



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Industrial

Diseño de un modelo de predicción de demanda eléctrica
en España utilizando variables meteorológicas

Trabajo Fin de Grado

Grado en Ingeniería de la Energía

AUTOR/A: Alvarado Gozaine, Willman José

Tutor/a: Trull Domínguez, Óscar

CURSO ACADÉMICO: 2021/2022



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



ESCUELA TÉCNICA
SUPERIOR INGENIERÍA
INDUSTRIAL VALENCIA

Curso Académico:

AGRADECIMIENTOS

Muchas gracias:

A mi familia por apoyarme siempre en mis decisiones, especialmente a mi padre por ser una gran guía e inspiración y a mi mamá por todos los consejos, ánimos y ayudas a lo largo de mi vida.

A mis amigos de la carrera, especialmente a los del grupo bravosygeniales, quienes me hicieron tremendamente amenos todos estos años durante los distintos cursos y viajes.

A mis amigos de Castellón, por todo el apoyo durante este final del grado, especialmente a Xena y Nabil por su gran apoyo durante el desarrollo de TFG y a Guzmán por toda la ayuda y apoyo en estos últimos años de la carrera.

A mis profesores de la carrera, por toda la enseñanza y aprendizaje durante estos años, especialmente a mi tutor por la atención prestada en los últimos días del proyecto pese a lo justo del tiempo.

RESUMEN

En el presente trabajo final de grado se pretende desarrollar un modelo de predicción de la demanda eléctrica peninsular utilizando redes neuronales basándose en condiciones meteorológicas. La importancia de la previsión energética hoy en día es fundamental de cara a los agentes participantes en el mercado eléctrico ya sea para mejorar su gestión u optimizar los movimientos económicos que se hacen entorno a ello.

Durante el desarrollo del documento se realiza una explicación del mercado eléctrico peninsular, su funcionamiento, agentes que intervienen y horizontes de predicción sobre los cuales trabajar (corto, medio y largo plazo). Seguido de esto se hace un repaso sobre la predicción energética, explicando los diferentes métodos que se pueden utilizar para la realización de distintos modelos y citando los distintos trabajos que se han realizado entorno a ello, siguiendo distintas metodologías, haciendo un enfoque en los trabajos realizados mediante redes neuronales y también trabajos basados en el modelado de las condiciones meteorológicas para la predicción de la demanda.

Para el desarrollo del modelo se analizarán las variables necesarias para poder ejecutar dicho trabajo, haciendo un estudio de las variables meteorológicas que afectan la demanda, escogiendo las de mayor peso a la hora de realizar un modelo predictivo, así como otros factores que afectan la demanda eléctrica diaria. Una vez seleccionadas las variables, se explicará el funcionamiento de la red neuronal, su arquitectura y entrenamiento.

Finalmente se construirá el modelo que generará las predicciones y se estudiarán los resultados obtenidos, comparándolos con la demanda real, analizando el error cometido por la red, y comparando distintos periodos de tiempo en los que se realizaron las predicciones. Tras esto se hará un análisis final de los resultados obtenidos, puntualizando los errores del modelo y proponiendo posibles medidas de mejora de cara a trabajos futuros.

Palabras Clave: Predicción, electricidad, demanda, meteorológicas.

RESUM

En el present treball final de grau es pretén desenvolupar un model de predicció de la demanda elèctrica peninsular utilitzant xarxes neuronals basant-se en condicions meteorològiques. La importància de la previsió energètica hui dia és fonamental de cara als agents participants en el mercat elèctric ja siga per a millorar la seua gestió o optimitzar els moviments econòmics que es fan entorn a l'assumpte.

Durant el desenvolupament del document s'explica com funciona el mercat elèctric peninsular, els agents que intervenen i els horitzons de predicció sobre els quals treballar (curt, mitjà i llarg termini). Seguit d'això es fa un repàs de la predicció energètica, explicant els diferents mètodes que es poden utilitzar per a la realització de diversos models i indicant els diversos treballs acadèmics que s'han realitzat entorn a la temàtica, seguint diferents metodologies, fent un enfocament dels mateixos realitzats mitjançant xarxes neuronals i també treballs acadèmics basats en el procés de generar un model de les condicions meteorològiques per al seu ús en la predicció de la demanda energètica.

Per al desenvolupament del model s'analitzaran les variables necessàries per a poder executar aquesta comesa. Duent a terme un estudi de les variables meteorològiques que afecten la demanda, triant les de major rellevància a l'hora de realitzar un model predictiu. Així com altres factors que afecten la demanda elèctrica diària. Una vegada seleccionades les variables, s'explicarà el funcionament de la xarxa neuronal, la seua arquitectura i entrenament.

Finalment es construirà el model que generarà les prediccions i s'estudiaren els resultats obtinguts, comparant-los amb la demanda real, analitzant l'error comés per la xarxa, i comparant diferents períodes de temps en els quals es van realitzar les prediccions. Després es farà una anàlisi final dels resultats obtinguts, puntualitzant els errors del model i proposant possibles mesures de millora de cara a treballs futurs.

Paraules clau: Predicció, electricitat, demanda, meteorològiques

ABSTRACT

The aim of this final degree project is to develop a model for forecasting peninsular electricity demand using neural networks based on meteorological conditions. The importance of energy forecasting nowadays is fundamental for the agents participating in the electricity market, whether to improve its management or to optimize the economic movements that take place around it.

During the development of the document, it is explained how the peninsular electricity market works, the agents involved and the forecasting horizons on which to work (short, medium and long term). This is followed by a review of energy forecasting, explaining the different methods that can be used to make various models and indicating the various academic studies that have been carried out in this area, following different methodologies, focusing on these using neural networks and also academic studies based on the process of generating a model of weather conditions for use in predicting energy demand.

In order to develop the model, the variables necessary to fulfil this task will be analyzed. A study of the meteorological variables that affect demand will be carried out, choosing those of greatest relevance when making a predictive model. As well as other factors that affect daily electricity demand. Once the variables have been selected, the operation of the neural network, its architecture and training will be explained.

Lastly, the model that will generate the predictions will be built and the results obtained will be studied, comparing them with the real demand, analyzing the error committed by the network, and comparing different time periods in which the predictions were made. After this, a final analysis of the results obtained will be made, pointing out the errors of the model and proposing possible improvement measures for future work.

Keywords: Forecasting, electricity, demand, meteorological.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

DOCUMENTOS CONTENIDOS EN EL TFG

- Memoria
- Presupuesto

ÍNDICE DE LA MEMORIA

Índice de figuras	9
1. Introducción	11
1.1. Antecedentes	11
1.2. Motivación y justificación	11
1.3. Objetivo	11
1.4. Organización del trabajo	12
2. Estado del arte	13
2.1. El mercado energético	13
2.1.1. Introducción	13
2.1.2. MIBEL	13
2.1.3. Agentes participantes en el mercado	14
2.1.4. Mercados que componen el MIBEL	15
2.1.5. Mercado de futuros	16
2.1.6. Mercado diario	17
2.1.7. Casación de la energía	17
2.1.8. Mercado intradiario	20
2.2. Métodos de previsión energética	21
2.2.1. Introducción	21
2.2.2. Importancia de la previsión de la demanda	21
2.2.3. Clasificación de los métodos de previsión	21
2.2.4. Modelos de previsión energética	22
2.2.5. Modelización de la temperatura para el estudio de la demanda	23
3. Metodología	25
3.1. Introducción	25
3.2. Identificación de variables	26
3.2.1. Introducción	26
3.2.2. Variables meteorológicas	26
3.2.3. Demanda previa	28
3.2.4. Días de la semana	28

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

3.2.5. Festivos	29
3.3. Redes Neuronales	29
3.3.1. Introducción.....	29
3.3.2. Descripción y funcionamiento de las redes neuronales artificiales	29
3.3.3. Descripción del ajuste y aprendizaje de la red	31
4. Caso de aplicación.....	32
4.1. Introducción.....	32
4.2. Entrenamiento de la red.....	32
5. Resultados.....	36
5.1. Previsión para el año 2022 (01/01/2022 al 31/07/2022)	36
5.1.1. Comparativa de la previsión y la carga real, error y error porcentual (todo el año):	36
5.1.2. Predicciones mes de enero:.....	38
5.1.3. Predicciones mes de febrero:	39
5.1.4. Predicciones mes de marzo:	40
5.1.5. Predicciones mes de abril:	41
5.1.6. Predicciones mes de mayo:	42
5.1.7. Predicciones mes de junio:	43
5.1.8. Predicciones mes de julio:	44
5.2. Previsiones mensuales.....	45
6. Conclusiones	47
Bibliografía	49
Presupuesto	53

ÍNDICE FIGURAS:

Figura 1. Mercados regionales europeos de la energía.	13
Figura 2. Distribución del mercado de la energía.	15
Figura 3. Fase casación simple. Fuente: apuntes mercados eléctricos.	18
Figura 4. Fase casación compleja. Fuente: apuntes mercados eléctricos.	18
Figura 5. Fase transacciones transfronterizas (España-Francia)	19
Figura 6. Mercado intradiario.	20
Figura 7. Diagrama de bloque del desarrollo del modelo.	25
Figura 8. Mapa de temperatura peninsular	26
Figura 9. Demanda energética real, año 2022.....	28
Figura 10. Arquitectura red neuronal.	29
Figura 11. Función sigmoide.	30
Figura 12. Matriz de entrada a la red.	32
Figura 13. Matriz de salida.....	33
Figura 14. Errores obtenidos de diferente número de neuronas en la red.....	33
Figura 15. Arquitectura del modelo propuesto.	34
Figura 16. Comparación demanda real- demanda prevista.	36
Figura 17. Error absoluto a lo largo del año de previsión.....	37
Figura 18. Error absoluto porcentual a lo largo del año de la previsión.....	37
Figura 19. Comparativa demanda real-demanda prevista, mes de enero.	38
Figura 20. Error absoluto porcentual, mes de enero.....	38
Figura 21. Comparativa demanda real-demanda prevista, mes de febrero.	39
Figura 22. Error absoluto porcentual, febrero.....	39
Figura 23. Comparativa demanda real-demanda prevista, mes de marzo.	40
Figura 24. Error absoluto porcentual, marzo.....	40
Figura 25. Comparativa demanda real-demanda prevista, mes de abril.	41
Figura 26. Error absoluto porcentual, abril.....	41
Figura 27. Comparativa demanda real-demanda prevista, mes de mayo.....	42
Figura 28. Error absoluto porcentual, mayo.....	42
Figura 29. Comparativa demanda real-demanda prevista, mes de junio.	43

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Figura 30. Error absoluto porcentual, junio.....	43
Figura 31. Comparativa demanda real-demanda prevista, mes de julio.....	44
Figura 32. Error absoluto porcentual, julio.....	44
Figura 33. Error absoluto medio de cada mes.	45
Figura 34. Error absoluto medio porcentual cada mes.	45

CAPÍTULO 1. INTRODUCCIÓN

1.1. Antecedentes:

Los mercados energéticos han alcanzado una importancia fundamental para la economía ya que mueven cantidades enormes de dinero tanto en la parte de la generación (agentes vendedores del mercado) como en la parte de las comercializadoras y grandes consumidores (agentes compradores del mercado). La capacidad de predecir la demanda eléctrica es fundamental para poder hacer frente a la creciente complejidad de la gestión energética, innovando continuamente los distintos métodos de predicción, de manera que sea más sencillo coordinar las distintas fuentes de generación, así como poder optimizar la compra de energía en el mercado, minimizando las pérdidas de los agentes compradores.

Para el caso de España y Portugal, su actividad se desarrolla en el Mercado Ibérico de la Electricidad (MIBEL), el cual está formado por un conjunto de mercados organizados y no organizados (quienes conforman el mercado mayorista, donde se mueven grandes cantidades de energía) donde se realizan transacciones y contratos de energía eléctrica. Dichos contratos se negocian para distintos periodos de tiempo (mercados de futuros, mercado diario, mercado intradiario) y distintas cantidades de energía. Es en este punto donde radica la importancia de los métodos de predicción de la demanda, ya que el consumo de la energía es instantáneo puesto que esta no se puede almacenar, con lo que poder predecir con la mayor exactitud posible dicha demanda supone una ventaja enorme a la hora de intervenir en dicho mercado.

1.2. Motivación y justificación:

La razón del enfoque de este trabajo se debe a la fuerte relación que se puede apreciar entre las condiciones meteorológicas y la demanda energética, ejemplo de esto pueden ser la ola de frío de enero de 2021 (conocida como filomena), en la que los precios de la electricidad se dispararon, o las fuertes olas de calor producidas durante el verano los últimos dos años.

Por otro lado, la creciente utilización de las energías renovables en la producción energética también juega un papel importante, pues estas están fuertemente relacionadas con las condiciones climatológicas, y dependiendo de estas condiciones para un día en concreto, las energías renovables tendrán un papel mayor o menor en la producción de ese día, cambiando radicalmente el precio de esta para esa sesión del mercado.

1.3. Objetivo:

El objetivo del presente trabajo se centra el desarrollo de un modelo de previsión de la demanda energética peninsular utilizando condiciones climatológicas del territorio español, para ello se empleará y desarrollará un modelo basado en redes neuronales artificiales (RNA), del cual se extraerán las previsiones, se compararán con la demanda real, estudiando el error cometido por la red y se expondrá las conclusiones de dicho método tras la puesta en marcha y prueba de este.

1.4. Organización del trabajo:

El trabajo desarrollado se distribuirá en 6 capítulos detallados a continuación:

1. Introducción: en este capítulo se describirán los objetivos que se buscan alcanzar con el presente trabajo, así como los antecedentes y la justificación de este.
2. Estado del arte: aquí se describirá el funcionamiento del mercado eléctrico para el caso peninsular, detallando los distintos mercados que lo componen, el proceso de casación de la energía, los agentes que intervienen en este, etc. A continuación, se explicarán los diversos métodos de previsión de la demanda utilizados en la actualidad y la relevancia que va obteniendo con el tiempo el uso de redes neuronales artificiales (RNA).
3. Metodología: este apartado se centrará por una parte en identificar las variables a utilizar para el desarrollo de la RNA empleada en el trabajo, y por otra parte se profundizará en la arquitectura dicha RNA, explicando el desarrollo teórico que se sigue para poder llegar a las previsiones obtenidas de esta y los errores que presentan dichas previsiones.
4. Desarrollo de la red: una vez identificadas las variables de entrada y explicado el desarrollo teórico de la red, se procederá a generar el modelo en el cual se centrará el estudio del trabajo, explicando su funcionamiento.
5. Caso de aplicación: tras la preparación del modelo, se dispondrá a probar lo haciendo previsiones para un periodo de tiempo conocido, para comprobar la fiabilidad de dicho modelo y poder elegir la variable óptima para la realización final del proyecto.
6. Conclusiones: finalmente, tras la puesta a prueba del modelo obtenido y la comprobación y estudio de los resultados, se procederá a exponer las conclusiones obtenidas sobre el proyecto identificando fallos, buscando posibles puntos de mejora y dejando la reflexión final del TFG.

CAPÍTULO 2: ESTADO DEL ARTE

2.1. El mercado energético:

2.1.1. Introducción:

En este primer apartado del capítulo se explicará primero el funcionamiento y organización del mercado eléctrico español, centrándonos en el mercado mayorista; mencionando también los diferentes agentes que intervienen en este, tipos de mercados presentes en el MIBEL y finalmente el proceso de casación de la oferta y la demanda en el mercado diario. La mayor parte de la información es extraída de los apuntes de

2.1.2. MIBEL:

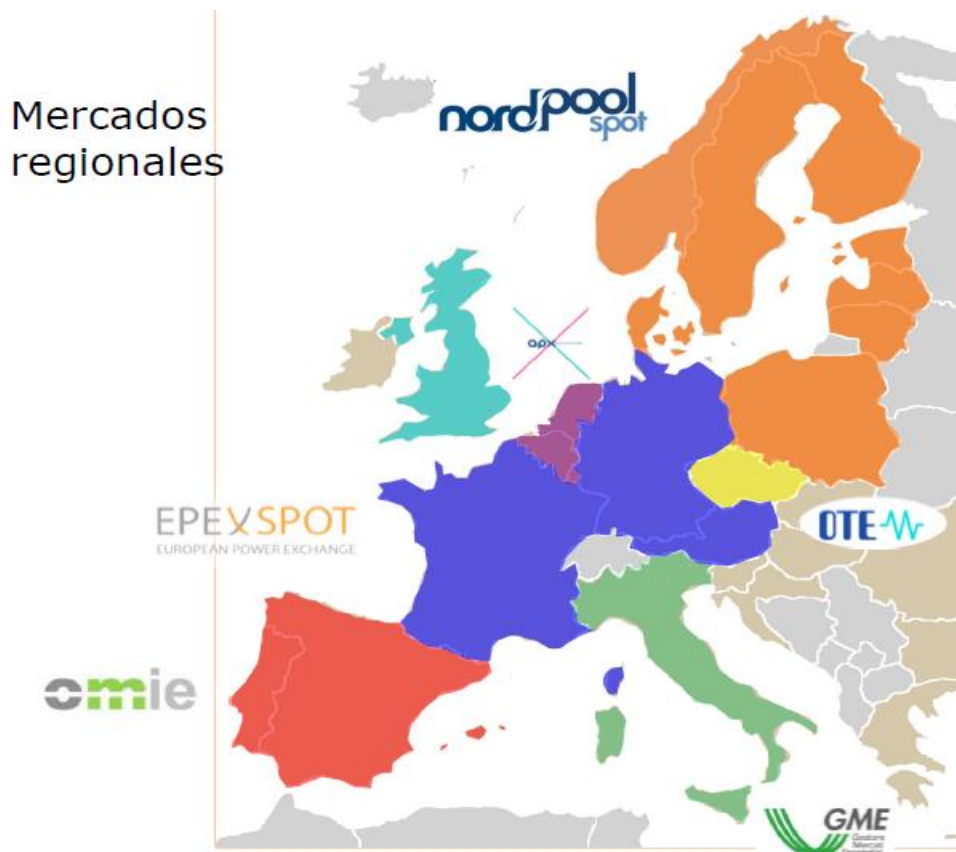


Figura 1. Mercados regionales europeos de la energía. Fuente: apuntes mercados eléctricos

“El Mercado Ibérico de la Electricidad (MIBEL) es el resultado de un proceso de cooperación desarrollado por los gobiernos de España y Portugal con el fin de promover la integración de los sistemas eléctricos de ambos países”. (página MIBEL, <https://www.mibel.com/es/home_es/>). El

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

proceso de creación de este comenzó en 2001 con la firma del protocolo colaboración de ambos países, para después en 2004 en el Acuerdo de Santiago de Compostela establecerse las bases del régimen jurídico que regularía el funcionamiento y comenzar su funcionamiento el 1 de julio de 2007.

Con la creación de este mercado se pretende reforzar la capacidad de interconexión entre España y Portugal, aproximando progresivamente los mecanismos de funcionamientos de los mercados minoristas de dichos países para que la liberación del mercado se realice entre ambos, consiguiendo aumentar las transacciones energéticas entre ellos y logrando una actuación ibérica conjunta entre sus principales grupos energéticos empresariales obteniendo de esta manera precios más competitivos a semejanza de otros mercados regionales europeos.

2.1.3. Agentes participantes en el mercado:

- **Productores de energía eléctrica:** son aquellos que generan la energía eléctrica y se encargan de la construcción, operación y mantenimiento de las centrales de producción tanto en régimen ordinario como régimen especial. Pueden vender su producción tanto en el mercado organizado como a través de contratos bilaterales agentes compradores de electricidad. Para poder actuar en el mercado deben tener al menos una potencia instalada de 1MW, y en caso de tener una potencia inferior a este umbral, deberán intervenir mediante un agente vendedor que presente sus ofertas en el mercado.
- **Comercializadores:** agentes que adquieren la energía eléctrica a los productores, nacionales o internacionales, o a otros comercializadores a través de las redes de distribución y transporte, y la venden a los consumidores u otros comercializadores. También existe un tipo de comercializador denominado “Comercializador de referencia” que vende energía eléctrica a consumidores a tarifa regulada (PVPC)*. Estos agentes pueden intercambiar energía eléctrica con agentes de otros sistemas eléctricos fuera del MIBEL pagando los peajes correspondientes.
- **Consumidores cualificados:** estos agentes se caracterizan por tener un consumo energético bastante relevante, con lo que tienen la capacidad para intervenir directamente en el mercado, ya que tras la eliminación de tarifas en 2008-2009, cualquier consumidor puede adquirir energía eléctrica libremente ya sea adquiriéndola en el mercado, mediante una comercializadora o suscribiendo un contrato bilateral con cualquier productor.
- **Representantes:** Actúan por cuenta de un sujeto del mercado, ya sea en su nombre o en nombre propio. Existe un tipo de representante facultado especialmente para productores en régimen especial, denominado Agente Vendedor, que puede agrupar ofertas para que exista una posición final neta de todos sus representados frente al mercado

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

2.1.4. Mercados que componen el MIBEL:

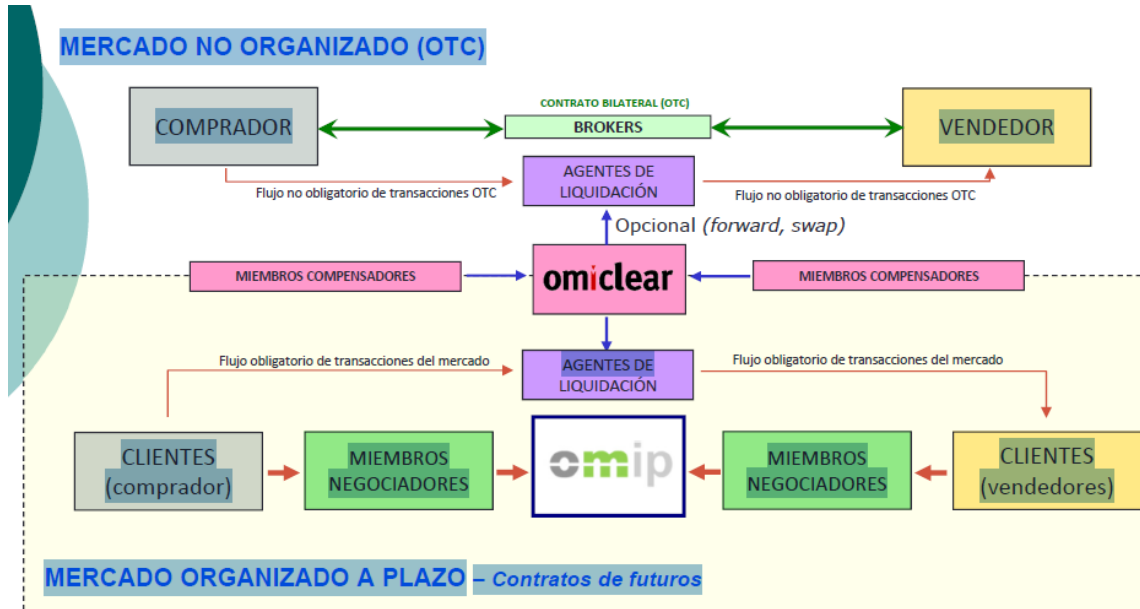


Figura 2. Distribución del mercado de la energía. Fuente: apuntes mercados eléctricos

- **Mercado no organizado:** es la parte del mercado donde se producen contratos bilaterales de liquidación por entrega física y financiera entre agentes del MIBEL.
- **Mercado organizado:** esta parte del mercado está regulada por distintos operadores dentro del MIBEL que se encargan de gestionar determinados puntos del mercado. Este mercado está compuesto por:
 - **Mercados de operación:** gestionado por red eléctrica de España (REE) y red eléctrica nacional (operador del sistema portugués), es el servicio de ajuste del sistema que se encarga de garantizar la seguridad y continuidad del servicio eléctrico, gestionando los denominados servicios de ajuste para la solución de restricciones técnicas, la asignación de los servicios complementarios y la gestión de desvíos. También es el encargado de realizar las previsiones de la evolución de la demanda energética a medio y a largo plazo, así como de su cobertura para poder elaborar de manera óptima el desarrollo de la red de transporte para los años venideros.
 - **Mercado a plazo o mercados de futuro:** gestionado por el OMIP (Operador del Mercado Ibérico de la energía- Polo portugués), se basa en una sesión diaria, donde se negocian transacciones relacionadas con el intercambio de energía eléctrica desde cuatro años hasta dos días antes del intercambio. La operación de este mercado se lleva a cabo a través del OMIP (que gestiona la parte técnica, ocupándose de la negociación) y el OMiclear (que gestiona la parte económica, ocupándose de la compensación).
 - **Mercado diario:** gestionado por el OMIE (Operador del Mercado Ibérico de la energía- polo español). La negociación en el mercado “spot” se basa en una sesión diaria, con casación de ofertas de compra y venta de electricidad, con liquidación

de la energía para todas las horas del día siguiente con un precio único para España y Portugal (excepto cuando se activa el mecanismo de separación de mercados o “market splitting”)

- **Mercado interdiario:** gestionado también por el OMIE, sirve para realizar un ajuste más fino y próximo al tiempo real entre la oferta y la demanda, pudiéndose llegar a acuerdos ya sea por subastas intradiarias (método tradicional), o mediante contratación continua (mercado XBID).

2.1.5. Mercado de futuros:

- **Participantes:** podemos destacar 4 tipos de participantes en este mercado:
 - -Miembros negociadores: habilitados por el OMIP, son las entidades con capacidad para negociar en el mercado a plazo: introducen órdenes de compra y venta en la plataforma del operador del mercado.
 - -Miembros compensadores: habilitados por el OMIClear, son las entidades capacitadas para garantizar que los pagos y cobros se realicen a lo largo del tiempo.
 - -Agentes de liquidación: también habilitados por el OMIClear, son los responsables de la liquidación de las operaciones, ejecutando pagos y cobros.
 - -Clientes: son las entidades que compran y venden en este mercado, pudiendo estar habilitados en el mercado o subcontratando los servicios de otra entidad para que los represente.
- **Funcionamiento:** compradores y vendedores hacen públicas sus ofertas la plataforma gestionada por el OMIP, cuando estas sean similares, se producirá una transacción a un precio que beneficie a ambas partes, mediante contratos estandarizados, característicos de un mercado organizado. En el momento del acuerdo se pactan la cantidad de energía y el precio a pagar por ella, así como la fecha de entrega y cobro de esta, sin realizarse ningún pago o cobro en el momento del acuerdo.
- **Tipos de contrato:** primero se debe destacar la naturaleza de los contratos que depende del tipo de liquidación, que pueden ser física (con intercambio de energía) o financiera (No se produce intercambio de energía, por lo que sólo se liquidan las diferencias entre el precio del producto y el precio medio de referencia en el mercado diario). Destacado esto existen 4 tipos de contratos para el mercado a plazos:
 - -_Contratos de futuros: los únicos de que pertenecen al mercado organizado y, por ende, gestionados por el OMIP, pudiendo ser de naturaleza física o financiera. Todas las especificaciones de estos contratos están estandarizadas. Por ello,
 - cuando un participante del mercado abre una posición, tan sólo debe escoger en
 - qué contrato va a negociar, su correspondiente cantidad y el precio.
 - -_Forward: Contratos bilaterales (fuera del mercado organizado), de naturaleza física, en el que dos partes se comprometen a comprar o a vender electricidad en cantidad y calidad estandarizadas, en fecha y lugar predeterminados
 - -_Swap: Contratos bilaterales, de naturaleza financiera, en el que dos partes se comprometen a intercambiar una serie de cantidades de dinero en fechas futuras.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

- _Opciones: una opción da a su comprador el derecho, pero no la obligación, a
- comprar o vender bienes o valores a un precio determinado hasta
- una fecha concreta.

2.1.6. Mercado diario:

También conocido como “pool”, como parte del mercado energético, su objetivo es llevar a cabo las transacciones de energía eléctrica para el día siguiente, esto se consigue mediante la presentación de ofertas de compra y venta por parte de los distintos agentes del mercado. Estas ofertas son sometidas a un proceso de casación, cuyo valor es distinto para cada uno de los 24 periodos horarios del día siguiente dependiendo de las ofertas presentadas para cada periodo. Para este mercado todos los paquetes de energía superiores a 50MW que no estén suscritos a un contrato bilateral de carácter físico, tienen la obligación ser presentados como ofertas en el mercado diario. Para generadores cuya aportación sea menor de 50MW, su participación en este mercado es opcional.

2.1.7. Casación de la energía:

El proceso de casación de la energía se hace mediante un mecanismo marginalista en el que se va cubriendo la oferta primero con las fuentes más baratas, sumándose progresivamente todas las ofertas hasta que se cruza con la curva de la demanda. Las ofertas presentadas pueden ser simples (se presenta un único paquete a un único precio), o complejas (se presentan varios tramos (hasta 25 por cada hora) con distinto precio para cada tramo, ordenándose los tramos de menor a mayor precio).

El MIBEL se encuentra acoplado al área PCR (Prince Coupling of Region) desde el año 2014. Esta área (conformada actualmente por 19 países) se caracteriza por utilizar el algoritmo EUPHEMIA para el proceso de casación de la energía para todos los mercados que componen dicha área. Este algoritmo realiza la casación en 3 fases:

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

- Fase 1. Casación simple: todas las ofertas presentadas se consideran simples, obteniéndose un primer precio provisional.

Fase 1: Casación simple




Figura 3. Fase casación simple. Fuente: apuntes mercados eléctricos.

- Fase 2. Re-casación: se aplican las condiciones complejas a las ofertas presentadas que lo requieran, dando como resultado que algunas ofertas sean descartadas.

Fase 2: Re-casación (aplicación de condiciones complejas)

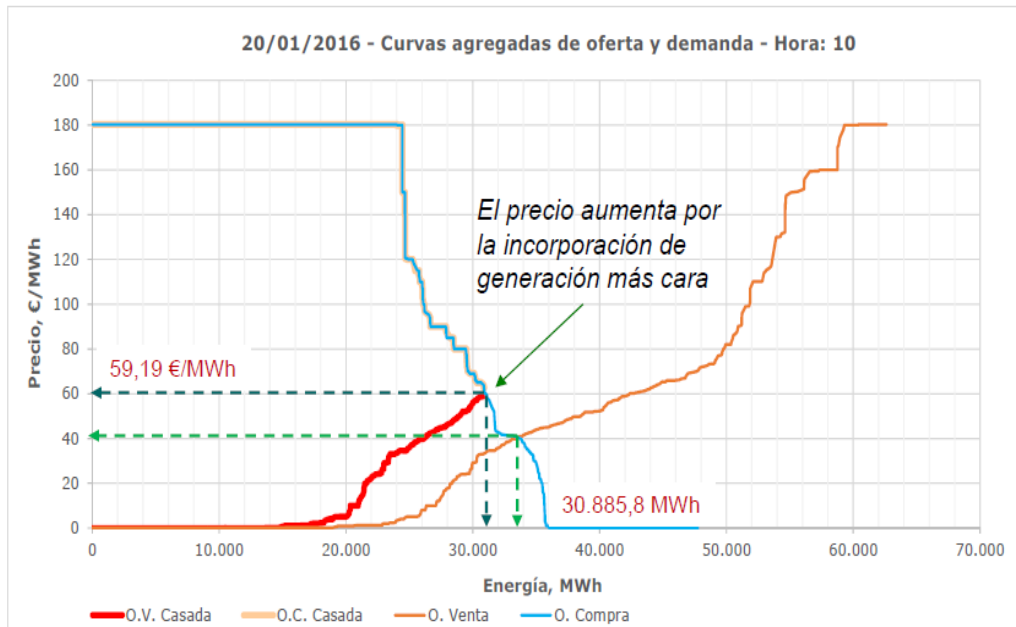


Figura 4. Fase casación compleja. Fuente: apuntes mercados eléctricos.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

- Fase 3. Transacciones transfronterizas: una vez conocidos los resultados de la casación de todos los mercados del área PCR, el algoritmo EUPHEMIA calcula las transacciones transfronterizas que optimizarían el bienestar social del área PCR y la capacidad de interconexión. Para el caso del MIBEL las transacciones se realizan entre España y Francia, en caso de que la dirección de la transacción sea España-Francia (Francia compra), la transacción se incorpora a la curva del MIBEL como una oferta de compra a precio instrumental 180 €/MWh, en caso de que la dirección sea Francia-España (Francia vende), la transacción se incorpora a la curva del MIBEL como oferta de venta a precio 0.

Fase 3: **Transacciones transfronterizas** (España-Francia)




Figura 5. Fase transacciones transfronterizas (España-Francia). Fuente: apuntes mercados eléctricos.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

2.1.8. Mercado intradiario:




Figura 6. Mercado intradiario. Fuente: apuntes mercados eléctricos.

El objetivo de este mercado es realizar ajustes sobre el programa diario viable, una vez cerrado el mercado diario. En este mercado agentes productores pueden comprar energía, así como agentes vendedores (comercializadoras) pueden venderla.

Desde junio de 2018, este mercado sigue un modelo híbrido, formado por dos tipos de contratación:

- Modo de subastas intradiarias: tras la sesión del mercado diario, se realizan 6 sesiones a lo largo del día. En cada una de ellas se realiza un cruce marginalista de oferta y demanda, con ofertas simples y complejas. La primera sesión cubre 27 horas (las últimas 3 en D-1 y las 24 del día D); la sexta, las últimas 9 horas del día D. Sólo pueden participar los agentes que previamente hayan participado en el mercado diario o que hubieran ejecutado un contrato bilateral. Estos agentes sólo pueden participar en el mercado intradiario para los periodos horarios de programación que se correspondan con los incluidos en la sesión de mercado diario en la que participaron.
- Modo de contratación continua: permite la contratación entre agentes locales o externos (dependiendo de la capacidad de interconexión disponible). Se realiza mediante el sistema informático central común (XBID), en el que se puede ajustar la energía contratada desde una hora después del cierre de la subasta y hasta una hora antes del suministro.

2.2. Métodos de previsión energética

2.2.1. Introducción:

Una vez visto como se compone el mercado eléctrico en España, a continuación, se procederá a hablar de la previsión de la demanda, tema central en el que se trabajará en la tesis, resaltando la importancia de la previsión para los distintos agentes del mercado y haciendo un repaso por los distintos métodos de previsión y su clasificación citando distintos métodos utilizados para este fin, haciendo un especial enfoque en métodos basados en condiciones climatológicas.

2.2.2 Importancia de la previsión de la demanda:

Como ya se ha comentado en la introducción, la previsión de la demanda es un tema cada vez más importante, ya sea para tener una ventaja competitiva por parte de las comercializadoras en el mercado energético, gestionar de la mejor manera posible la generación, evitando desabastecimientos y organizar mejor las fuentes de energía a utilizar para cada día.

2.2.3. Clasificación de los métodos de previsión:

Basándose en los trabajos de Khatoon, et al (2012) y Trull y Garcia (2019) se hace un repaso por los distintos métodos de previsión de la demanda:

- Métodos de previsión tradicionales: fueron los primeros métodos utilizados para la previsión de la demanda, se basaban en métodos matemáticos convencionales los principales son:
 - Métodos regresivos: es uno de los métodos estadísticos más utilizados que tiene en cuenta la carga y otros factores que condicionan esta, como las condiciones climáticas, tipo de día o hábitos de consumo. Este método se basa en que la demanda se puede suponer como una demanda estándar con tendencia lineal que se descompone en distintos también de tendencia lineal.
 - Regresión múltiple: modelo estadístico versátil para evaluar las relaciones la demanda y los factores que le afectan directamente, utilizando principalmente estimación por mínimos cuadrados (MSE).
 - Suavizado exponencial: método estadístico basado en la observación de datos anteriores ponderando estos datos de manera que los de mayor relevancia y peso este basado en datos finales.
- Métodos tradicionales modificados:
 - Previsión adaptativa de la demanda: este tipo de método se basa en corregir automáticamente los parámetros de la previsión de la demanda para mantener un registro de los cambios en esta para poder responder mejor a la demanda futura.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

- Series temporales estocásticas: una serie temporal estocástica es aquella que está compuesta por un grupo de variables aleatorias las cuales fluctúan en el tiempo pudiéndose estudiar ciertos periodos de esta serie caracterizados por su tendencia, estacionalidad, etc. Los modelos más comunes de previsión mediante series temporales son:
 - Modelo Autorregresivo (AR).
 - Modelo de Media Móvil "Moving Average" (MA).
 - Modelo Autorregresivo de Media Móvil "Autoregressive Moving Average" (ARMA).
 - Modelos Autorregresivo de Media Móvil Integrado "Autoregressive Integrated Moving Average" (ARIMA).
- Máquinas de vector de soporte: Herramienta computacional de previsión que tiene como objetivo clasificar en el espacio distintos datos divididos según patrones realizando modelos de regresión simple en cada uno de ellos.
- Métodos computacionales suaves:
 - Redes Neuronales: este método se profundizará más adelante. Son métodos útiles para tratar series no lineales, su funcionamiento se basa en el aprendizaje mediante un proceso de entrenamiento en el que se pueden ajustar los valores de entrada, así como los componentes de la red (compuesta por nodos, llamados neuronas ordenadas en capas).
 - Redes neuronales de lógica difusa: la lógica difusa aplicada a las redes neuronales consiste en que las neuronas asimilan valores cualitativos, distintos de 0 y 1. En el modelo aplicado a la previsión de la demanda partiendo de las redes neuronales se le aplican valores cualitativos como si se tratase de un operador.
 - Sistemas expertos

2.2.4 Modelos de previsión energética:

A continuación, se hace un repaso de distintos trabajos de previsión de la demanda que ha habido a lo largo de los años con distintos enfoques:

- Modelos estadísticos:

Primero se tiene el trabajo realizado por Cancelo y Espasa (1991). El cual se basa en un modelo de series temporales para predecir la demanda diaria teniendo en cuenta la demanda de meses anteriores, variables meteorológicas, particularmente la temperatura y las horas de luz a lo largo del año, la influencia de los días laborales y festivos en la demanda. Los puntos que resalta este trabajo son la complicación para parametrizar las condiciones climatológicas, especialmente la temperatura y obteniendo buenos resultados de errores de menos del 2%. Después también se tiene el modelo de Cancelo J. R., Espasa A. y Grafe R. (2008). En el que se hace un estudio de la demanda horaria para el sistema eléctrico español teniendo en cuenta nuevamente las demandas anteriores, la temperatura, la influencia de la laborabilidad. Este trabajo se centra más en la comparar los resultados obtenidos para distintos tipos de días, ya sean días de semana, fin de

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

semana, días festivos, obteniendo buenos resultados en los errores medios porcentuales absolutos (MAPE). Por otro lado, se tiene también el trabajo realizado por Escrivá-Escrivá Roldán-Blay y Álvarez-Bel (2014). En el que se propone un estudio de previsión la demanda diaria basado en los consumos finales, como ejemplo la climatización en edificios, el alumbrado público, consumo general, etc. A continuación, se tiene el trabajo de Sidhharth y Taylor (2018). En el que se hace un estudio de la demanda en días especiales para el mercado francés basado en un modelo autorregresivo de media móvil con estacionalidad doble (SARMA). Por último, tenemos el trabajo propuesto por Trull (2019). En el que se hace un estudio de la demanda a corto plazo (horaria) en España basado en modelos optimizados de Holt-Winters con estacionalidad múltiple, teniendo en cuenta variables como el efecto calendario (festividades, laborabilidad, etc.), condiciones climatológicas como la temperatura y cambios horarios entre verano e invierno.

- Modelos de redes neuronales: los modelos basados en redes neuronales cada vez están cobrando más peso por su gran adaptabilidad a parámetros no lineales. En los trabajos presentados por Ahmad et al (2014) y Mishra et al (2015), se hace un repaso de distintos modelos basados en redes neuronales y su utilidad en la actualidad. Algunos ejemplos de modelos pueden ser el modelo propuesto por Mashud y Koprinska (2014). En el que se hace un modelo de previsión mediante redes neuronales y se comparan las demandas y sus respectivas predicciones de Australia, Portugal y España. También se tiene el trabajo de Akarlan (2018). En el que se estudia y prevé la demanda eléctrica de una micro red. A continuación, se tiene el modelo propuesto por Mateo (2021). En el que se realiza la previsión de la demanda de administración pública basándose en los tipos de consumo descomponiéndolos en distintos grupos (como alumbrado público, consumo de escuelas, bibliotecas, museos, etc.). Y por último se tiene el trabajo de Roldán-Blay et al (2013). En el que se hace una mejora de un modelo basado en redes neuronales utilizando un modelo de curva de temperatura horaria.

2.2.5 Modelización de la temperatura para el estudio de la demanda:

En este último apartado se hará un repaso por distintos métodos de modelización de la temperatura para utilizarla en la previsión de la demanda. La temperatura es el principal factor climatológico que se tiene en cuenta a la hora de generar un modelo de previsión de la demanda ya que es el que se muestra más relacionado directamente, sin embargo, es complicado a la hora de generar un modelo de previsión, ya que las previsiones de condiciones climatológicas son más complicadas que las mismas previsiones de la energía, con lo que se han generado varios modelos para intentar relacionar las temperaturas con la demanda energética. Algunos de estos modelos pueden ser por ejemplo Thompson (1976), Karanta y Ruusunen (1992), los que se estudia la demanda horaria estableciendo también un método de estimación de la temperatura para estos intervalos de tiempo mediante métodos estadísticos, siendo un modelo regresivo en el primer caso y un modelo SARMA en el segundo. También hay que resaltar los modelos propuestos por Valor, Meneu, y Caselles (2001) y Taylor y Buizza (2003), en el que los modelos se basan en la demanda diaria en el primer caso para el mercado español y el segundo para el mercado

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

inglés. Y por último mencionar los trabajos de Moral-Carcedo y Vicéns-Otero (2005) y Moral-Carcedo y Pérez-García (2015). En el primero presenta un modelo para la respuesta de la demanda energética a las variaciones de la temperatura y en el segundo analiza cómo afecta la temperatura a distintos sectores de consumo (sectores residenciales, comerciales, etc.).

CAPÍTULO 3: METODOLOGÍA

3.1. Introducción:

En este capítulo se procederá a explicar la metodología empleada para la realización del trabajo. Como ya se ha explicado se pretende desarrollar un modelo de previsión mediante RNA basándose en condiciones climatológicas. El horizonte de previsión del modelo será la demanda diaria en la península. En el primer apartado de este capítulo se explica que datos climatológicos se tendrán en cuenta, además de otras variables de entrada a utilizar para el entrenamiento de la red y su posterior puesta en funcionamiento. El segundo apartado de este capítulo se explica el funcionamiento de los modelos de redes neuronales, su arquitectura y el método de entrenamiento empleado para el presente trabajo.

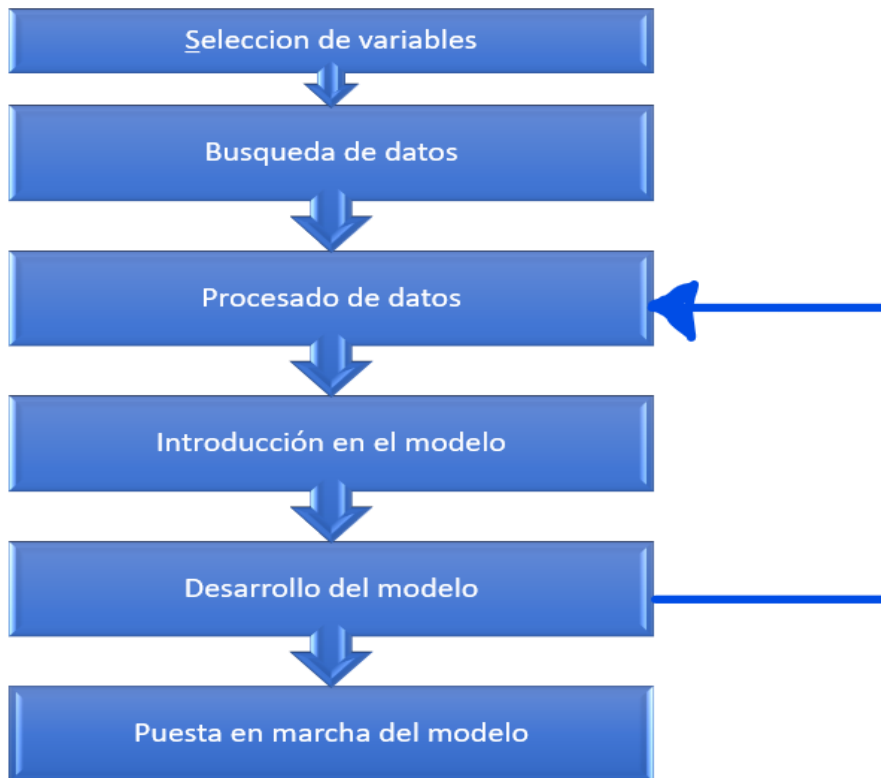


Figura 7. Diagrama de bloque del desarrollo del modelo. Fuente: elaboración propia.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

3.2. Identificación de variables:

3.2.1. Introducción:

En este apartado se describirán las variables de entrada para la red neuronal para su entrenamiento y funcionamiento, los inputs del modelo son 5, dos variables climatológicas (temperatura y horas de sol), demanda en días previos, día de la semana y días festivos.

3.2.2. Variables meteorológicas:




Figura 8. Mapa de temperatura peninsular. Fuente:

<https://www.mequieroir.com/paises/espana/emiqrar/descripcion/clima/>

Las variables climatológicas para un modelo de previsión son diversas, se pueden tener en cuenta la temperatura, la humedad, las precipitaciones, velocidad del viento o estaciones del año. De estas variables mencionadas las que tienen mayor utilidad para la previsión de la demanda son la temperatura y las horas de sol (forma en la que se han interpretado las estaciones), ya que la

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

humedad tiene un peso bastante bajo a la hora de realizar un modelo predictivo, y la velocidad del viento y las precipitaciones tienen mayor interés a la hora de prever el precio más no la demanda, ya que estas variables están relacionadas con la producción de energía (las precipitaciones son de interés para las reservas hidráulicas y la velocidad del viento para la producción eólica) sin embargo la demanda no se ve directamente afectada por estas.

- **Temperatura (°C):** La temperatura es la variable de mayor peso a la hora de prever la demanda ya que afecta directamente el consumo de los usuarios, reflejado en los sistemas de climatización los cuales representan siempre el mayor punto de consumo en cualquier instalación. La temperatura en la península es muy diversa ya que se presentan distintos climas dependiendo de la localización, destacando el norte de la península que presenta el clima más frío en la península (Asturias, Galicia, Cantabria País Vasco, entre otras), la costa mediterránea que presenta temperaturas más suaves pero con una mayor humedad en el ambiente (Comunidad Valenciana, Cataluña Murcia), la meseta ubicada en el centro y que presenta temperaturas intermedias entre el norte y el sur y con un clima más seco que en la costa (Madrid, Castilla la Mancha, Castilla y León) y por último el sur de la península donde se presentan las temperaturas más elevadas (Andalucía). Debido a esta variabilidad en la temperatura se ha optado por hacer un promedio de las temperaturas de distintas provincias de distintos climas para obtener la temperatura promedio de la península. Los datos se han obtenido de una base de datos llamada "datos clima" (<https://datosclima.es>) donde están recolectadas las temperaturas diarias históricas presentadas en por la Aemet (Agencia Estatal Meteorológica).
- **Estacionalidad:** en general el clima de la península va variando con las estaciones, esto se puede ver reflejado en las horas diarias de sol (días más largos en verano y más cortos en invierno), esta variable se tiene en cuenta ya que cuantas más horas de sol haya, menor será el gasto de la iluminación por la noche, representando el punto de consumo más grande la iluminación pública la cual funciona en base a calendarios solares. De la misma manera que la temperatura, las horas de sol también se ven por la localización. Siendo Huelva la provincia con más horas de sol al año (recibiendo más de 3500 horas al año) y Bilbao la provincia con menos horas de sol al año (recibiendo menos de 1700 horas al año, menos de la mitad que Huelva). Con lo cual se ha promediado las horas solares diarias en de la misma manera que la temperatura, cogiendo las horas diarias de sol en distintas provincias de distintos puntos de la península. Los datos de las horas solares se han sacado de una página web llamada "salida y puesta del sol" (<https://salidaypuestadelosol.com>).

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

3.2.3. Demanda Previa:




Figura 9. Demanda energética real, año 2022. Fuente: www.esios.ree.es

La demanda en días previos es la variable de más peso a la hora de generar un modelo de previsión, ya que son los principales valores de los que va a aprender la red para ser capaz de generar una previsión fiable, por lo menos en cuanto a ordenes de magnitud, luego los ajustes se consiguen mediante el resto de las variables. Los valores de la demanda diaria se han obtenido de la página web www.esios.ree.es, página oficial del operador del sistema eléctrico, de red eléctrica de España (REE).

3.2.4. Días de la semana:

El consumo diario va variando a lo largo de la semana dependiendo de la laborabilidad del día, presentándose mayor demanda de energía entre semana (de martes a jueves), y siendo los días de menor consumo los fines de semana. Para poder procesar los datos en la red, se le ha asignado un valor numérico a cada día de la semana de la siguiente manera: lunes=1, martes=2, miércoles=3, jueves=4, viernes=5, sábado=6, domingo=7.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

3.2.5. Festivos:

Los días festivos son un caso particular ya que son los días que menor consumo se presenta ya que la actividad laboral suele ser mínima. Para introducir este concepto en la red se le ha dado un valor 1 en caso de que sea festivo, y valor 0 en caso de que sea un día normal. Los días festivos que se han tenido en cuenta para el desarrollo del trabajo son los festivos nacionales, sacados de calendarios laborales.

3.3. Redes Neuronales:

3.3.1. Introducción:

En este apartado se va a explicar detalladamente el funcionamiento de los modelos de RNA, así como la arquitectura de esta y el método de entrenamiento que se ha empleado para el desarrollo de la red de este proyecto.

3.3.2. Descripción y funcionamiento de las redes neuronales artificiales:

La red neuronal basa su funcionamiento en nodos llamados neuronas artificiales, dispuestas en distintas capas, esta distribución se conoce como arquitectura de la red. Estas neuronas se caracterizan por tener un nivel interno de activación. El nivel de activación cambia dependiendo de las señales que recibe y de una función conocida como función de activación.




Figura 10. Arquitectura red neuronal. Fuente: elaboración propia.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Las señales de entrada a la red se procesarían de la siguiente manera:

Al entrar a la primera capa (en el caso de este trabajo solo se tendría una), cada señal se enviaría a todas las neuronas. Cada señal \mathbf{X} tiene un peso asignado en cada neurona al cual llamaremos \mathbf{w} , de manera la entrada a la neurona se obtendría multiplicando la señal por su peso $\mathbf{E} = \mathbf{X} * \mathbf{w}$. Para varias señales de entrada ($\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots \mathbf{x}_n$) y distintas neuronas ($\mathbf{y}_1, \mathbf{y}_2, \mathbf{y}_3, \dots \mathbf{y}_k$), la entrada quedaría de la forma:

$$\mathbf{E} = \mathbf{x}_1 * \mathbf{w}_{k1} + \mathbf{x}_2 * \mathbf{w}_{k2} + \mathbf{x}_3 * \mathbf{w}_{k3} \dots \mathbf{x}_n * \mathbf{w}_{kn}$$

Para la ejecución de la neurona también existe un parámetro conocido como umbral de activación \mathbf{b} , único para cada neurona, es cual sirve para comparar la entrada con la salida de la neurona. La activación de la neurona se obtiene mediante la suma ponderada entre la entrada menos el umbral de activación. La señal de activación es a continuación procesada por la función de activación. Esta función debe ser creciente, continua en el rango $[0,1]$, y derivable para todo el intervalo, por ello la función más empleada comúnmente y la que usa el modelo propuesto es la función sigmoide, cuya expresión es $f(x) = (1 + e^{-x})^{-1}$

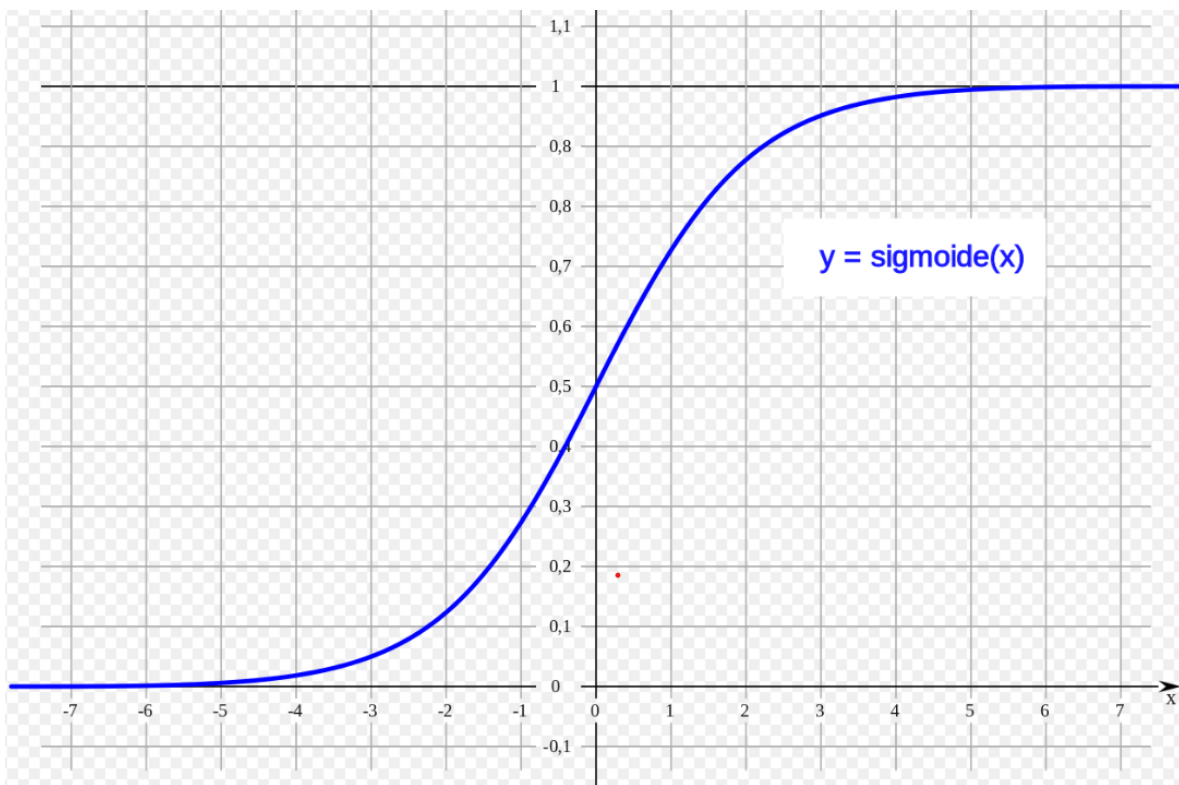


Figura 11. Función sigmoide. Fuente: https://es.wikipedia.org/wiki/Funci%C3%B3n_sigmoide

Con lo que la salida de la neurona \mathbf{y}_k , se obtendría de la siguiente manera:

$$\mathbf{y}_k = f\left(\sum_{i=1}^n (\mathbf{w}_{ki} * \mathbf{x}_i + \mathbf{b}_k)\right)$$

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Una vez obtenidas las salidas de la primera capa, pasaríamos a la siguiente, que para el caso del presente proyecto sería la capa de salida, el proceso de obtención de esta sería similar, solo que las entradas ahora serían las salidas de la anterior capa ($y_1, y_2, y_3, \dots, y_k$), y de la misma manera cada neurona tendría un peso asignado para la neurona de salida ($w_1, w_2, w_3, \dots, w_k$), la cual también tiene su respectivo umbral de activación b . Con lo que la salida se obtendría de la siguiente manera:

$$S = \sum_{i=1}^k (y_i * w_i) * b$$

3.3.3. Descripción del ajuste y aprendizaje de la red:

Una vez explicada la estructura de la red y funcionamiento de la red, se pasa a profundizar en los procesos internos de esta. Los pesos de las neuronas y sus umbrales de activación van cambiando continuamente a lo largo del proceso de aprendizaje (conocido como entrenamiento de la red), en el cual la red va ajustando estos valores mediante el método de *Backpropagation*, en el que se propaga hacia atrás el error de la salida (obtenido comparando la salida obtenida por la red y el valor de la salida real), yendo capa por capa y cambiando los valores de los umbrales y pesos de manera que se consiga minimizar el error final. El algoritmo de entrenamiento utilizado para el modelo propuesto es el algoritmo de regularización bayesiano, basándose en el trabajo de **Murat Kayri (2016)**, y en los ensayos realizados durante el desarrollo de la red, ya que es el método que ofrece mejores resultados en cuanto al error obtenido.

CAPÍTULO 4: CASO DE APLICACIÓN

4.1. Introducción

Una vez expuesta la metodología seguida en el trabajo, se pasa a continuación a desarrollar la red empleada para el modelo de previsión propuesto, donde se explican los ajustes hechos en el entrenamiento para conseguir el modelo que se usará en el caso de estudio

4.2. Entrenamiento de la red:

El modelo se ha generado a partir del paquete de MATLAB de Deep Learning Toolbox, paquete utilizado para realizar modelos de redes neuronales, en particular la herramienta de Neural Network Fitting, en la que se han introducido los inputs utilizados para el modelo, mencionados anterior mente en la metodología. Siendo la matriz de entrada:

fecha	demanda diaria prevista	temperatura	horas solares	días semana	festivos
3/2/2021	29,109,118	12.19	11.37	2	0
3/3/2021	29,810,361	12.37	11.41	3	0
3/4/2021	29,544,701	11.99	11.45	4	0
3/5/2021	29,334,701	11.67	11.50	5	0
3/6/2021	26,185,590	11.06	11.54	6	0
3/7/2021	24,714,847	10.68	11.58	7	0
3/8/2021	29,525,958	9.73	11.62	1	0
3/9/2021	30,282,785	9.44	11.67	2	0
3/10/2021	29,959,806	10.00	11.71	3	0
3/11/2021	29,496,590	12.73	11.75	4	0
3/12/2021	29,030,625	11.98	11.79	5	0
3/13/2021	25,773,243	10.77	11.84	6	0
3/14/2021	24,193,139	11.68	11.88	7	0
3/15/2021	28,691,674	11.28	11.92	1	0
3/16/2021	29,217,056	12.02	11.96	2	0
3/17/2021	29,200,292	12.73	12.01	3	0
3/18/2021	29,522,090	9.65	12.05	4	0
3/19/2021	28,035,611	8.38	12.09	5	0
3/20/2021	26,632,736	7.97	12.13	6	0
3/21/2021	25,076,285	8.66	12.18	7	0
3/22/2021	29,275,729	10.56	12.22	1	0
3/23/2021	29,516,646	11.54	12.26	2	0
3/24/2021	29,183,090	12.49	12.30	3	0

Figura 12. Matriz de entrada a la red. Fuente: elaboración propia.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Siendo la matriz de salida:

fecha	demanda real
3/2/2021	29,921,403
3/3/2021	29,772,160
3/4/2021	29,515,806
3/5/2021	29,311,736
3/6/2021	26,129,403
3/7/2021	24,680,458
3/8/2021	29,528,201
3/9/2021	30,280,278
3/10/2021	29,922,153
3/11/2021	29,479,806
3/12/2021	29,010,465
3/13/2021	25,712,736
3/14/2021	24,135,313
3/15/2021	28,730,938
3/16/2021	29,221,785
3/17/2021	29,220,944
3/18/2021	29,541,708
3/19/2021	28,059,146
3/20/2021	26,625,861
3/21/2021	25,041,799
3/22/2021	29,270,431
3/23/2021	29,467,590
3/24/2021	29,165,799

Figura 13. Matriz de salida. Fuente: elaboración propia.

El modelo generado utiliza 13 neuronas, elegido así ya que durante el proceso de testeo de la red se observó que era el número de neuronas que ofrecía menor error:

número de neuronas	error medio MW	err medio %
8	1543500	5.8206
9	1965400	7.4072
10	1696900	6.399
11	1294200	4.825
12	2033000	7.6345
13	1041207	3.8818
14	2176400	8.2145
15	1882700	7.0209
16	1162500	4.3516
17	1468800	5.2645

Figura 14. Errores obtenidos de diferente número de neuronas en la red. Fuente: elaboración propia.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Quedando definida la arquitectura de la red de la siguiente forma

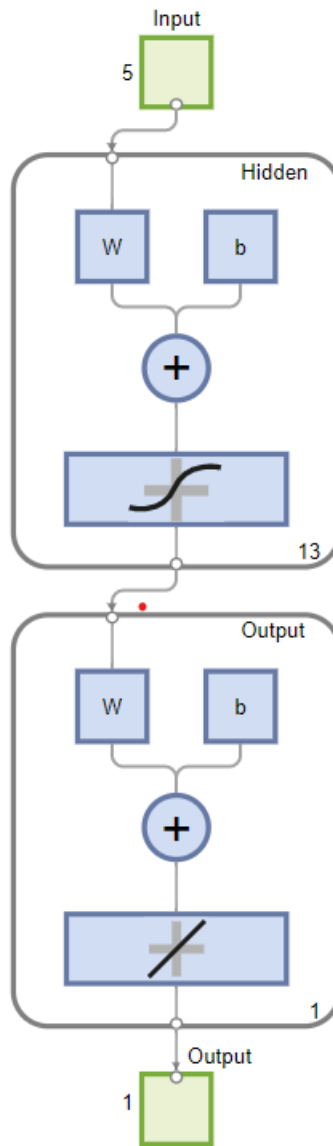


Figura 15. Arquitectura del modelo propuesto. Fuente: elaboración propia.

Con lo que observamos un modelo de 2 capas, la primera con 13 neuronas que serán las neuronas de entrada que se encargarán de procesar los inputs, y las segunda con una sola neurona, encargada de proporcionar la salida.

Por último, el rango de datos que se escogió para entrenar la red fue del año 2021, desde el 01/01/2021 hasta el 31/01/2021. Ya que, al aumentar el rango de datos, el error crecía. Esto podría deberse a lo atípico del año 2020, donde la demanda se vuelve muy irregular a lo largo del año por acciones de la pandemia. Se comprobó esto utilizando periodos anteriores, del 2017 al

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

2019, para ser específicos. Sin embargo, también cabe resaltar que el error no mejoraba en excesivamente, y a partir del segundo año de prueba crecía nuevamente el error, con lo que se escogió el año 2021 debido al ser el más óptimo para realizar las pruebas además de ser el inmediatamente anterior al año sobre el que se realiza el caso de estudio.

CAPÍTULO 5: RESULTADOS

Una vez entrenada y testeada la red se procede a ponerla en marcha realizando previsiones para el año 2022, desde el mes de enero a el mes de julio, abarcando así 3 de las 4 estaciones del año, pudiéndose así ver como se adapta la red a los cambios en el clima.

5.1. Previsión para el año 2022 (01/01/2022 al 31/07/2022)

5.1.1. Comparativa de la previsión y la carga real, error y error porcentual (todo el año):




Figura 16. Comparación demanda real- demanda prevista. Fuente: elaboración propia.

Primero se realiza una previsión global del año 2022, observándose en la figura 16 una gran similitud de la demanda real respecto de la demanda prevista por la red, los picos en los que se diferencia más la previsión respecto de la demanda real se comentarán a continuación en el análisis mes a mes.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas




Figura 17. Error absoluto a lo largo del año de previsión. Fuente: elaboración propia.

Observando el error cometido en las predicciones se observa una tendencia ascendente entre los meses de marzo, abril y mayo, esta tendencia se estudiará en el análisis mensual de los errores en promedio. El rango de error va entre $2 \cdot 10^6$ MW, y $0.5 \cdot 10^6$ MW, siendo un error aceptable pero mejorable.




Figura 18. Error absoluto porcentual a lo largo del año de la previsión. Fuente: elaboración propia.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Viéndose reflejado en el error porcentual, estando la mayoría de los valores entre el 2% y el 8%.

A continuación, se hará un análisis más preciso, viendo las previsiones de cada mes del periodo estudiado.

5.1.2. Predicciones mes de enero:




Figura 19. Comparativa demanda real-demanda prevista, mes de enero. Fuente: elaboración propia.




Figura 20. Error absoluto porcentual, mes de enero. Fuente: elaboración propia.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Las predicciones vistas en la figura 19 cualitativamente son las mejores, ya que el error medio cometido en este periodo es de 1,75%, siendo el mes con el error más bajo. Se puede observar en la figura 20 un mayor error en los fines de semana y el día 6 de enero (festivo), como se observará esta tendencia es algo que se repite en los siguientes meses que se comentaran a continuación. Sin embargo, las predicciones de este mes siguen considerándose positivas debido al bajo error que se presenta, pese a que los fines de semana el error es mayor, este está entorno al 3%.

5.1.3. Predicciones mes de febrero:




Figura 21. Comparativa demanda real-demanda prevista, mes de febrero. Fuente: elaboración propia.




Figura 22. Error absoluto porcentual, febrero. Fuente: elaboración propia.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Observando la figura 22, se aprecia que el error medio crece respecto observado en la figura 20, siendo del 2.95%, sin embargo, los valores nuevamente son bastante aceptables, quedando todos prácticamente por debajo del 6%. Por otro lado, se comienza a observar mejor la imprecisión de la red para la demanda en los fines de semana, siendo los donde se observan los mayores errores.

5.1.4. Predicciones mes de marzo:




Figura 23. Comparativa demanda real-demanda prevista, mes de marzo. Fuente: elaboración propia.




Figura 24. Error absoluto porcentual, marzo. Fuente: elaboración propia.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

En la figura 24 se aprecia que el error crece entorno a un 1% más que en la figura 22, esta tendencia se comentara en el siguiente punto. El error medio de este mes es del 3,64%, observándose nuevamente la tendencia de los fines de semana, por otro se puede observar una ciclicidad muy marcada en las previsiones semanales, siendo los errores prácticamente idénticos cada semana.

5.1.5. Predicciones mes de abril:




Figura 25. Comparativa demanda real-demanda prevista, mes de abril. Fuente: elaboración propia.




Figura 26. Error absoluto porcentual, abril. Fuente: elaboración propia.

El mes de abril es el mes que presenta los errores mas altos, siendo de un 4,40% el error medio cometido en este mes. Las previsiones entre semana fueron las mejores, estando por entre el 2% y el 3%. Los picos con los mayores errores fueron nuevamente los fines de semana, y los días festivos de pascua.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

5.1.6. Predicciones mes de mayo:




Figura 27. Comparativa demanda real-demanda prevista, mes de mayo. Fuente: elaboración propia.




Figura 28. Error absoluto porcentual, mayo. Fuente: elaboración propia.

En el mes de mayo el error tiene una tendencia descendente, siendo el error medio de 2,7%, menor que los dos meses anteriores, notándose nuevamente las imprecisiones en los fines de semana, sin embargo, las predicciones de los días semanales son bastante buenas, llegando incluso a estar debajo del 1% en algunos casos.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

5.1.7. Predicciones mes de junio:




Figura 29. Comparativa demanda real-demanda prevista, mes de junio. Fuente: elaboración propia.




Figura 30. Error absoluto porcentual, junio. Fuente: elaboración propia.

En el mes de junio el error sigue disminuyendo respecto de los meses de primavera. El error medio de este mes es del 2.1%, viéndose afectado principalmente por 3 días en particular. Quedando la gran mayoría de los días por debajo del 3%.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

5.1.8. Predicciones mes de julio:




Figura 31. Comparativa demanda real-demanda prevista, mes de julio. Fuente: elaboración propia.




Figura 32. Error absoluto porcentual, julio. Fuente: elaboración propia.

Nuevamente el error medio disminuye, quedando en 2,06%, siendo este mes un poco mas regular que el mes de junio, esto se debe al cambio de laborabilidad del mes de junio respecto de julio, al ser el termino del periodo lectivo, ya que se observa una estabilización del error a partir de la segunda semana del mes, estando la mayoría de los valores entre el 1% y el 3%.

5.2. Previsiones mensuales




Figura 33. Error absoluto medio de cada mes. Fuente: elaboración propia.

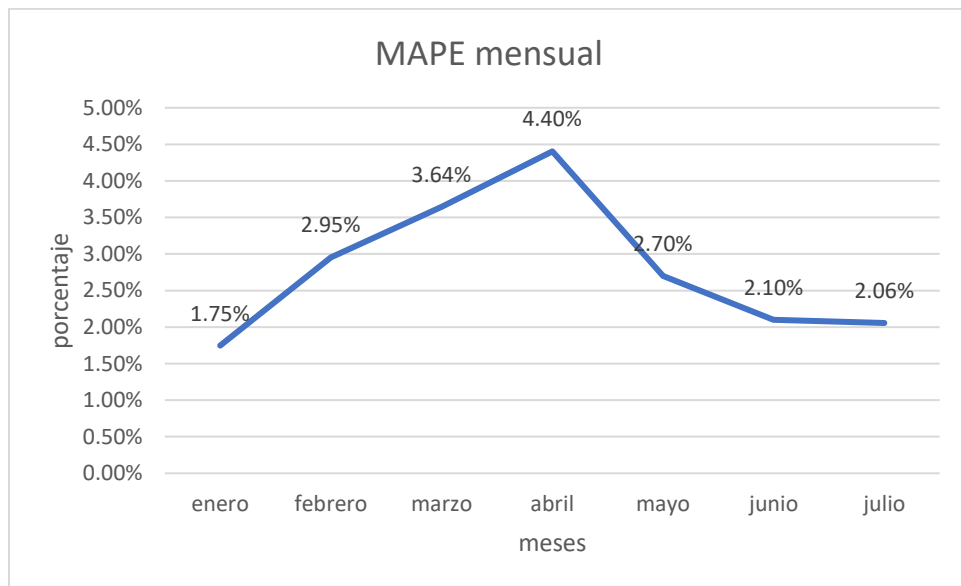


Figura 34. Error absoluto medio porcentual cada mes. Fuente: elaboración propia.

Haciendo un análisis del error medio cometido en los diferentes meses que se han estudiado, se puede observar un crecimiento en los meses de primavera respecto invierno y verano (más de un 2%). Esto se debe a que en estos meses las condiciones meteorológicas son muy

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

cambiantes, con lo que, haciendo un modelo basado en el clima, esto hará crecer la imprecisión en estos meses.

CAPÍTULO 6: CONCLUSIONES

En el presente trabajo se ha desarrollado un modelo de previsión de la demanda mediante redes neuronales utilizando condiciones meteorológicas, en el que primero se ha estudiado el mercado energético y su funcionamiento para analizar el horizonte de previsión sobre el cual se desarrollaría el modelo. Después de esto se ha hecho estudio bibliográfico de distintos trabajos relacionados con la previsión de la demanda, enfocándose en los relacionados con modelos de redes neuronales y también estudios de las condiciones meteorológicas de cara a la previsión de la demanda, con el fin de enfocar de la mejor manera el proyecto desarrollado. Una vez hecho este estudio se procedió a la búsqueda y recolección de datos para las variables a utilizar para el desarrollo del modelo, clasificándolos y ordenándolos de cara a introducirlos en la red neuronal. Tras la recolección de los datos se procedió a desarrollar el modelo mediante el programa MATLAB, probando distintos métodos de entrenamiento para la red, así como variando el número de neuronas eligiéndose finalmente el método de regularización bayesiano para entrenar la red basándose en la bibliografía y en las pruebas realizadas con el programa, así como también se decidió utilizar una red con 13 neuronas ya que con este número de neuronas se obtenía un menor error. Elegido el método de entrenamiento y diseñada la arquitectura de la red, se procedió a elegir el rango de datos para el entrenamiento de la red, escogiéndose un año como periodo de entrenamiento, ya que era el periodo más óptimo para el desarrollo del modelo, escogiéndose el año 2021 debido a su cercanía al periodo sobre el que se quería hacer el análisis del funcionamiento de la red, además de ser el año donde se comenzó a regularizar la demanda energética tras la pandemia. Tras el entrenamiento de la red se puso en marcha el modelo, ofreciendo resultados relativamente buenos pero mejorables en cuanto al error cometido, notándose mayores imprecisiones los meses de primavera, y también habiéndolas en los días festivos y fines de semana, particularmente los domingos.

Los puntos de mejora del modelo propuesto se centrarían en mejorar las predicciones de cara a los fines de semana y días festivos, siendo estos los días que presentan un mayor error. Consiguiendo mejorar la predicción en estos días se conseguiría una notable disminución del error cometido por la red. Así como también, disminuir el error en los meses de primavera, que como se ha podido observar son los meses más imprecisos, pudiéndose deducir un comportamiento similar para los meses de otoño.

De cara a posibles trabajos futuros, primeramente, se propondría disminuir el error obtenido, mejorando como se ha dicho la previsión en los festivos y fines de semana, así como el error en general, ya sea aumentando la precisión de las variables a tener en cuenta o bien añadiendo nuevas variables que mejoren las predicciones hechas por el modelo. Por otro lado, de cara a futuros trabajos enfocados también en condiciones meteorológicas se propondría hacer estudios de los distintos climas existentes en la península y territorios no peninsulares, mejorando así la precisión de las condiciones climatológicas a tener en cuenta, ya que como se ha mencionado en la identificación de variables (punto 3.2 del documento), al haber climas tan diversos en la península se ha de hacer un promedio de las distintas zonas para poder tener un valor aproximado de las condiciones meteorológicas. Otro posible estudio que se podría

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

desarrollar en base a este proyecto sería comparar las demandas en las distintas estaciones del año, apuntando a mejorar la imprecisión antes mencionada en los meses de primavera, de cara disminuir el error cometido en estos meses. Por último, otro enfoque que se podría dar al modelo propuesto sería desarrollarlo de cara a la demanda horaria, viendo cómo afectan las condiciones meteorológicas a la demanda para este horizonte, centrándose en las estaciones de verano o invierno, que serían en las que se vería más reflejada la influencia del clima en la demanda eléctrica teniendo en cuenta la importancia de los sistemas de climatización en estas estaciones.

BIBLIOGRAFÍA:

- Ahmad, A. S.; Hassan, M. Y.; Abdullah, M. P.; Rahman, H. A.; Hussin, F.; Abdullah, H. y Saidur, R. (2014). "A review on applications of ANN and SVM for building electrical energy consumption forecasting." *Renewable and Sustainable Energy Reviews*. 33, 102-109.
<https://doi.org/10.1016/j.rser.2014.01.069>
- Akarlan E., Hocaoglu, F.O. (2018). "Electricity demand forecasting of a micro grid using ANN," 2018 9th International Renewable Energy Congress (IREC),
<https://doi.org/10.1109/IREC.2018.8362471>
- Aneiros, G.; Vilar, J. M. y Raña, P. (2016). "Short-term forecast of daily curves of electricity demand and price." *International Journal of Electrical Power & Energy Systems*. 80, 96-108.
<https://doi.org/10.1016/j.ijepes.2016.01.034>
- Apuntes Mercados energéticos, curso 3, Grado de ingeniería de la energía.
- Aries, M. B.C. y Newsham, G. R. (2008). "Effect of daylight-saving time on lighting energy use: A literature review." *Energy Policy*. 36(6), 1858-1866 <https://doi.org/10.1016/j.enpol.2007.05.021>
- Arora, S. y Taylor, J. W. (2013). "Rule-based autoregressive moving average models for forecasting load on special days: A case study for France." *European Journal of Operational Research*, 266(1), 259-268 <https://doi.org/10.1016/j.ejor.2017.08.056>
- Arunesh Kumar Singh. Ibraheem; S. Khatoun; Md. Muazzam; D. K. Chaturvedi (2012) "Load forecasting techniques and methodologies: A review". 2012 2nd International Conference on Power, Control and Embedded Systems, <https://doi.org/10.1109/ICPCES.2012.6508132>
- Asbury, C. E. (1975). "Weather load model for electric demand and energy forecasting.": *IEEE Transactions on Power Apparatus and Systems* 94(4), 1111 – 1116 <https://doi.org/10.1109/T-PAS.1975.31945>
- Baliyan, A.; Gaurav, K. y Kumar Mishra, S. (2015). "A Review of Short-Term Load Forecasting using Artificial Neural Network Models." *Procedia Computer Science*. 48, 121-125.
<https://doi.org/10.1016/j.procs.2015.04.160>
- Base de datos meteorológica < <https://datosclima.es/Aemethistorico/Meteostation.php>>, [Consulta: 26 de agosto de 2022].
- Cancelo J. R., Espasa A., Grafe R. (2008). "Forecasting the electricity load from one day to one week ahead for the Spanish system operator." *International Journal of Forecasting*, 24(4) 588-602
<https://doi.org/10.1016/j.ijforecast.2008.07.005>
- Cancelo, J. R. y Espasa, A. (1991) "Forecasting daily demand for electricity with multiple-input nonlinear transfer function models: a case study". 91-121. Madrid, Spain.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Cancelo, J. R. y Espasa, A. (1995) *“Modelización del efecto temperatura en el consumo de electricidad: un ejercicio de búsqueda de especificación en relaciones dinámicas no lineales”*. ESTADÍSTICA ESPAÑOLA 37 (139): 183-200.

Castaño, E. 2007. *“Reconstrucción de datos de series de tiempo: una aplicación a la demanda horaria de la electricidad”*. Revista Colombiana de Estadística 30: 247-263.

Corpening, S.; Reppen, N.D. y Ringlee, R.J. (197). *“Experience with Weather Sensitive Load Models for Short and Long-Term Forecasting.”* IEEE Transactions on Power Apparatus and Systems 92(6), 1966 – 1972 <https://doi.org/10.1109/TPAS.1973.293576>

Escrivá Escrivá G., Roldán-Blay C., Álvarez-Bel C. (2014). *“Electrical consumption forecast using actual data of building end-use decomposition.”* Energy and Buildings, 82, 73-81. <https://doi.org/10.1016/j.enbuild.2014.07.024>

Felice, M.; Alessandri, A. y Catalano, F. (2015). *“Seasonal climate forecasts for medium-term electricity demand forecasting.”* Applied Energy. 137, 435-444. <https://doi.org/10.1016/j.apenergy.2014.10.030>

Hippert, H.S.; Pedreira, C.E. y Souza, R.C. (2001). *“Neural networks for short-term load forecasting: a review and evaluation.”* IEEE Transactions on Power Systems 16 (1), 44-55. <https://doi.org/10.1109/59.910780>

Karanta, I. y Ruusunen, J. (1992). *“Modelling the Temperature Factor in Short-term Electrical Load Forecasting.”* IFAC Proceedings 25 (1), 269-272. [https://doi.org/10.1016/S1474-6670\(17\)50465-6](https://doi.org/10.1016/S1474-6670(17)50465-6)

Mateo Barcos S. (2022). *“Design and analysis of artificial neural networks for the prediction of the electricity demand of public administrations based on type of consumption decomposition.”* Trabajo final de máster, Universidad Politécnica de Valencia.

MIBEL. (2021). *El mercado ibérico de la electricidad–mibel*. https://www.mibel.com/es/home_es/

Mohamed, N.; Ahmad, M.H.; Suhartono y Ahmad, W. M. (2012). *“Forecasting short term load demand using multilayer feedforward (MLFF) neural network model.”* Applied Mathematical Sciences 6 (108), 5359-5368.

Moral-Carcedo, J. y Pérez-García, J. (2015). *“Temperature effects on firms’ electricity demand: An analysis of sectorial differences in Spain.”* Applied Energy 142, 407-425. <https://doi.org/10.1016/j.apenergy.2014.12.064>

Moral-Carcedo, J. y Vicéns-Otero, J. (2005). *“Modelling the nonlinear response of Spanish electricity demand to temperature variations.”* Energy Economics 27 (3), 477-494. <https://doi.org/10.1016/j.eneco.2005.01.003>

Murat K. (2016). *“Predictive Abilities of Bayesian Regularization and Levenberg–Marquardt Algorithms in Artificial Neural Networks: A Comparative Empirical Study on Social Data.”* Mathematical and Computational Applications 21(20), 1-11. <https://doi.org/10.3390/mca21020020>

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Ortiz-Beviá, M. J. y Ruiz de Elvira, A. (2012). "Evolution of heating and cooling degree-days in Spain: Trends and interannual variability." *Global and Planetary Change* 92-93, 236-247.

<https://doi.org/10.1016/j.gloplacha.2012.05.023>

Ortiz-Beviá, M. J.; Ruiz de Elvira, A. y Álvarez-García, F.J. (2014). "The influence of meteorological variability on the mid-term evolution of the electricity load." *Energy* 76, 850-856.

<https://doi.org/https://doi.org/10.1016/j.energy.2014.08.084>

Pardo, A.; Meneu, V. y Valor, E. (2002). "Temperature and seasonality influences on Spanish electricity load." *Energy Economics* 24 (1), 55-70. [https://doi.org/10.1016/S0140-9883\(01\)00082-2](https://doi.org/10.1016/S0140-9883(01)00082-2)

Querol Herrá, J. (2019). "Desarrollo de un modelo de predicción del precio de la energía eléctrica para el mercado a plazo mediante redes neuronales". Trabajo final de máster Universidad Politécnica de Valencia.

Rana, M.; Koprinska, I. y Troncoso, A. (2014). "Forecasting hourly electricity load profile using neural networks." En 2014 International Joint Conference on Neural Networks (IJCNN), 824-831.

<https://doi.org/10.1109/IJCNN.2014.6889489>

REE, ESIOS < <https://www.esios.ree.es/es?locale=es> > [Consulta: 23 de agosto de 2022].

Roldán-Blay C., Escrivá Escrivá G., Álvarez-Bel C., Roldán-Porta C., Rodríguez-García J. (2013). "Upgrade of an artificial neural network prediction method for electrical consumption forecasting using an hourly temperature curve model." *Energy and Buildings*, 60, 38-46.

<https://doi.org/10.1016/j.enbuild.2012.12.009>

Santos Martin, D. (2017). "Desarrollo de un modelo de predicción del precio horario de la energía eléctrica para el mercado diario mediante redes neuronales". Trabajo final de máster, Universidad Politécnica de Valencia.

Taylor, J. W. y Buizza, R. (2003). "Using weather ensemble predictions in electricity demand forecasting." *International Journal of Forecasting* 19 (1), 57-70. [https://doi.org/10.1016/S0169-2070\(01\)00123-6](https://doi.org/10.1016/S0169-2070(01)00123-6)

Thompson, R. P. (1976). "Weather sensitive electric demand and energy analysis on a large geographically diverse power system. Application to short term hourly electric demand forecasting." *IEEE Transactions on Power Apparatus and Systems* 95 (1), 385-393.

<https://doi.org/10.1109/TPAS.1976.32116>

Valor, E.; Meneu, V. y Caselles, V. (2001). "Daily Air Temperature and Electricity Load in Spain." *Journal of Applied Meteorology* 40 (8), 1413-1421. [https://doi.org/10.1175/1520-0450\(2001\)040<1413:DATAEL>2.0.CO;2](https://doi.org/10.1175/1520-0450(2001)040<1413:DATAEL>2.0.CO;2)

Saeed, M. (2021). "A gentle introduction to sigmoid function."

<https://machinelearningmastery.com/a-gentle-introduction-to-sigmoid-function/>

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

PRESUPUESTO

Introducción:

A continuación, se detalla el coste del proyecto realizado, teniendo en cuenta las distintas fases del proyecto, el tiempo invertido en estas, así como los costes de los medios utilizados para el desarrollo del proyecto. Quedando dividido en dos 2 partes:

- Coste de mano de obra
- Coste de software y equipos

Los recursos evaluados para la realización del proyecto son los que a continuación se detallan, sin tener en cuenta costes de instalaciones, limpieza, climatización. Ya que estos costes se consideran amortizados.

Coste mano de obra:

La mano de obra para la realización del proyecto se ha calculado en base al personal que ha intervenido en su desarrollo, siendo estos el ingeniero Junior (alumno que ha desarrollado el proyecto), y el ingeniero industrial doctorado (tutor que dirigió el proyecto).

mano de obra	unidades (h)	Coste unitario (€/h)	coste (€)
Ingeniero Junior (alumno)			
búsqueda de información	70	30	2100
recopilación de datos	40	30	1200
desarrollo del modelo	80	30	2400
análisis de los resultados	30	30	900
redacción del documento	50	30	1500
Reuniones con el tutor	10	30	300
mano de obra ingeniero			8400
Tutor (doctor)			
Reuniones con el alumno	10	70	700
Corrección del trabajo	30	70	2100
mano de obra doctor			2800
TOTAL			€ 11,200

Tabla de costes 1. Mano de obra.

Diseño de un modelo de predicción de demanda eléctrica en España utilizando variables meteorológicas

Coste software y equipos:

Los Medios materiales considerados para el desarrollo del proyecto serían los equipos informáticos utilizados durante el proyecto, así como los distintos programas con los que se ha trabajado.

software y equipos	unidades	coste unitario (€)
Chuwi Lapbook pro	1	350
Sistema Operativo	1	145
Licencia MATLAB	1	250
Licencia Deep Learning Toolbox	1	100
Licencia office	1	70
TOTAL		€ 915

Presupuesto Total:

Para finalizar, a la hora de calcular el coste total del desarrollo del proyecto, se suman los recursos humanos junto a los recursos informáticos, con los que obtendríamos la base imponible (coste bruto del proyecto). A este monto se le habrá de sumar el 21% de IVA, quedando el coste final del proyecto calculado en € 14,659.15.

Presupuesto total	coste (€)
coste mano de obra	€ 11,200
coste software y equipos	€ 915
base imponible	€ 12,115
IVA (21%)	€ 2,544.15
Coste Final	€ 14,659.15