



## Trabajo Fin de Grado

Previsión del precio del mercado mayorista de la  
energía eléctrica mediante redes neuronales

Wholesale electricity market price forecast using  
neural networks

Autor/es

Daniel Alcalde Sierra

Director/es

José Luis Bernal Agustín

Escuela de Ingeniería y Arquitectura  
2021



# PREVISIÓN DEL PRECIO DEL MERCADO MAYORISTA DE LA ENERGÍA ELÉCTRICA MEDIANTE REDES NEURONALES

## RESUMEN

A través de este trabajo de fin de grado se ha realizado un modelo de predicción del precio de la electricidad, mediante la introducción de variables que ejercen influencia sobre él.

Se han estudiado los factores que pueden afectar con mayor fuerza la determinación del precio y se ha entrenado, con estas variables, una red neuronal que ha permitido crear este modelo y ejecutarlo a partir de una función de MATLAB.

Se ha realizado una primera estimación, la cual se ha ido mejorando con la adición de nuevas variables que han permitido reducir la diferencia entre los valores estimados obtenidos mediante el modelo y los valores reales. Todo esto ha sido estudiado con la utilización de numerosas gráficas comparando las curvas de los precios reales y estimados durante los distintos períodos de tiempo.

Gracias a este análisis se ha comprobado la gran influencia que llevan diversos factores en el precio de la electricidad, como es el caso de las cantidades de energía generadas por las distintas tecnologías de generación, la demanda de energía o el precio y el volumen del gas.

Por último, se ha comprobado si empleando las variables del modelo en distintas configuraciones temporales de entrenamiento y predicción que la inicial se consiguen alcanzar resultados de la misma utilidad. Para ello se ha realizado el entrenamiento con datos de las variables en época de COVID-19 (2020 y 2021), y posteriormente se ha realizado la predicción del precio en el año 2019, en el cual todavía no ejercía influencia la pandemia.

La realización de este estudio ha permitido demostrar que las variables utilizadas se comportan de un modo similar para cualquier configuración temporal, proporcionando una estimación que sigue fielmente la tendencia de los valores reales y que, por lo tanto, su utilización puede ser de gran utilidad en el futuro.



# INDICE DE CONTENIDO

<b>1. INTRODUCCIÓN .....</b>	<b>1</b>
1.1. OBJETIVO .....	1
1.2. ALCANCE DEL PROYECTO .....	1
1.3. ORGANIZACIÓN DE LA MEMORIA .....	2
<b>2. MERCADO ELÉCTRICO .....</b>	<b>4</b>
2.1. MERCADO MAYORISTA .....	4
3.2.1. MERCADO DIARIO .....	6
3.2.2. MERCADO INTRADIARIO .....	10
<b>4. SISTEMAS DE GENERACIÓN.....</b>	<b>11</b>
4.2. CENTRALES HIDRÁULICAS .....	12
4.3. CENTRALES EÓLICAS.....	13
4.4. CENTRALES SOLARES .....	13
4.5. CENTRALES TÉRMICAS CONVENCIONALES .....	14
4.6. CENTRALES NUCLEARES .....	14
4.7. CENTRALES DE CICLO COMBINADO .....	15
4.8. CENTRALES DE COGENERACIÓN .....	15
<b>5. DIFICULTAD PARA REALIZAR UNA BUENA PREDICCIÓN DEL PRECIO DE LA ELECTRICIDAD.....</b>	<b>16</b>
<b>6. IMPORTANCIA DE LA PREDICCIÓN DEL PRECIO DE LA ELECTRICIDAD .....</b>	<b>17</b>
<b>7. OBTENCIÓN DE VARIABLES .....</b>	<b>17</b>
<b>8. ENTRENAMIENTO DEL MODELO MEDIANTE REDES NEURONALES .....</b>	<b>18</b>
8.1. CASO 1. 12 VARIABLES .....	18
8.2. CASO 2. 13 VARIABLES .....	23
8.3. CASO 3. 15 VARIABLES .....	30
8.4. CASO 4. 15 VARIABLES. DISTINTA CONFIGURACIÓN DE ENTRENAMIENTO Y PREDICCIÓN.....	39
<b>9. CONCLUSIONES .....</b>	<b>48</b>
<b>10. BIBLIOGRAFÍA.....</b>	<b>53</b>
<b>11. INDICE DE FIGURAS.....</b>	<b>55</b>
<b>12. INDICE DE GRÁFICAS.....</b>	<b>57</b>
<b>13. INDICE DE TABLAS .....</b>	<b>60</b>
<b>14. ANEXOS.....</b>	<b>61</b>
14.1. CONCEPTO DE RED NEURONAL.....	61
14.2. ENTRENAMIENTO DEL MODELO MEDIANTE REDES NEURONALES .....	62



14.2.1. CASO 1. 12 VARIABLES. 100 NEURONAS OCULTAS .....	64
14.2.2. CASO 2. 13 VARIABLES. 300 NEURONAS OCULTAS .....	69
14.2.3. CASO 3. 15 VARIABLES. 100 NEURONAS OCULTAS .....	73
14.2.4. CASO 4. 15 VARIABLES. 100 NEURONAS OCULTAS. DISTINTA CONFIGURACIÓN TEMPORAL.....	77
14.3. FUNCIONES EMPLEADAS PARA LA ESTIMACIÓN.....	81
14.3.1. FUNCIÓN CASO 1. 12 VARIABLES .....	82
14.3.2. FUNCIÓN CASO 2. 13 VARIABLES .....	83
14.3.3. FUNCIÓN CASO 3. 15 VARIABLES .....	84
14.3.4. FUNCIÓN CASO 4. 15 VARIABLES. DISTINTA CONFIGURACIÓN TEMPORAL .....	85



# 1. INTRODUCCIÓN

## 1.1. OBJETIVO

La finalidad principal de este proyecto es la estimación del precio de la electricidad en función de distintas variables que pueden ejercer influencia sobre él, optimizando un modelo que pueda ser de utilidad en el futuro.

Estudiar cuáles son las variables más influyentes para la determinación de ese precio, cómo determinarlas y explicar por qué han sido elegidas.

Realizar conclusiones sobre los resultados obtenidos en las predicciones. Observar cuáles son las franjas temporales en las que se obtiene una mejor predicción y en cuáles ocurre lo contrario, y explicar los posibles motivos que provocan estas diferencias.

Realizar un entrenamiento de la red con distinto orden cronológico de entrenamiento y predicción, utilizando las mismas variables, y comprobar si el uso de las variables estudiadas tiene validez para cualquier periodo de tiempo.

Es de importancia, además, estudiar las posibles aplicaciones de este proyecto en el futuro. Quiénes podrían darle un uso adecuado y cómo se podría mejorar para la obtención de mejores resultados.

## 1.2. ALCANCE DEL PROYECTO

La electricidad ha estado siempre presente en el mundo. Desde el hombre primitivo ya se percibía electricidad mediante fenómenos visibles como los relámpagos. Hoy en día, además de ser un servicio, es una necesidad básica que nos permite realizar una gran cantidad de actividades. Comprendemos electricidad como un conjunto de fenómenos físicos vinculados a la presencia y transmisión de cargas eléctricas. [1]

Es una fuente muy versátil y transformadora, capaz de aprovecharse para diversos usos como generar luz (flujo eléctrico en el vacío), generar calor (paso de los electrones por un conductor), generar movimiento (uso de motores y rotores), ser almacenada (mediante pilas o baterías) o transmitir datos (mediante sistemas electrónicos, circuitos eléctricos o redes de cableado). [2]

Actualmente, la vida sin electricidad sería algo impensable. Nuestra forma de ver el mundo va unida de forma muy directa al uso de la electricidad. Obviamente, no se puede decir que seríamos incapaces de vivir sin electricidad, pero se encuentra tan presente actualmente para nuestra vida cotidiana que sería muy complicado llenar su vacío.

El uso de la electricidad se extiende para prácticamente todos los ámbitos, desde iluminar cuando no hay suficiente luz, hasta proporcionar suministro en hospitales que permitan salvar la vida de gran cantidad de personas cada día. Para muchas de las cosas que realizamos diariamente es imprescindible la electricidad.



En nuestras casas, para abastecernos eléctricamente, contratamos tarifas buscando una oferta que nos ofrezca la cantidad de energía que necesitamos. Sin embargo, todas estas tarifas tienden a variar con el tiempo. El precio de la electricidad no es siempre el mismo y está en constante cambio. Esto se debe a numerosos factores, de los cuales muchos no se pueden controlar. Pueden ser factores puramente energéticos, factores económicos o incluso aspectos medioambientales. [18]

Realizar una buena predicción de estos precios puede suponer un ahorro enorme para numerosas empresas e instituciones, permitiéndoles anteponerse a futuras irregularidades que puedan suponer efectos negativos para los intereses de estas. La utilización de estas herramientas permite así a organismos generadores de energía establecer pautas que les permitan realizar ofertas de venta de la energía que producen en el momento adecuado. Del mismo modo que, a los principales consumidores y comercializadores, les permitirá conocer el momento idóneo para realizar las ofertas de compra y saber cuándo, por el contrario, la compra de energía podría suponerles pérdidas.

Para realizar esta estimación se han utilizado las redes neuronales artificiales. Esta herramienta permite el establecimiento de una relación, lineal o no lineal, entre distintas salidas y entradas. Su funcionamiento se inspira en el sistema nervioso humano, proporcionando así ventajas como la capacidad de aprendizaje adaptativo, la capacidad de organizarse automáticamente y la posibilidad de funcionamiento en paralelo en tiempo real.

### 1.3. ORGANIZACIÓN DE LA MEMORIA

Para poder entender la importancia de una buena predicción, es necesario conocer el funcionamiento del mercado eléctrico. El conocimiento de cómo se obtiene el precio de la electricidad y de quienes participan en su consecución es de vital importancia.

La obtención del precio marginal depende de todos los organismos que participan en el mercado, tanto compradores como vendedores, y este varía durante todas las horas del día. Es el resultante de las ofertas de compra y de venta que se realizan durante cada una de esas horas.

Por ello, no todos los vendedores (sistemas generadores) van a ofertar a un mismo precio, dependiendo de los costes que suponga la obtención del determinado tipo de energía en cada caso. Del mismo modo, no todos los compradores van a ofertar a un mismo precio, en función de la necesidad que tengan o no de obtener esa energía. Tanto compradores como vendedores, sin embargo, tienen obligación de participar en el mercado eléctrico.

Es de importancia conocer los distintos tipos de sistemas de generación de energía eléctrica, y hacerse una idea del funcionamiento de cada uno de ellos, los costes que suponen su mantenimiento y su producción, y por lo tanto la importancia que tienen en el mercado eléctrico. Esto nos proporciona una idea de cómo afectaría un déficit de alguno de los tipos de generación al precio de la energía eléctrica, proporcionando una valiosa información a la hora de realizar la predicción.



Del mismo modo, es conveniente el conocimiento de la herramienta utilizada para realizar la predicción, las redes neuronales. En los anexos se encuentran los pasos seguidos para la realización del entrenamiento de la red mediante la aplicación, así como el resumen y los resultados más característicos obtenidos en cada uno de los entrenamientos. Se muestran además las funciones proporcionadas por la aplicación de MATLAB, que permiten la ejecución de los datos para realizar la predicción de los precios (una vez entrenada la red).

En esta memoria se encuentran explicados los pasos que se han seguido para la realización del estudio. Numerosas gráficas que permiten comparar los valores obtenidos en la estimación con respecto a los valores reales. A partir de los estudios realizados, se han podido obtener conclusiones de la calidad de la estimación, y se ha podido saber en qué medida es necesaria la introducción de nuevas variables para mejorar el entrenamiento y adquirir mejores resultados.



## 2. MERCADO ELÉCTRICO

La electricidad es producida en centrales encargadas de obtener energía eléctrica a partir de energías primarias. Estas energías primarias pueden ser renovables o no renovables. Las energías renovables provienen de fenómenos como el viento, la radiación solar, el agua o la biomasa vegetal o animal. Se basan en la utilización de recursos naturales inagotables capaces de renovarse ilimitadamente, en vez de combustibles fósiles. Las no renovables, sin embargo, son limitadas y disminuyen a medida que se consumen. Al disminuir las reservas es más difícil su extracción y se produce un aumento en su coste. Energías no renovables pueden ser el petróleo, el carbón, el gas natural o la energía nuclear.

Las empresas propietarias (total o parcialmente) de las diferentes centrales venden la energía generada a las compañías comercializadoras. Cuando la energía ha sido tratada y transformada en electricidad, se envía por vías elevadas o subterráneas desde las centrales hasta las subestaciones. Estas subestaciones suelen estar localizadas al aire libre, en lugares cercanos a las centrales o en la periferia de las ciudades. Si son pequeñas pueden encontrarse también dentro de un edificio en el interior de la ciudad.

Desde las subestaciones se envía la electricidad a los hogares más próximos por medio de las compañías distribuidoras. Estas empresas se encargan, además, de solucionar las averías ocasionadas. Las empresas comercializadoras son las encargadas de comprar la energía a las empresas de generación y venderla a los consumidores (facturas), mediante la realización de diversas tarifas y ofertas.

El mercado eléctrico español comenzó en el año 1998 con la liberalización del sector eléctrico. En 2007, el sistema eléctrico español se integró con el portugués para formar el Mercado Ibérico de Electricidad, MIBEL, que forma parte del Mercado Interior de la Energía de la Unión Europea, que surgió tras la liberalización de las actividades de generación y comercialización de energía eléctrica.

### 2.1. MERCADO MAYORISTA

El mercado mayorista de energía eléctrica es el encargado de comprar y vender grandes cantidades de energía eléctrica. En el caso de España, este mercado está liberalizado, es decir, todo el mundo puede comprar y vender energía eléctrica. El precio depende de la oferta y la demanda del producto. Si existe una gran oferta y una baja demanda los precios serán más bajos, mientras que si existe menor oferta y mayor demanda los precios aumentarán.

Los operadores de la red de transporte se encargan de garantizar el funcionamiento del sistema y la gestión técnica de la red. En el caso de España, el operador de red es la Red Eléctrica de España (REE), mientras que en Portugal se encuentra las Redes Energéticas Nacionais (REN). La entidad encargada de gestionar el mercado mayorista MIBEL es el Operador del Mercado Ibérico de Energía-Polo Español (OMIE), el cual está conformado por el mercado diario, los mercados intradiarios de subastas y el mercado intradiario continuo.

De esta manera, en los mercados spot, diario e intradiario se obtienen dos precios, uno para el sistema eléctrico español y otro para el sistema portugués, que en ausencia de congestiones en

las interconexiones son iguales. Esto se debe a la aplicación del método del market splitting (o acoplamiento del mercado) cuyo objetivo es garantizar la máxima utilización de la capacidad comercial y que la normativa comunitaria considera preferente.

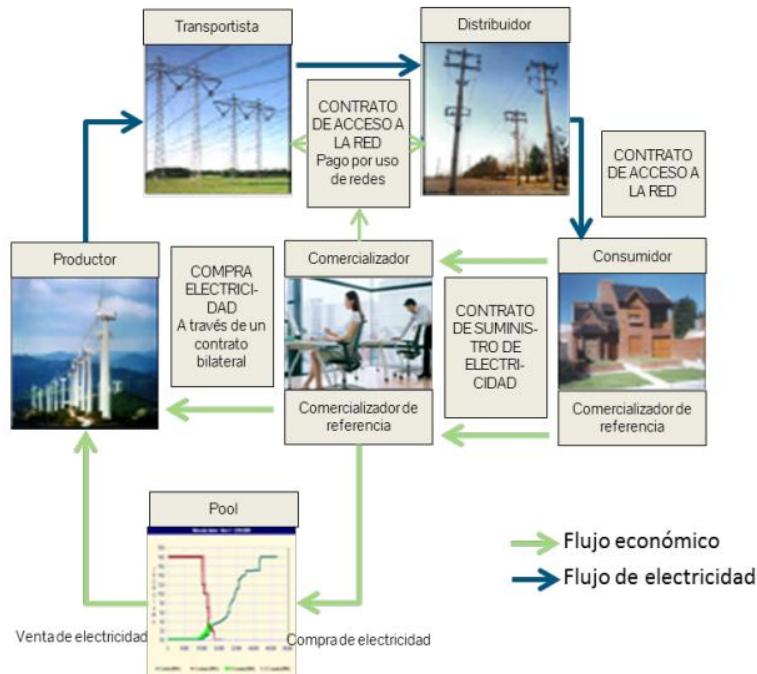


Figura 1. Descripción de la organización del sistema eléctrico en España.  
[11]

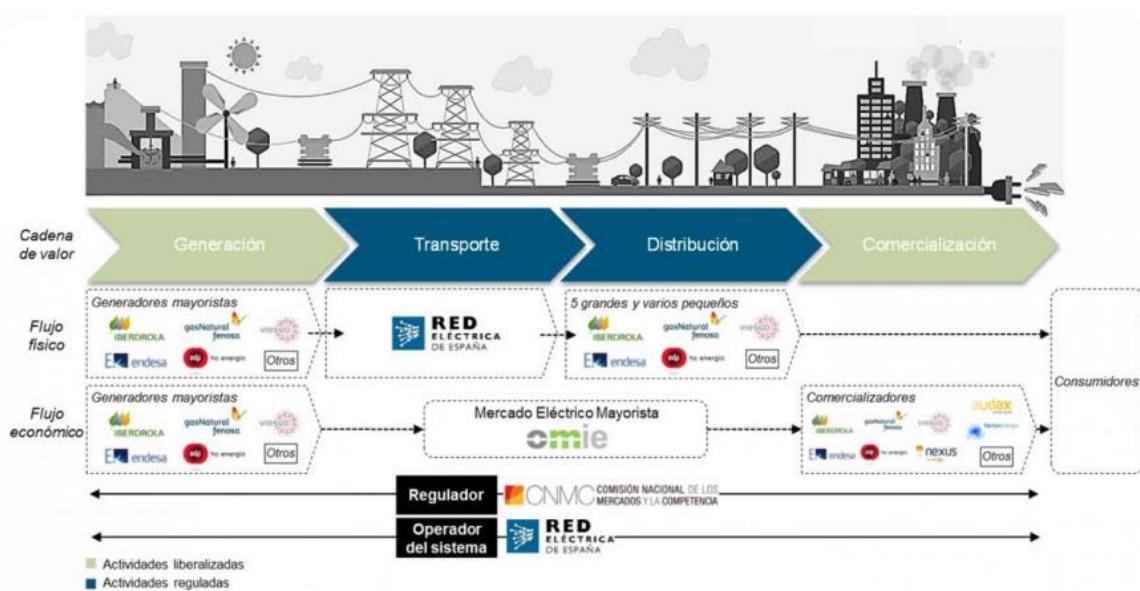


Figura 2. Actividades reguladas y liberalizadas del Sector Eléctrico en España. [11]

En el mercado mayorista se determinan el precio de la energía en cada una de las horas del día y la cantidad de energía que producirá cada central eléctrica.



Se considera agente del mercado a toda persona física o jurídica que intervenga en las transacciones económicas que tienen lugar en el mercado de producción de energía eléctrica, comprando o vendiendo electricidad. Son agentes del mercado los productores de energía eléctrica, los comercializadores (intermediarios entre el mercado mayorista y el cliente), los consumidores directos en el mercado y los representantes.

Tanto el Operador del Mercado como el Operador del Sistema tienen gran importancia para el correcto funcionamiento del mercado. Se trata de sociedades mercantiles que intervienen en las transacciones económicas del mercado.

La empresa OMI-POLO ESPAÑOL, S.A. (OMIE) [16] actúa como operador del mercado, siendo la responsable de la gestión económica del sistema. Por otra parte, la empresa Red Eléctrica de España, S.A., actúa como operador del sistema, siendo así la responsable de la gestión técnica del mismo, encargándose de que la energía eléctrica fluya adecuadamente por la red eléctrica.

En cuanto a las formas de contratación más habituales, cabe destacar dos de ellas, aunque no son las únicas.

- Mediante la competencia entre los productores y los compradores de electricidad, a través de los mercados de energía (también llamado “pool”), gestionados por el Operador del Mercado, y los mercados de operación técnica, gestionados por el Operador del Sistema.
- Mediante contratos bilaterales que se establecen directamente entre los generadores y los consumidores cualificados. Los términos económicos se acuerdan libremente por ambas partes, pero su ejecución debe ser comunicada al Operador del Mercado.

Los mercados de energía más importantes son el mercado diario y el mercado intradiario, y están gestionados por el Operador del Mercado (parte económica) y el Operador del Sistema (parte técnica).

### 3.2.1. MERCADO DIARIO

El mercado diario tiene como objetivo llevar a cabo las transacciones de energía eléctrica para cada una de las horas del día siguiente, mediante la presentación de ofertas de venta y adquisición por parte de los agentes del mercado. En él, los generadores actúan como vendedores, mientras que los comercializadores y los clientes cualificados actúan como compradores. Los agentes externos pueden ser tanto compradores como vendedores, según se trate de importaciones o exportaciones de electricidad.

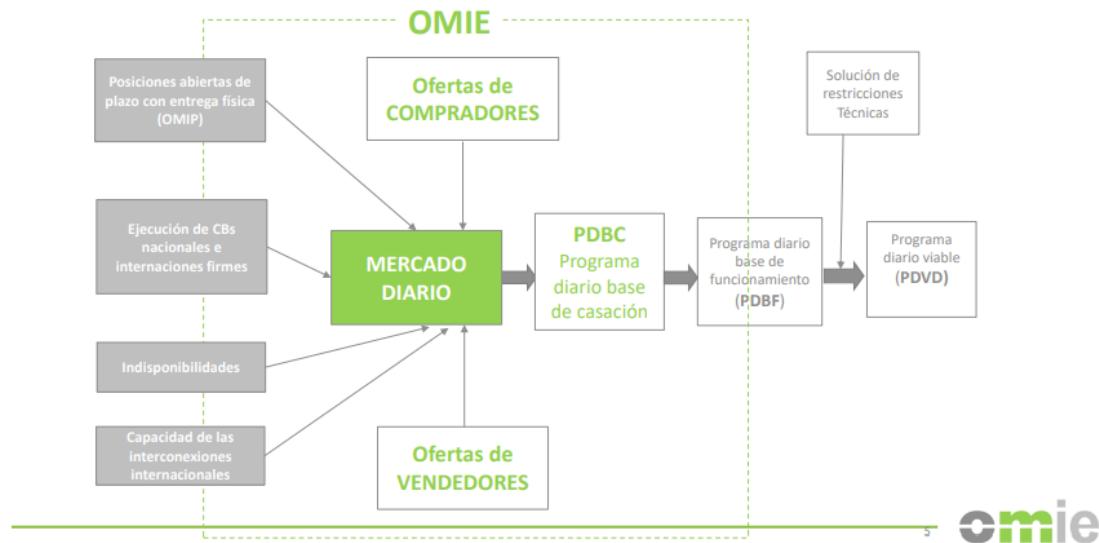


Figura 3. Mercado diario en MIBEL [19]

El mercado diario es el principal mercado de contratación de electricidad en la Península Ibérica y funciona los 365 días del año. Como en el resto de la Unión Europea, se trata de un mercado marginalista en el que el precio y el volumen de contratación en cada hora se establecen a partir del punto de equilibrio entre la oferta y la demanda.

Para realizar la casación se utiliza un algoritmo europeo denominado EUPHEMIA. Una vez finalizado el proceso, OMIE comunica de forma pública los precios y la energía que se producirá y comprará en cada una de las horas del día siguiente en el mercado Ibérico. El algoritmo de casación maximiza el beneficio conjunto de los productores y los consumidores para el conjunto de países europeos, cumpliendo con las restricciones del sistema. [20]

Todas las unidades de producción disponibles que no estén afectadas a un contrato bilateral físisco tienen la obligación de presentar ofertas para el mercado diario. También podrán presentar ofertas de venta de energía los agentes comercializadores no residentes autorizados a ello.

Cada unidad de venta debe decidir la cantidad y precio a ofertar. La cantidad puede ser cualquiera, siempre que no supere el límite de su capacidad de producción (no comprendido en contratos bilaterales), mientras que el precio dependerá de la tecnología de generación. Los vendedores ofertan a diferentes precios incrementales. A su vez, cada unidad de compra debe decidir la cantidad y precio a ofertar, y realizan las ofertas de compra a diferentes precios decrementales.

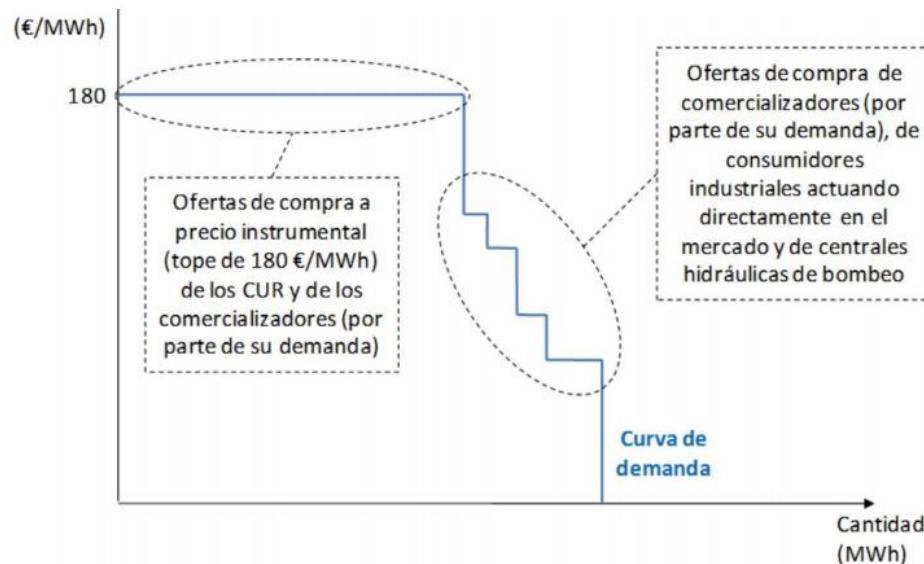


Figura 4. Curva de ofertas de compra. [11]

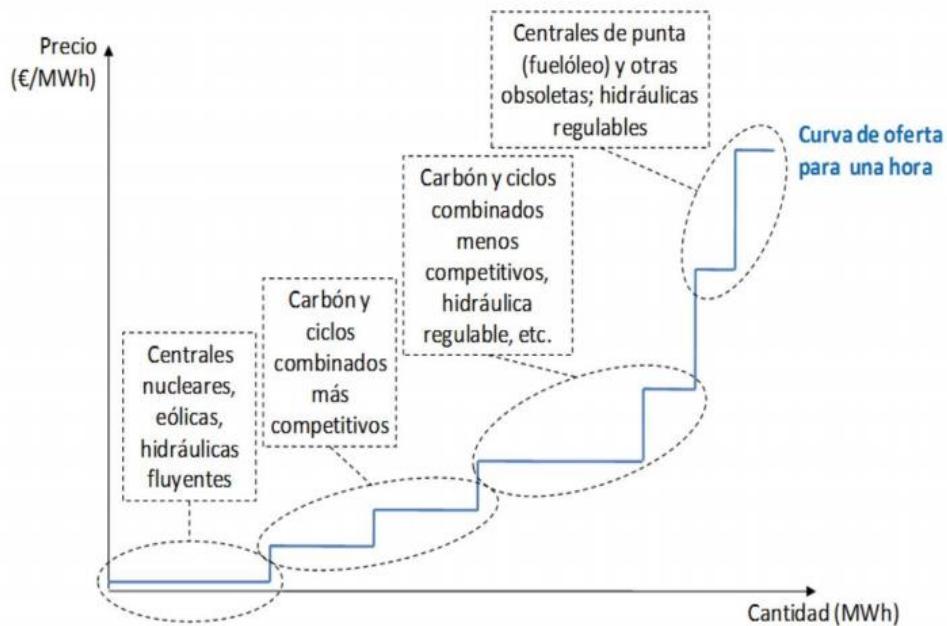


Figura 5. Curva de ofertas de venta. [11]

Una vez agregadas todas las ofertas de venta de todas las tecnologías y todas las ofertas de compra de todos los consumidores, se generan las curvas agregadas formadas por esas ofertas. El punto de corte entre ambas curvas (punto de equilibrio entre la oferta y la demanda) establece la energía casada, y el precio de la hora (precio marginal). Esta oferta se envía antes de las 12:00 del día anterior.



Figura 6. Ejemplo de curva agregada. [20]

La estrategia de compra o venta dependerá de la necesidad que tenga cada empresa de adquirir o vender más o menos cantidad de energía eléctrica, teniendo en cuenta la obligatoriedad de realizar ofertas de venta y compra.

- Los compradores que realizan ofertas a precios muy altos necesitan adquirir energía eléctrica de forma obligatoria y ofertan a elevados precios para asegurarse la compra.
- Los compradores que ofertan a precios medios comprarán solo si el precio del mercado lo permite (si su oferta supera el precio marginal).
- Los compradores que ofertan a precios bajos no tienen necesidad de comprar.
- Si los vendedores ofertan a precios muy bajos (como centrales nucleares), se debe a que ya están amortizados, no tienen elevados costes de generación y les interesa vender toda la energía eléctrica generada, por ello subastan primero. Es el caso por ejemplo de las centrales hidráulicas fluyentes o las centrales eólicas, que una vez obtienen la energía tienen la necesidad de venderla para que no sea desaprovechada.
- El caso de los centros de generación que utilizan combustibles fósiles como gas y carbón, al tener costes de generación mayores, realizarán las ofertas de venta después y a mayor precio.
- Si los vendedores ofertan a precios muy elevados significa que no tienen interés en vender y ofertan por obligación, como puede ser el caso de empresas que generen energía eléctrica para el consumo propio.

Para aquellos que no han conseguido ni comprar ni vender en el mercado diario existe la posibilidad de volver a intentarlo en el mercado intradiario (sólo si ha ofertado antes en el mercado diario).

En estos momentos las ofertas se realizan y gestionan considerando el mercado ibérico de electricidad (España y Portugal). En un futuro se pretende que el ámbito sea europeo.

Las ofertas económicas de venta de energía eléctrica que los vendedores presenten al operador del mercado pueden ser simples o incorporar condiciones complejas en razón de su contenido. Las ofertas simples son ofertas económicas de venta de energía que los vendedores presentan para cada periodo horario y unidad de producción de la que sean titulares con expresión de un precio y de una cantidad de energía. Las ofertas que incorporan condiciones complejas de venta

son aquellas que, cumpliendo con los requisitos exigidos para las ofertas simples, incorporan alguna condición técnica o económica.

### 3.2.2. MERCADO INTRADIARIO

El mercado intradiario es un mercado de ajustes que consta de seis sesiones. Su cometido es que cada agente pueda ajustar con mayor precisión la energía negociada en el mercado diario, ya que se dispone de más información que en la sesión de este. Por ejemplo, si se produce una avería en un grupo generador, este puede recomprar la energía que ha vendido en la sesión del mercado diario.

En el caso de los compradores en el mercado diario, para poder acudir al mercado intradiario tienen que haber participado en la correspondiente sesión del mercado diario o en la ejecución de un contrato bilateral físico. No es obligatoria la presentación de ofertas, pero todos los agentes deben indicar la causa que motiva su oferta de ajuste. [21]

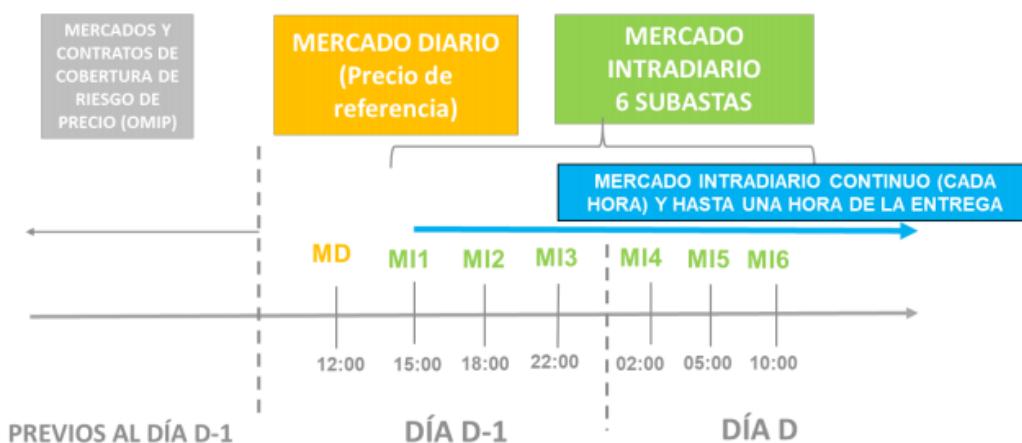


Figura 7. Desarrollo temporal del mercado [19]

Los agentes podrán presentar tanto ofertas de venta de energía como de adquisición de la misma, para una unidad de producción o de adquisición y podrán enviarlas a partir de la apertura de la sesión hasta el cierre de esta. Las ofertas, además, podrán ser simples o incorporar condiciones complejas. El empleo de condiciones complejas nunca permitirá la aceptación de la oferta por encima de la que se obtendría en caso de no utilizarse la misma. Todas las ofertas de energía deberán incorporar precio, pudiendo ser cero €/MWh.

El mercado intradiario permite a los agentes del mercado corregir situaciones no deseadas hasta antes del tiempo real. Las restricciones técnicas se resuelven mediante la retirada de las ofertas de compra y venta que provocan la misma. REE, como Operador del Sistema (OS), gestiona los mercados de ajuste, necesarios para mantener el sistema eléctrico en equilibrio y con un nivel de seguridad adecuado.

Todos estos procesos permiten llevar a cabo el control y la operación del sistema eléctrico en tiempo real, gestionando la red de transporte y coordinándola con la generación, de manera que se garantice en todo momento la continuidad y seguridad del suministro eléctrico.

Existen además otras opciones aparte de los mercados diario e intradiario, como es el caso de los contratos a plazo (OTC, OMIP), que reflejan el precio del mercado esperado a futuro y se determina también por el cruce entre las curvas de oferta y demanda, intercambiando contratos previos a la generación y consumo de la energía. [11]

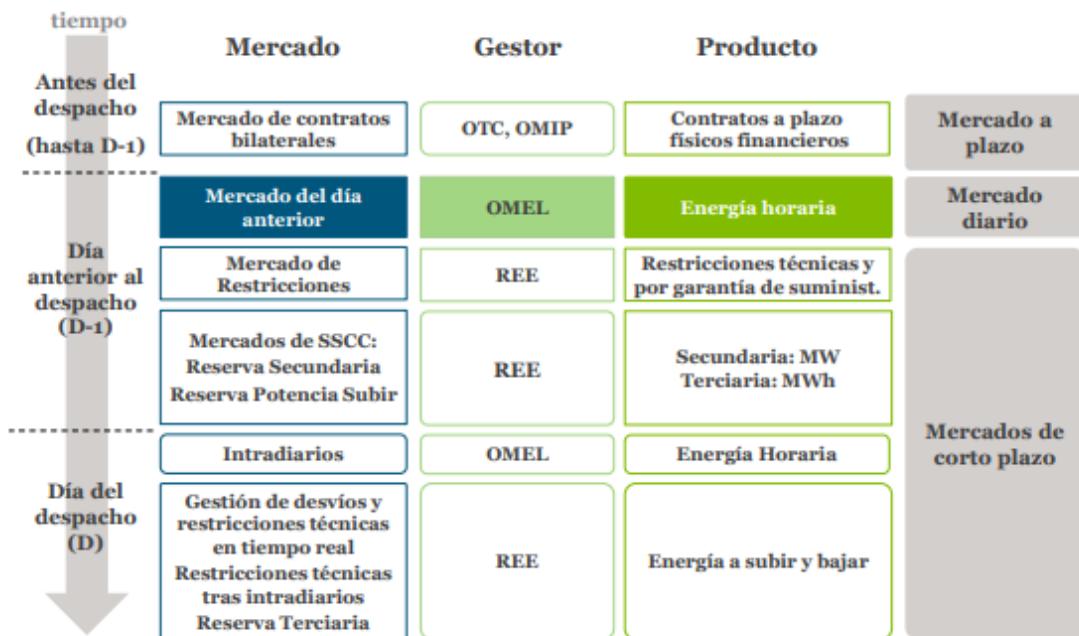


Figura 8. Secuencia de mercados de energía eléctrica [11]

## 4. SISTEMAS DE GENERACIÓN

El abastecimiento convencional de la electricidad a los consumidores se realiza a través de redes de transporte y distribución, las cuales están conectadas a las distintas centrales de generación. Estas centrales deben cumplir principalmente tres requisitos que impone la red eléctrica: disponibilidad y fiabilidad de generación, capacidad de seguimiento de carga y seguimiento de costes de generación.

Las centrales de generación eléctrica en la actualidad son básicamente de dos tipos tecnológicos distintos, que a su vez utilizan fuentes energéticas primarias: renovables o no renovables.

La generación de energía eléctrica va a tener un papel fundamental a la hora de determinar el precio de la electricidad en cada momento. Según cual sea la fuente generadora predominante en el mercado en cada momento el precio tiende a variar. Dependiendo del origen de la electricidad, los costes en su generación serán mayores o menores, así como otros factores

como la posibilidad de almacenaje de energía o los costos de las instalaciones generadoras. Por lo tanto, como ya se ha comentado anteriormente, todos estos factores van a tener una influencia sobre el precio de casación del mercado eléctrico.

El caso, por ejemplo, de las centrales de generación renovable (eólica, hidráulica y solar) consta de costes variables muy bajos, incluso nulos en algunos casos. Tienen costes de inversión elevados, pero una vez se encuentran en uso, proporcionan gastos mínimos de funcionamiento. Ocurre lo mismo en el caso de las centrales nucleares, que tienen también de costes variables bastante bajos. Además, detener y devolver el funcionamiento a una central nuclear no es fácil ni rentable, pudiendo suponer hasta pérdidas económicas. Todos estos tipos de centrales realizaran ofertas a precios más bajos en el mercado spot, ya que les interesa vender cuanto antes.

Otros tipos de centrales como las centrales térmicas o las centrales de ciclo combinado realizarán ofertas de venta a mayor precio debido a que los costes de generación son mayores que en el caso de las mencionadas anteriormente.

Mediante la gráfica mostrada en la figura 5, se puede observar a qué precio oferta cada tipo de central generadora. Según la época del año o las condiciones climatológicas, predominará la generación de energía eléctrica de un tipo de central u otro, lo que conllevará un constante cambio en el precio de ésta.

## 4.2. CENTRALES HIDRÁULICAS

Se trata de centrales capaces de transformar la diferencia de energía potencial de un volumen de agua situado a una determinada altura geométrica respecto a otra cota de nivel más bajo, a la cual se envía el agua. Están situadas en los cauces de los ríos o aprovechando la disposición específica de un lago. El agua en su caída impulsa una turbina hidráulica que arrastra un generador eléctrico. Proporcionan una respuesta a las demandas de la red muy rápida ya que tienen gran disponibilidad siempre que exista recurso hidráulico. [5]

Según el régimen de flujos de la central hidráulica, se puede distinguir principalmente entre:

- Centrales de agua fluyente. Capaces de utilizar parte del flujo de un río para generar energía eléctrica operando de forma continua al no disponer de embalse.
- Centrales de embalse. Cuentan con una o más presas que forman lagos donde se almacena un volumen de agua por encima de las turbinas. Exigen mayor inversión de capital que el caso de las de agua fluyente.
- Centrales de bombeo o reversibles. Disponen de dos embalses situados a distintos niveles. Con demanda diaria de energía máxima trabajan como una central hidroeléctrica convencional, pero durante las horas del día de menor demanda, el agua es bombeada al embalse superior para poder repetir el ciclo productivo.

Los costes variables de generación de este tipo de centrales, como ocurre con el resto de centrales de generación renovable (solar y eólica) son muy bajos.

La energía eléctrica obtenida a partir de las centrales hidráulicas, sobretodo en el caso de las centrales de agua fluyente, ejerce un efecto reductor sobre el precio de la electricidad. Tal y como es generada, la energía eléctrica tiene que ser consumida. Este hecho provoca que este

tipo de centrales oferten a precios muy bajos en el mercado debido a su necesidad de vender urgentemente. En el caso de las centrales de bombeo, los costes de generación son mayores, pero aseguran una mayor disponibilidad de la producción.

### 4.3. CENTRALES EÓLICAS

La energía eólica es la energía que se obtiene del viento. Se trata de un tipo de energía cinética producida por el efecto de las corrientes de aire. Esta energía la podemos convertir en electricidad a través de un generador eléctrico. Es una energía renovable, limpia, que no contamina y que ayuda a reemplazar la energía producida a través de los combustibles fósiles. La disponibilidad energética es intermitente, dependiendo de las distintas épocas del año y de sus situaciones meteorológicas.

La energía eólica se obtiene al convertir el movimiento de las palas de un aerogenerador en energía eléctrica. Un aerogenerador es un generador eléctrico movido por una turbina accionada por el viento. Sus predecesores son los molinos de viento. Un aerogenerador puede alcanzar una capacidad de energía similar a la de 1.000 kg de petróleo.

Estas instalaciones utilizan la red eléctrica como su almacén, pero en la actualidad no pueden regular el sistema ni dar respuesta a las variaciones de demanda. Si su participación en la generación eléctrica supera el 10% de la demanda en la red, necesitan el apoyo de otros sistemas de generación para garantizar el suministro en cualquier circunstancia y dar estabilidad a la red eléctrica. [6]

Según el artículo de investigación de Dyna Energía, ‘Interrelación de las variables que inciden en el mercado diario de la electricidad’, se puede afirmar que “la generación de la eólica tiene una clara correlación inversa (-0.48) con el precio de la electricidad, a medida que crece la producción eólica disminuye el precio del mercado. Este efecto reductor que produce la eólica sobre los precios del mercado eléctrico es debido a su importante peso relativo (23 GW, un 22% del total de la potencia instalada en España) y a su bajo coste de generación frente a las tecnologías convencionales”. [17]

### 4.4. CENTRALES SOLARES

La energía solar es una energía renovable obtenida a partir de la radiación electromagnética del Sol, que es una fuente natural e inagotable. Es una de las fuentes de energía renovable más fácil de producir, especialmente la solar fotovoltaica (paneles). Este hecho hace que se extienda su uso en zonas con abundantes horas de sol (como es el caso de España, aunque todavía existe mucho margen de mejora).

Dependiendo del origen y procesamiento de la energía solar, los principales tipos son:

- Energía solar térmica. Es la encargada de aprovechar la energía del sol para producir calor, que posteriormente se usa como fuente de energía tanto a nivel doméstico como industrial, transformando esta energía en mecánica y, a partir de ella, en energía eléctrica.

- Energía solar fotovoltaica. Se encarga de obtener directamente la energía eléctrica a partir de la radiación solar. Esto se consigue gracias a la instalación de paneles fotovoltaicos, que cuentan con células de silicio que transforman la luz y calor del sol en electricidad. Al igual que la energía solar térmica, estos paneles o placas solares pueden instalarse tanto a nivel doméstico, como en grandes instalaciones. [10]

Entre sus ventajas cabe destacar que es ecológica e inagotable, no produce residuos, el impacto en el medio es bajo y contribuye a la generación de empleo y al desarrollo sostenible. No genera costes variables de generación, lo que provoca que estas centrales oferten a precios muy bajos. En caso de una abundante producción de este tipo de energía en un determinado periodo de tiempo, se contribuye a la reducción de su precio marginal en el mercado para esa franja horaria.

## 4.5. CENTRALES TÉRMICAS CONVENCIONALES

Las centrales térmicas convencionales son aquellas que utilizan combustibles fósiles (gas natural, carbón o fueloil) para generar energía eléctrica. Para ello utilizan un ciclo termodinámico de agua-vapor. Se les llama “convencionales” para poder diferenciarlas de otros tipos de centrales térmicas como las de ciclo combinado o las nucleares.

El combustible es quemado en una caldera y produce energía térmica. Esta energía se utiliza para calentar agua, que se transforma en vapor a una presión muy elevada. Ese vapor se utiliza para hacer girar una gran turbina, convirtiendo la energía calorífica en energía mecánica. Esta energía mecánica se transforma finalmente en energía eléctrica mediante un alternador. La electricidad pasa por un transformador para aumentar su tensión y permitir transportarla reduciendo las pérdidas por Efecto Joule. El vapor que sale de la turbina es enviado a un condensador para convertirlo en agua y devolverlo a la caldera para empezar un nuevo ciclo de producción de vapor. [9]

Las centrales térmicas convencionales tienen efectos sobre el medioambiente, tanto por la emisión de residuos a la atmósfera como por la transferencia térmica. Por este motivo, estas centrales poseen chimeneas de gran altura que reducen la influencia negativa de estas partículas en el aire. Además también constan de filtros de partículas que retienen gran parte de estas, para evitar su salida al exterior. En comparación con la mayoría de las otras centrales, las centrales térmicas tienen unos costes de generación variables considerablemente más elevados, lo que supone que sus ofertas de venta sean considerablemente mayores que en el caso de las centrales renovables o las nucleares, que prácticamente no tienen costes de generación.

## 4.6. CENTRALES NUCLEARES

Una central nuclear es una instalación industrial en la que se genera electricidad a partir de la energía térmica producida mediante reacciones de fisión en la vasija de un reactor nuclear.

El componente principal de una central es el reactor. En el reactor se aloja el combustible nuclear y permite iniciar, mantener y detener, de modo controlado, reacciones nucleares de fisión que liberan grandes cantidades de energía térmica. Esta energía térmica liberada es utilizada para el



calentamiento del agua hasta convertirla en vapor a alta presión y temperatura. Este vapor hace girar una turbina conectada a un generador que transforma la energía mecánica del giro de la turbina en energía eléctrica.

Aunque este principio básico de funcionamiento es relativamente sencillo, la tecnología aplicada es muy compleja. Esto se debe a los fenómenos físicos que intervienen, las grandes potencias alcanzadas, los requisitos técnicos y las estrictas medidas de seguridad necesarias para garantizar, en todo momento, tanto la seguridad de los trabajadores y de la población como la protección del medio ambiente. [8]

Además de producir una gran cantidad de energía eléctrica, uno de los principales problemas de estas centrales se debe a la generación de residuos nucleares que hay que almacenar en depósitos especializados. Por otra parte, no produce contaminación atmosférica de gases derivados de la combustión que producen el efecto invernadero, ya que no se utilizan combustibles fósiles durante el proceso.

Como se ha comentado anteriormente, al igual que las centrales generadoras renovables, las centrales nucleares tienen unos costes variables de generación muy pequeños y permiten que estas centrales oferten a precios muy bajos en el mercado eléctrico.

#### 4.7. CENTRALES DE CICLO COMBINADO

Son plantas que producen energía eléctrica mediante un generador que es accionado mediante una turbina de combustión. El principal combustible utilizado en estas centrales es el gas natural.

Los gases de escape que se generan en la combustión son aprovechados para el calentamiento del agua en una caldera de recuperación, produciendo vapor. Este vapor se aprovecha para el accionamiento de una segunda turbina, que puede accionar el mismo generador que la de gas u otro distinto.

La disponibilidad de grandes volúmenes de gas natural favorece el uso de este tipo de centrales. Además, pueden ser usadas con otros combustibles como gasóleo, GLP o carbón gasificado. Su disponibilidad es elevada y trabajan a altos rendimientos, con buen factor de carga. Producen además menos emisiones de CO<sub>2</sub> por KWh producido. [7]

#### 4.8. CENTRALES DE COGENERACIÓN

Las centrales de cogeneración son aquellas capaces de producir simultáneamente dos o más tipos de energía. Normalmente, las energías que se generan son eléctrica y térmica, aunque también se pueden generar otros tipos de energía, como la mecánica. Esto permite que gran parte de la energía pueda ser utilizada simultáneamente, implicando proximidad de la planta generadora con los consumos, al contrario de los sistemas convencionales, en los cuales, aunque se desprende calor, este no es aprovechado y se expulsa al medioambiente. El objetivo de la cogeneración es que se pierda la menor cantidad de energía posible. [4]



## 5. DIFICULTAD PARA REALIZAR UNA BUENA PREDICCIÓN DEL PRECIO DE LA ELECTRICIDAD

La electricidad es uno de los aspectos más importantes para el desarrollo económico e industrial de la sociedad. Sin embargo, estimar un precio que se asemeje a la realidad no es tarea fácil. La predicción de precios de la electricidad difiere respecto a la predicción de precios en otros tipos de mercados debido a particularidades propias de la electricidad.

La generación de electricidad es un factor muy importante en la actualidad, ya que debe atender a la demanda instantánea de forma efectiva. El almacenaje de energía es un proceso que supone grandes inversiones económicas y es por ello que suministrar de forma instantánea la electricidad evita pérdidas considerables. Esto produce una importante diferencia con respecto a la mayoría de los mercados tradicionales.

Se producen frecuentemente numerosas variaciones de demanda debidas a la diversidad de tecnologías de generación, cada una con distintos costes de producción. Además, los avances en el uso de la energía renovable y el aumento de la eficacia de las tecnologías existentes suponen importantes incrementos en las variaciones del precio.

El consumo eléctrico, además, puede variar por multitud de aspectos, lo que dificulta realizar una estimación exacta. Los cambios pueden deberse a numerosos factores cíclicos como las estaciones del año, los días festivos y laborables, o las horas de luz. También es importante la influencia de las condiciones climáticas, que incrementan el uso de aparatos domésticos como aires acondicionados, ventiladores o calefacciones.

Otro de los aspectos que dificulta la predicción de este precio es la liberalización de la industria de la electricidad. Esto permite que cada agente trabaje de forma descentralizada y buscando su propio interés. Muchos resultados son revisados por los agentes con el fin de alcanzar sus propios objetivos organizadores. De este modo, las decisiones descentralizadas tomadas por las compañías de generación, los distribuidores, los transmisores y los administradores del mercado influyen en el desarrollo del mercado eléctrico, y por lo tanto, en el precio de la electricidad.

Todos estos factores, entre otros, ejercen gran influencia en el precio de la electricidad. Sin embargo, tenerlos en cuenta a la hora de realizar la estimación es una tarea realmente complicada. Esto hace que obtener unos resultados cercanos a los reales sea en algunos casos muy complejo. [15]

## 6. IMPORTANCIA DE LA PREDICCIÓN DEL PRECIO DE LA ELECTRICIDAD

Pronosticar los precios de la electricidad es de vital importancia, ya que todas las decisiones operativas y estratégicas de los que participan en el mercado se basan en estas estimaciones.

Para los productores, tener una buena predicción del precio supone grandes ventajas. A corto plazo, esta predicción les permitirá realizar estrategias comercializadoras en el mercado. En un plazo medio, proporcionará una mejor organización a la hora de negociar contratos bilaterales que les permita obtener beneficios. A largo plazo, una buena estimación será imprescindible para anteponerse a decisiones futuras como la compra de nuevas plantas o la venta de las ya existentes, si fuera necesario.

En el caso de los distribuidores y los grandes consumidores, contar con una buena estimación a corto y mediano plazo les permitirá negociar adecuadamente en el mercado eléctrico y realizar contratos bilaterales beneficiosos para sus intereses.

También cabe mencionar la importancia que supone la realización de una buena predicción para el operador de mercado (OMIE), el cual se encarga de realizar las casaciones para la fijación del precio de la electricidad, proporcionándole mayor facilidad para la gestión económica del sistema. [15]

## 7. OBTENCIÓN DE VARIABLES

El primer paso a realizar es la búsqueda de variables que puedan influir en el precio, así como el precio en cada periodo de tiempo. Todos los datos obtenidos de las variables utilizadas en el entrenamiento de la red neuronal son de carácter horario.

El precio marginal en el sistema español (€/kWh) se ha obtenido de la página de OMIE [16], así como la energía total con bilaterales del mercado Ibérico (MWh), la energía total de compra sistema español (MWh) y la energía total de venta sistema español (MWh).

La cantidad de energía generada por cada tipo de central es uno de los factores más importantes a la hora de la predicción del precio de la electricidad. Como se ha estudiado anteriormente, en función de la cantidad de energía generada por cada tipo de central generadora, el precio tenderá a aumentar o disminuir en la casación del mercado. Por este motivo es de gran interés el uso de estas variables.

Mediante la página de ESIOS [14] se han recopilado los datos de la cantidad de energía generada para los distintos tipos de sistemas de generación: eólica, solar térmica, solar fotovoltaica, hidráulica, nuclear, térmica renovable, por carbón, por ciclo combinado y por cogeneración.

Esto supone un total de 12 variables, de las cuales se ha almacenado información horaria desde el 1 de enero de 2019 hasta el 31 de marzo de 2021. Lo que implica un total de 19.703 datos para cada una de ellas.



Para realizar el entrenamiento se utilizarán los valores comprendidos entre el 1 de enero de 2019 y el 31 de octubre de 2020 (16080 valores). Una vez entrenada la red, se realizará la estimación del precio para el periodo comprendido entre el 1 de noviembre de 2020 y el 31 de marzo de 2021 (3623 valores).

## 8. ENTRENAMIENTO DEL MODELO MEDIANTE REDES NEURONALES

Se ha procedido al entrenamiento de una red neuronal mediante la utilización de las variables mencionadas anteriormente. A partir de este entrenamiento se obtiene una función de MATLAB que nos permite, al ejecutarla, realizar una estimación del precio en base a la introducción de nuevos datos de las variables utilizadas. Una vez obtenida la predicción, se han comparado los valores estimados con los valores reales y se han buscado alternativas para la mejora de esta.

### 8.1. CASO 1. 12 VARIABLES

Las variables utilizadas para esta estimación (valores horarios), como se ha mencionado antes, son las siguientes:

- Generación por solar fotovoltaica (MW).
- Generación por solar térmica (MW).
- Generación por eólica (MW).
- Generación por hidráulica (MW).
- Generación por nuclear (MW).
- Generación por térmica renovable (MW).
- Generación por carbón (MW).
- Generación por ciclo combinado (MW).
- Generación por cogeneración (MW).
- Energía total con bilaterales del mercado ibérico (MWh).
- Energía total de compra del sistema español (MWh).
- Energía total de venta del sistema español (MWh).

Una vez entrenada la red, la aplicación proporciona una función de MATLAB. Esta función se ha ejecutado en MATLAB, utilizando los datos de las variables para el periodo de tiempo en el que queremos estimar el precio de la electricidad (desde el 1 de noviembre de 2020 hasta el 31 de marzo de 2021), es decir, un total de 3623 valores. A partir de este proceso, se han obtenido los valores estimados del precio de la electricidad y se han comparado con los reales.

Se ha realizado este procedimiento para números distintos de neuronas ocultas y se ha elegido el caso que menos se ha alejado de los valores reales. Se han realizado pruebas para 100, 200, 300 y 400 neuronas. Mediante Excel, se ha calculado la diferencia en valor absoluto, para cada uno de los casos, entre los valores reales y estimados. Por último se ha realizado la media

aritmética de todas las diferencias para observar qué estimación en su conjunto se aleja menos de la realidad.

NÚMERO DE NEURONAS OCULTAS	MEDIA DE LA DIFERENCIA EN VALOR ABSOLUTO ENTRE VALORES REALES Y ESTIMADOS (€/MWh)
100	11,96224425
200	14,9258202
300	12,69404743
400	13,72074743

Tabla 1. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados de los distintos entrenamientos realizados para el caso 1. (Fuente: elaboración propia)

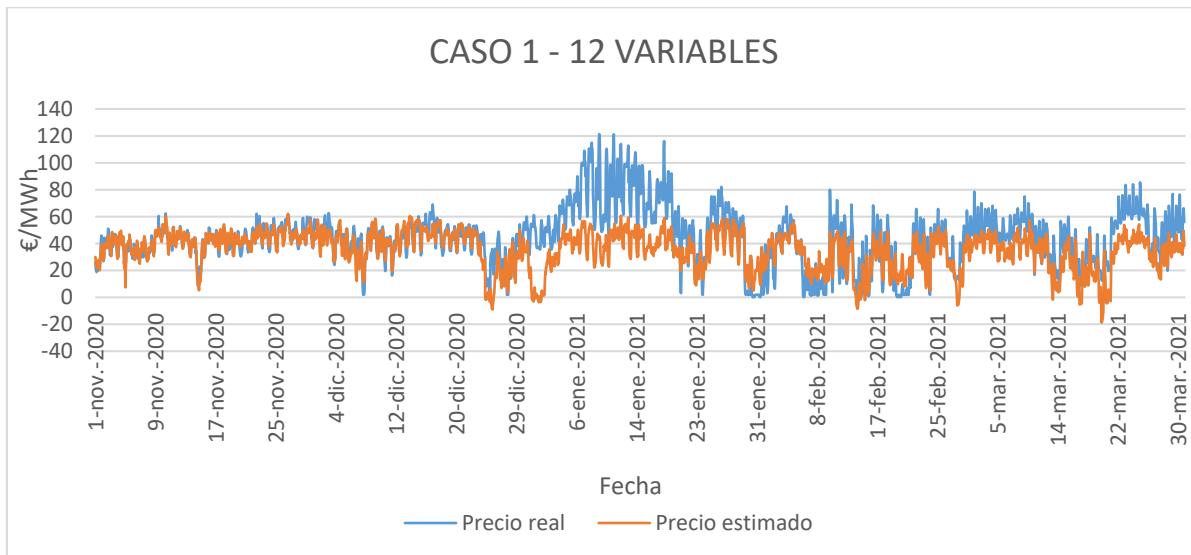
Teniendo en cuenta estas diferencias, la mejor estimación es la realizada con 100 neuronas ocultas.

Mediante este entrenamiento con la red neuronal se ha obtenido un valor de R de 9,73799e-1 y un valor de MSE de 9,10941.

MSE es el error cuadrático medio, calculado como la diferencia cuadrática promedio entre los resultados y los datos reales del problema. Si este valor es cercano a cero significa que el entrenamiento es bueno. En el caso de que fuera cero, significaría que no existe error.

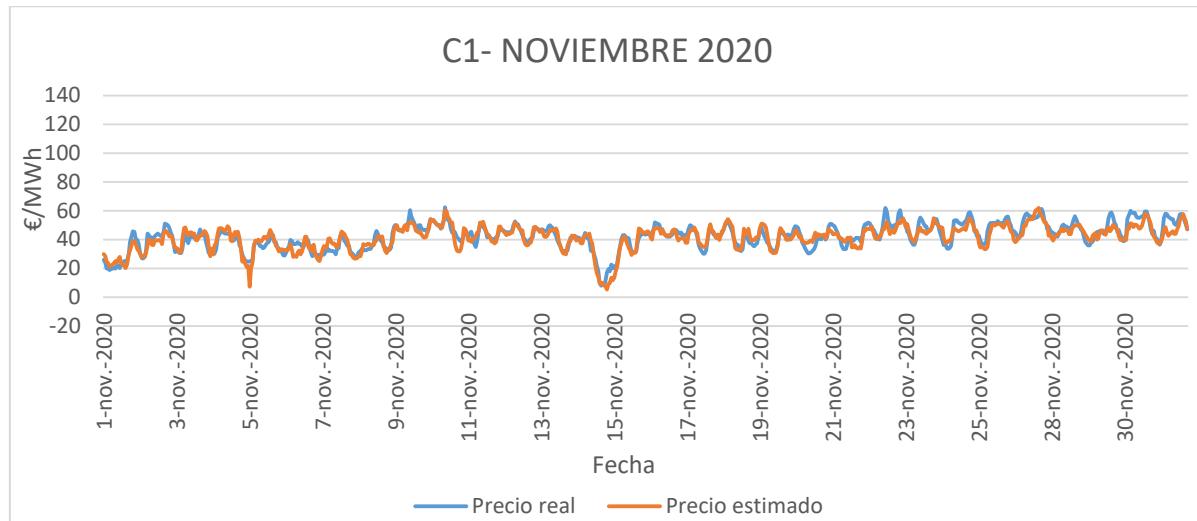
R es el parámetro de regresión. Con este factor se mide la correlación entre los valores predichos en la salida y los valores de salida reales introducidos en la red. Cuanto más próximo se encuentre de la unidad, mejor será la correlación. En este caso se obtiene un buen resultado, ya que el valor de R es muy cercano a 1.

A continuación se muestra una gráfica en la que se representa el precio real y estimado respecto al tiempo, desde el 1 de noviembre de 2020 hasta el 31 de marzo de 2021, utilizando la función obtenida mediante el entrenamiento anterior.

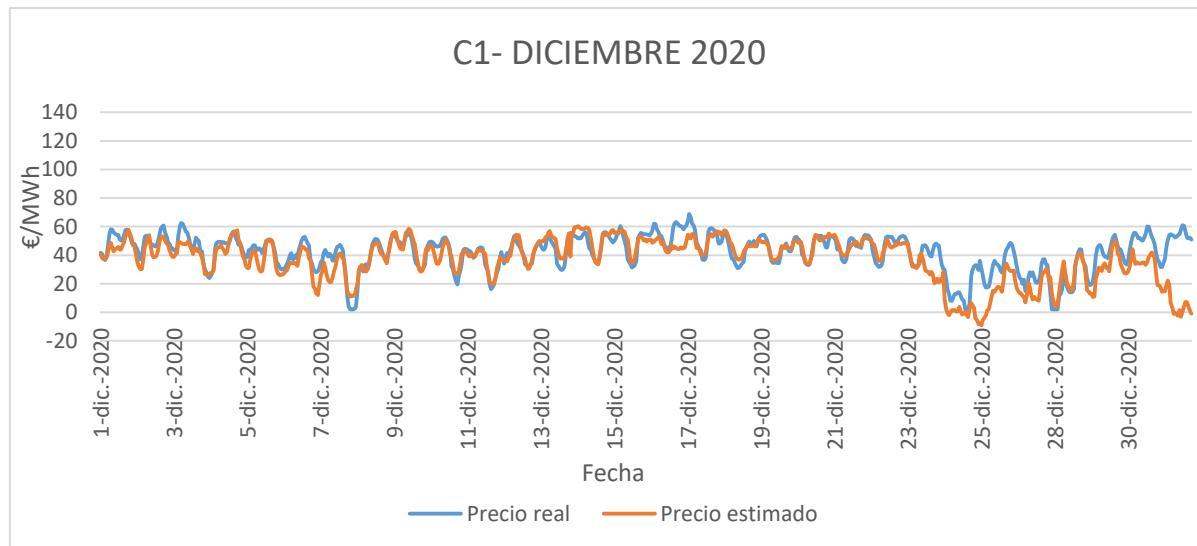


Gráfica 1. Comparación entre precio real y estimado. Caso 1, 12 variables. (Fuente: elaboración propia)

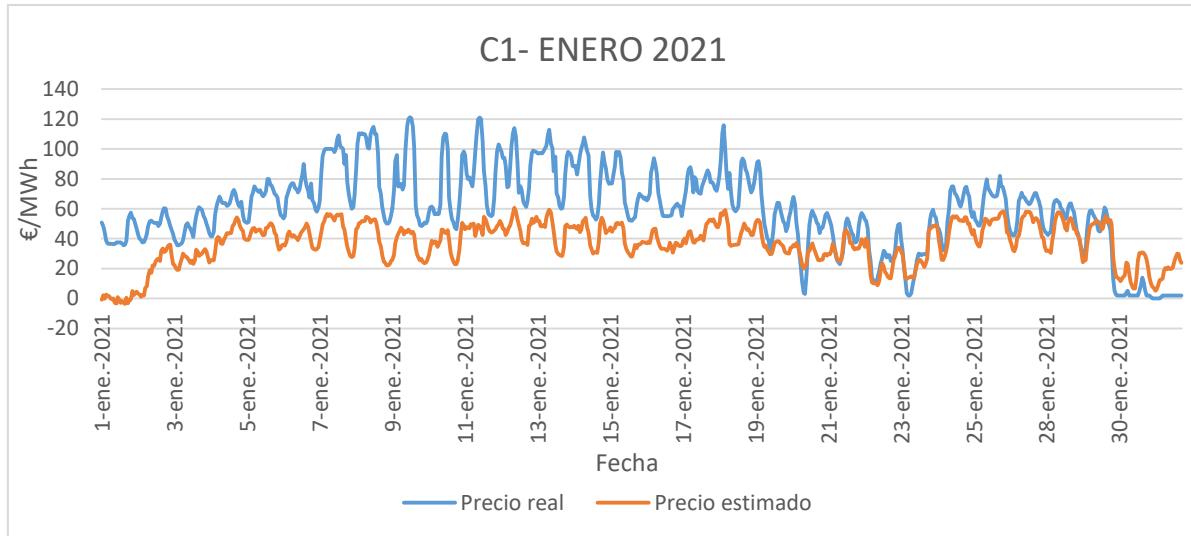
Para poder observar con mayor claridad los resultados obtenidos, se ha dividido la gráfica anterior en gráficas separadas para cada uno de los cinco meses estimados. De este modo se podrá apreciar qué mes estima mejor y en cuáles la estimación no es tan buena.



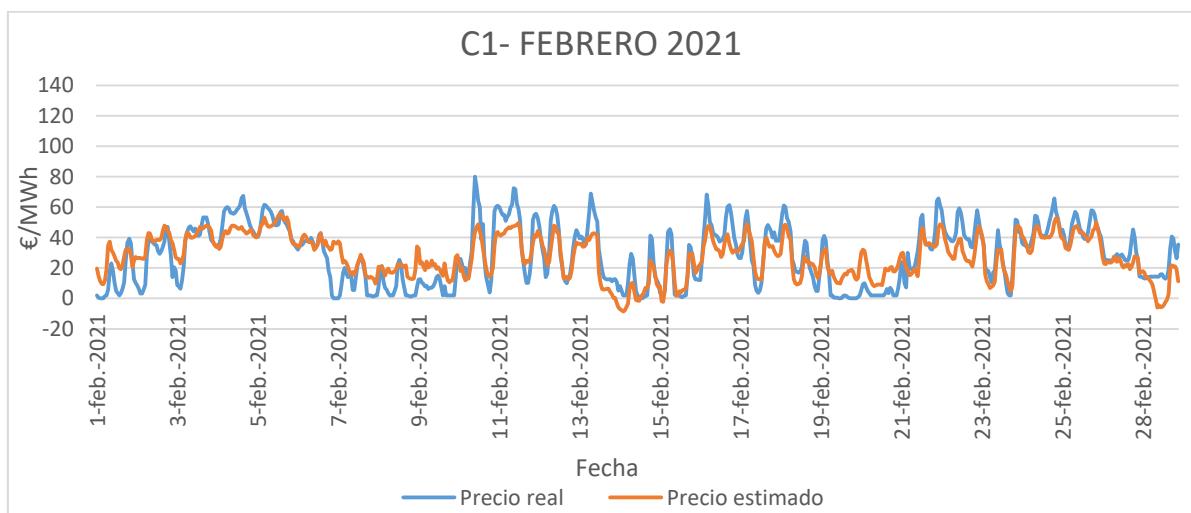
Gráfica 2. Comparación entre precio real y estimado en noviembre de 2020. Caso 1, 12 variables. (Fuente: elaboración propia)



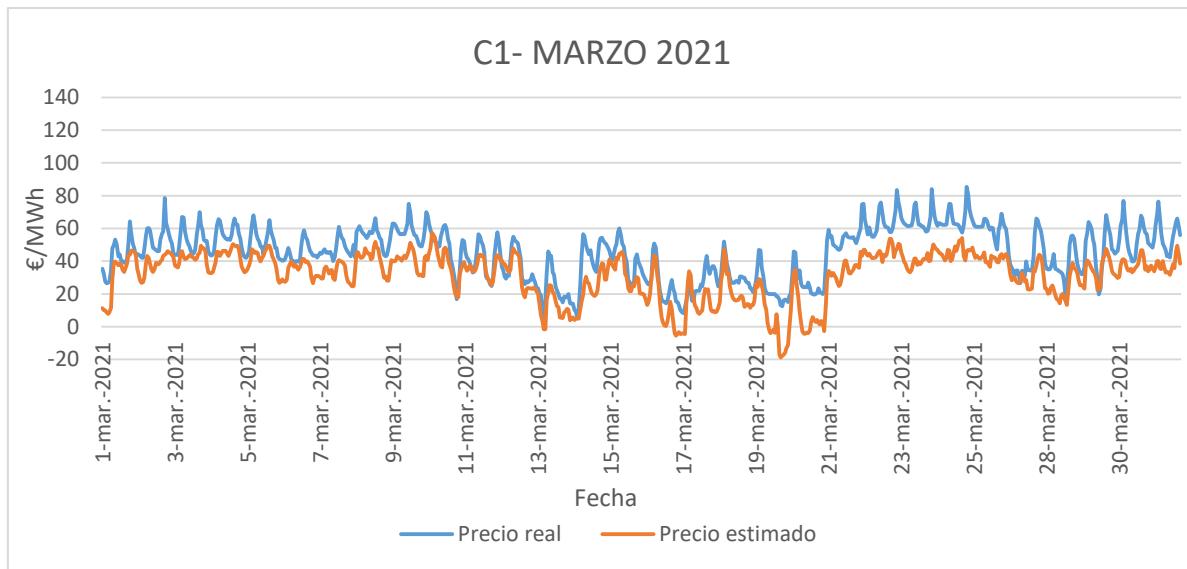
Gráfica 3. Comparación entre precio real y estimado en diciembre de 2020. Caso 1, 12 variables. (Fuente: elaboración propia)



Gráfica 4. Comparación entre precio real y estimado en enero de 2021. Caso 1, 12 variables. (Fuente: elaboración propia)



Gráfica 5. Comparación entre precio real y estimado en febrero de 2021. Caso 1, 12 variables. (Fuente: elaboración propia)



Gráfica 6. Comparación entre precio real y estimado en marzo de 2021. Caso 1, 12 variables. (Fuente: elaboración propia)

Analizando las gráficas se puede apreciar que tanto los valores reales como los estimados siguen una misma tendencia. Sin embargo, no para todos los meses se producen buenas estimaciones.

La predicción realizada para los últimos meses de 2020 (noviembre y diciembre) es buena y nos proporciona unos valores bastante cercanos a los reales, como se puede apreciar en las gráficas.

A partir de enero de 2021 los valores estimados y reales difieren de manera importante. El caso más preocupante es el del mes de enero, en el cual los valores reales del precio son mucho mayores que los estimados. A partir de febrero la diferencia entre los valores estimados y reales disminuye, aunque es mayor que en el caso de los últimos meses del año 2020.

Durante el mes de enero, tal y como se puede ver en la gráfica, se produjo un importante aumento del precio de la electricidad, con valores pico que alcanzan los 120 €/MWh. Los factores que afectan a este fenómeno principalmente son el agotamiento de las existencias de gas, el intenso frío durante este mes o el descenso de la producción de energía renovable.

El estudio de estas razones puede ser de gran utilidad para conseguir disminuir la diferencia durante este mes y obtener así una mejor estimación, haciendo que el método sea más fiable.

Debido a la ola de frío, la producción renovable sufrió un descenso, lo que abarató su precio. Esto ha obligado el uso de otros tipos de fuentes de energía para cubrir la demanda energética, como es el caso de los ciclos combinados. Esta tecnología utiliza gas natural para su funcionamiento, cuyo precio fue muy alto durante los primeros días del mes.

Además, el temporal Filomena provocó bajas temperaturas que dispararon el consumo en toda la Península, subiendo hasta en un 10% la demanda eléctrica. Estas malas condiciones meteorológicas provocaron el desabastecimiento en los mercados de gas, lo que influyó en el aumento del precio de la luz.

Desde finales de diciembre hasta mediados de enero se produjo además una ola de frío sin precedentes en el continente asiático. Este frío provocó el agotamiento de las existencias de gas y su precio se elevó de manera nunca vista en los mercados asiáticos, aumentando el precio de

los buques metaneros y obligando a la cancelación de algunos de ellos, dirigidos al continente europeo, redirigiéndose a Asia. [3]

## 8.2. CASO 2. 13 VARIABLES

Aunque la estimación obtenida anteriormente con los datos utilizados es bastante buena, se tiene como objetivo mejorarla e intentar conseguir una mejor predicción. Para ello ha sido necesaria la búsqueda de nuevas variables que, junto con las que ya se han utilizado, han permitido realizar un entrenamiento que produzca mejoras en los resultados.

Mediante las variables utilizadas hasta el momento no se abarcó la totalidad de los factores influyentes en el cambio de tendencia del precio en el mes de enero. De forma directa, de las variables que se han utilizado hasta este instante, las únicas que podrían ser un factor importante para este suceso serían las variables de generación.

Como se ha comentado anteriormente, los principales factores que teóricamente aumentaron los precios de la electricidad en enero de 2021 son el agotamiento de las existencias de gas, el intenso frío durante este mes o el descenso de la producción de energía renovable. [3] De estos factores, tanto el agotamiento de las existencias de gas como la caída de la temperatura son variables que pueden afectar indirectamente a muchas de las variables utilizadas. Sin embargo, al no verse incluidas directamente en el estudio, no provocan una suficiente influencia como para que afecten de manera correcta. Este puede ser uno de los principales motivos por los que, en enero, al ser tan grande la influencia de ambas variables, no se produzca la estimación deseada. La producción de energía renovable, en cambio, sí que se tiene en cuenta en este estudio. Se verá reflejado principalmente en las generaciones de energía eólica, solar (térmica y fotovoltaica), hidráulica y térmica renovable, que se verán, teóricamente, disminuidas. Si esto ocurre, la generación de energía no renovable (carbón, ciclo combinado, cogeneración y nuclear) tenderá a aumentar para poder abarcar toda la demanda.

Con los datos disponibles, se ha procedido a realizar una media de los valores mensuales de cada una de estas variables desde noviembre hasta enero para comprobar si, efectivamente, las fuentes generadoras de energía renovable sufrieron una disminución durante el mes de enero, y las fuentes generadoras de energía no renovable, por este motivo, sufrieron un aumento en su producción.

Se ha realizado una recopilación de los valores medios mensuales de cada energía renovable y no renovable para el mes de enero y los meses próximos a este, para poder comprobar si existe algún cambio brusco entre ellos. En la siguiente tabla se muestra el resultado:

GENERACIÓN	NOVIEMBRE	DICIEMBRE	ENERO	FEBRERO	MARZO
Solar fotovoltaica	1105,840289	970,0521962	1105,432574	1395,774568	2227,912203
Solar térmica	150,0185111	101,4800645	132,4937312	202,4392336	483,4361452
Eólica	5703,430785	9751,635304	9538,874336	9344,025795	7471,520617
Hidráulica	3381,221751	4086,495962	5103,014313	6174,182051	4831,257602
Nuclear	6458,768761	7089,507616	6982,65434	6485,343987	6491,043695
Térmica renovable	561,4201333	586,0795202	538,2582863	553,5992068	483,4876774
Carbón	492,2291708	321,7159449	784,2645672	284,3524301	346,1156008
Ciclo combinado	4542,296057	3488,019457	3015,965728	1665,356414	2264,432351
Cogeneración	3679,809256	3504,163077	3541,804212	3080,408249	3357,507614
Total renovable	10901,93147	15495,74305	16418,07324	17670,02085	15497,61424
Total no renovable	11493,29399	10899,24302	10782,88464	8435,05283	9101,591647

Tabla 2. Recopilación de los valores medios mensuales de las tecnologías renovables y no renovables.  
(Fuente: elaboración propia)

Mediante estos datos se puede observar que en enero realmente no se produjo un descenso en cuanto a la generación de energía renovable. De hecho, de diciembre a enero se produjo un aumento de esta, que se prolongó hasta febrero.

Los valores particulares de cada tecnología de generación no sufrieron grandes cambios en este mes con respecto a los anteriores o posteriores. Cabe destacar un aumento importante en la generación de carbón. Los demás valores, tanto en el caso de renovables como de no renovables, siguen la misma tendencia que los meses anteriores.

Por este motivo se ha llegado a la conclusión de que la disminución de energía renovable no es el factor principal por el cual la estimación en el mes de enero no es la adecuada. Fue necesario, por lo tanto, la búsqueda de otras variables que puedan abarcar alguno de estos factores.

La variable de “demanda prevista” puede ser de interés ya que proporciona la cantidad de energía que necesitan los consumidores, es decir, la energía que demandan. Dependiendo de las condiciones específicas en cada época del año los consumidores demandarán más o menos cantidad de energía, incluyéndose así factores, que con las variables que se utilizaron hasta el momento, no se incluían en su totalidad, como pueden ser el agotamiento de las existencias de gas o las bajas temperaturas.

Según la descripción de la página de ESIOS, esta variable indica “la previsión de consumo que REE elabora teniendo en cuenta los valores de consumo registrados en períodos precedentes similares, así como otros factores con influencia en el consumo eléctrico como la laboralidad, la

climatología y la actividad económica". [14] Por lo tanto, de este modo se tuvieron en cuenta aspectos como la temperatura (que en enero tuvo una importante disminución), además de otros factores económicos. Se esperaba que mediante el uso de esta variable se proporcionara una mejora de la estimación.

Se ha seleccionado en ESIOS la variable de "demanda prevista" en lugar de "demanda real" debido a que en el caso de que se utilice este modelo de predicción en el futuro, su objetivo principal va a ser el de predecir valores futuros, por lo tanto, lógicamente, será imposible obtener los valores de la demanda en tiempo real y será necesario recurrir a las estimaciones de demanda previstas por la REE. Este fenómeno, en caso de predicciones futuras, será necesario tenerlo en cuenta en todos los factores y trabajar, por lo tanto, con valores previstos de cada una de las variables utilizadas.

Se ha procedido a realizar otro estudio utilizando la misma herramienta, añadiendo la variable "demanda prevista" a las doce que ya se utilizaron anteriormente. Al realizar el entrenamiento y la posterior estimación del precio para el mismo rango temporal, se ha comprobado si al añadir esta variable se obtienen mejores resultados y una menor diferencia entre las curvas de precio real y estimado, sobretodo en el periodo en el que se obtiene una peor estimación (enero de 2021).

Variables utilizadas para el entrenamiento de la red en el caso 2:

- Generación por solar fotovoltaica (MW).
- Generación por solar térmica (MW).
- Generación por eólica (MW).
- Generación por hidráulica (MW).
- Generación por nuclear (MW).
- Generación por térmica renovable (MW).
- Generación por carbón (MW).
- Generación por ciclo combinado (MW).
- Generación por cogeneración (MW).
- Energía total con bilaterales del mercado ibérico (MWh).
- Energía total de compra del sistema español (MWh).
- Energía total de venta del sistema español (MWh).
- Demanda prevista (MW).

Se han realizado distintos entrenamientos de la red neuronal mediante la utilización de distintas neuronas ocultas (como en el caso anterior), utilizando los mismos datos de las variables. A partir de las funciones obtenidas mediante el entrenamiento de cada una se ha obtenido, mediante MATLAB, una predicción para el mismo periodo de tiempo que en el caso 1 (desde el 1 de noviembre de 2020 hasta el 31 de marzo de 2021), y se ha seleccionado el caso en el cual la media entre todos los valores en valor absoluto de la diferencia entre los precios reales y estimados ha sido menor.

Se han realizado pruebas para los siguientes valores de neuronas ocultas: 100, 150, 200, 250, 300, 350 y 400. A continuación se muestra una tabla con los resultados obtenidos.

NÚMERO DE NEURONAS OCULTAS	MEDIA DE LA DIFERENCIA EN VALOR ABSOLUTO LOS VALORES REALES Y ESTIMADOS (€/MWh)
100	12,70471436
150	15,22907796
200	13,76465405
250	12,38220859
300	11,9597993
300 (2)	14,22186258
350	14,69405424
400	12,66235783
400 (2)	14,00315849

Tabla 3. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados de los distintos entrenamientos realizados para el caso 2. (Fuente: elaboración propia)

Al observar los resultados de la diferencia medida entre los valores reales y estimados con respecto al caso anterior, se puede apreciar que, en el mejor de los casos, esta diferencia es prácticamente del mismo valor. En el caso anterior se obtuvo una diferencia de 11,96224425, mientras que en este caso la diferencia es de 11,9597993. Sin embargo, al observar los valores de R y MSE obtenidos tras el entrenamiento de la red, se puede apreciar como estos tienen una mejora considerable con respecto al entrenamiento anterior.

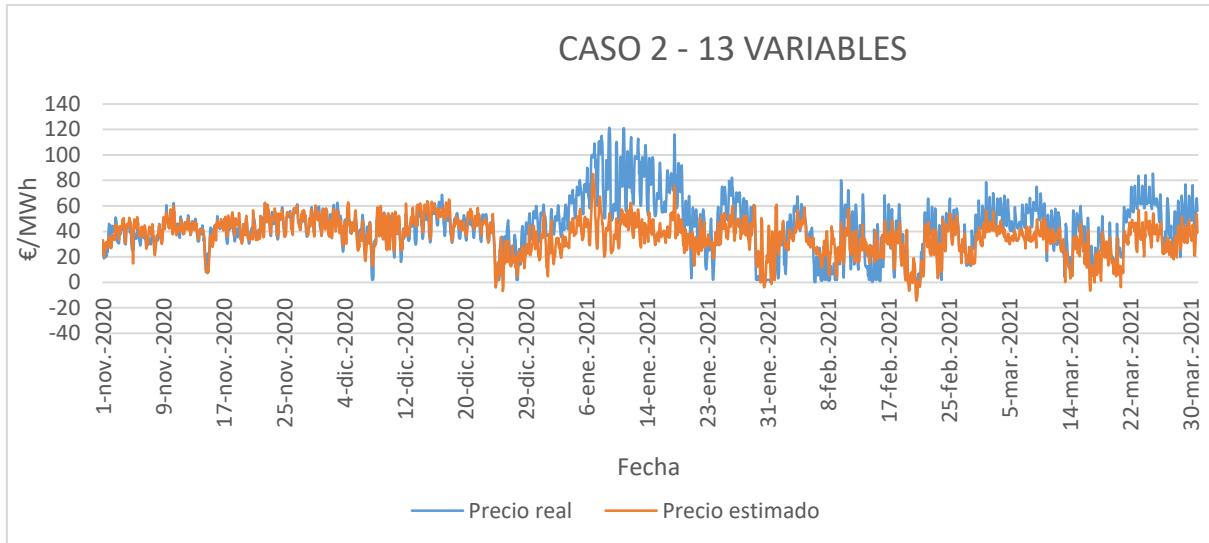
Si se hace una comparación del valor de los parámetros MSE y R del entrenamiento entre ambos casos se puede observar como el valor de MSE es más cercano a 0 y el valor de R es más cercano a 1 en este caso, lo que supone una mejora en los resultados del entrenamiento tras el uso de esta variable.

Nº CASO	MSE (validation)	R (validation)
Caso 1	9,10941	9,73799e-1
Caso 2	7,63899	9,78308e-1

Tabla 4. Comparación entre los valores de MSE y R del entrenamiento de los casos 1 y 2. (Fuente: elaboración propia)

Por este motivo, se ha llegado a la conclusión de que incluir esta variable en la estimación aporta una ligera mejora en los resultados estimados y proporciona una mayor calidad en el entrenamiento.

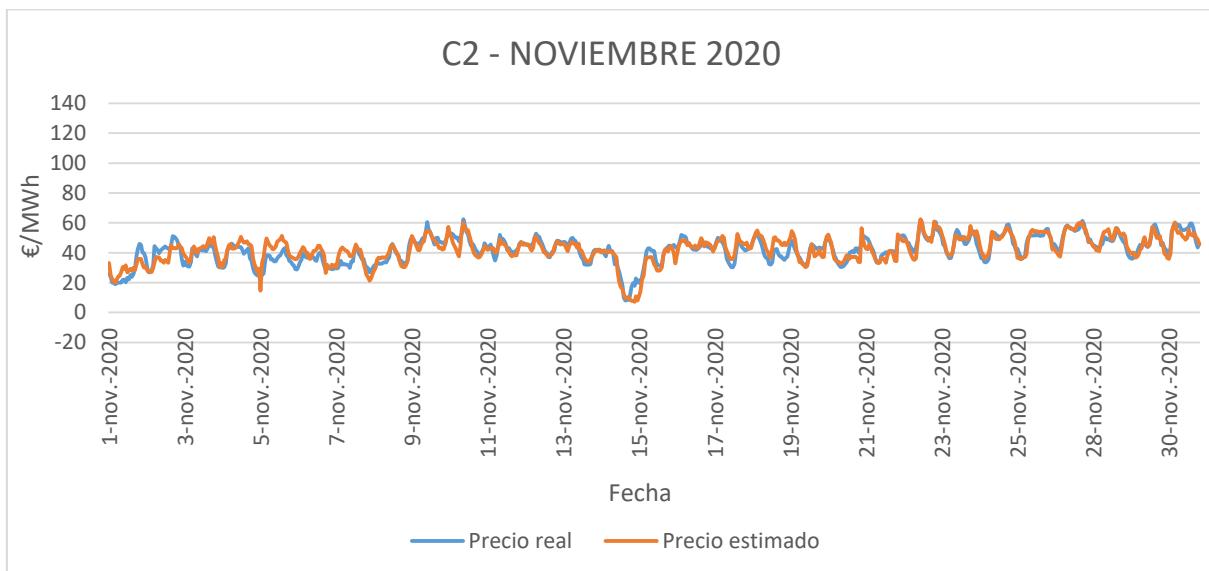
A continuación se va a mostrar la gráfica en la que se comparan los valores reales y estimados, para poder comprobar de manera visual si, en efecto, se ha obtenido una mejora en cuanto a la predicción.



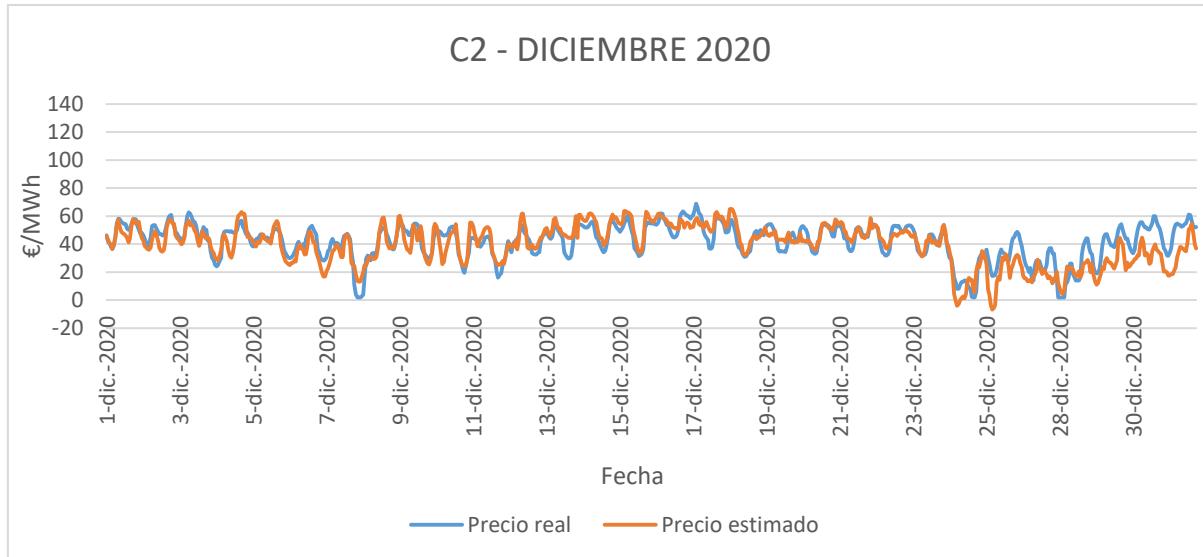
Gráfica 7. Comparación entre precio real y estimado. Caso 2, 13 variables. (Fuente: elaboración propia)

Mediante esta gráfica podemos observar que el resultado obtenido es un poco mejor que en el caso anterior, pero todavía no se consigue el resultado deseado en las zonas mencionadas anteriormente. Siguen siendo noviembre y diciembre de 2020 los meses con mejor estimación.

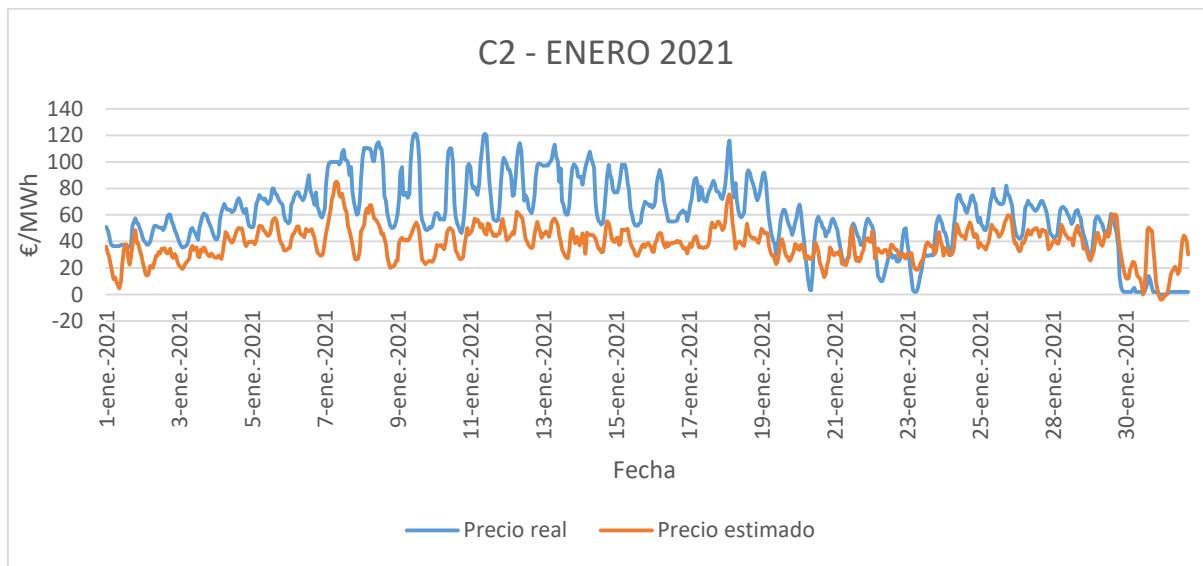
En las siguientes gráficas, se muestran los resultados de la estimación mes a mes, al igual que se ha realizado en el caso anterior, para poder ver con mayor claridad cada parte de la predicción.



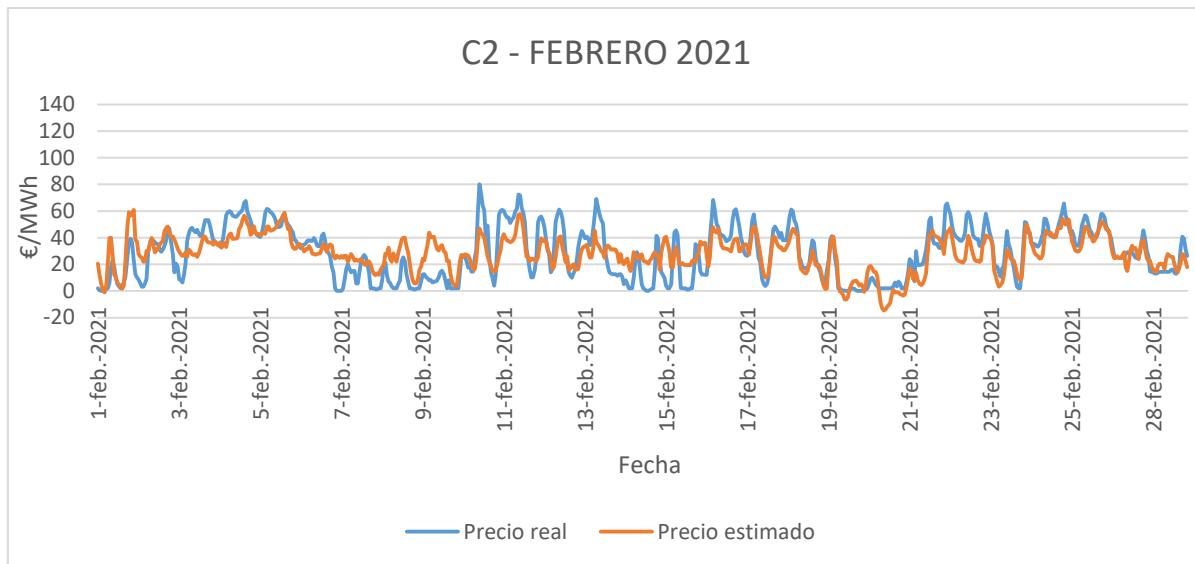
Gráfica 8. Comparación entre precio real y estimado en noviembre de 2020. Caso 2, 13 variables. (Fuente: elaboración propia)



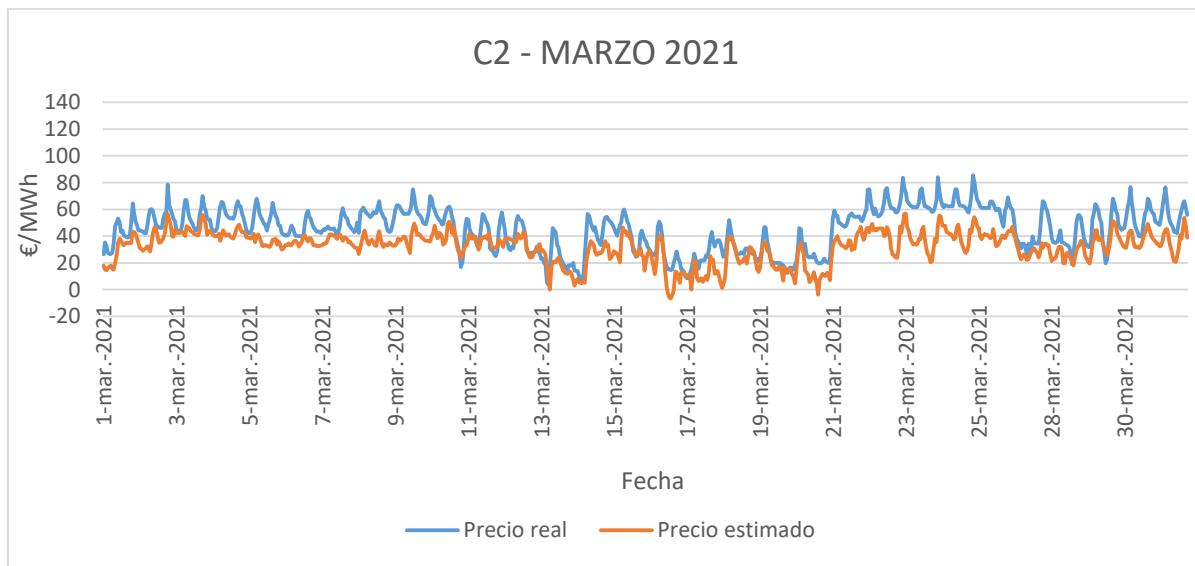
Gráfica 9. Comparación entre precio real y estimado en diciembre de 2020. Caso 2, 13 variables. (Fuente: elaboración propia)



Gráfica 10. Comparación entre precio real y estimado en enero de 2021. Caso 2, 13 variables. (Fuente: elaboración propia)



Gráfica 11. Comparación entre precio real y estimado en febrero de 2021. Caso 2, 13 variables. (Fuente: elaboración propia)



Gráfica 12. Comparación entre precio real y estimado en marzo de 2021. Caso 2, 13 variables. (Fuente: elaboración propia)

Al igual que en el caso anterior, Enero de 2021 es el mes en el cual se ha obtenido una peor estimación. Observamos sin embargo que la tendencia de la predicción es la misma que en los casos reales y que la diferencia entre ambas curvas, sobretodo en este mes, es ligeramente menor, lo que indica una mejor estimación.

En el caso de noviembre y diciembre de 2020, la estimación sigue siendo muy buena. No se aprecia una mejora demasiado destacable, pero se podría decir que los resultados siguen siendo igual de buenos que en el primer caso, lo cual es de gran importancia.

En el caso de febrero y marzo de 2021, los resultados han sido muy parecidos a los obtenidos en el primer caso. No son tan buenos como en el caso de noviembre y diciembre de 2020, pero mejores que en el caso de enero de 2021.

Mediante este segundo caso, por lo tanto, se ha conseguido una pequeña mejora con respecto al primero. Sin embargo, sería de gran interés añadir una o varias variables a las que ya se han utilizado para poder mejorar la estimación, minimizando el error y permitiendo que sea fiable para futuras predicciones.

### 8.3. CASO 3. 15 VARIABLES

Como se ha comentado anteriormente, durante el mes de enero (en el que obteníamos una peor predicción), se agotaron las existencias de gas, lo que provocó un aumento en su precio y dificultad para su abastecimiento. Por este motivo, se ha llegado a la conclusión de que el estudio del gas puede ser un factor determinante a la hora de mejorar la efectividad del entrenamiento y mejorar de este modo los resultados previos.

Para ello, mediante la página web de MIBGAS [13], se han obtenido los valores históricos de precio y volumen de gas, los cuales pueden ser de gran utilidad a la hora de entrenar la red y obtener así una mayor predicción del precio de la electricidad. Estas variables se encuentran en valores diarios tanto de precio como de volumen. El estudio realizado en este proyecto utiliza valores horarios, por lo que ha sido necesario convertir estos valores diarios a horarios.

En el caso del precio, en esta página se han obtenido los €/MWh que cuesta el gas cada día. Se ha supuesto este valor constante para todas las horas del día y así se han obtenido los valores horarios. En cuanto al volumen de gas, la página de MIBGAS ha proporcionado los valores diarios en MWh de volumen de gas. Para realizar la estimación se han dividido esos valores entre las 24 horas del día, tomando como constante el volumen de gas generado durante cada hora.

Dicho esto, el tercer caso que se ha estudiado consta, por lo tanto, de las trece variables utilizadas en el caso anterior, además de las dos que se acaban de comentar, siendo un total de 15 variables:

- Generación por solar fotovoltaica (MW).
- Generación por solar térmica (MW).
- Generación por eólica (MW).
- Generación por hidráulica (MW).
- Generación por nuclear (MW).
- Generación por térmica renovable (MW).
- Generación por carbón (MW).
- Generación por ciclo combinado (MW).
- Generación por cogeneración (MW).
- Energía total con bilaterales del mercado ibérico (MWh).
- Energía total de compra del sistema español (MWh).
- Energía total de venta del sistema español (MWh).
- Demanda prevista (MW).

Se ha realizado, al igual que en los casos anteriores, pruebas con números distintos de neuronas ocultas. Se ha realizado el entrenamiento de la red para cada caso y se han obtenido los valores estimados para el mismo periodo de tiempo que en los casos anteriores.

En la siguiente tabla se muestran la media del valor absoluto de la diferencia entre los valores reales y estimados en cada caso, para poder elegir así el caso más favorable.

NÚMERO DE NEURONAS OCULTAS	MEDIA DE LA DIFERENCIA EN VALOR ABSOLUTO ENTRE LOS VALORES REALES Y ESTIMADOS (€/MWh)
80	13,008413
100	8,13337607
100 (2)	16,2540672
100 (3)	9,58995446
100 (4)	11,2992159
120	10,2049813
150	12,1390398
200	16,1578851
400	17,594607

Tabla 5. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados de los distintos entrenamientos realizados para el caso 3. (Fuente: elaboración propia)

Como se puede apreciar, el resultado de la diferencia obtenido en el mejor caso es mucho mejor que en los casos anteriores (más de tres unidades de diferencia). Esto indica que, teóricamente, la estimación ha mejorado de manera considerable.

Nº CASO	MEDIA DE LA DIFERENCIA EN VALOR ABSOLUTO ENTRE LOS VALORES REALES Y ESTIMADOS (€/MWh)
CASO 1	11,96224425
CASO 2	11,9597993
CASO 3	8,13337607

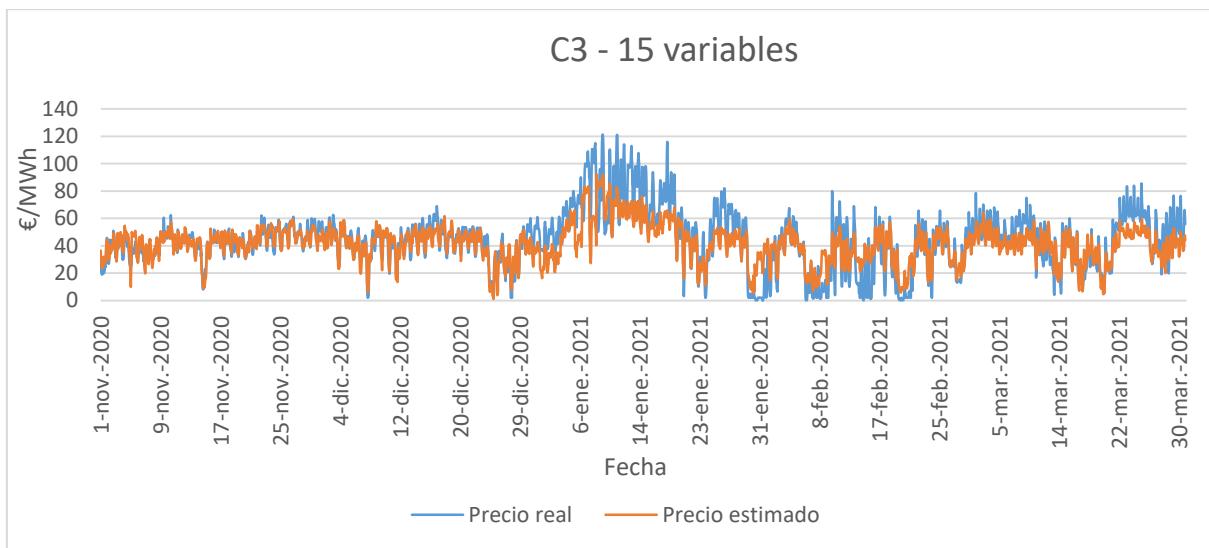
Tabla 6. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados en los casos 1, 2 y 3. (Fuente: elaboración propia)

En cuanto a los resultados de R y MSE del entrenamiento, se puede observar como mediante la utilización de estas variables se obtiene una ligera mejora con respecto a los casos anteriores. Como se observa en la siguiente tabla, el valor de R se encuentra más cercano a la unidad, mientras que el valor de MSE es menor que en los casos anteriores, lo que indica una mejora en el entrenamiento.

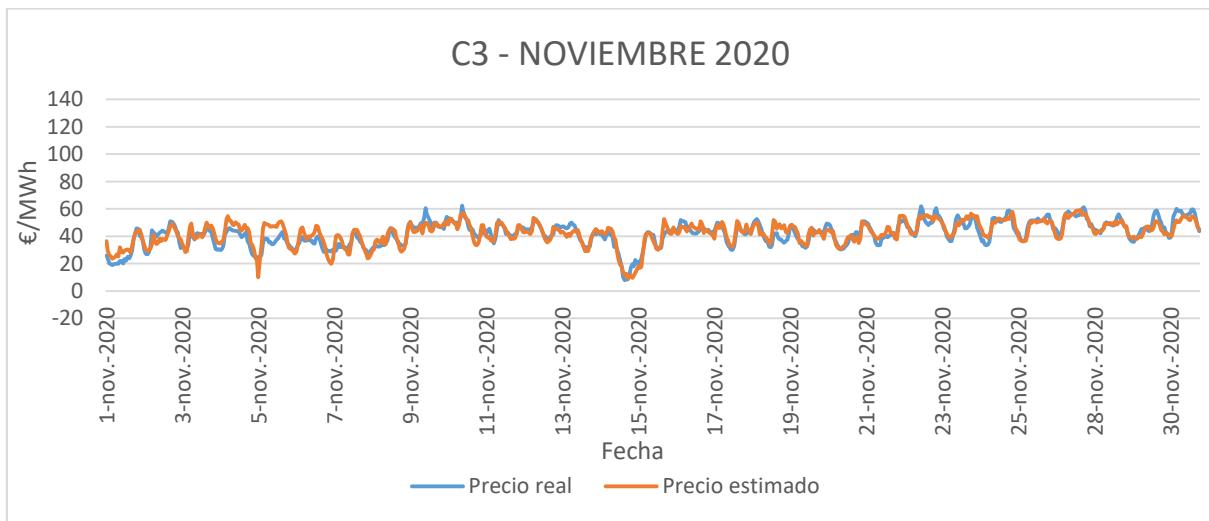
Nº CASO	MSE (validation)	R (validation)
Caso 1	9,10941	9,73799e-1
Caso 2	7,63899	9,78308e-1
Caso 3	7,01543	9,80386e-1

Tabla 7. Comparación de los valores de MSE y R del entrenamiento de los casos 1, 2 y 3. (Fuente: elaboración propia)

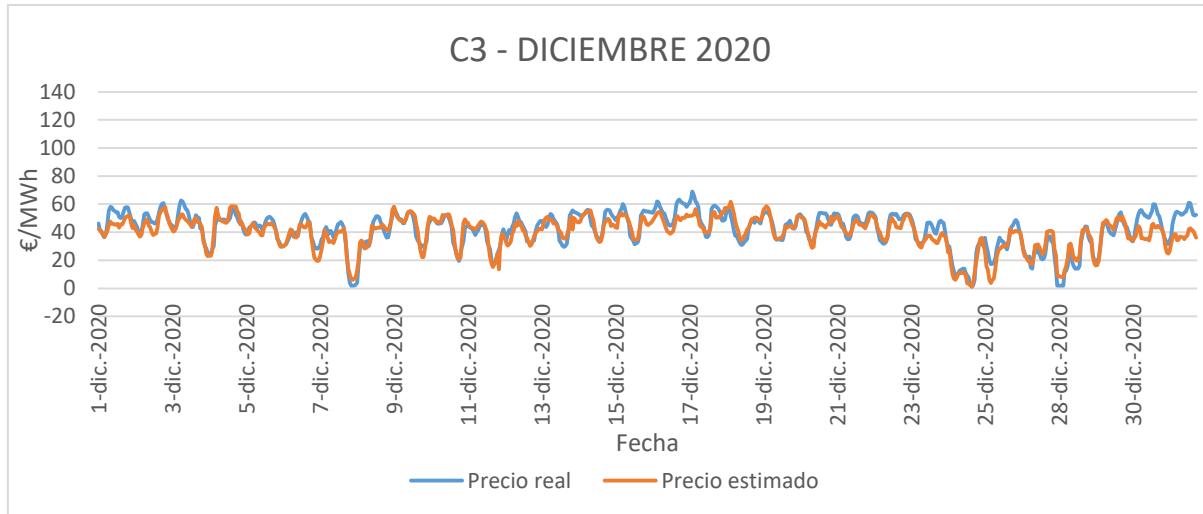
Para comprobar si, efectivamente, con el uso de las variables de precio y volumen de gas se ha obtenido una mejora con respecto a los casos anteriores, se han realizado las gráficas comparativas entre los precios reales y los estimados con la red. Es de interés observar con detenimiento el mes de enero, en el cual los precios estimados no alcanzaban los valores reales. Estos valores eran muy elevados, entre otras cosas, por el agotamiento de las existencias de gas. En este caso, al tener en cuenta el estudio del gas, se espera un mayor ajuste.



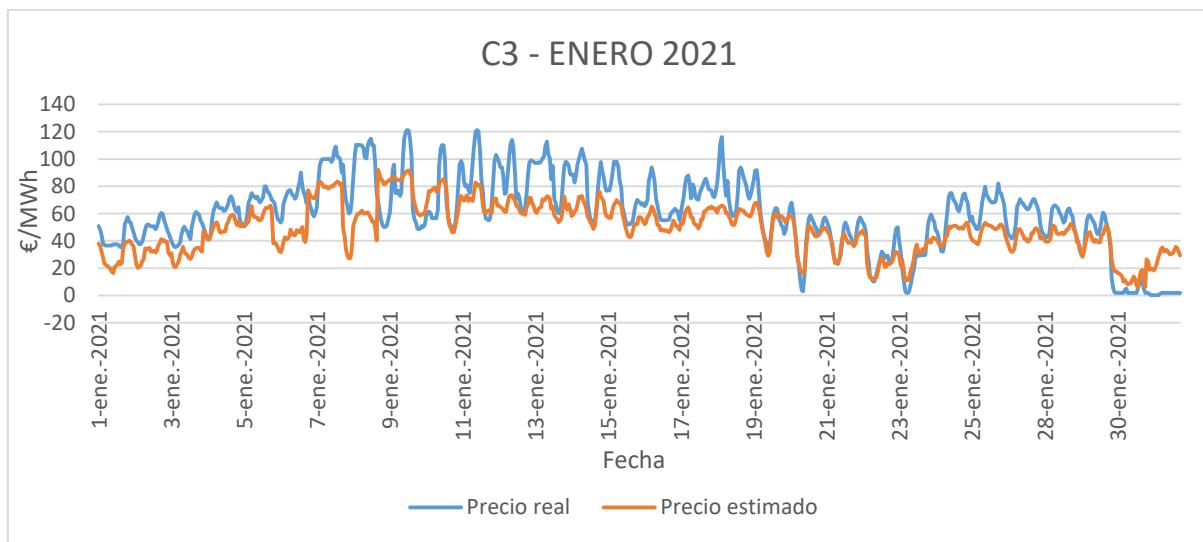
Gráfica 13. Comparación entre precio real y estimado. Caso 3, 15 variables. (Fuente: elaboración propia)



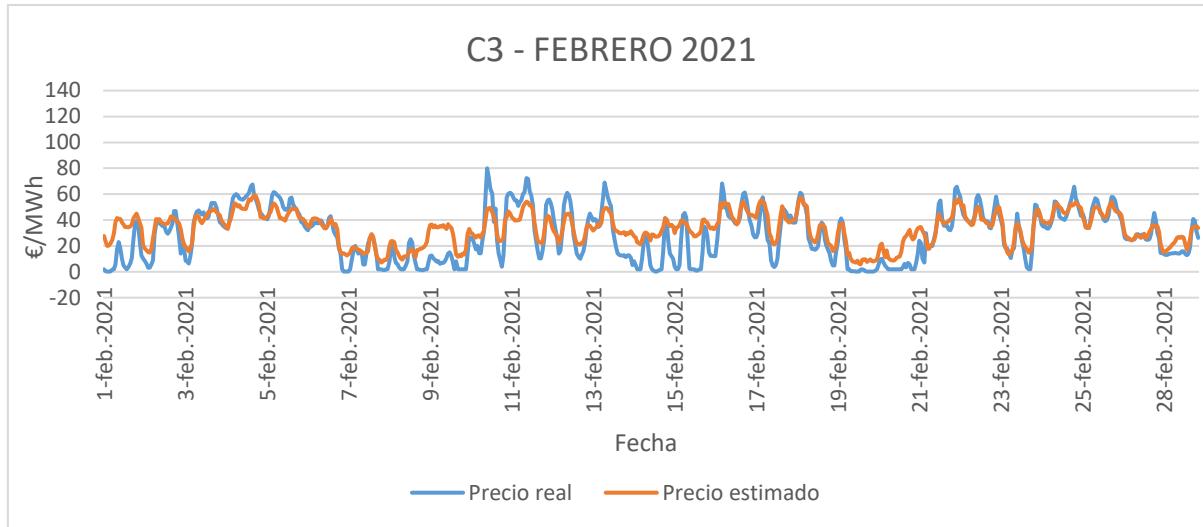
Gráfica 14. Comparación entre precio real y estimado en noviembre de 2020. Caso 3, 15 variables. (Fuente: elaboración propia)



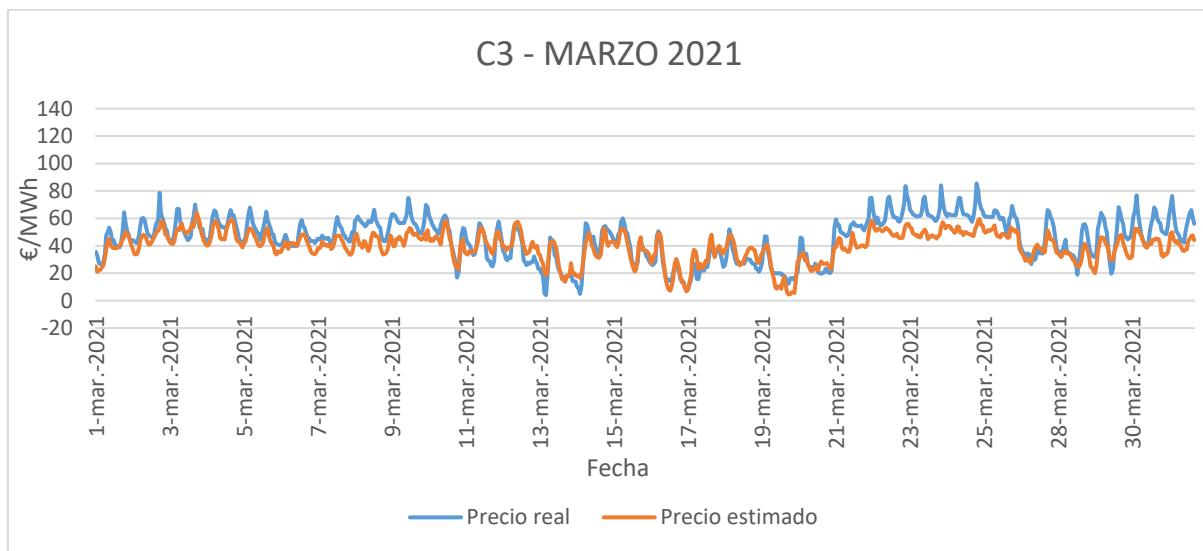
Gráfica 15. Comparación entre precio real y estimado en diciembre de 2020. Caso 3, 15 variables. (Fuente: elaboración propia)



Gráfica 16. Comparación entre precio real y estimado en enero de 2021. Caso 3, 15 variables. (Fuente: elaboración propia)



Gráfica 17. Comparación entre precio real y estimado en febrero de 2021. Caso 3, 15 variables. (Fuente: elaboración propia)



Gráfica 18. Comparación entre precio real y estimado en marzo de 2021. Caso 3, 15 variables. (Fuente: elaboración propia)

Tras analizar las gráficas se puede apreciar visualmente como existe una mejora con respecto a los casos anteriores, sobretodo en el mes de enero de 2021. Mediante la incorporación de estas dos variables del gas se ha conseguido un mayor ajuste en este mes, aunque no se ha conseguido llegar a los picos máximos de precio en este, pero la diferencia entre el precio real y el estimado se ha reducido considerablemente gracias a este último entrenamiento.

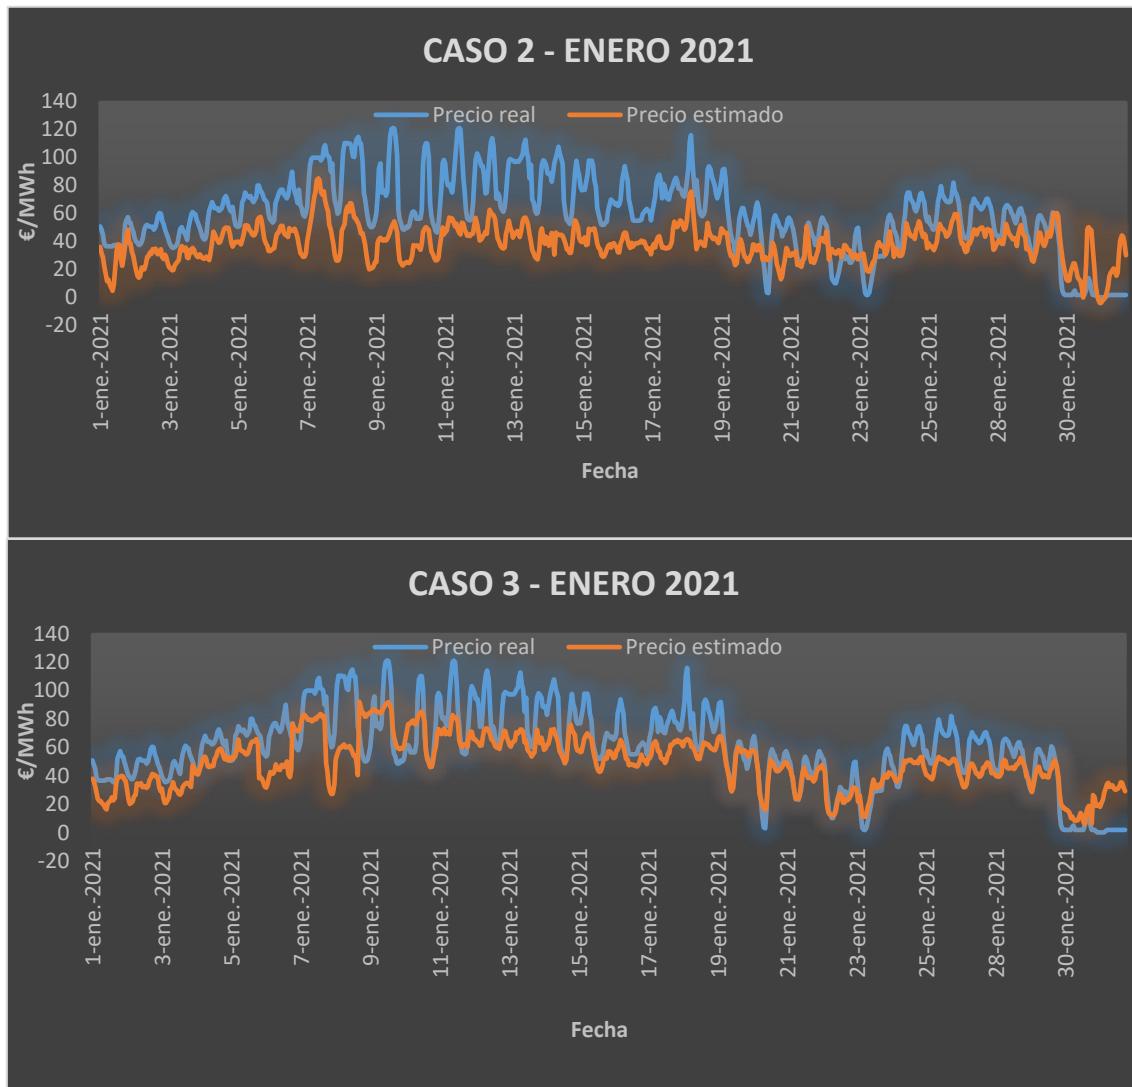


Figura 9. Efecto de añadir el estudio de gas. Comparación el precio real y estimado en enero de 2021 de los casos 2 y 3. (Fuente: elaboración propia)

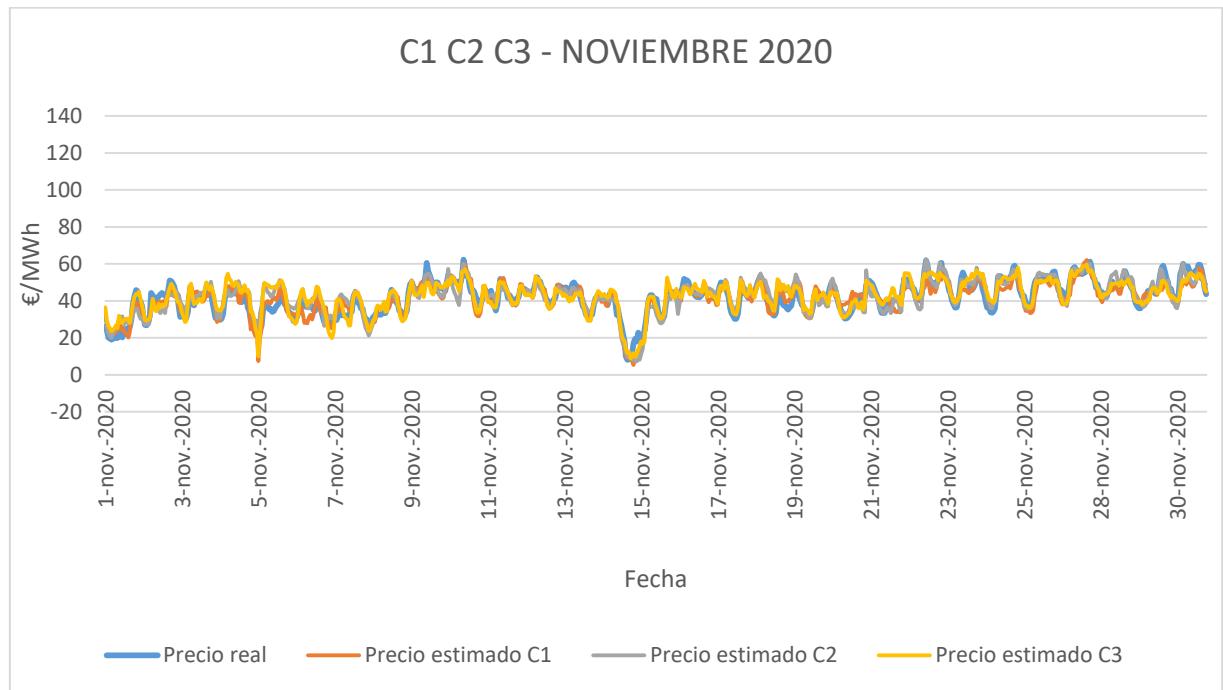
Gracias a la gráfica anterior se puede apreciar cómo, durante este mes, la predicción obtenida mediante el caso 3, es considerablemente más cercana a los valores reales que en el caso anterior, proporcionando un mayor ajuste.

Hay que tener en cuenta que se han realizado aproximaciones, como se ha comentado anteriormente, debido a que los valores que se han obtenido en la página de MIBGAS [13] son diarios y no horarios. Este hecho puede influir en cuanto a la estimación, haciendo que esta sea menos precisa. Sin embargo, añadir estas variables ha servido para mejorar la función de la red neuronal y perfeccionar el ajuste de la estimación.

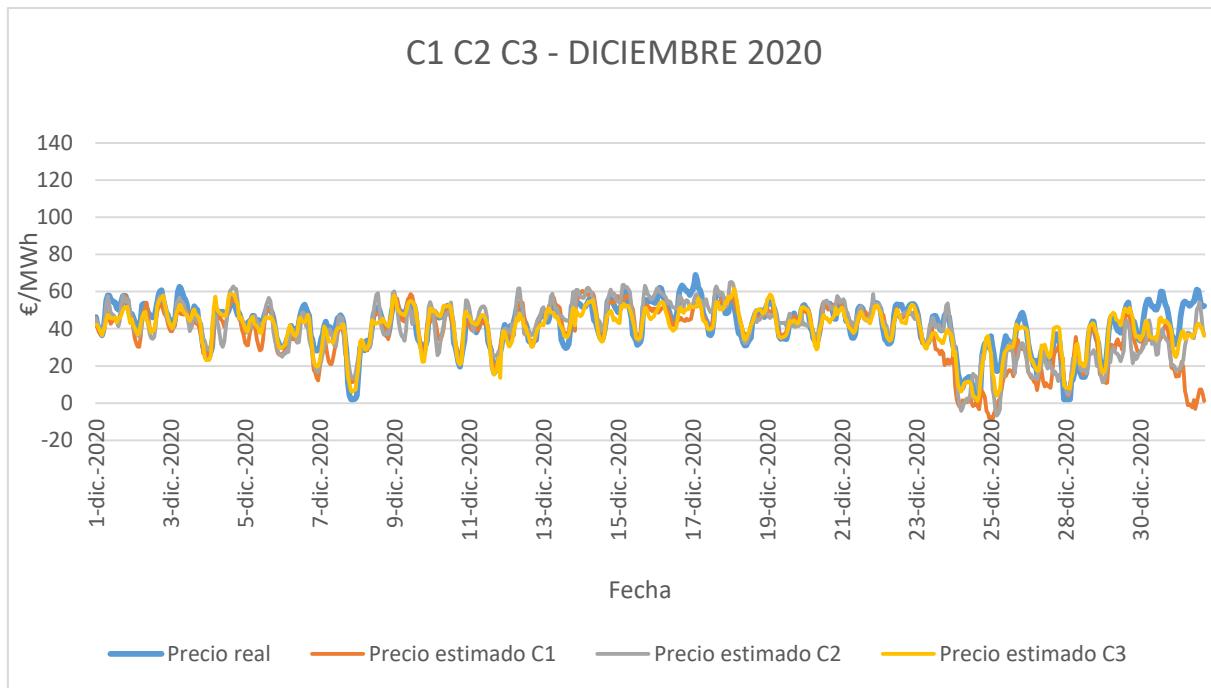
Como punto negativo en esta última estimación cabe destacar que en el mes de febrero de 2021 la estimación ha sido un poco peor a primera vista que en el primer caso. Esto puede ser debido a que en este mes, las variables añadidas principalmente para la mejora de la predicción de enero (en la cual teníamos los peores resultados), no tienen tanta influencia como en el mes anterior y pueden ejercer un efecto negativo en esta.

Tanto en el caso de noviembre como diciembre de 2020, las predicciones siguen siendo muy buenas. En el caso de marzo de 2021 se aprecia también una mejora considerable con respecto a los casos anteriores.

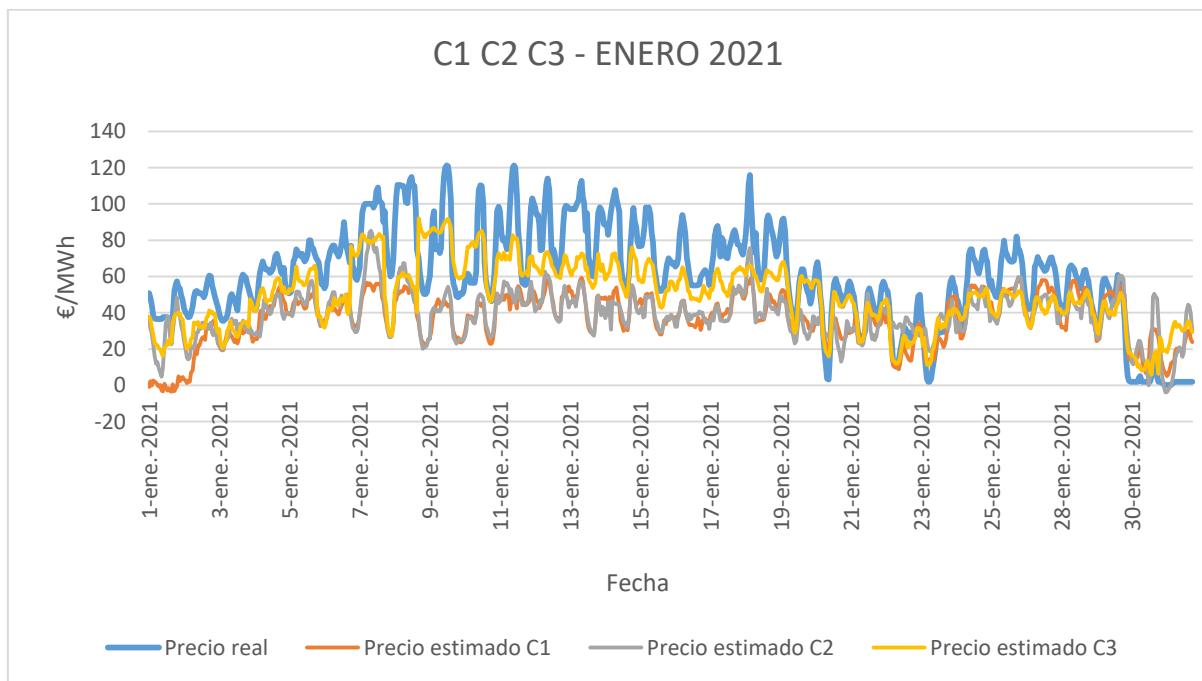
Para apreciar visualmente las diferencias entre los tres casos que se acaban de comentar, se procede a mostrar las gráficas de relación entre precio real y estimado teniendo en cuenta los tres casos para cada mes estimado.



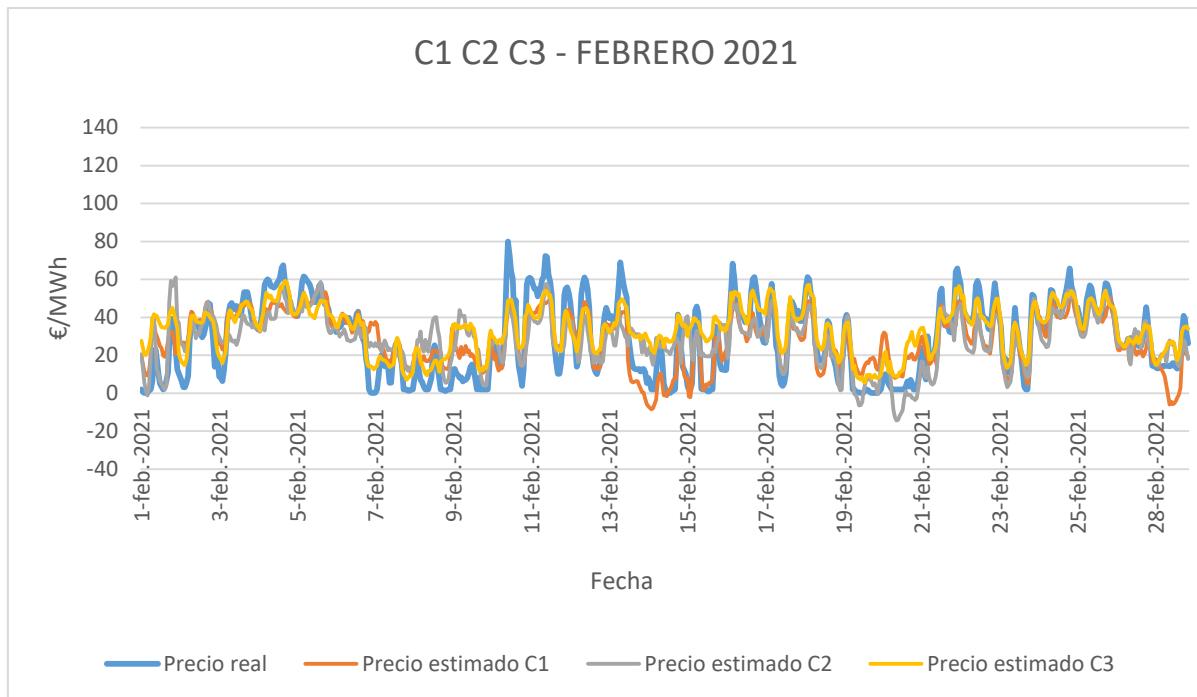
Gráfica 19. Comparación entre precio real y los estimados en los tres casos en noviembre de 2020. (Fuente: elaboración propia)



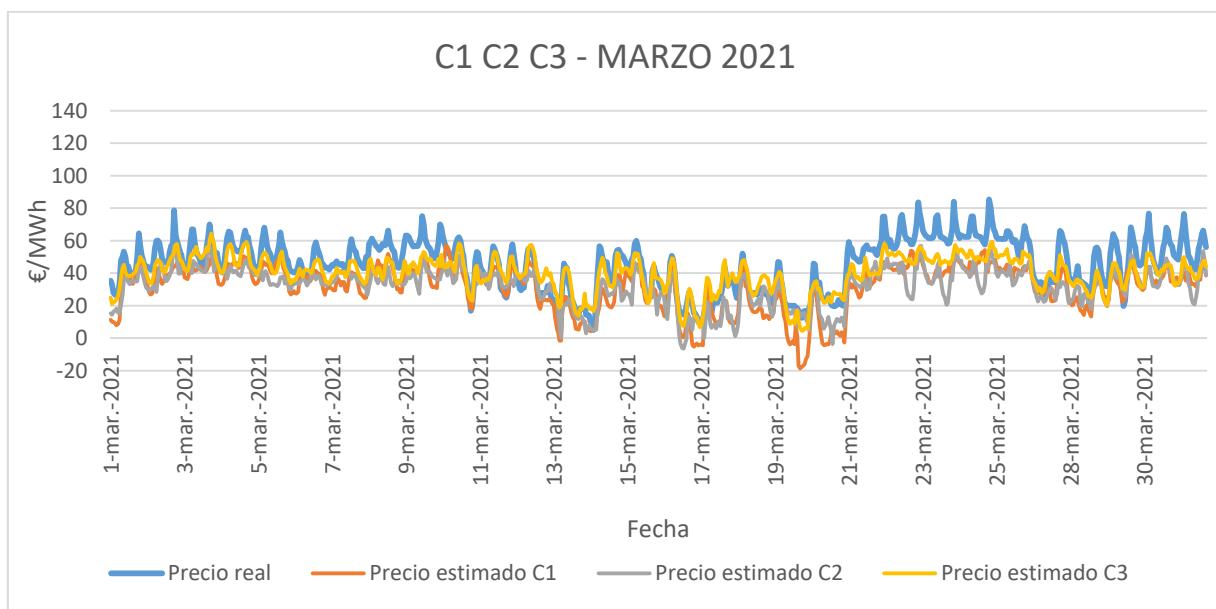
Gráfica 20. Comparación entre precio real y los estimados en los tres casos en diciembre de 2020. (Fuente: elaboración propia)



Gráfica 21. Comparación entre precio real y los estimados en los tres casos en enero de 2021. (Fuente: elaboración propia)



Gráfica 22. Comparación entre precio real y los estimados en los tres casos en febrero de 2021. (Fuente: elaboración propia)



Gráfica 23. Comparación entre precio real y los estimados en los tres casos en marzo de 2021. (Fuente: elaboración propia)

Si se analizan las gráficas detenidamente se puede apreciar como en la mayor parte del tiempo en el que se ha realizado la estimación, la mejor predicción corresponde con el último caso, con



más variables. Este resultado es el esperado ya que es en el caso 3 (el último entrenamiento realizado) en el cual se ha añadido un mayor número de datos. Se podría decir que es el caso más completo de los que se han realizado en este estudio.

Como ya se ha comentado anteriormente, no siempre se cumple que el caso 3 sea el que mejor estimación efectúa. Hay zonas en las que las estimaciones anteriores actúan con mayor exactitud. Este puede ser el caso de mediados de febrero de 2021, donde el precio sufre un repentino cambio negativo a partir del día 13 de este mes. Según podemos observar en la gráfica 22, es el caso 1 el que mejor realiza la estimación en ese momento.

Las últimas variables añadidas al entrenamiento han sido utilizadas, sobretodo, con la finalidad de rebajar la excesiva diferencia entre estimación y realidad en enero de 2021, donde el precio de la electricidad sufrió un aumento muy brusco. Estas variables, por lo tanto, sirvieron para reducir la disimilitud durante este mes. Sin embargo, en otros períodos temporales distintos, donde la influencia de estas variables no es de tanto interés, añadirlas puede empeorar la predicción realizada, como es el caso de alguna zona de febrero de 2021.

En cómputo global, añadir estos datos a los que ya se tenían ha permitido mejorar la predicción, permitiendo la optimización de un modelo que puede ser de gran utilidad en ámbitos energéticos empresariales, donde anteponerse a lo que pueda ocurrir en el futuro puede suponer el ahorro en gastos innecesarios por falta de planificación.

## 8.4. CASO 4. 15 VARIABLES. DISTINTA CONFIGURACIÓN DE ENTRENAMIENTO Y PREDICCIÓN

Mediante los apartados anteriores se ha conseguido diseñar un modelo que permite la estimación del precio de la electricidad. Se ha obtenido un modelo de predicción mediante el entrenamiento de una red neuronal con los datos horarios de 15 variables distintas desde el 1 de enero de 2019 hasta el 31 de octubre de 2020, es decir, utilizando los datos de un total de 22 meses.

Tras analizar los resultados obtenidos en la estimación, se puede comprobar que la predicción no se aleja excesivamente de la realidad en la mayoría de los casos y proporciona gran ayuda a la hora de realizar estimaciones de precios futuros de la electricidad y poder anteponerse a fenómenos que puedan afectar a la sociedad.

Se puede confirmar, por lo tanto, que las variables seleccionadas son las adecuadas para realizar la predicción, al menos en el caso anterior. Sin embargo, ¿estas variables serían igual de útiles en cualquier periodo de tiempo?, ¿el uso de las mismas variables para el entrenamiento de otra red neuronal pero utilizando unos datos temporales de distintas fechas seguiría proporcionando un modelo con la misma utilidad? En esta parte del proyecto se pretende responder a estas preguntas y poder corroborar que, efectivamente, los factores estudiados y utilizados para el entrenamiento son los apropiados.

Los datos utilizados para esta parte del proyecto han seguido siendo los mismos, es decir, los datos horarios de las 15 variables y del precio de la electricidad desde el 1 de enero de 2019 hasta el 31 de marzo de 2021 (2 años y 3 meses). Para los estudios previos a este caso se han utilizado los primeros 22 meses para el entrenamiento de la red (desde el 1 de enero de 2019

hasta el 31 de octubre de 2020) y los últimos 5 meses para realizar la predicción del precio y compararla con los resultados reales (desde el 1 de noviembre de 2020 hasta el 31 de marzo de 2021).

Durante los 2 años y 3 meses en los que se desarrolla el estudio del proyecto, como es bien sabido, han ocurrido sucesos sin precedentes durante épocas previas. La aparición del coronavirus ha influido en la vida de tal forma que ha provocado un importante cambio en las personas. Además de la influencia en la vida personal de cada individuo, la pandemia ha provocado grandes cambios en numerosos aspectos.

Se puede destacar la electricidad como uno de los casos en los cuales se han producido cambios debido al coronavirus. Cabe la posibilidad de que muchos de los aspectos que condicionaban en mayor medida el precio de la electricidad en épocas “pre-pandemia” no sean exactamente los mismos que durante la presencia del COVID-19. Factores como el aumento del uso doméstico de la electricidad en épocas de confinamiento o la disminución de la demanda energética debido al cierre de numerosas empresas pueden ser algunos de los ejemplos que han podido modificar el desarrollo de la demanda eléctrica, afectando así a la generación eléctrica y, por lo tanto, al precio de la electricidad.

En este caso, se ha procedido al entrenamiento de una red neuronal mediante la utilización de datos que provienen de la época en la que ha habido pandemia, es decir, utilizando los datos de las variables desde el 1 de enero de 2020 hasta el 31 de marzo de 2021. Una vez entrenada la red con estos datos, se ha realizado una estimación del precio de la electricidad para el año 2019, durante el cual todavía no se desarrolló la pandemia. Se han utilizado las mismas 15 variables que han permitido realizar un modelo válido de estimación en el caso anterior.

De este modo, si utilizando esta configuración de entrenamiento y predicción se han conseguido unos resultados similares, se habrá confirmado que las variables seleccionadas son las idóneas y que, por lo tanto, podrían ser usadas para realizar estimaciones del precio en cualquier momento temporal. Además se comprobará de este modo si la aparición de la pandemia ha influido de manera excesiva a la obtención del precio del mercado mayorista de la electricidad.

Al igual que en los casos anteriores, se han realizado numerosas pruebas utilizando distintos números de neuronas ocultas para el entrenamiento de la red. Se ha seleccionado, de todas ellas, la prueba que presenta la menor media entre el valor absoluto de las diferencias entre los datos reales y los estimados. A continuación, se muestra una tabla con los resultados obtenidos.

NÚMERO DE NEURONAS OCULTAS	MEDIA DE LA DIFERENCIA EN VALOR ABSOLUTO LOS VALORES REALES Y ESTIMADOS (€/MWh)
100	8,05607401
100 (2)	9,98934633
100 (3)	9,46868261
100 (4)	9,52974321
120	8,06285971
200	18,2157661
300	18,622876
400	22,0187382

Tabla 8. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados de los distintos entrenamientos realizados para el caso 4. (Fuente: elaboración propia)

Como se puede apreciar, el mejor resultado se ha obtenido con 100 neuronas. La media del error obtenida mediante esta configuración temporal es menor, aunque muy similar, que el conseguido con la anterior (8,13337607). Esto quiere decir que el entrenamiento ha proporcionado, a priori, buenos resultados.

En la siguiente tabla se comparan los valores de MSE y de R en la validación obtenidos mediante el entrenamiento anterior (caso 4) con respecto a los del caso 3, teniendo en cuenta que en ambos casos se han utilizado las mismas variables:

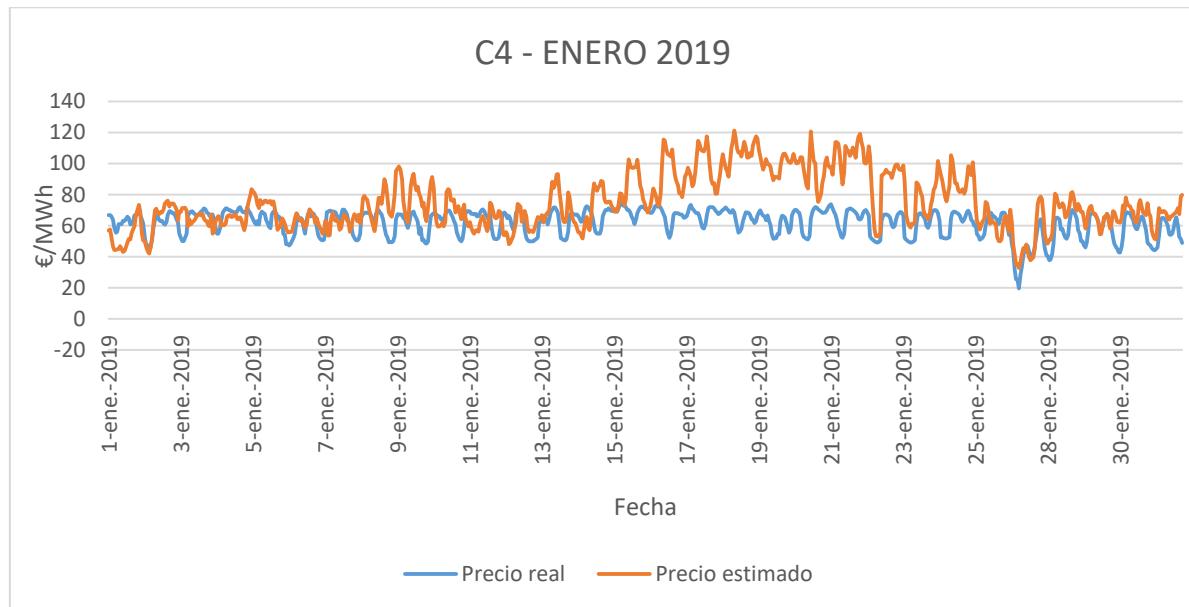
CASO	MSE	R
CASO 3	7,01543	9,80386 e-1
CASO 4	9,96571	9,80672 e-1

Tabla 9. Comparación entre los valores de MSE y R de los entrenamientos de los casos 3 y 4. (Fuente: elaboración propia)

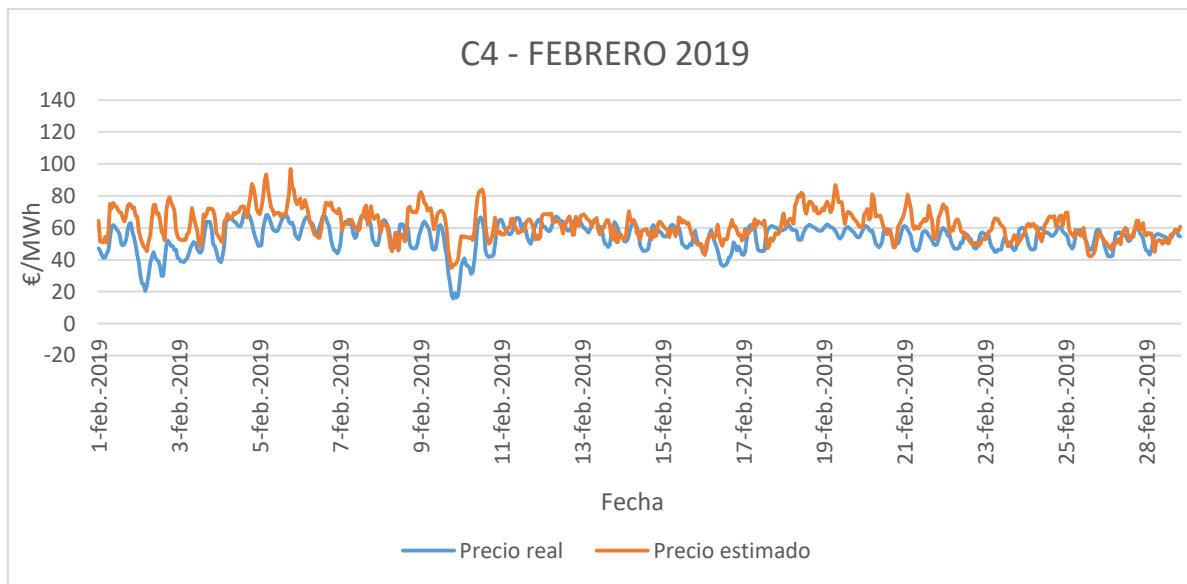
Se puede apreciar como el valor de R es prácticamente el mismo que en el caso anterior, lo que indica que la correlación del entrenamiento sigue siendo muy buena. En cuanto al valor de MSE, se obtienen peores resultados que en el caso anterior, lo que indica que el error cuadrático es mayor.

Teniendo en cuenta la media del valor absoluto de la diferencia entre valores reales y estimados obtenida, además de estos parámetros, se han obtenido unos buenos resultados de entrenamiento y de predicción, pese al aumento del valor de MSE del entrenamiento.

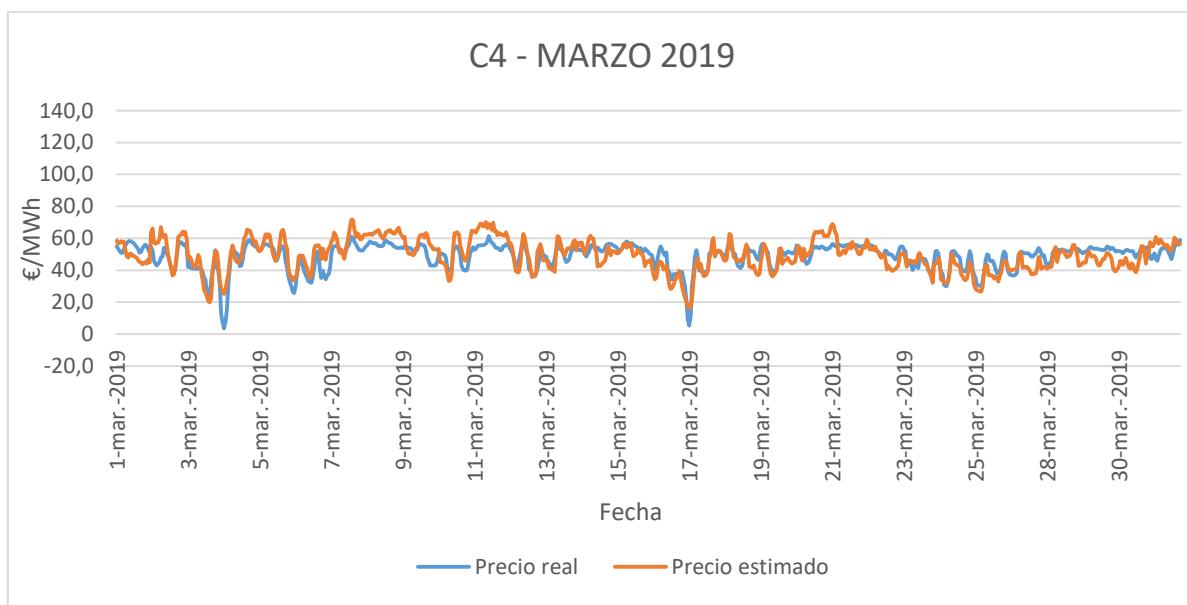
Para confirmar que esto es correcto, se ha realizado una comparación entre los valores reales y los estimados. A continuación se muestran gráficas de esas comparaciones para todos los meses estimados (año 2019).



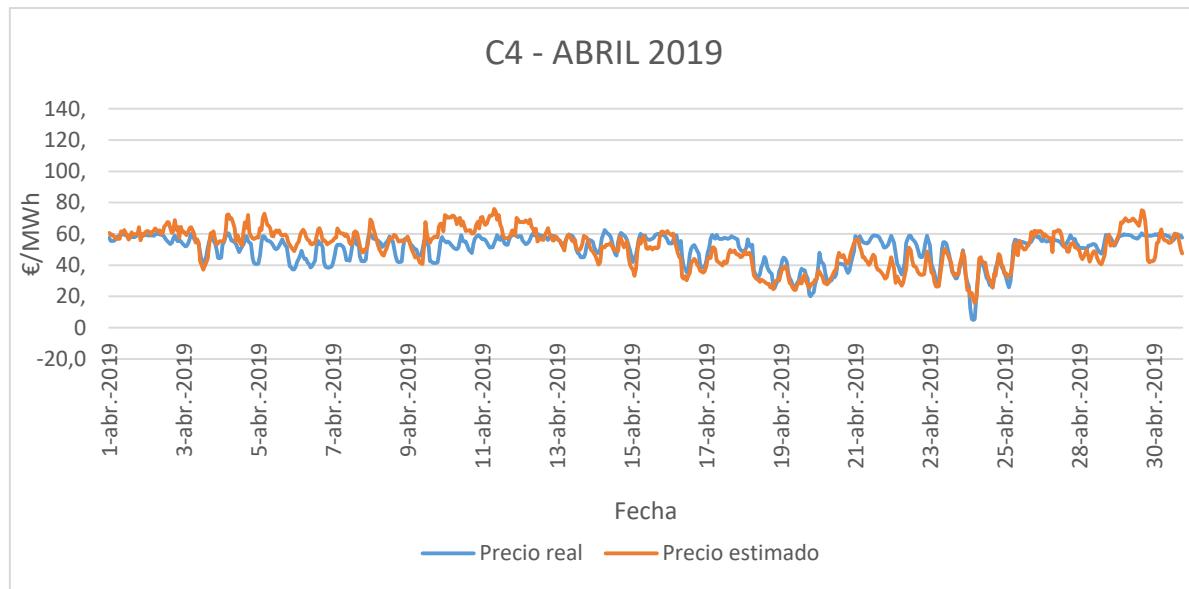
Gráfica 24. Comparación entre precio real y los estimados en los tres casos en enero de 2019. (Fuente: elaboración propia)



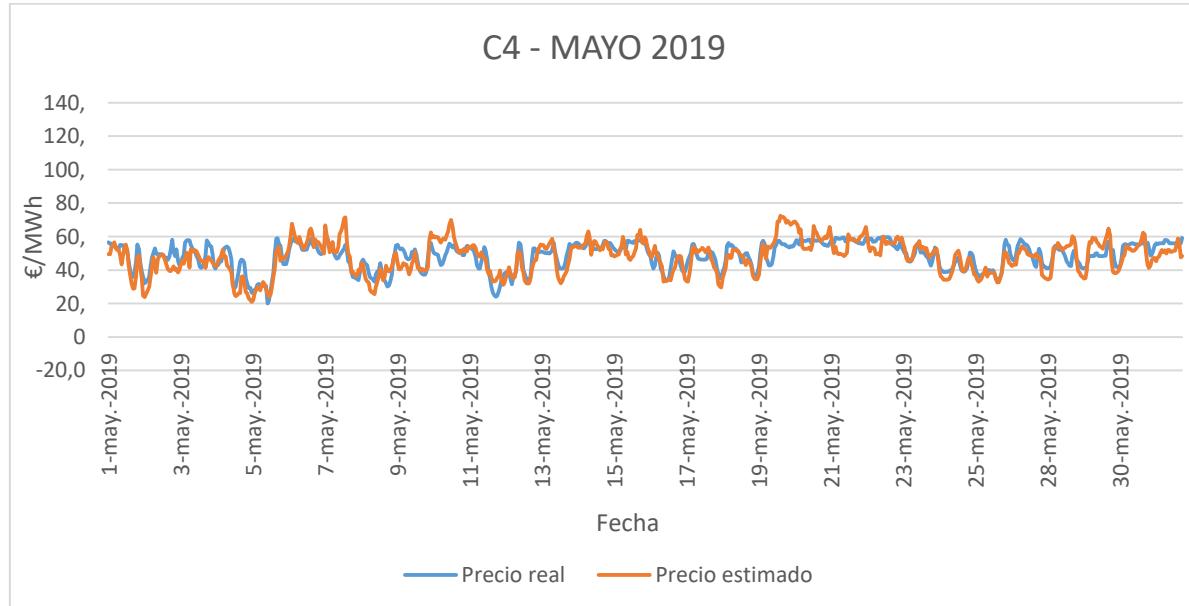
Gráfica 25. Comparación entre precio real y los estimados en los tres casos en febrero de 2019. (Fuente: elaboración propia)



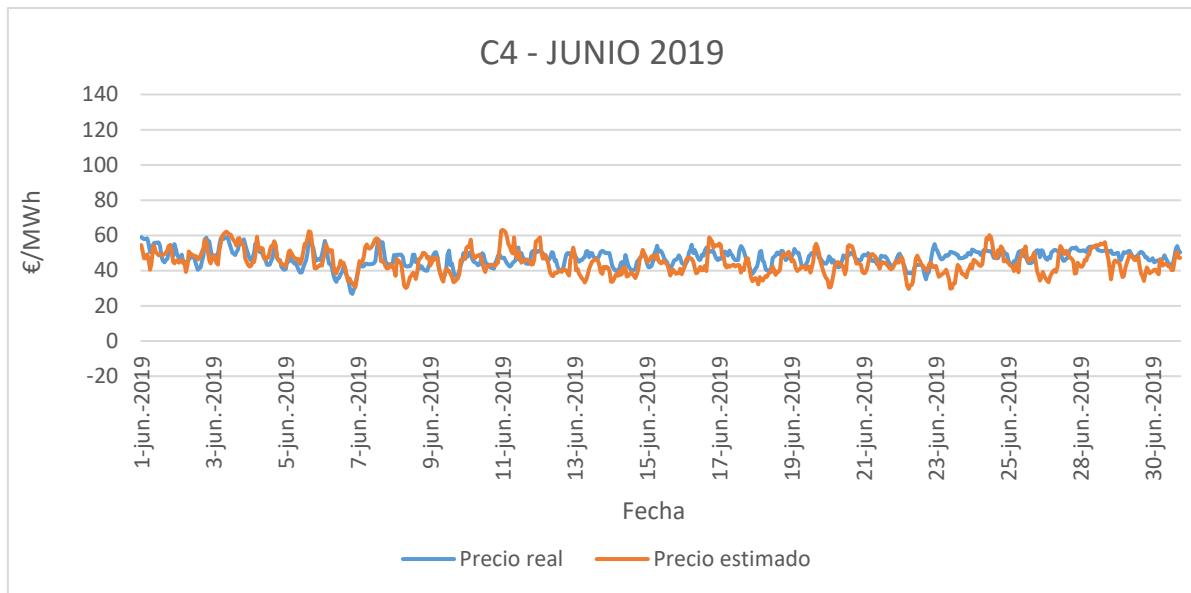
Gráfica 26. Comparación entre precio real y los estimados en los tres casos en marzo de 2019. (Fuente: elaboración propia)



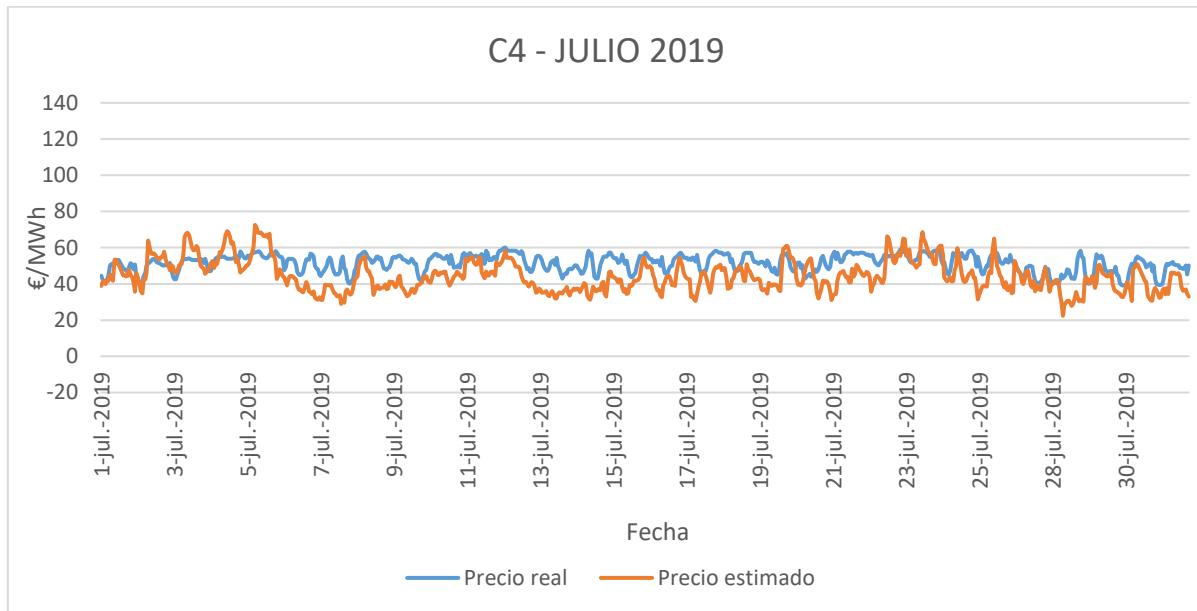
Gráfica 27. . Comparación entre precio real y los estimados en los tres casos en abril de 2019. (Fuente: elaboración propia)



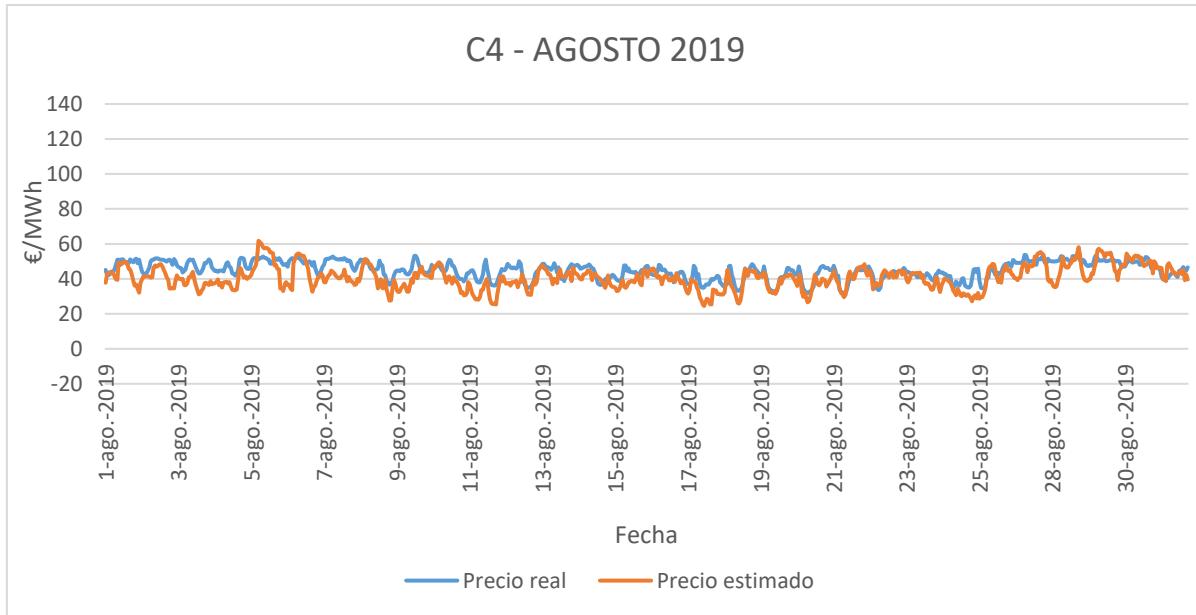
Gráfica 28. Comparación entre precio real y los estimados en los tres casos en mayo de 2019. (Fuente: elaboración propia)



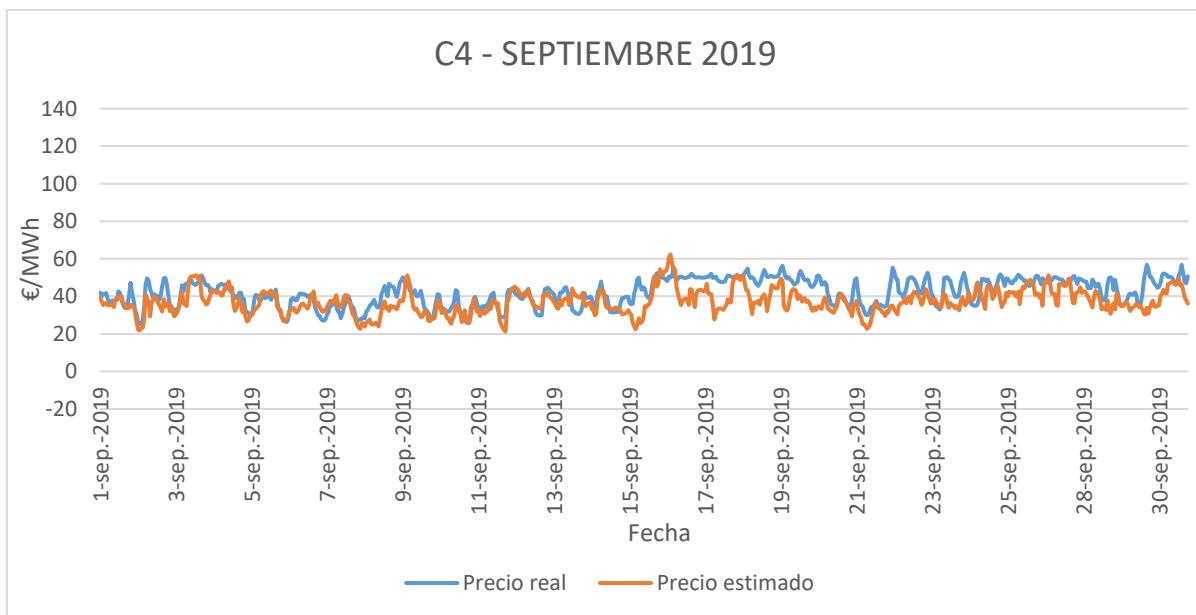
Gráfica 29. Comparación entre precio real y los estimados en los tres casos en junio de 2019. (Fuente: elaboración propia)



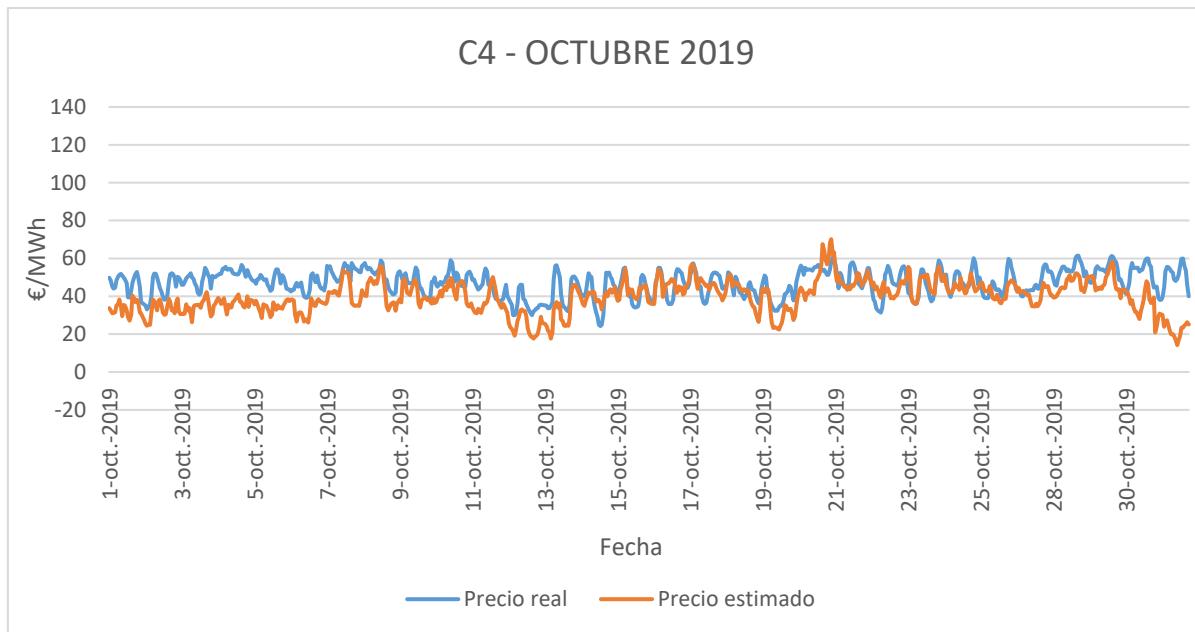
Gráfica 30. Comparación entre precio real y los estimados en los tres casos en julio de 2019. (Fuente: elaboración propia)



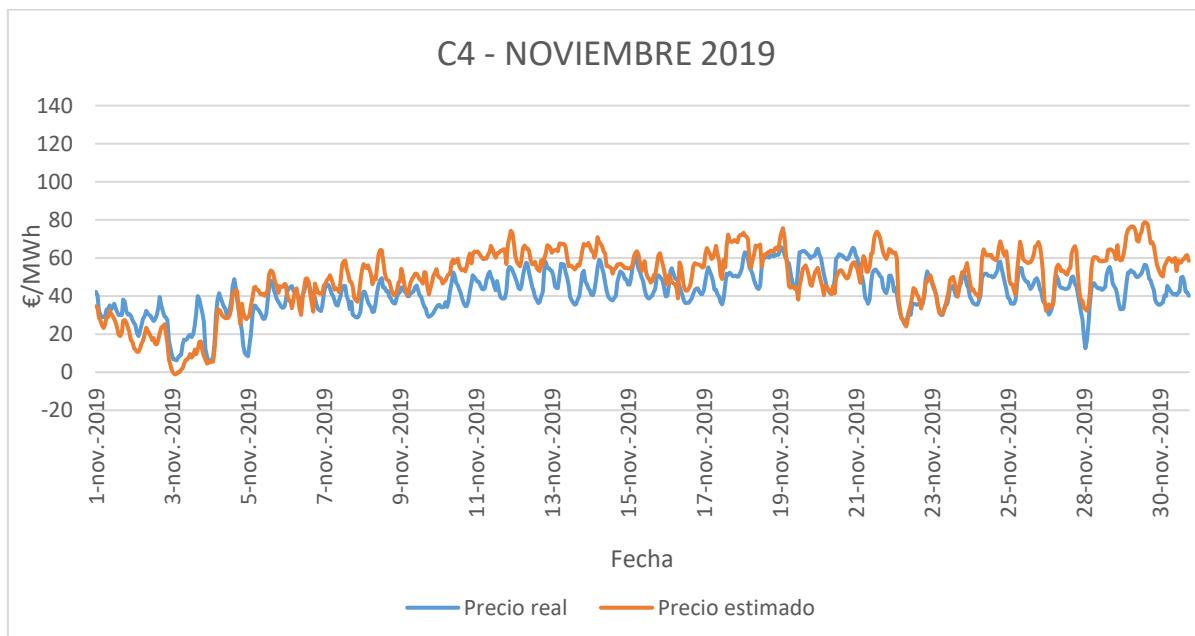
Gráfica 31. Comparación entre precio real y los estimados en los tres casos en agosto de 2019. (Fuente: elaboración propia)



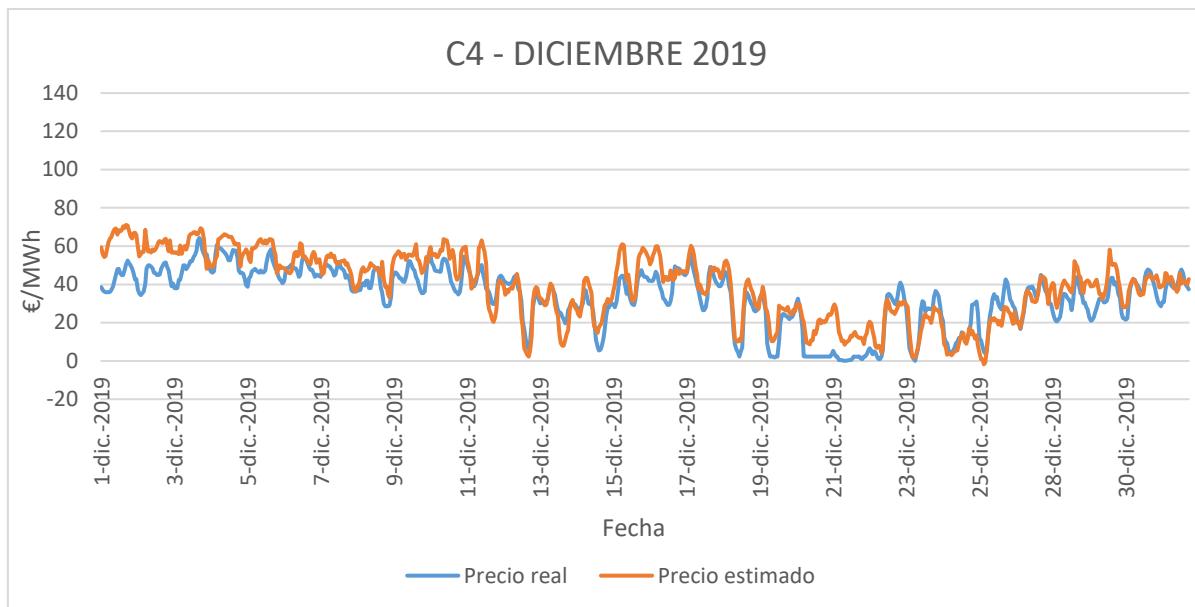
Gráfica 32. Comparación entre precio real y los estimados en los tres casos en septiembre de 2019. (Fuente: elaboración propia)



Gráfica 33. Comparación entre precio real y los estimados en los tres casos en octubre de 2019. (Fuente: elaboración propia)



Gráfica 34. Comparación entre precio real y los estimados en los tres casos en noviembre de 2019. (Fuente: elaboración propia)



Gráfica 35. Comparación entre precio real y los estimados en los tres casos en diciembre de 2019. (Fuente: elaboración propia)

Tras analizar estas gráficas, se puede observar que las estimaciones siguen la misma tendencia que los valores reales. Al igual que ha ocurrido en el caso anterior, existen zonas en las que la disimilitud entre la realidad y la estimación ha sido superior que en otras. A pesar de esto, se puede corroborar que ambos valores, en la mayoría de los meses, siguen exactamente la misma tendencia.

Como ocurría en los casos anteriores, es enero (aunque del año 2019) el mes que ha presentado una mayor divergencia. Entre el 15 y el 25 de enero, principalmente, se han producido unos picos demasiado exagerados en la curva de predicción. Este fenómeno puede ser debido a que alguna variable ha ejercido un efecto negativo sobre la estimación en ese periodo.

Al observar las gráficas de todos los meses observamos que, con mayor o menor exactitud, la curva de estimación sigue la misma tendencia que la real. Gracias a estos resultados se ha llegado a la conclusión de que las variables seleccionadas tienen un comportamiento similar a pesar de haber sido utilizadas mediante distinta configuración horaria para el entrenamiento de la red y posterior estimación del precio. Este hecho confirma la validez de los factores estudiados y asegura unos resultados útiles para tener una idea de cuál va a ser la tendencia de este precio y poder anteponerse en caso de subidas bruscas o bajadas.

## 9. CONCLUSIONES

Hacer una selección de todos los factores que afectan a la consecución del precio de la electricidad y obtener a partir de ellos una estimación fiel de la realidad es una tarea muy complicada.

Existen gran cantidad de variables que, a priori, tienen una importancia muy grande a la hora de realizar esta estimación y que, sin embargo, una vez estudiadas y utilizadas para la predicción, no proporcionan los resultados esperados. Del mismo modo, existen otras variables que en un principio no reciben la importancia necesaria y que al final te permiten obtener unos mejores objetivos.

Al realizar una primera estimación (caso 1) únicamente con los valores generados por cada tipo de central generadora, y los valores de energía total, de compra y de venta, se ha podido constatar la importancia de estas variables y obtener un primer resultado que sigue fielmente la tendencia real. Simplemente con el uso de estas variables se puede tener una idea de si el precio va a subir o bajar en cada periodo de tiempo, lo cual sugiere un resultado muy interesante.

Tras observar este primer resultado se han podido analizar los puntos fuertes y débiles de la estimación y conseguir, a partir de ellos, mejorar las zonas más desfavorables sin empeorar las zonas con mejores predicciones. Para ello se han de buscar otros factores que puedan ser influyentes en el aspecto de estudio y comprobar si, efectivamente, a partir de ellos se obtienen las mejoras pertinentes.

Otras variables que pueden ser muy útiles, como pueden ser factores climatológicos como la temperatura o la cantidad de lluvia, han sido muy complicadas de tener en cuenta en el estudio. Al trabajar con valores horarios y abarcar un territorio tan grande como es España, es de gran complejidad obtener unos valores adecuados para ese tipo de aspectos. En el caso de que se pudieran obtener unos datos estimados de estas variables, estos tendrían un error excesivamente grande, y en vez de ser de utilidad, probablemente entorpecerían la predicción.

En el caso de que una empresa utilizara este modelo para la estimación, no le sería de tal complejidad obtener datos fiables de este tipo de variables, y podrían mejorar considerablemente la predicción y obtener resultados mucho más parecidos a los reales.

Para solucionar esta cuestión se ha tenido en cuenta la variable de “demanda prevista”, que como se ha comentado anteriormente, responde a este tipo de cuestiones climatológicas, al igual que a otros factores económicos o de laboralidad.

Una vez determinados los resultados mediante el uso de esta variable se ha observado que no se produce una excesiva mejoría y visualmente las curvas tienen un aspecto similar. Sin embargo, sí que se reduce la diferencia entre valores reales y estimados (ligeramente) y los resultados del entrenamiento de la red neuronal son mejores.

Para obtener mejoras en los tramos más desfavorables ha sido necesaria la búsqueda de información. Enero de 2021 ha sido el año con peor predicción y, tras observar su curva, se puede apreciar como el precio sufrió, durante este mes, un importante aumento con respecto a los anteriores y los posteriores. Este aumento pudo ser debido a varios factores: el descenso



excesivo de las temperaturas durante este mes, el descenso de la generación renovable y el agotamiento de las existencias de gas.

El primero de ellos, el descenso de las temperaturas, se tuvo en cuenta mediante la utilización de la variable “demanda prevista”, con la cual no se consigue disminuir la diferencia en gran medida durante este mes.

La generación de energía renovable es un factor, que en caso de tener influencia sobre la estimación, ya se habría tenido en cuenta. Desde el primer modelo de predicción realizado se ha incluido la cantidad de energía generada por cada una de las centrales de generación, tanto renovable como no renovable. Sin embargo, ha sido posible, con los datos que ya se tenían, comprobar si, en efecto, la generación de energía renovable ha sufrido un importante descenso durante este mes, provocando un aumento de la generación no renovable.

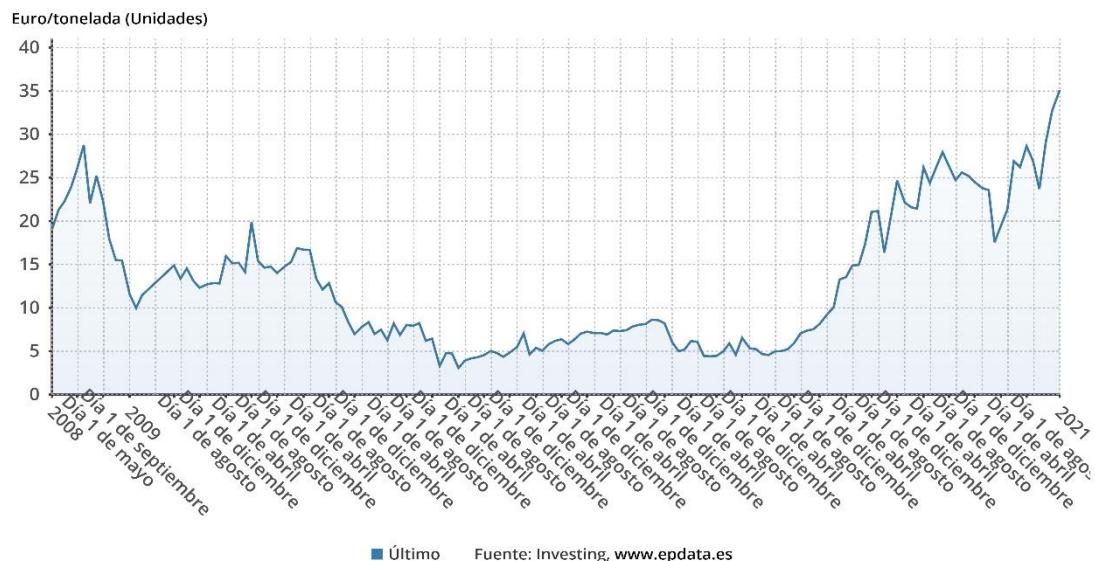
Tras realizar una media de la energía generada mensualmente por cada tipo de generación, se llega a la conclusión de que durante este mes la energía renovable ha seguido la misma tendencia que los meses anteriores, sin un descenso brusco en su generación. El aumento de la producción de energía a partir de carbón ha sido el único dato que ha llamado la atención en cuanto a variación, pero su incidencia en el precio no es lo suficientemente importante como para provocar tan elevados precios.

El siguiente paso ha sido el estudio de la influencia que ejerce el gas en el precio de la electricidad. Tanto el precio como el volumen del gas han podido proporcionar mejoras en la predicción, teniendo en cuenta así los aumentos y disminuciones en la demanda de gas y el agotamiento de sus existencias, en caso de producirse.

La emisión de gases contaminantes a la atmósfera supone a las centrales eléctricas de gas y carbón el pago de los derechos de emisión de CO<sub>2</sub>. Cada año, la producción eléctrica produce alrededor de 70 millones de toneladas de CO<sub>2</sub>, debido a la importancia de este tipo de centrales. Los costes que han de pagar las centrales eléctricas de gas y carbón como consecuencia de estas emisiones a la atmósfera se denominan derechos de emisión de CO<sub>2</sub> (EUA). Este impuesto de emisión de CO<sub>2</sub> no es directo, sino que es comercializado por la Unión Europea para incentivar la disminución de las emisiones.

Los costes de emisión de CO<sub>2</sub> han sufrido un aumento progresivo durante los últimos años. Emitir este tipo de gases a la atmósfera cada vez supone un mayor esfuerzo económico por parte de las centrales. Las centrales generadoras de emisiones tienen obligación de compra de derechos de emisión, sin embargo, estos derechos antes no suponían ningún problema, ya que eran considerablemente más baratos. [22]

### Evolución del precio de los derechos de emisión de CO2

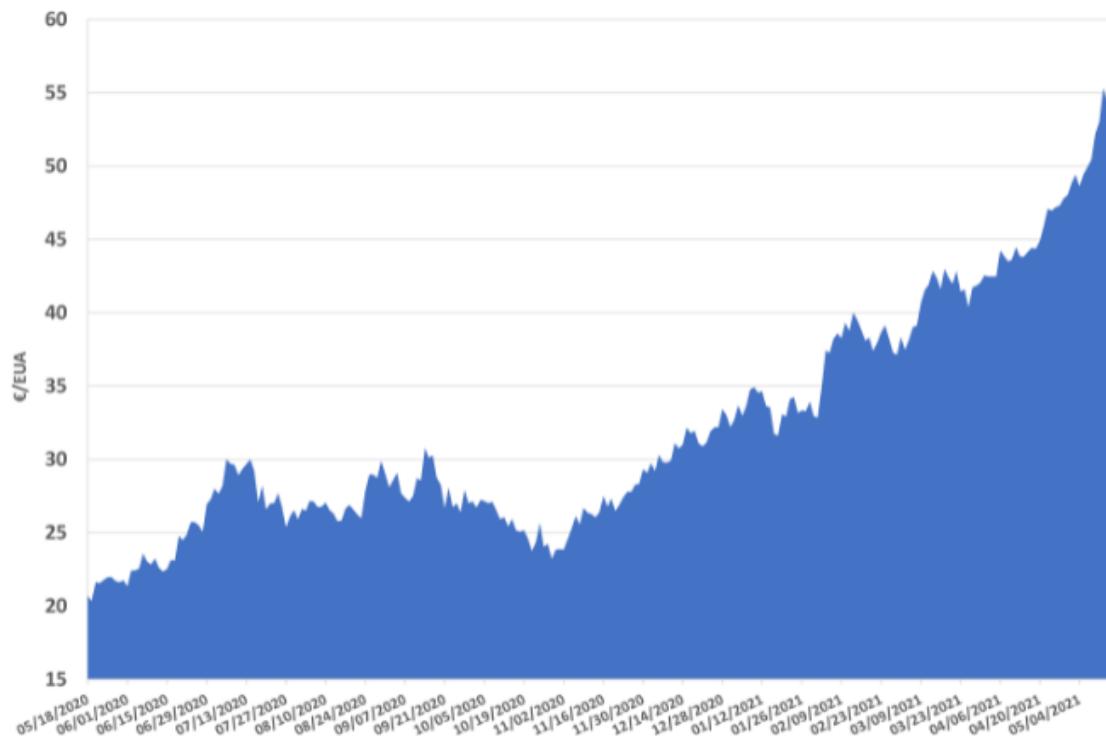


Gráfica 36. Evolución del precio de los derechos de emisión de CO2 desde 2008 hasta 2021. [25]

En la gráfica anterior, se observa la evolución que ha sufrido el coste de los derechos de emisión de CO2 desde 2008 hasta la actualidad. Se puede apreciar como en 2021 se encuentra el mayor pico de este coste, con una enorme diferencia con respecto a los valores intermedios de la curva.

Observamos cómo, años atrás, estas centrales pagaban unos 5 € por tonelada de CO2 emitida. [22] Actualmente, en el año 2021, los costes de estas emisiones suponen unos precios mucho más elevados y se prevé que sigan en aumento durante los próximos años. [23]

En la siguiente gráfica (Gráfica 37) se puede distinguir el aumento que ha sufrido este coste desde mayo de 2020 hasta mayo de 2021. Se toma como unidad del coste de las emisiones los €/EUAs. Los EUAs (European Union Allowances) son la cantidad de derechos asignados equivalentes a las emisiones que se han realizado en un determinado periodo de tiempo, es decir, las toneladas emitidas. Se observa así como en mayo de 2021 se han alcanzado unos costes de emisión de casi 60 €/EUAs, muy superior a los precios anteriores. [24]



Gráfica 37. Evolución del precio de los EUAs. [24]

El gran aumento del precio de estos derechos provoca que, lo que antes suponía algo asequible para estas centrales, en la actualidad suponga un excesivo gasto de generación. Por ello, estas centrales de gas y carbón tienen cada vez mayores costes de producción de la electricidad, lo que implica que, al entrar en el mercado mayorista de electricidad, se eleve el precio marginal. Este suceso provoca grandes picos en determinadas épocas del año, difícilmente estimables sin variables que tengan en cuenta estos efectos.

Incluir el precio y el volumen del gas en el estudio y entrenamiento de la red neuronal es un acierto, ya que nos permite tener en cuenta en gran medida este factor, proporcionando un mayor ajuste en la estimación, como se ha podido apreciar en las distintas comparaciones entre los casos. Además, añadir la variable del precio de los derechos de emisión de CO<sub>2</sub> en futuros entrenamientos podría aportar una mejora y proporcionar una mejor estimación.

Si miramos al futuro, este aumento de los costes de emisión del CO<sub>2</sub> es positivo. Las energías contaminantes tienen un alto coste de producción y, por lo tanto, dejan paso a energías de menor coste que favorecen a la transición energética positiva. En esta transición, las energías renovables son las de mayor importancia, siendo tecnologías limpias y que no están afectadas por los precios del CO<sub>2</sub>. [22]

Una vez analizada y estudiada la influencia del gas, se han incluido las variables del precio y volumen del gas en el estudio, utilizando estos datos para el entrenamiento de la red neuronal. Tras realizar la predicción se ha obtenido una importante mejora en la estimación y se ha conseguido un modelo de predicción útil para el futuro. Esto se puede apreciar claramente en el mes de enero de 2021, donde estimar valores cercanos a la realidad ha sido muy complicado en casos anteriores, pero se aprecia una gran mejora con la entrada de estas variables en el modelo

Por otra parte, mediante este estudio se ha demostrado que con la configuración temporal de entrenamiento y predicción establecida y el empleo de estas variables, al final se consiguen unos buenos resultados. Sin embargo, ha sido de gran interés comprobar si estas mismas variables utilizadas servirían para entrenar una red con los datos de distintos períodos de tiempo que el utilizado hasta ahora (desde el 1 de enero de 2019 hasta el 31 de octubre de 2020 para entrenar y desde el 1 de noviembre de 2020 y el 31 de marzo de 2021 para predecir). Por ello se ha realizado un estudio para distintos períodos de tiempo, utilizando la misma herramienta, y nos ha permitido confirmar que esas variables se comportan de manera adecuada para cualquier instante y nos permiten realizar modelos fiables.

Aprovechando que parte de los datos se suceden en tiempos de pandemia y la otra parte no, se han utilizado los primeros para entrenar la red, mientras que los tiempos en los que no ejercía influencia el coronavirus sobre la sociedad se han utilizado para realizar la predicción.

Una vez obtenidos los resultados se ha llegado a la conclusión de que el nuevo modelo realizado con esta configuración tiene prácticamente la misma eficacia que el obtenido con la anterior. Por lo tanto, se confirma así que las variables utilizadas para este estudio son las adecuadas para realizar predicciones de estas características y que la calidad de esta estimación no variará en gran medida al modificar la configuración temporal del modelo.

Obtener una mejor estimación que la obtenida en este trabajo de fin de grado sería posible en el caso de obtener variables que aporten mejoras al entrenamiento. Por ello este proyecto podría ser continuado mediante la adición de estas nuevas variables que permitan una predicción cada vez más fiable hasta poder conseguir, en un futuro, estimar de forma prácticamente exacta este precio.

Para el caso de estimación en tiempos futuros, dado que no son conocidos los valores reales de las variables, será necesario trabajar con valores previstos para cada una de ellas. Esto puede suponer un incremento en cuanto al error a la hora de estimar.

La utilización de este modelo puede permitir mejorar la operación de cualquier comercializadora a la hora de prever el precio y permitir así anticiparse a la hora de ofertar. Gracias a esto, la empresa se ahorraría gran cantidad de dinero con la simple acción de saber cuándo es más rentable ofertar y de anticiparse en caso de subidas extraordinarias, como puede ser el caso de un temporal o condiciones que impidan el buen funcionamiento de las energías renovables.

Mediante el uso de este modelo, una comercializadora podría haberse antepuesto a la subida de los precios durante el mes de enero de 2021, debida principalmente a los efectos de la tormenta Filomena, el intenso frío y el agotamiento de las existencias de gas, permitiendo de este modo a la empresa estar sobre aviso para anteponerse a esas situaciones y evitar así pérdidas económicas.

## 10. BIBLIOGRAFÍA

1. S. (2020, 22 julio). *Electricidad - Concepto, origen, importancia y características*. Concepto. <https://concepto.de/electricidad-2/>
2. Endesa, C. D. (2021, 24 febrero). *Cómo se genera la energía eléctrica / Endesa*. Endesa. <https://www.endesa.com/es/conoce-la-energia/energia-y-mas/como-se-genera-electricidad>
3. R. (2021, 23 mayo). *¿Por qué subió tanto la luz en enero?* Verde y Azul. <https://verdeyazul.diarioinformacion.com/por-que-subio-tanto-la-luz-en-enero.html#:~:text=El%20agotamiento%20de%20las%20existencias,60%2C2%20%E2%82%AC%2FMWh>.
4. *Las Plantas de Cogeneración*. (2013). Renove Tecnología S.L. <http://www.plantasdecogeneracion.com/index.php/las-plantas-de-cogeneracion>
5. *Descubre el funcionamiento de una central hidroeléctrica*. (2021). Fundación Endesa. <https://www.fundacionendesa.org/es/centrales-renovables/a201908-central-hidroelectrica>
6. *Energía eólica: cómo funciona y sus ventajas*. (2021, 15 febrero). Factorenergia. <https://www.factorenergia.com/es/blog/eficiencia-energetica/energia-eolica/>
7. GARRIDO, S. G. (2014). *I. LAS CENTRALES DE CICLO COMBINADO*. Renove Tecnología S.L. <http://www.cicloscombinados.com/index.php/1-las-centrales-de-ciclo-combinado#:~:text=Una%20central%20de%20ciclo%20combinado,recuperaci%C3%B3n%20que%20produce%20vapor%20aprovechable>
8. *Cómo funciona - CSN*. (2021). Consejo de Seguridad Nuclear. <https://www.csn.es/como-funciona>
9. *Funcionamiento de una central térmica convencional*. (2021). Fundación Endesa. <https://www.fundacionendesa.org/es/centrales-electricas-convencionales/a201908-central-termica-convencional>
10. *Energía solar: todo lo que tienes que saber*. (2021, 18 marzo). Factorenergia. <https://www.factorenergia.com/es/blog/autoconsumo/energia-solar/#:~:text=Al%20contrario%20que%20la%20energ%C3%ADa,calor%20de%20sol%20en%20electricidad>
11. *Energía y sociedad* (2015). Industriales ETSII - [www.energiaysociedad.es](http://www.energiaysociedad.es)
12. *REData* (2021). Red Eléctrica de España. - <https://www.ree.es/es>
13. *Resultados del mercado de MIBGAS / MIBGAS - Mercado Ibérico del Gas*. (2021). MIBGAS. <https://www.mibgas.es/es/market-results?menu=1&parent=9&this=9>

14. *Sistema de información del operador del sistema/ ESIOS electricidad.* (2021). ESIOS REE.  
<https://www.esios.ree.es/es?locale=es>
15. JUAN DAVID VELÁSQUEZ HENAO, ISAAC DYNER RESONSEW, REINALDO CASTRO SOUZA. (2007) *¿Por qué es tan difícil obtener buenos pronósticos de los precios de la electricidad en mercados competitivos?* (2007)
16. *Mercado de electricidad / OMIE.* (2021). Operador del Mercado Ibérico de Energía-Polo Español. <https://www.omie.es/es/mercado-de-electricidad>
17. SARA JIMÉNEZ DEL CASO, EMILIO LÓPEZ CANO, ARTURO FARFÁN MARTÍN, JAVIER MARTÍNEZ MOGUERZA, CRISINA SÁEZ BLAZQUEZ (2017). *Interrelación de las variables que inciden en el mercado diario de la electricidad.* DYNA SL. <https://www.dyna-energia.com>
18. UNAI CASADO GALDEANO, MACARENA LARREA BASTERRA (2017). *Determinantes del precio de la electricidad - Estadística Española • Volumen 59, número 194 / 2017, pp. 119-149.*
19. YOLANDA CUELLAR (2020). OMIE. 0209 Módulo II. *Organización del mercado spot.*
20. JOSÉ CARLOS MORENO (2020). OMIE. 0211 Módulo III. *Funcionamiento y resultados del mercado diario.*
21. NURIA TRANCHO TEJERINA (2020). OMIE. Módulo IV. *Subastas MIBEL. Funcionamiento y resultados.*
22. LUZ, P. Q. S. (2019, 5 junio). *¿Afectan los derechos de emisiones de CO2 al precio de la luz? ¿Por qué sube la luz?* <https://porquesubelaluz.es/2019/06/05/afectan-los-derechos-de-emisiones-de-co2-al-precio-de-la-luz/>
23. MORALES, I. (2021, 5 mayo). *El coste del CO2 dispara el precio de la electricidad a niveles históricos.* Precio CO2.  
[https://www.elconfidencial.com/medioambiente/energia/2021-05-06/emisiones-co2-precio-de-la-electricidad-abril\\_3064915/](https://www.elconfidencial.com/medioambiente/energia/2021-05-06/emisiones-co2-precio-de-la-electricidad-abril_3064915/)
24. AEQ. *Evolución de los precios de los derechos de emisión (EUAs) / AEQ.* (2021). EUAs.  
<https://www.aeqenergia.com/blog/evolucion-de-los-precios-de-los-derechos-de-emision-euas>
25. EPDATA. *Evolución del precio de los derechos de emisión de CO2.* (2021). EpData.  
<https://www.epdata.es/evolucion-precio-derechos-emision-co2/3487e5a4-0b3d-40c4-8105-b425a5111d06>
26. MATLAB *¿Qué es una red neuronal?* (2021). MATLAB & Simulink.  
<https://es.mathworks.com/discovery/neural-network.html>



## 11. INDICE DE FIGURAS

<i>Figura 1. Descripción de la organización del sistema eléctrico en España.</i> .....	5
<i>Figura 2. Actividades reguladas y liberalizadas del Sector Eléctrico en España. [11]</i> .....	5
<i>Figura 3. Mercado diario en MIBEL [19]</i> .....	7
<i>Figura 4. Curva de ofertas de compra. [11]</i> .....	8
<i>Figura 5. Curva de ofertas de venta. [11]</i> .....	8
<i>Figura 6. Ejemplo de curva agregada. [20]</i> .....	9
<i>Figura 7. Desarrollo temporal del mercado [19]</i> .....	10
<i>Figura 8. Secuencia de mercados de energía eléctrica [11]</i> .....	11
<i>Figura 9. Efecto de añadir el estudio de gas. Comparación el precio real y estimado en enero de 2021 de los casos 2 y 3. (Fuente: elaboración propia)</i> .....	35
<i>Figura 10. Arquitectura típica de una red neuronal</i> .....	61
<i>Figura 11. Selección de datos desde el workspace</i> .....	62
<i>Figura 12. Selección de porcentajes para el entrenamiento, validación y prueba de la red</i> .....	62
<i>Figura 13. Selección de número de capas ocultas</i> .....	63
<i>Figura 14. Esquema de la red neuronal mediante Neural Net Fitting</i> .....	63
<i>Figura 15. Selección de algoritmo y entrenamiento</i> .....	64
<i>Figura 16. Resultado del entrenamiento seleccionado</i> .....	65
<i>Figura 17. Resumen del entrenamiento del caso 1 (nntraintool)</i> .....	66
<i>Figura 18. Plotperform, representación del error cuadrático en función de las interacciones del entrenamiento. Caso 1</i> .....	67
<i>Figura 19. Representación del histograma de error del entrenamiento. Caso 1</i> .....	67
<i>Figura 20. Gráfico de regresión del entrenamiento. Caso 1</i> .....	68
<i>Figura 21. Resumen del entrenamiento en el caso 2</i> .....	70
<i>Figura 22. Resultados del entrenamiento en el caso 2</i> .....	70
<i>Figura 23. Plotperform, representación del error cuadrático en función de las interacciones del entrenamiento. Caso 2</i> .....	71
<i>Figura 24. Representación del histograma de error del entrenamiento. Caso 2</i> .....	72
<i>Figura 25. Gráfico de regresión del entrenamiento. Caso 2</i> .....	72
<i>Figura 26. Resumen del entrenamiento. Caso 3, 15 variables</i> .....	74
<i>Figura 27. Resultados del entrenamiento. Caso 3, 15 variables</i> .....	74
<i>Figura 28. Plotperform, representación del error cuadrático en función de las interacciones del entrenamiento. Caso 3</i> .....	75



<i>Figura 29. Representación del histograma de error del entrenamiento. Caso 3.</i> .....	76
<i>Figura 30. Gráfico de regresión del entrenamiento. Caso 3.</i> .....	76
<i>Figura 31. Resumen del entrenamiento. Caso 4.</i> .....	77
<i>Figura 32. Resultados del entrenamiento. Caso 4.</i> .....	78
<i>Figura 33. Plotperform, representación del error cuadrático en función de las interacciones del entrenamiento. Caso 4.</i> .....	79
<i>Figura 34. Representación del histograma de error del entrenamiento. Caso 4.</i> .....	79
<i>Figura 35. Gráfico de regresión del entrenamiento. Caso 4.</i> .....	80
<i>Figura 36. Obtención del código de MATLAB.</i> .....	81
<i>Figura 37. Código de MATLAB para la predicción del precio. Caso 1.</i> .....	82
<i>Figura 38. Código de MATLAB para la predicción del precio. Caso 2.</i> .....	83
<i>Figura 39. Código de MATLAB para la predicción del precio. Caso 3.</i> .....	84
<i>Figura 40. Código de MATLAB para la predicción del precio. Caso 4.</i> .....	85



## 12. INDICE DE GRÁFICAS

<i>Gráfica 1. Comparación entre precio real y estimado. Caso 1, 12 variables. (Fuente: elaboración propia).....</i>	19
<i>Gráfica 2. Comparación entre precio real y estimado en noviembre de 2020. Caso 1, 12 variables. (Fuente: elaboración propia) .....</i>	20
<i>Gráfica 3. Comparación entre precio real y estimado en diciembre de 2020. Caso 1, 12 variables. (Fuente: elaboración propia) .....</i>	20
<i>Gráfica 4. Comparación entre precio real y estimado en enero de 2021. Caso 1, 12 variables. (Fuente: elaboración propia).....</i>	21
<i>Gráfica 5. Comparación entre precio real y estimado en febrero de 2021. Caso 1, 12 variables. (Fuente: elaboración propia).....</i>	21
<i>Gráfica 6. Comparación entre precio real y estimado en marzo de 2021. Caso 1, 12 variables. (Fuente: elaboración propia).....</i>	22
<i>Gráfica 7. Comparación entre precio real y estimado. Caso 2, 13 variables. (Fuente: elaboración propia).....</i>	27
<i>Gráfica 8. Comparación entre precio real y estimado en noviembre de 2020. Caso 2, 13 variables. (Fuente: elaboración propia) .....</i>	27
<i>Gráfica 9. Comparación entre precio real y estimado en diciembre de 2020. Caso 2, 13 variables. (Fuente: elaboración propia) .....</i>	28
<i>Gráfica 10. Comparación entre precio real y estimado en enero de 2021. Caso 2, 13 variables. (Fuente: elaboración propia).....</i>	28
<i>Gráfica 11. Comparación entre precio real y estimado en febrero de 2021. Caso 2, 13 variables. (Fuente: elaboración propia).....</i>	29
<i>Gráfica 12. Comparación entre precio real y estimado en marzo de 2021. Caso 2, 13 variables. (Fuente: elaboración propia).....</i>	29
<i>Gráfica 13. Comparación entre precio real y estimado. Caso 3, 15 variables. (Fuente: elaboración propia).....</i>	32
<i>Gráfica 14. Comparación entre precio real y estimado en noviembre de 2020. Caso 3, 15 variables. (Fuente: elaboración propia) .....</i>	32
<i>Gráfica 15. Comparación entre precio real y estimado en diciembre de 2020. Caso 3, 15 variables. (Fuente: elaboración propia) .....</i>	33
<i>Gráfica 16. Comparación entre precio real y estimado en enero de 2021. Caso 3, 15 variables. (Fuente: elaboración propia).....</i>	33



<i>Gráfica 17. Comparación entre precio real y estimado en febrero de 2021. Caso 3, 15 variables.</i> (Fuente: elaboración propia).....	34
<i>Gráfica 18. Comparación entre precio real y estimado en marzo de 2021. Caso 3, 15 variables.</i> (Fuente: elaboración propia).....	34
<i>Gráfica 19. Comparación entre precio real y los estimados en los tres casos en noviembre de 2020. (Fuente: elaboración propia).....</i>	36
<i>Gráfica 20. Comparación entre precio real y los estimados en los tres casos en diciembre de 2020. (Fuente: elaboración propia).....</i>	37
<i>Gráfica 21. Comparación entre precio real y los estimados en los tres casos en enero de 2021.</i> (Fuente: elaboración propia).....	37
<i>Gráfica 22. Comparación entre precio real y los estimados en los tres casos en febrero de 2021.</i> (Fuente: elaboración propia).....	38
<i>Gráfica 23. Comparación entre precio real y los estimados en los tres casos en marzo de 2021.</i> (Fuente: elaboración propia).....	38
<i>Gráfica 24. Comparación entre precio real y los estimados en los tres casos en enero de 2019.</i> (Fuente: elaboración propia).....	41
<i>Gráfica 25. Comparación entre precio real y los estimados en los tres casos en febrero de 2019.</i> (Fuente: elaboración propia).....	42
<i>Gráfica 26. Comparación entre precio real y los estimados en los tres casos en marzo de 2019.</i> (Fuente: elaboración propia).....	42
<i>Gráfica 27. . Comparación entre precio real y los estimados en los tres casos en abril de 2019.</i> (Fuente: elaboración propia).....	43
<i>Gráfica 28. Comparación entre precio real y los estimados en los tres casos en mayo de 2019.</i> (Fuente: elaboración propia).....	43
<i>Gráfica 29. Comparación entre precio real y los estimados en los tres casos en junio de 2019.</i> (Fuente: elaboración propia).....	44
<i>Gráfica 30. Comparación entre precio real y los estimados en los tres casos en julio de 2019.</i> (Fuente: elaboración propia).....	44
<i>Gráfica 31. Comparación entre precio real y los estimados en los tres casos en agosto de 2019.</i> (Fuente: elaboración propia).....	45
<i>Gráfica 32. Comparación entre precio real y los estimados en los tres casos en septiembre de 2019. (Fuente: elaboración propia).....</i>	45
<i>Gráfica 33. Comparación entre precio real y los estimados en los tres casos en octubre de 2019.</i> (Fuente: elaboración propia).....	46

<i>Gráfica 34. Comparación entre precio real y los estimados en los tres casos en noviembre de 2019. (Fuente: elaboración propia).....</i>	46
<i>Gráfica 35. Comparación entre precio real y los estimados en los tres casos en diciembre de 2019. (Fuente: elaboración propia).....</i>	47
<i>Gráfica 36. Evolución del precio de los derechos de emisión de CO2 desde 2008 hasta 2021. [25]</i>	
.....	50
<i>Gráfica 37. Evolución del precio de los EUAs. [24] .....</i>	51

## 13. INDICE DE TABLAS

<i>Tabla 1. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados de los distintos entrenamientos realizados para el caso 1. (Fuente: elaboración propia).....</i>	19
<i>Tabla 2. Recopilación de los valores medios mensuales de las tecnologías renovables y no renovables. (Fuente: elaboración propia).....</i>	24
<i>Tabla 3. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados de los distintos entrenamientos realizados para el caso 2. (Fuente: elaboración propia).....</i>	26
<i>Tabla 4. Comparación entre los valores de MSE y R del entrenamiento de los casos 1 y 2. (Fuente: elaboración propia).....</i>	26
<i>Tabla 5. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados de los distintos entrenamientos realizados para el caso 3. (Fuente: elaboración propia).....</i>	31
<i>Tabla 6. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados en los casos 1, 2 y 3. (Fuente: elaboración propia).....</i>	31
<i>Tabla 7. Comparación de los valores de MSE y R del entrenamiento de los casos 1, 2 y 3. (Fuente: elaboración propia).....</i>	32
<i>Tabla 8. Comparación entre las medias de las diferencias en valor absoluto entre los valores reales y estimados de los distintos entrenamientos realizados para el caso 4. (Fuente: elaboración propia).....</i>	40
<i>Tabla 9. Comparación entre los valores de MSE y R de los entrenamientos de los casos 3 y 4. (Fuente: elaboración propia).....</i>	41
<i>Tabla 10. Comparación entre los valores de MSE y R del entrenamiento en los casos 1 y 2. ....</i>	71
<i>Tabla 11. Comparación entre los valores de MSE y R del entrenamiento en los casos 1,2 y 3 ...</i>	75
<i>Tabla 12. Comparación entre los valores de MSE y R del entrenamiento en los casos 3 y 4. ....</i>	78

## 14. ANEXOS

### 14.1. CONCEPTO DE RED NEURONAL

Una red neuronal es un modelo computacional con una estructura de capas similar a la estructura interconectada de las neuronas en el cerebro, con capas de nodos conectados. Esta red es capaz de aprender datos, permitiendo su entrenamiento para que reconozca patrones, clasifique datos y realice pronósticos de eventos futuros.

Son capaces de descomponer las entradas en capas de abstracción. Su comportamiento se define por la forma en que se conectan sus elementos individuales, así como por la importancia o ponderación de estas conexiones. Estas ponderaciones se ajustan de forma automática durante el entrenamiento mediante una regla de aprendizaje especificada hasta que la red lleva a cabo la tarea requerida de forma correcta.

Estas redes realizan una combinación de diversas capas de procesamiento y utiliza elementos simples que operan paralelamente, inspiradas en los sistemas nerviosos biológicos. Está formada por una capa de entrada, una o varias capas ocultas y una capa de salida. Estas capas se interconectan mediante nodos o neuronas. Cada capa utiliza como entrada la salida de la capa anterior.

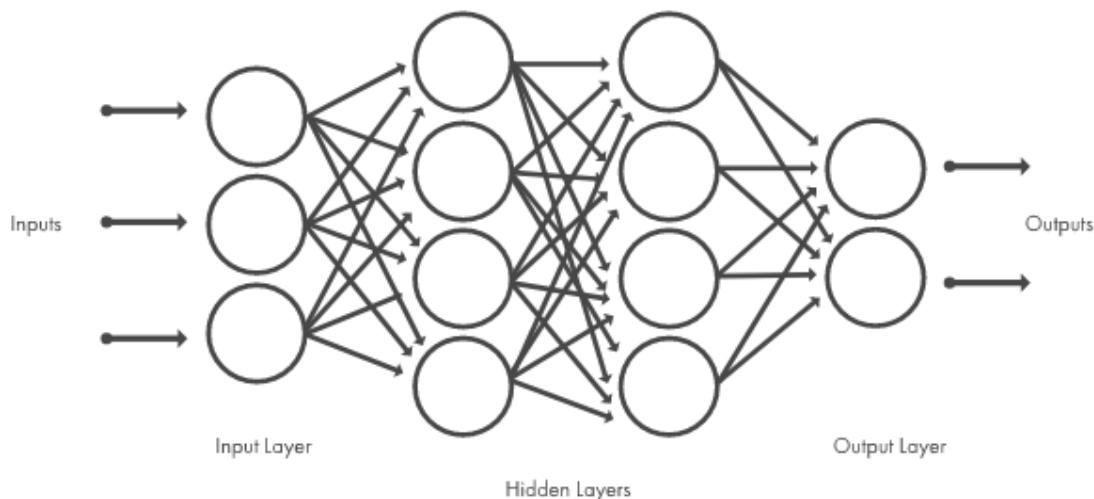


Figura 10. Arquitectura típica de una red neuronal

Las redes neuronales tienen distintas técnicas de actuación. En el caso de este proyecto se ha utilizado un modelo de regresión, mediante el cual se describe la relación entre una variable de respuesta (salida) y una o varias variables de predicción (entrada).

Se han recopilado las distintas variables que pueden afectar de forma determinada al precio de la electricidad. Una vez almacenadas las variables en una hoja Excel, se ha procedido a generar una red neuronal en Matlab utilizando los datos almacenados. Para ello se ha utilizado el toolbox de Matlab, “Neural Net Fitting”. Esta red neuronal realiza un estudio entre un conjunto de datos de entradas numéricas y un conjunto de objetivos numéricos, permitiendo la selección de datos,

la creación y el entrenamiento de la red y la evaluación de su rendimiento mediante el análisis de regresión y el error cuadrático medio.

## 14.2. ENTRENAMIENTO DEL MODELO MEDIANTE REDES NEURONALES

En primer lugar, se ha introducido en la aplicación desde el workspace tanto los inputs (datos de las 12 variables de entrenamiento), como los targets (el precio o variable objetivo).

Se introducen los datos en el programa:

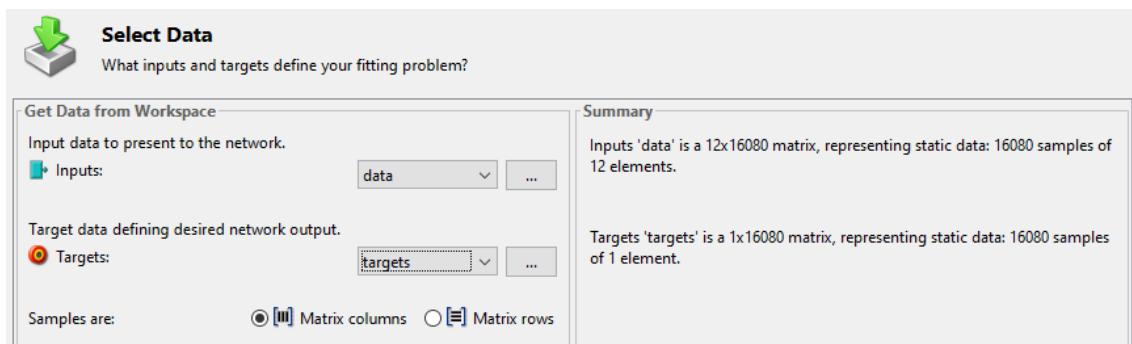


Figura 11. Selección de datos desde el workspace

Después de introducir los datos se ha indicado la configuración de los porcentajes de entrenamiento, validación y prueba de la red, antes de realizar el entrenamiento de la red neuronal.

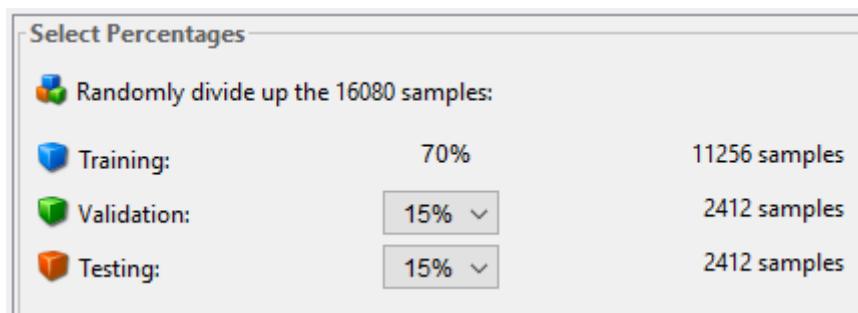


Figura 12. Selección de porcentajes para el entrenamiento, validación y prueba de la red.

Los datos utilizados para “training” se presentan a la red durante el entrenamiento, haciendo que esta se ajuste según su error. Los datos de “validation” se utilizan para medir la generalización de la red y para detener el entrenamiento cuando la generalización deja de

mejorar. Por último, los datos de “testing” no tienen ningún efecto sobre el entrenamiento y, por lo tanto, proporcionan una medida independiente del rendimiento de la red durante y después del entrenamiento.

De este modo, teniendo en cuenta los tres primeros casos de entrenamiento, de los 16.080 datos que se han introducido a la red, el 70% se han utilizado para realizar el entrenamiento de esta, el 15% proporcionó su validación y el 15% restante se ha utilizado para realizar una prueba de la red neuronal.

El siguiente paso ha sido introducir el número de capas ocultas de la red neuronal. Estas capas ocultas contienen unidades no observables. No se encuentra conectada directamente con el entorno. Son las encargadas de proporcionar los distintos grados de libertad a la red neuronal, los cuales permiten representar determinadas características del entorno para su posterior modelado.

Encontramos tres tipos distintos de capas. La capa de entrada está formada por neuronas que reciben datos o señales preferentes del entorno. La capa de salida está formada por neuronas que proporcionan la respuesta de la red neuronal. Por último, la capa oculta, que como hemos comentado anteriormente no tiene conexión directa con el entorno.

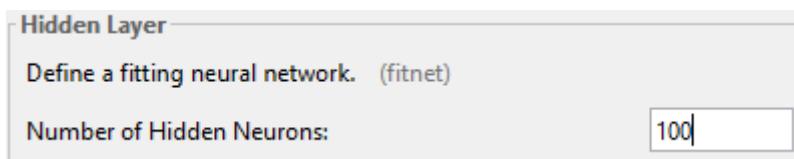


Figura 13. Selección de número de capas ocultas

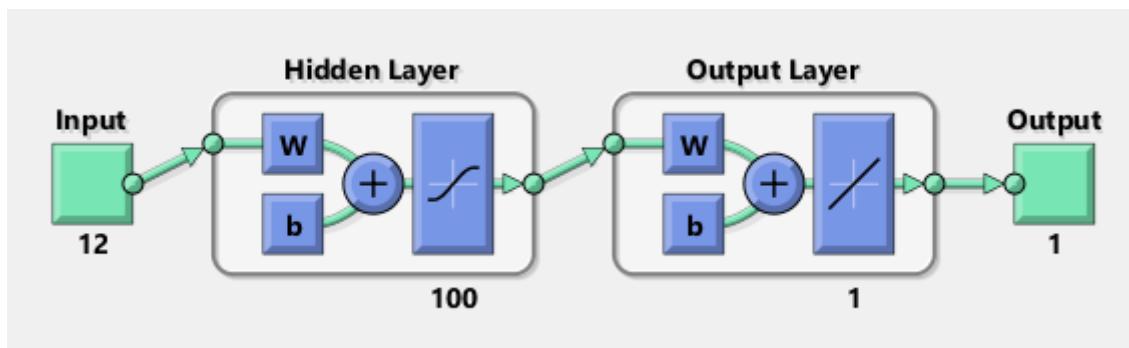


Figura 14. Esquema de la red neuronal mediante Neural Net Fitting

A continuación se ha seleccionado el algoritmo de entrenamiento de la red. Se ha elegido el algoritmo Levenberg-Marquardt. Este algoritmo requiere más memoria pero trabaja en un menor tiempo y suele proporcionar buenos resultados. Una vez indicado, se procede al entrenamiento de la red (train).

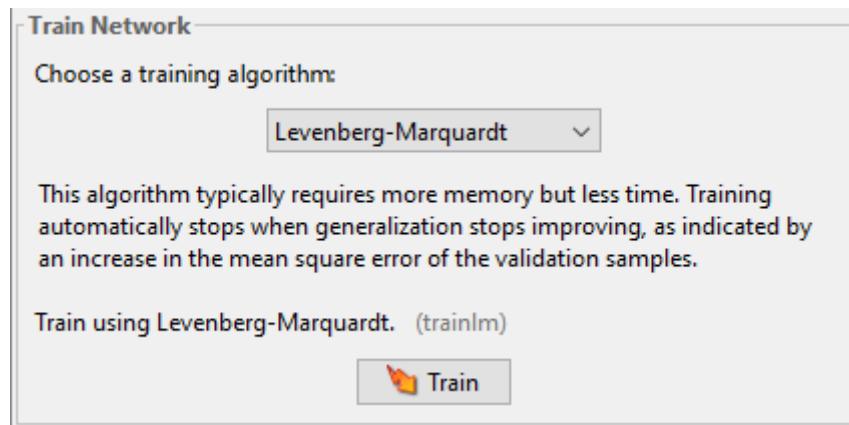


Figura 15. Selección de algoritmo y entrenamiento

Después de la realización del entrenamiento de la red neuronal se obtienen una serie de resultados en forma de gráficas, así como un resumen del entrenamiento realizado. Como se ha comentado en la memoria, para cada caso se han realizado numerosas pruebas, utilizando números distintos de neuronas ocultas para así poder asegurar con qué configuración se obtienen mejores resultados y utilizar el resultado más apto como objeto de estudio y modelo de predicción.

A continuación se muestran los resúmenes y resultados obtenidos en cada uno de los casos seleccionados como aptos para cada uno de los casos, como se ha indicado en la memoria del trabajo:

- Caso 1. 12 variables. 100 neuronas ocultas.
- Caso 2. 13 variables. 300 neuronas ocultas.
- Caso 3. 15 variables. 100 neuronas ocultas
- Caso 4. 15 variables. Distinta configuración temporal. 100 neuronas ocultas.

#### 14.2.1. CASO 1. 12 VARIABLES. 100 NEURONAS OCULTAS

Las variables utilizadas para la realización de este entrenamiento de la red neuronal son las siguientes:

- Generación por solar fotovoltaica (MW).
- Generación por solar térmica (MW).
- Generación por eólica (MW).
- Generación por hidráulica (MW).
- Generación por nuclear (MW).
- Generación por térmica renovable (MW).
- Generación por carbón (MW).
- Generación por ciclo combinado (MW).
- Generación por cogeneración (MW).
- Energía total con bilaterales del mercado ibérico (MWh).
- Energía total de compra del sistema español (MWh).
- Energía total de venta del sistema español (MWh).

Para cada una de ellas se ha trabajado con un total de 16.080 valores para el entrenamiento de la red. Estos valores corresponden a los valores horarios de cada una de las variables desde el 1 de enero de 2019 hasta el 31 de octubre de 2020. Como se ha comentado anteriormente, una parte de los datos se ha utilizado para entrenar la red, otra para su validación y otra para el test. El entrenamiento con mejores resultados en este caso ha sido el obtenido con 100 neuronas ocultas.

A continuación se muestran los resultados obtenidos tras el entrenamiento:

	Samples	MSE	R
Training:	11256	5.70010e-0	9.83729e-1
Validation:	2412	9.10941e-0	9.73799e-1
Testing:	2412	9.11409e-0	9.73614e-1

Figura 16. Resultado del entrenamiento seleccionado

MSE es el error cuadrático medio, calculado como la diferencia cuadrática promedio entre los resultados y los datos reales del problema. Si este valor es cercano a cero significa que el entrenamiento es bueno. En el caso de que fuera cero, significaría que no existe error. Siendo  $M$  el número total de puntos, el MSE se puede expresar mediante la siguiente fórmula:

$$MSE = \frac{1}{M} \sum_{i=1}^M (real_i - estimado_i)^2$$

Ecuación 1

R es el parámetro de regresión. Con este factor se mide la correlación entre los valores predichos en la salida y los valores de salida reales introducidos en la red. Cuanto más próximo se encuentre de la unidad, mejor será la correlación. En este caso se obtiene un buen resultado, ya que el valor de R es muy cercano a 1.

A medida que aumenta el proceso de entrenamiento de la red, el error cuadrático disminuye. Cuando el entrenamiento alcanza el menor error de validación, este se mantiene constante.

A continuación, se puede ver un resumen del entrenamiento realizado en el caso 1 (Figura 17).

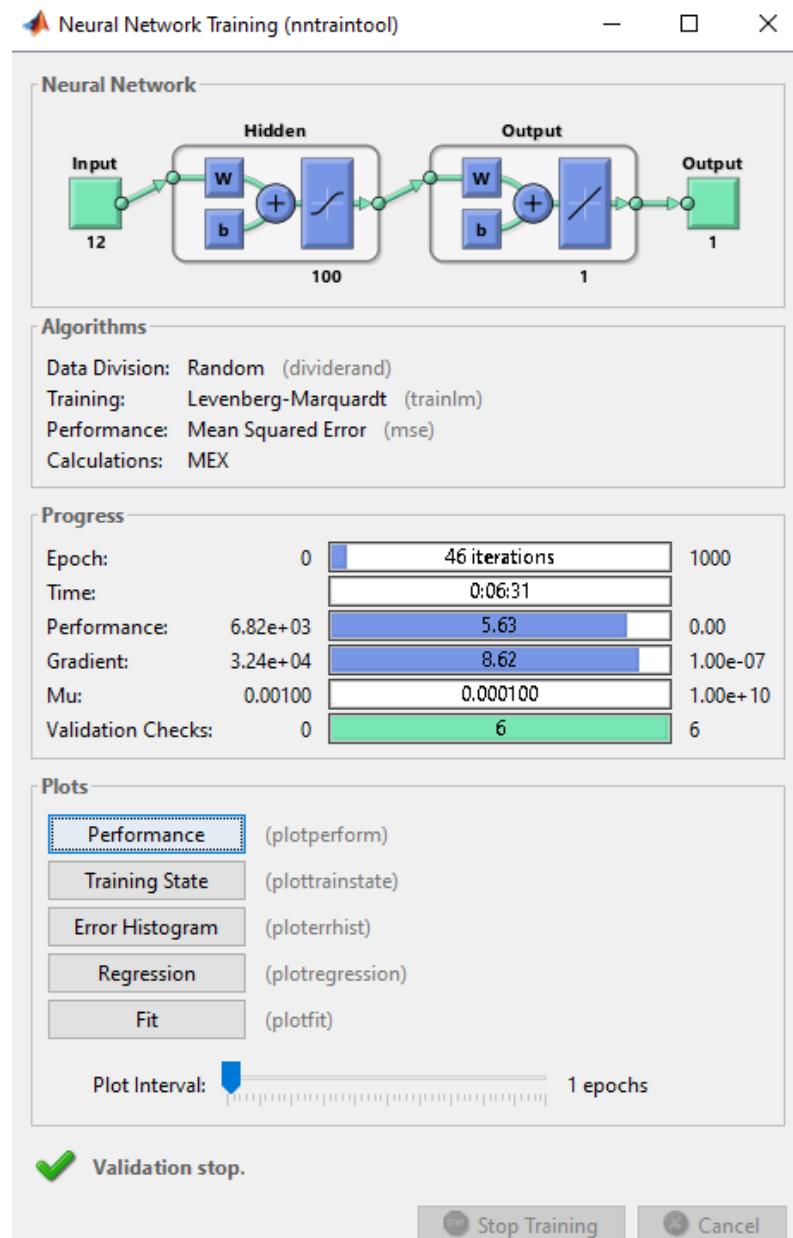


Figura 17. Resumen del entrenamiento del caso 1 (nntraintool).

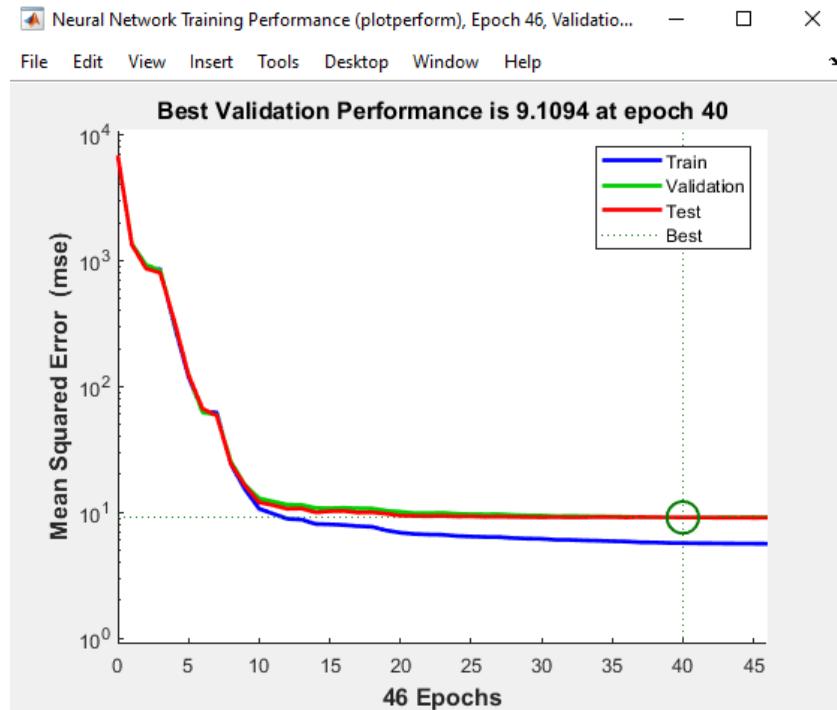


Figura 18. Plotperform, representación del error cuadrático en función de las interacciones del entrenamiento. Caso 1.

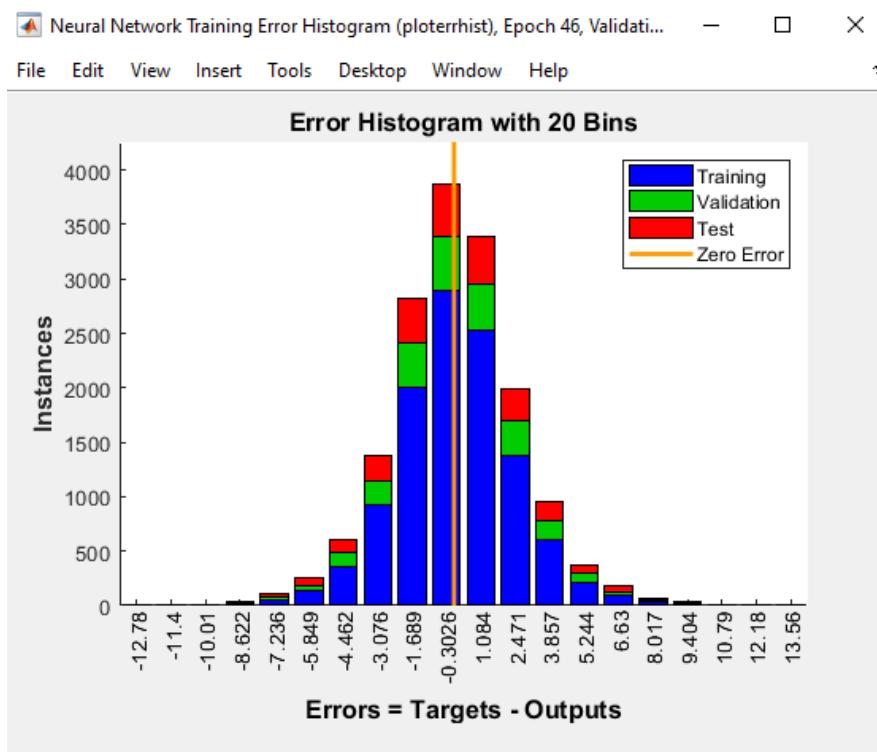


Figura 19. Representación del histograma de error del entrenamiento. Caso 1.

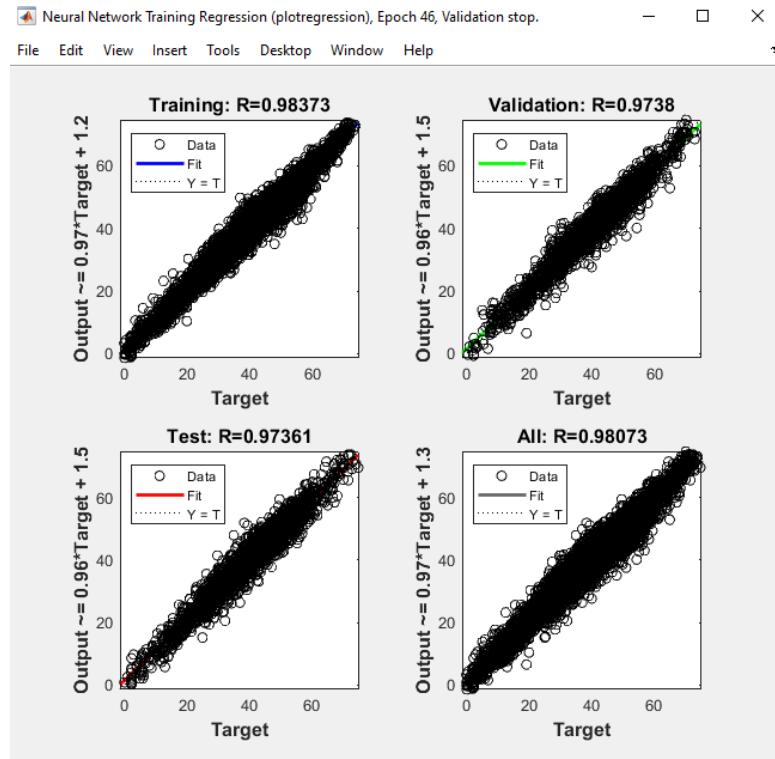


Figura 20. Gráfico de regresión del entrenamiento. Caso 1.

El menor error cuadrático de validación, como se puede observar en la figura 9, se ha producido en la iteración número 40 y ha sido de 9,1094. Se puede apreciar como en las primeras iteraciones del entrenamiento el error cuadrático disminuye de manera notoria y posteriormente se estabiliza hasta que se mantiene constante.

Mediante el histograma de error (figura 10) se puede comprobar si todos los resultados se encuentran entorno a pequeños errores y que, por lo tanto, no hay datos que se comportan de forma mucho peor que el resto. En el eje X de esta gráfica se representa el error de todas las entradas introducidas a la red (instances), es decir, cada uno de los 16.080 casos empleados para entrenar la red (valores horarios), que pueden ser para entrenamiento (training), validación (validation) o test. En el eje Y se encuentra el distinto número de casos que corresponde a cada error representado.

La línea “Zero Error” muestra cual sería el error nulo, es decir, una estimación perfecta. Como podemos apreciar en la figura, la mayoría de los valores se encuentran próximos a esta línea. Cuanto más cerca nos encontramos de esta línea, mayor es la cantidad de valores graficados, lo cual indica que el entrenamiento tiene tendencia al error nulo. A medida que aumenta el error (cuanto más nos alejamos de la línea de “Zero Error”), el número de valores graficados es menor.

Gracias al gráfico de regresión (figura 10) se puede observar la correlación que existe entre los datos objetivo y los proporcionados por la red. Mediante el gráfico proporcionado se puede apreciar como en los tres casos (entrenamiento, validación y test), los valores siguen la tendencia de la línea diagonal. Cuanto más cerca se encuentren de esta línea, mejores son los resultados.

## 14.2.2. CASO 2. 13 VARIABLES. 300 NEURONAS OCULTAS

Para la realización de este entrenamiento se han utilizado las siguientes variables:

- Generación por solar fotovoltaica (MW).
- Generación por solar térmica (MW).
- Generación por eólica (MW).
- Generación por hidráulica (MW).
- Generación por nuclear (MW).
- Generación por térmica renovable (MW).
- Generación por carbón (MW).
- Generación por ciclo combinado (MW).
- Generación por cogeneración (MW).
- Energía total con bilaterales del mercado ibérico (MWh).
- Energía total de compra del sistema español (MWh).
- Energía total de venta del sistema español (MWh).
- Demanda prevista (MW).

Al igual que en el caso anterior, para entrenar esta red se han utilizado 16.080 valores de cada una de las variables, correspondiendo a los datos horarios de cada una de ellas en el periodo de tiempo comprendido entre el 1 de enero de 2019 y el 31 de octubre de 2020. Se han realizado entrenamientos para distintos números de neuronas ocultas, para posteriormente seleccionar aquel que proporciona unos mejores resultados. En este caso, el mejor resultado se ha obtenido con 300 neuronas ocultas.

En las siguientes imágenes se muestra el resumen del entrenamiento realizado en este caso, así como los resultados obtenidos tras el entrenamiento, los cuales se han comparado con los obtenidos en el caso anterior para comprobar si existe una mejora considerable.

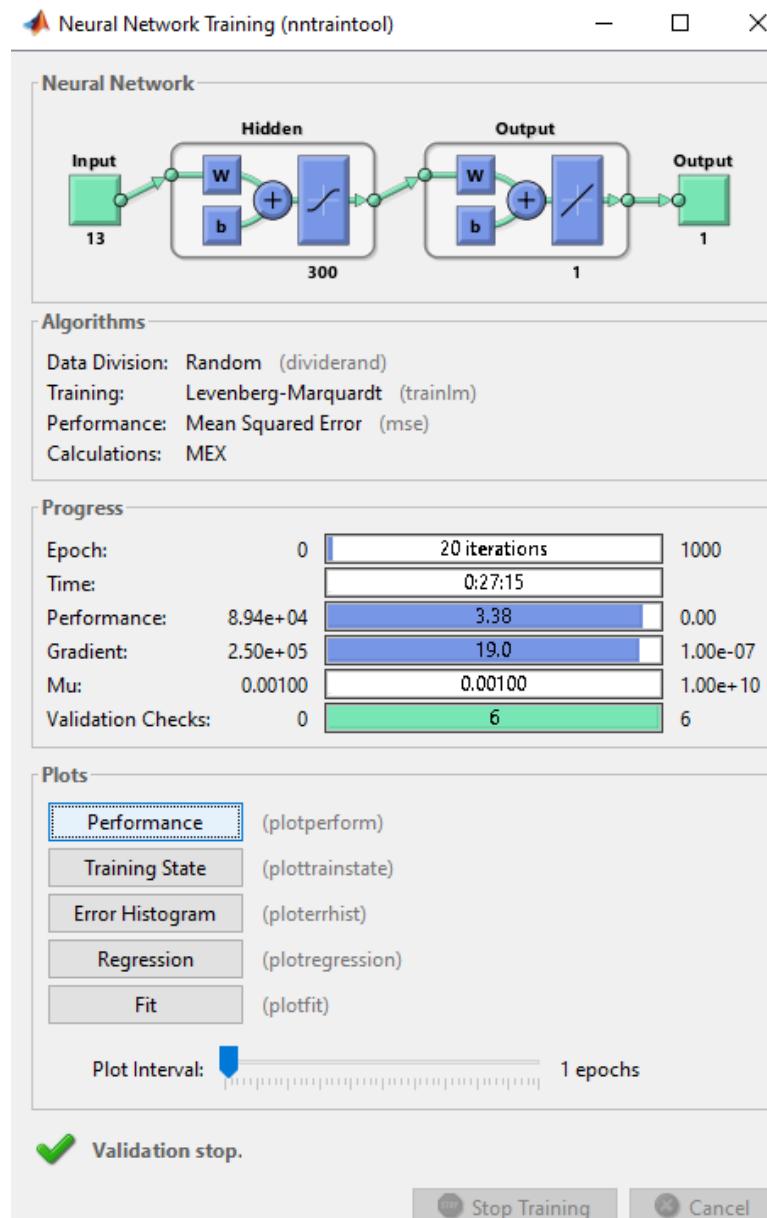


Figura 21. Resumen del entrenamiento en el caso 2.

Results

	Samples	MSE	R
Training:	11256	4.05281e-0	9.88410e-1
Validation:	2412	7.63899e-0	9.78308e-1
Testing:	2412	7.99433e-0	9.77123e-1

Figura 22. Resultados del entrenamiento en el caso 2.

En el caso de MSE (error cuadrático medio) los valores han sido menores que en el caso anterior, lo que indica que la estimación es mejor y el error del entrenamiento es más pequeño. También se observa mejora si tenemos en cuenta el parámetro R o parámetro de regresión, más cercano a 1 que en el caso anterior, lo que implica una mejor correlación.

Nº CASO	MSE (validation)	R (validation)
Caso 1	9,10941	9,73799e-1
Caso 2	7,63899	9,78308e-1

Tabla 10. Comparación entre los valores de MSE y R del entrenamiento en los casos 1 y 2.

En las siguientes imágenes se muestran los distintos gráficos obtenidos mediante la aplicación tras el entrenamiento de la red. Nos dan una idea de la evolución que ha llevado el entrenamiento y de si los resultados obtenidos son los adecuados.

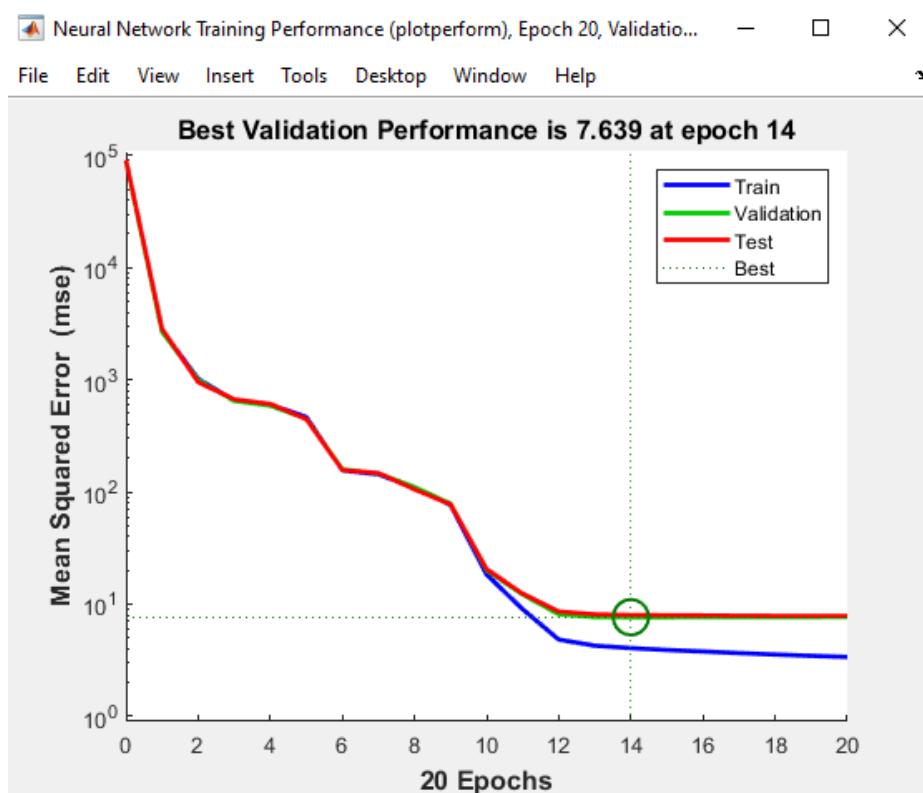


Figura 23. Plotperform, representación del error cuadrático en función de las interacciones del entrenamiento. Caso 2.

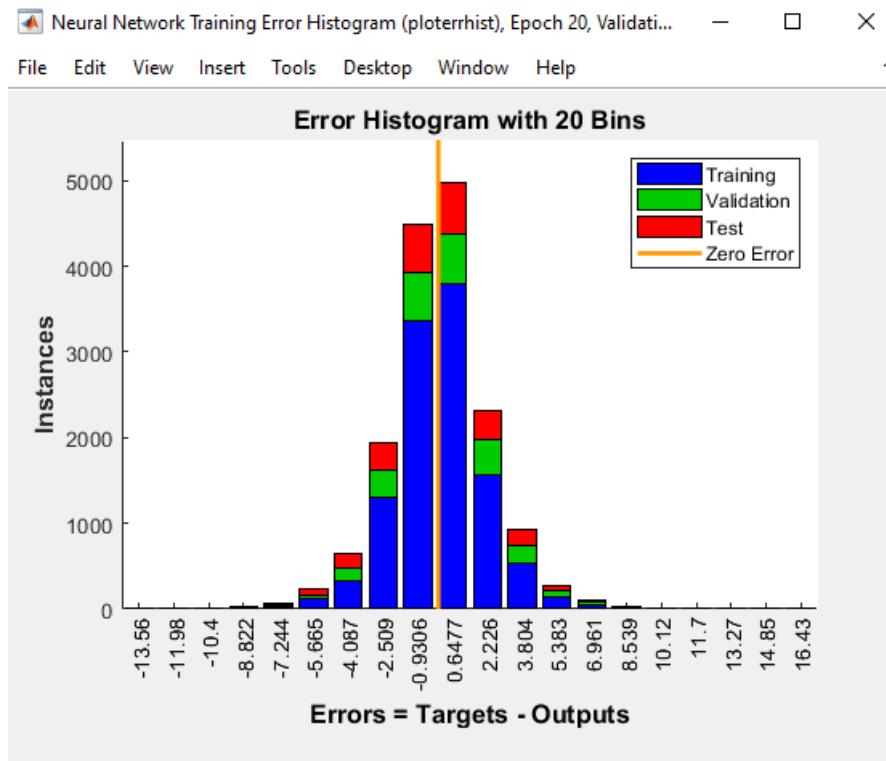


Figura 24. Representación del histograma de error del entrenamiento. Caso 2.

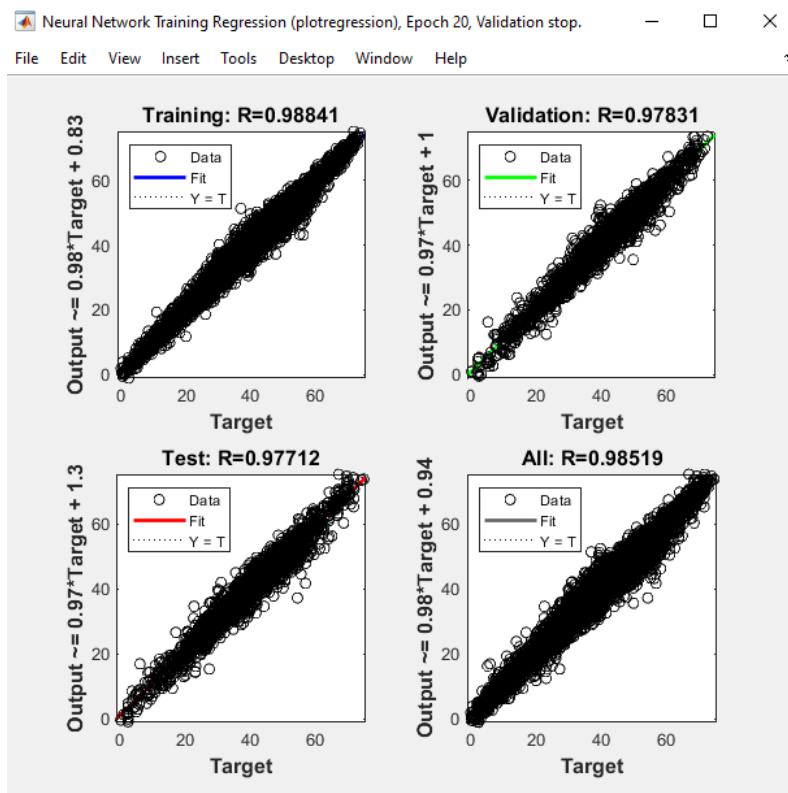


Figura 25. Gráfico de regresión del entrenamiento. Caso 2.

En la figura 13 observamos, como en el caso anterior, como a medida que el entrenamiento se llevaba a cabo, el error disminuía. Se ha obtenido el menor error de validación a partir de la iteración 14. Este error tiene un valor de 7,639, que es menor, por lo tanto, el obtenido en el caso anterior, de 9,1094. Esto indica que el entrenamiento realizado con la incorporación de la variable “demanda prevista” supone una mejora con respecto al caso anterior.

La figura 14 se muestra el histograma de error. En esta gráfica podemos apreciar como la mayor parte de los valores se encuentran próximos a la línea de “Zero Error”, lo cual, al igual que en el entrenamiento anterior, indica que el entrenamiento sigue los resultados esperados.

En el gráfico de regresión (figura 15) se puede apreciar como los valores siguen la tendencia de la línea diagonal y por lo tanto el resultado es el esperado.

#### 14.2.3. CASO 3. 15 VARIABLES. 100 NEURONAS OCULTAS

Para el entrenamiento de la red en este caso se han utilizado un total de 15 neuronas, añadiendo el volumen y el precio de gas a las que ya teníamos en el caso anterior:

- Generación por solar fotovoltaica (MW).
- Generación por solar térmica (MW).
- Generación por eólica (MW).
- Generación por hidráulica (MW).
- Generación por nuclear (MW).
- Generación por térmica renovable (MW).
- Generación por carbón (MW).
- Generación por ciclo combinado (MW).
- Generación por cogeneración (MW).
- Energía total con bilaterales del mercado ibérico (MWh).
- Energía total de compra del sistema español (MWh).
- Energía total de venta del sistema español (MWh).
- Demanda prevista (MW).

Tras realizar las pruebas pertinentes con distintos números de neuronas ocultas, la mejor predicción se ha obtenido utilizando 100 neuronas ocultas.

En las siguientes gráficas se muestra el resumen del entrenamiento de la red neuronal y los resultados de MSE y R obtenidos tras el proceso.

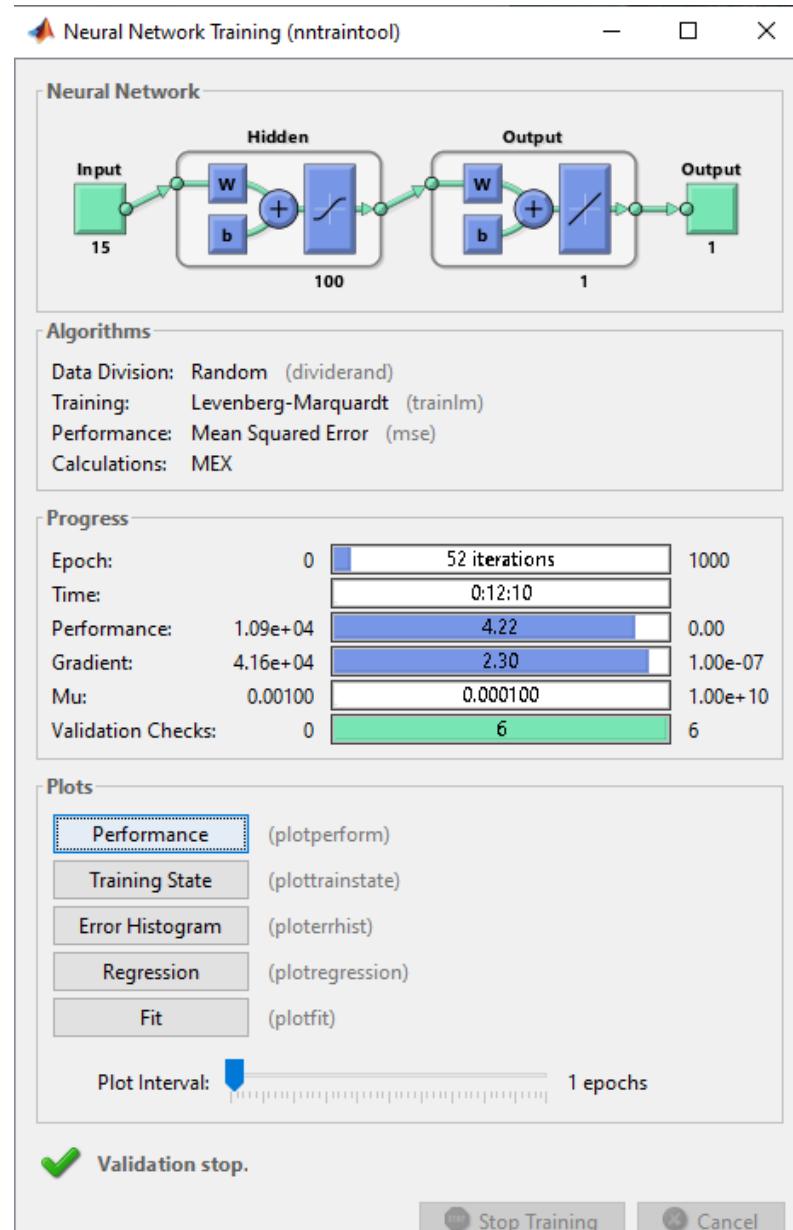


Figura 26. Resumen del entrenamiento. Caso 3, 15 variables.

Results			
	Samples	MSE	R
Training:	11256	4.27829e-0	9.87673e-1
Validation:	2412	7.01543e-0	9.80386e-1
Testing:	2412	7.74429e-0	9.78006e-1

Figura 27. Resultados del entrenamiento. Caso 3, 15 variables.

Se puede apreciar que los resultados de MSE y de R son mejores que en los casos anteriores, obteniéndose un valor de R en la validación más cercano a 1 y un valor de MSE menor que en los casos anteriores.

Nº CASO	MSE (validation)	R (validation)
Caso 1	9,10941	9,73799e-1
Caso 2	7,63899	9,78308e-1
Caso 3	7,01543	9,80386e-1

Tabla 11. Comparación entre los valores de MSE y R del entrenamiento en los casos 1,2 y 3.

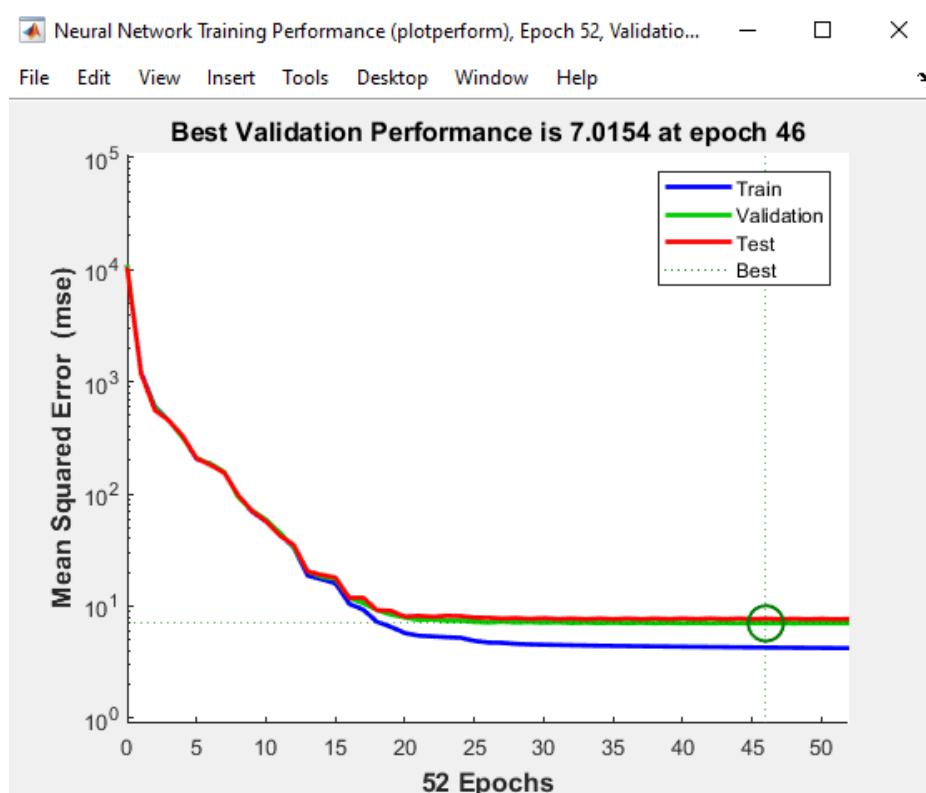


Figura 28. Plotperform, representación del error cuadrático en función de las interacciones del entrenamiento. Caso 3.

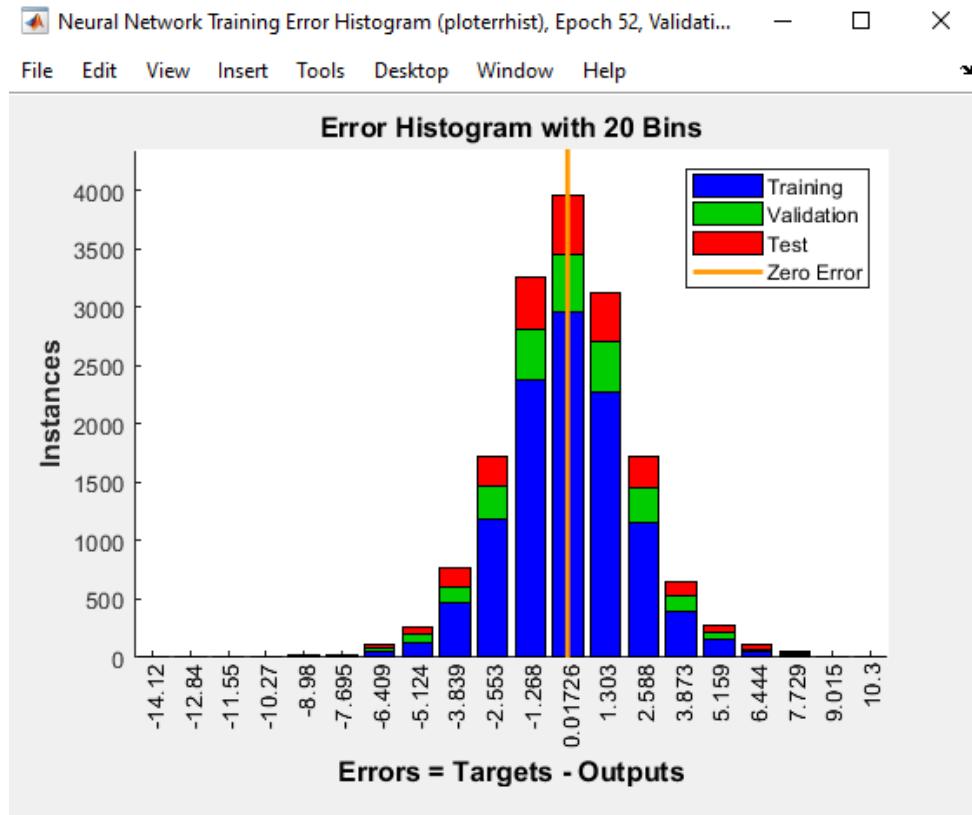


Figura 29. Representación del histograma de error del entrenamiento. Caso 3.

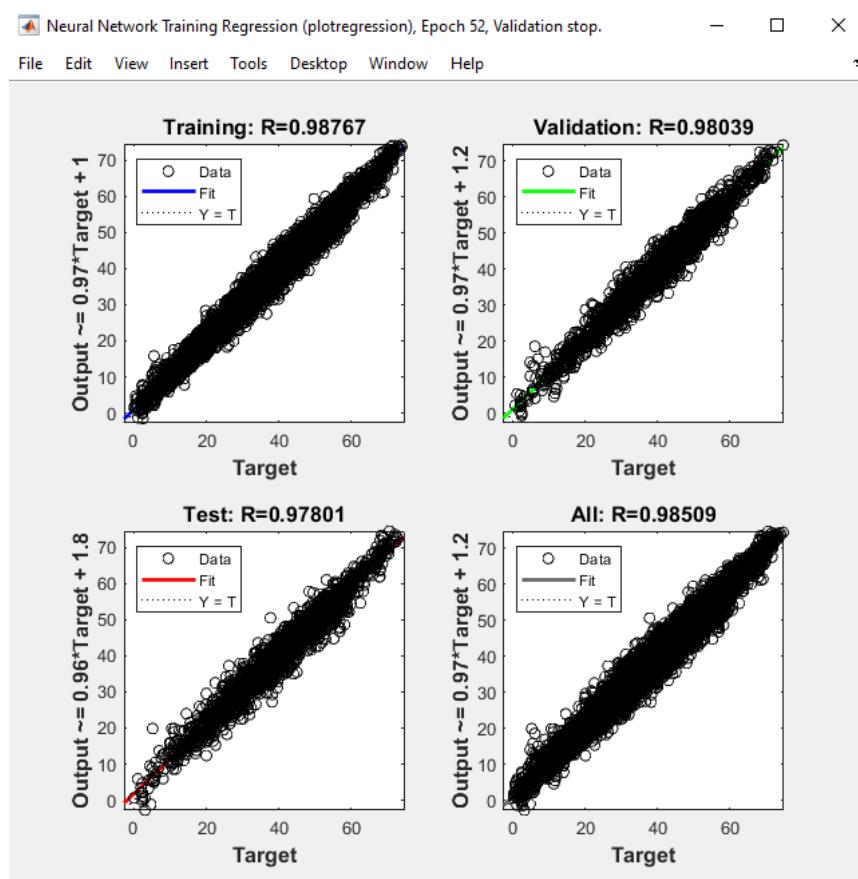


Figura 30. Gráfico de regresión del entrenamiento. Caso 3.

Como se muestra en la figura 18, el menor error cuadrático se produce en la iteración 46, y es de 7,0154, mejorando el caso anterior.

Si observamos las figuras 19 y 20, los resultados son los esperados, al igual que ocurría en los casos anteriores.

#### 14.2.4. CASO 4. 15 VARIABLES. 100 NEURONAS OCULTAS. DISTINTA CONFIGURACIÓN TEMPORAL

El mejor resultado se ha obtenido utilizando 100 neuronas ocultas. A continuación se muestra el resumen del entrenamiento realizado, así como los resultados obtenidos y los gráficos del entrenamiento.

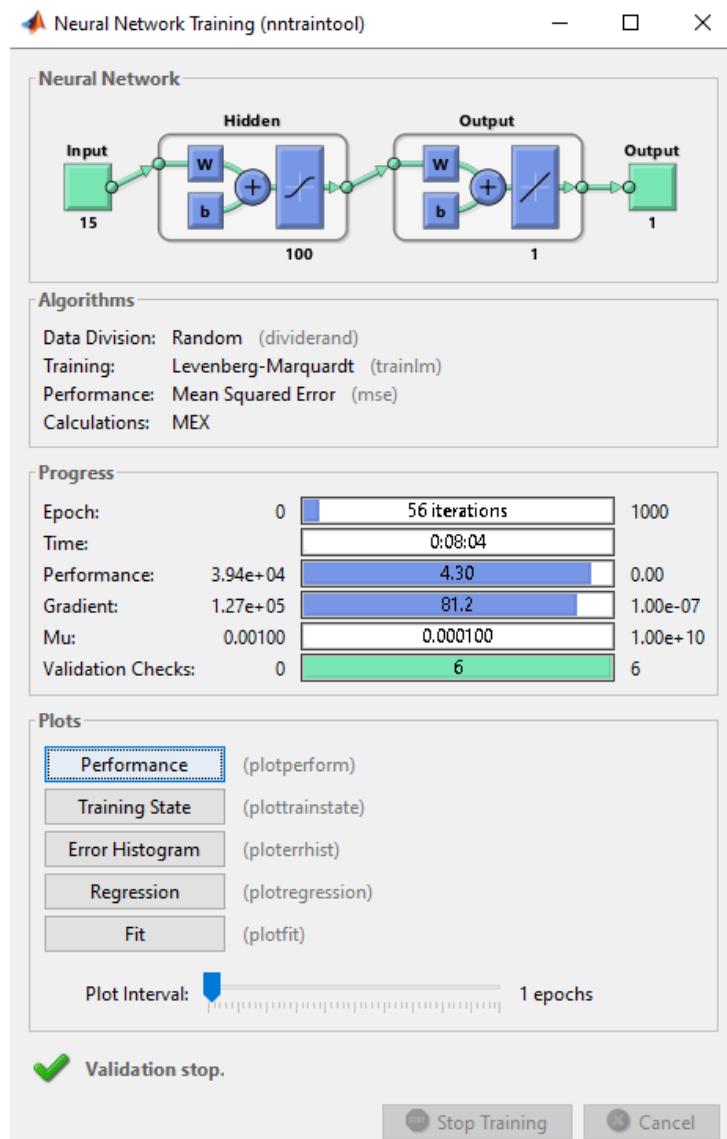


Figura 31. Resumen del entrenamiento. Caso 4.

Results			
	Samples	MSE	R
Training:	7661	4.34904e-0	9.90937e-1
Validation:	1641	9.96571e-0	9.80672e-1
Testing:	1641	9.34214e-0	9.81847e-1

Figura 32. Resultados del entrenamiento. Caso 4.

En la siguiente tabla se comparan los valores de MSE y de R en la validación obtenidos mediante el entrenamiento anterior (caso 4) con respecto a los del caso 3:

CASO	MSE	R
CASO 3	7,01543	9,80386 e-1
CASO 4	9,96571	9,80672 e-1

Tabla 12. Comparación entre los valores de MSE y R del entrenamiento en los casos 3 y 4.

Como se puede observar, el valor de R es prácticamente el mismo. El MSE en cambio es mayor que en el caso anterior, lo que indica que el error es algo mayor. Sin embargo, como se ha comprobado anteriormente, a la hora de estimar, el modelo de predicción desarrollado en el caso 4 tiene como media del valor absoluto de las diferencias entre los valores reales y estimados un valor de 8,05607401, inferior (aunque muy similar) al obtenido en el caso anterior (3), que es de 8,13337607. Con esto se llega a la conclusión de que la estimación realizada por ambos modelos es de una eficacia similar, pese a que los valores de MSE varían de uno a otro.

A continuación se muestran las gráficas del error cuadrático, el histograma y la gráfica de regresión del entrenamiento.

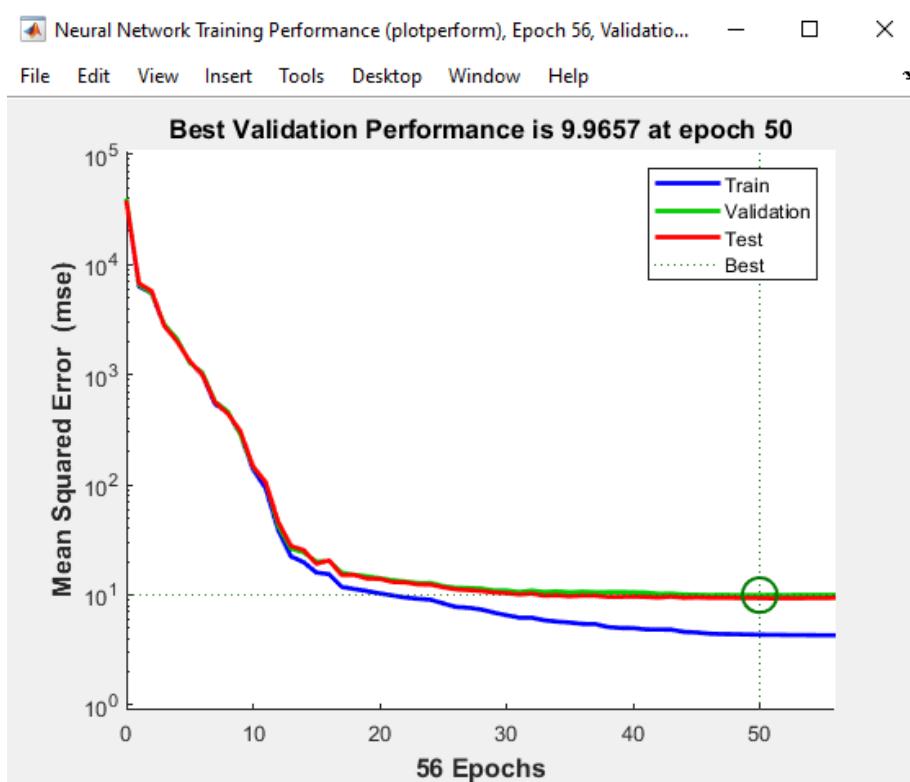


Figura 33. Plotperform, representación del error cuadrático en función de las interacciones del entrenamiento. Caso 4.

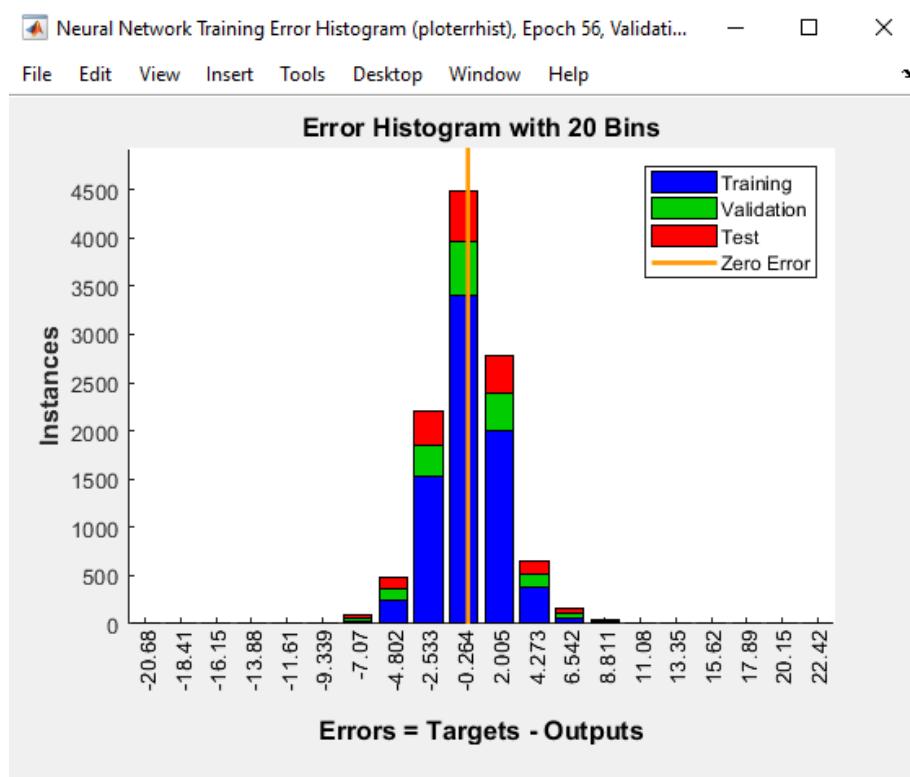


Figura 34. Representación del histograma de error del entrenamiento. Caso 4.

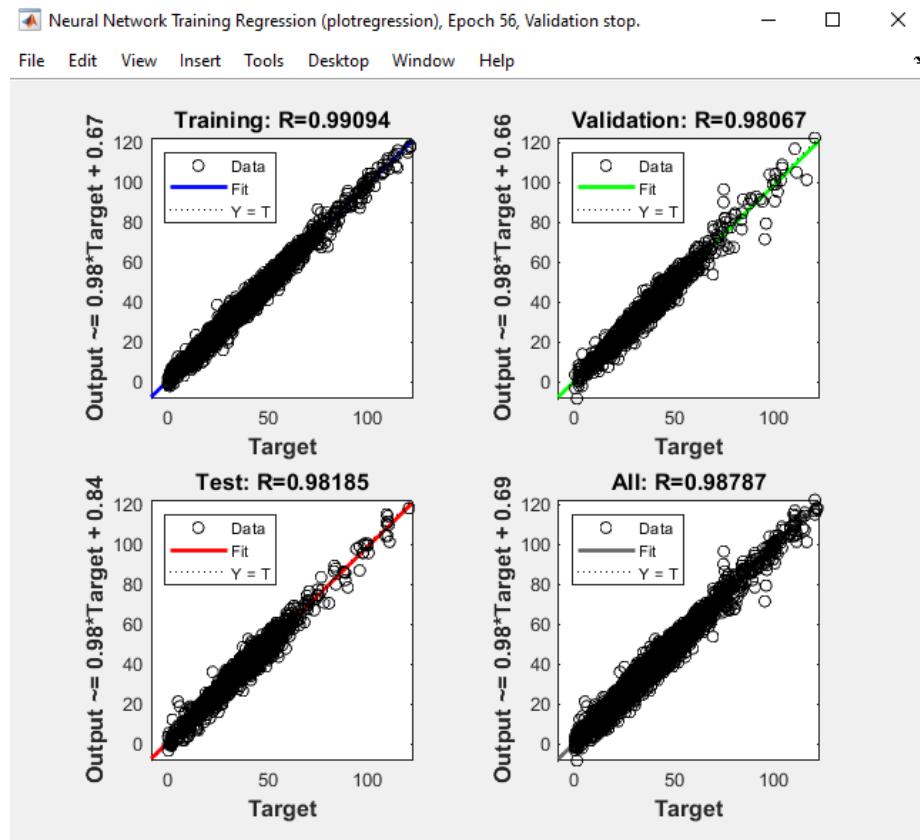


Figura 35. Gráfico de regresión del entrenamiento. Caso 4.

### 14.3. FUNCIONES EMPLEADAS PARA LA ESTIMACIÓN

Una vez entrenada la red, el programa Neural Net Fitting nos proporciona una función de MATLAB. Esta función es la empleada para realizar la predicción del precio de la electricidad a partir de su ejecución con nuevos datos de las variables empleadas anteriormente (del periodo de tiempo el cual queremos realizar la estimación).

La función ha sido obtenida del programa mediante la siguiente opción:



Figura 366. Obtención del código de MATLAB.

Se ha guardado cada función con el nombre deseado en la carpeta de trabajo de MATLAB.

Una vez obtenida, ha sido necesario importar los datos de las variables en el periodo en el que queremos realizar la estimación. Esto se ha realizado en MATLAB, en la pestaña “home”, clicando en la opción de “Import Data”. Será necesario añadir estas variables en forma de “Numeric Matrix”, para poder así ejecutar la función con estos datos. Cada vez que se añadan o se quiten variables será necesario volver a realizar este procedimiento, ya que la función solo es ejecutable para el mismo número de variables que el introducido en inputs para realizar el entrenamiento.

Una vez introducidas las variables en el workspace en forma de matriz, se ha ejecutado la función y se han obtenido los valores de la predicción.

A continuación, se muestran las funciones proporcionadas por el entrenamiento y que permiten la predicción en cada uno de los cuatro casos. Al ejecutar la función con distintos datos y números de variables (dependiendo en cada caso), se han podido obtener estimaciones del precio de la electricidad.

El código de las funciones obtenidas tras el entrenamiento, que se muestran en las siguientes figuras, se muestra de forma simplificada debido a su gran extensión. La complejidad de estos códigos se debe al gran número de datos utilizado para el entrenamiento de la red neuronal en cada uno de los casos.

### 14.3.1. FUNCIÓN CASO 1. 12 VARIABLES

```

function [y1] = myNeuralNetworkFunction(x1)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Generated by Neural Network Toolbox function genFunction, 13-May-2021 12:05:16.
%
% [y1] = myNeuralNetworkFunction(x1) takes these arguments:
%   x = 12xQ matrix, input #1
% and returns:
%   y = 1xQ matrix, output #1
% where Q is the number of samples.

 %#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [-94.333;-16.833;143;-3091.167;3616.667;281.667;0;385.5;2232.167;19922.5;11063.4;9456.2];
x1_step1.gain = [0.000273336066694;0.000914494741655235;0.000116262171196047;0.000145262619199782;0.0005702;
x1_step1.ymin = -1;

% Layer 1
b1 = [-0.73727233129178304516;3.855500480271299768;-10.002165597562154176;2.2183560717418955299;3.532446410;
IW1_1 = [0.12826221596665798863 0.26451154133328480533 0.39212894531898961903 0.88478933220427913309 1.7951;

% Layer 2
b2 = -0.23725528383242730501;
LW2_1 = [-0.60870054338493773116 0.36443701989866617019 0.018968372274481299505 -0.028181630213363267207 -0

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.0267701780216838;
y1_step1.xoffset = 0.03;

% ===== SIMULATION =====

% Dimensions
Q = size(x1,2); % samples

% Input 1
xp1 = mapminmax_apply(x1,x1_step1);

% Layer 1
a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*xp1);

% Layer 2
a2 = repmat(b2,1,Q) + LW2_1*a1;

% Output 1
y1 = mapminmax_reverse(a2,y1_step1);
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@divide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end

```

Figura 37. Código de MATLAB para la predicción del precio. Caso 1.

### 14.3.2. FUNCIÓN CASO 2. 13 VARIABLES

```

function [y1] = myNeuralNetworkFunction(x1)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Generated by Neural Network Toolbox function genFunction, 05-May-2021 17:12:13.
%
% [y1] = myNeuralNetworkFunction(x1) takes these arguments:
%   x = 13xQ matrix, input #1
% and returns:
%   y = 1xQ matrix, output #1
% where Q is the number of samples.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [-94.333;-16.833;143;-3091.167;3616.667;281.667;0;385.5;2232.167;19922.5;11063.4
x1_step1.gain = [0.00027336066694;0.000914494741655235;0.000116262171196047;0.000145262619199782;0
x1_step1.ymin = -1;

% Layer 1
b1 = [2.8067124524966993171;-3.460660020968182593;-2.6828643983374993454;1.9593057769303712234;-3.2;
IW1_1 = [-0.81842684175138791236 1.2430050603512134977 1.7302284301597552485 -0.9923586126943845231;

% Layer 2
b2 = -0.13323972322824731429;
LW2_1 = [0.071076716654387583905 0.25006368041710230754 0.66391449569064464598 0.331146463899763043;

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.0267701780216838;
y1_step1.xoffset = 0.03;

% ===== SIMULATION =====

% Dimensions
Q = size(x1,2); % samples

% Input 1
xp1 = mapminmax_apply(x1,x1_step1);

% Layer 1
a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*xp1);

% Layer 2
a2 = repmat(b2,1,Q) + LW2_1*a1;

% Output 1
y1 = mapminmax_reverse(a2,y1_step1);
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@divide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end

```

Figura 38. Código de MATLAB para la predicción del precio. Caso 2.

### 14.3.3. FUNCIÓN CASO 3. 15 VARIABLES

```

function [y1] = myNeuralNetworkFunction(x1)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Generated by Neural Network Toolbox function genFunction, 11-May-2021 11:17:27.
%
% [y1] = myNeuralNetworkFunction(x1) takes these arguments:
%   x = 15xQ matrix, input #1
% and returns:
%   y = 1xQ matrix, output #1
% where Q is the number of samples.

%%ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [-94.333;-16.833;143;-3091.167;3616.667;281.667;0;385.5;2232.167;19922.5;11063.4;9456.2
x1_step1.gain = [0.000273336066694;0.000914494741655235;0.000116262171196047;0.000145262619199782;0.000570
x1_step1.ymin = -1;

% Layer 1
b1 = [-0.19671589040501907819;-6.7775907013570808601;11.706698239284474283;-6.2362444116446207332;-4.27658
IW1_1 = [10.10932461397028348 -2.3751749872750429482 -6.9730328391398179733 3.1442813166199652386 8.647833

% Layer 2
b2 = -0.47218534506604636913;
LW2_1 = [-0.013600315516344099395 -0.014603210475859065842 -0.020151625390296187129 -0.0316782038475330873

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.0267701780216838;
y1_step1.xoffset = 0.03;

% ===== SIMULATION =====

% Dimensions
Q = size(x1,2); % samples

% Input 1
xp1 = mapminmax_apply(x1,x1_step1);

% Layer 1
a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*xp1);

% Layer 2
a2 = repmat(b2,1,Q) + LW2_1*a1;

% Output 1
y1 = mapminmax_reverse(a2,y1_step1);
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@rdivide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end

```

Figura 39. Código de MATLAB para la predicción del precio. Caso 3

#### 14.3.4. FUNCIÓN CASO 4. 15 VARIABLES. DISTINTA CONFIGURACIÓN TEMPORAL

```

function [y1] = myNeuralNetworkFunction(x1)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Generated by Neural Network Toolbox function genFunction, 18-May-2021 17:33:13.
%
% [y1] = myNeuralNetworkFunction(x1) takes these arguments:
%   x = 15xQ matrix, input #1
% and returns:
%   y = 1xQ matrix, output #1
% where Q is the number of samples.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [-62.833;-16.833;209.167;-2805.667;3616.667;335.333;0;432.333;2097.167;19922.5;11233;945
x1_step1.gain = [0.000236714404071488;0.00091533180778032;0.000104006864453054;0.000138293458719403;0.00056
x1_step1.ymin = -1;

% Layer 1
b1 = [5.5274436361798660045;-2.2440495986107502624;5.9196075356889821251;1.4001683750238806958;-12.22897481
IW1_1 = [10.48371340940080465 -6.8393733942640162482 8.0019480408335503796 -2.5340696870862364776 5.1741594

% Layer 2
b2 = 0.5314225409674818712;
LW2_1 = [0.013919352499158424083 -0.06267956070160625448 0.034247143142297133134 -0.013171382808819699292 -

% Output 1
y1_step1.ymin = -1;
y1_step1.gain = 0.0165180046250413;
y1_step1.xoffset = 0.16;

% ===== SIMULATION =====

% Dimensions
Q = size(x1,2); % samples

% Input 1
xp1 = mapminmax_apply(x1,x1_step1);

% Layer 1
a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*xp1);

% Layer 2
a2 = repmat(b2,1,Q) + LW2_1*a1;

% Output 1
y1 = mapminmax_reverse(a2,y1_step1);
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,-)
a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@divide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end

```

Figura 40. Código de MATLAB para la predicción del precio. Caso 4.