Error_MIN	%Error_PROMEDIO
1	365	365	41,32%	0,00%	12,11%
2	365	365	40,85%	0,10%	8,98%
4	365	365	31,64%	0,06%	7,68%
6	365	365	33,85%	0,02%	7,63%
8	365	365	31,37%	0,00%	7,30%
10	365	365	35,11%	0,00%	7,08%
15	365	365	31,08%	0,00%	6,81%
30	365	365	36,20%	0,04%	7,16%
60	365	365	36,51%	0,00%	6,88%
120	365	365	32,10%	0,02%	5,24%
240	365	365	72,71%	0,00%	5,19%
500	365	365	115,85%	0,00%	6,22%
1000	365	365	225,20%	0,01%	8,68%

Tabla 4.1: Comparativa Redes

En la tabla anterior se puede observar que con quinientas y mil neuronas se está obteniendo un error promedio de 6,22% y 8,68% respectivamente y con un error mínimo de valor casi del 0%. Esto no quiere decir que estas redes sean adecuadas, ya que la regresión lineal de ambas es de 0,56748 para la red con 500 neuronas y de 0,46941 con 1000 neuronas y siempre se busca que esta regresión sea lo más próxima al valor unidad. Además, habría que destacar que ambas tienen un error máximo de 115,85% y 225,20% dando lugar a unos picos de error demasiado elevados, traducándose como una pérdida de dinero por parte de la distribuidora a la hora de realizar las predicciones de demanda.

Una vez observado la comparativa de los diferentes entrenamientos variando el número de neuronas, se opta por realizar un entrenamiento con 344 muestras de entrada para las cinco variables que intervienen y 344 muestras para la única salida que tiene la red neuronal. Para ello, se realizarán estos con 8 y 240 neuronas ya que con 240 se obtiene 5,19% de error promedio pero con un pico máximo de error de 72,71% para observar como difiere este pico en los resultados obtenidos tras la simulación.

Por lo tanto se muestran las gráficas referidas a la red neuronal de 240 neuronas a continuación.




Figura 4.14.a: Entrenamiento 240 neuronas simulación




Figura 4.14.b: Entrenamiento 240 neuronas simulación




Figura 4.14.c: Entrenamiento 240 neuronas simulación

A continuación se muestran las gráficas del entrenamiento para la red con 8 neuronas:




Figura 4.15.a: Entrenamiento 8 neuronas simulación

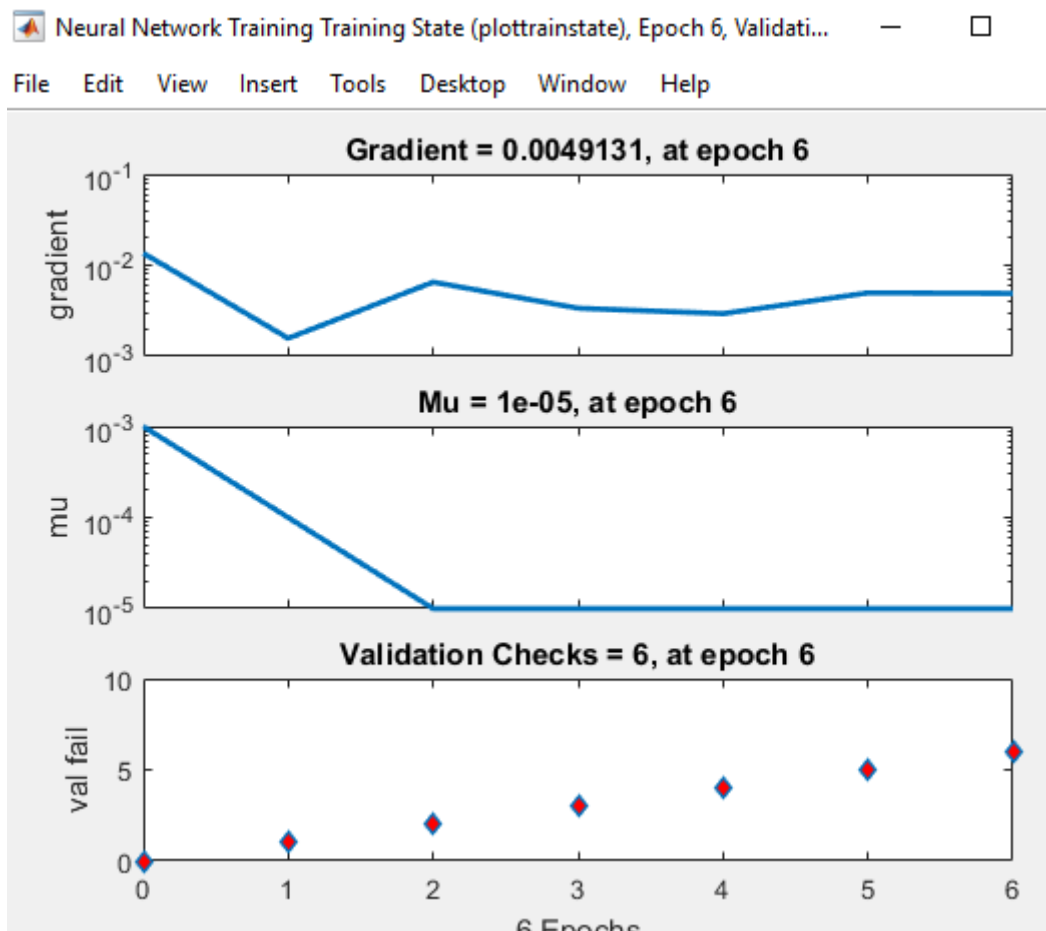


Figura 4.15.b: Entrenamiento 8 neuronas simulación




Figura 4.15.c: Entrenamiento 8 neuronas simulación

Se han obtenido los siguientes resultados después de realizar el entrenamiento de cada una de las dos topologías seleccionadas:

Nº Neuronas	Salidas	Entradas Simulación	%Error_MAX	%Error_MIN	%Error_PROMEDIO
8	334	31	33,29%	0,69%	9,07%
240	334	31	84,08%	3,53%	36,68%

Tabla 4.2: Comparativa simulación

En la figura anterior se puede observar que la mejor opción es con 8 neuronas un error mínimo de casi 0% y un error promedio de 9,07 cuyo valor es bastante

aceptable ya que para el entrenamiento se usaron los valores que corresponden a los meses de Febrero hasta Diciembre y la red ha sido capaz de generalizar y adaptar la red para los nuevos valores de entrada del mes Enero. También se puede confirmar que tener un pico en el error máximo conlleva a una mala solución.

Se muestran valores obtenidos con la red neuronal de 8 neuronas para las 31 entradas que corresponden a los días del mes de Enero de 2015:

SALIDA DESEADA	SALIDAS OBTENIDAS	ERROR %
0,287203243	0,042509545	24,47%
0,318822897	0,055388802	26,34%
0,25963686	0,057162212	20,25%
0,393477542	0,060544373	33,29%
0,359148813	0,078248506	28,09%
0,280709736	0,103847408	17,69%
0,290201836	0,118743359	17,15%
0,287285962	0,159727488	12,76%
0,261994375	0,153088963	10,89%
0,238977583	0,126103497	11,29%
0,231863678	0,155157758	7,67%
0,248531723	0,207867468	4,07%
0,236516668	0,228634314	0,79%
0,245698569	0,224134895	2,16%
0,24032178	0,265537515	2,52%
0,259057821	0,23994413	1,91%
0,241645297	0,278210661	3,66%
0,291215154	0,248724184	4,25%
0,29799818	0,282475874	1,55%
0,283232691	0,301712519	1,85%
0,335594342	0,276372007	5,92%
0,299983456	0,306912453	0,69%
0,261311936	0,312224842	5,09%
0,259264621	0,31257396	5,33%
0,24534701	0,312209501	6,69%
0,253164033	0,303999079	5,08%
0,256886426	0,304685483	4,78%
0,251695756	0,290316952	3,86%
0,276553065	0,290398884	1,38%
0,295020266	0,222102719	7,29%
0,251819836	0,27536782	2,35%

Tabla 4.3: Errores obtenidos con 8 neuronas

El error máximo obtenido ha sido de 33,29% y el error mínimo obtenido ha sido de 0,69% (lo que quiere decir que nuestra red ha sido capaz de predecir el valor).

El valor promedio del error ha sido de 9,07% lo que quiere decir que con un valor de correlación R en la regresión lineal superior a 0.95591 se obtienen predicciones bastante decentes.

5. CONCLUSIONES

En el presente trabajo fin de grado se creó una red neuronal tipo feed-forward backpropagation en la cual se obtuvo un error promedio de 9,07% el cual a mi parecer es bastante bueno puesto que las variables de entrada eran cinco pero probablemente serían las que más impacto podrían generar sobre la red neuronal con 365 datos por variable.

Otra variable de la que se obtuvo información del municipio de Canena fue el viento, pero se anuló dicha entrada ya que no aportaba una mejora a la hora de obtener predicciones siendo la variable más importante la temperatura. Para conseguir los datos climatológicos fue algo tedioso debido a la dificultad de encontrar una base de datos del municipio de Canena de forma gratuita y en los cuales una vez obtenidos, presentaban algunos errores en ciertas fechas con las que se subsanaron con los valores del día anterior lo que ha podido repercutir en la solución obtenida. Se barajó una alternativa a la hora de obtener los datos climatológicos con el programa PVsyst que incorpora la base de datos del programa Meteonorm del cual se puede obtener infinidad de variables. Se desechó esta opción porque al ser una versión de prueba, el rango de fecha no era el que se necesitaba ya que solo se dispone de datos hasta el año 2010.

Como se ha comprobado, no existe ningún método específico para determinar de una manera precisa los parámetros de la red neuronal quedando la determinación de estos parámetros expuestos a los criterios de prueba error.

Una red neuronal artificial requiere una menor experiencia con respecto a otros métodos de predicción, ya que es el propio algoritmo de aprendizaje el que determina cuales son los pesos sinápticos, a partir de los datos históricos. Sin embargo, sí que es necesario tener un buen conocimiento de las redes neuronales (el cuál yo no tenía al inicio de este trabajo).

A la hora de elegir las capas, neuronas, etc había leído varias versiones del número de neuronas necesario en la capa oculta siendo este no superior al doble del número de entradas siendo en este caso 10 y como se ha podido comprobar en la capa oculta se optó por tener 8 neuronas en la simulación que se obtuvieron mejores resultados y 240 neuronas en las que se obtuvieron unos resultados bastante

pésimos ya que puede llevar a un sobreajuste de la red y no haya sido capaz de generalizar correctamente.

En definitiva, es imposible saber (al menos de momento) la relación entre los pesos con las variables y como obtiene una o peor solución.

6. BIBLIOGRAFÍA Y REFERENCIAS

- [1] Cano, Antonio. Contenido de la asignatura Centrales Eléctricas II. Generación de energía eléctrica: Bloque I. Universidad de Jaén.
- [2] Gutiérrez Moya, E. Tesis Doctoral: La demanda de residencial de energía eléctrica en la Comunidad Autónoma de Andalucía: un análisis cuantitativo.
- [3] Jurado, Francisco. Contenido de la asignatura Sistemas Eléctricos de Potencia. Conceptos generales: Bloque I. Universidad de Jaén.
- [4] René Santa Cruz R. & Camila Corrêa. Intermittent demand forecasting with time series methods and artificial neural networks: A case study. Dyna, Universidad Nacional De Colombia, September 14, 2017.
- [5] Matich, D. J. (2001). Tema: Redes Neuronales: Conceptos Básicos y Aplicaciones. Rosario: Universidad Tecnológica Nacional.
- [6] HILERA GONZÁLEZ, JOSÉ RAMÓN. Redes neuronales artificiales: fundamentos, modelos y aplicaciones. Madrid: Ra-ma, D.L. 1995.
- [7] Martin T. Hagan, Howard B. Demuth, Mark H. Beale & Orlando de Jesús: Neural Network Design Martin Hagan, 2nd edition, 2014.
- [8] Yu, H., & M. Wilamowski, B. (2010). Levenberg-Marquardt Training. Auburn.
- [9] Hudson Beale, M., T. Hagan, M., & B. Demuth, H. (2010). Neural Network Toolbox 7. User's Guide.
- [10] Fernando Berzal: Redes Neuronales & Deep Learning EUG - Editorial Universidad de Granada, 2018.
- [11] Apuntes de Redes Neuronales. Pedro Larranaga, Inaki Inza, Abdelmalik Moujahid. Departamento de Ciencias de la Computación e Inteligencia Artificial. Universidad del País Vasco – Euskal Herriko Unibertsitatea.

[12] Rosenblatt F. (1961). "Principles of neurodynamics. Perceptrons and the theory of brain mechanisms" (No. VG-1196-G-8). CORNELL AERONAUTICAL LAB INC BUFFALO NY.

[13] Salas, Jesús San Miguel. Trabajo fin de master. Desarrollo con matlab de una red neuronal para estimar la demanda de energía eléctrica. Universidad de Valladolid.