



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



ESCUELA TÉCNICA  
SUPERIOR INGENIEROS  
INDUSTRIALES VALENCIA

Curso Académico:

## **Agradecimientos**

Quiero dar las gracias a mi familia, amigos, a los compañeros de trabajo, al tutor de este proyecto y al profesorado de la Escuela Técnica Superior de Ingeniería Industrial por darme esta oportunidad de desarrollar mi formación.

## Resumen

En este Trabajo Final de Máster se aborda la implementación de diferentes modelos de predicción del precio de la energía eléctrica para el mercado a plazo. El mercado a plazo presenta múltiples productos según el plazo de entrega, de esta forma hay productos para: fin de semana, semanal, mensual, cuatrimestral y anual. Por ello, en el trabajo se describe el funcionamiento del mercado a plazo.

En el desarrollo del trabajo se realiza un recorrido sobre los modelos de predicción existentes para dar un enfoque de la situación actual en el campo de la investigación. Se fija la atención en los sistemas de predicción de precios de la energía eléctrica basados en redes neuronales. Se constata que los trabajos realizados en la predicción del precio de la electricidad a más de tres meses son muy reducidos, en plazos mayores no se ha encontrado referencias.

El objetivo del trabajo es realizar la previsión a un año vista de los precios para el mercado a plazo empleando modelos basados en redes neuronales. Para ello se plantea generar tres modelos de predicción. Un primer modelo de red neuronal artificial de base que será el punto de partida de los otros, de ahí su denominación. El segundo modelo es un modelo de red neuronal artificial con retroalimentación. Este segundo modelo se plantea como alternativa a los modelos convencionales de redes neuronales, partiendo del concepto de los controles que se emplean para regular el sistema eléctrico para garantizar la calidad del servicio. Finalmente se desarrolla un modelo en cascada, donde una primera red neuronal recibe unas determinadas entradas para generar su predicción, para que una segunda red neuronal procese como variables de entrada las de la primera red junto con la salida de la misma.

Para el correcto desarrollo de estos modelos de predicción se definirán las variables necesarias y parámetros que los caracterizarán. La determinación de las variables de entrada se realizará mediante un análisis gráfico y un análisis de la sensibilidad que determinen la influencia en el precio del producto eléctrico de cada variable de entrada. Posteriormente se determinará la arquitectura de los modelos de predicción y se describirá su funcionamiento.

Después de esto se procederá a describir como se obtienen los diferentes modelos. Una vez generados, se realizará su aplicación para la predicción a largo plazo del precio de cinco productos, pertenecientes cada uno a uno de los tipos que encontramos en el mercado a plazo según el periodo de entrega del mercado a plazo. También se aplicarán a la predicción del precio de la electricidad en el mercado diario. Finalmente, se determinará el periodo de predicción óptimo de los modelos para cada uno de los casos de aplicación anteriores analizando los resultados obtenidos.

## Resum

En aquest Treball Final de Màster s'aborda la implementació de diferents models de predicció del preu de l'energia elèctrica per al mercat a termini. El mercat a termini presenta múltiples productes segons el termini de lliurament, d'aquesta forma hi ha productes per a: cap de setmana, setmanal, mensual, quadrimestral i anual. Per això, en el treball es descriu el funcionament del mercat a termini.

En el desenvolupament del treball es realitza un recorregut sobre els models de predicció existents per a donar un enfocament de la situació actual en el camp de la investigació. Es fixa l'atenció en els sistemes de predicció de preus de l'energia elèctrica basats en xarxes neuronals. Es constata que els treballs realitzats en la predicció del preu de l'electricitat a més de tres mesos són molt reduïts, en terminis majors no s'ha trobat referències.

L'objectiu del treball és realitzar la previsió a un any vista dels preus per al mercat a termini emprant models basats en xarxes neuronals. Per a això es planteja generar tres models de predicció. Un primer model de xarxa neuronal artificial de base que serà el punt de partida dels altres, d'ací la seua denominació. El segon model és un model de xarxa neuronal artificial amb retroalimentació. Aquest segon model es planteja com a alternativa als models convencionals de xarxes neuronals, partint del concepte dels controls que s'empren per a regular el sistema elèctric per a garantir la qualitat del servei. Finalment es desenvolupa un model en cascada, on una primera xarxa neuronal rep unes determinades entrades per a generar la seua predicció, perquè una segona xarxa neuronal processe com a variables d'entrada les de la primera xarxa juntament amb l'eixida d'aquesta.

Per al correcte desenvolupament d'aquests models de predicció es definiran les variables necessàries i paràmetres que els caracteritzaran. La determinació de les variables d'entrada es realitzarà mitjançant una anàlisi gràfica i una anàlisi de la sensibilitat que determinen la influència en el preu del producte elèctric de cada variable d'entrada. Posteriorment es determinarà l'arquitectura dels models de predicció i es descriurà el seu funcionament.

Després d'això es procedirà a descriure com s'obtenen els diferents models. Una vegada generats, es realitzarà la seua aplicació per a la predicció a llarg termini del preu de cinc productes, pertanyents cadascun a un dels tipus que trobem en el mercat a termini segons el període de lliurament del mercat a termini. També s'aplicaran a la predicció del preu de l'electricitat en el mercat diari. Finalment, es determinarà el període de predicció òptim dels models per a cadascun dels casos d'aplicació anteriors analitzant els resultats obtinguts.

## Abstract

In this work, it is addressed the implementation of different prediction models of the price of electric power for the forward market. The forward market presents multiple products according to the delivery time, so there are products for: weekend, weekly, monthly, quarterly and annual. Therefore, the work describes the functioning of the forward market.

In the development of the work, it will see the existing of prediction models to give an approach of the current situation in this field of the investigation. Attention is focused on electricity price prediction systems based on neural networks. It is verified that the works carried out in the prediction of the price of electricity for more than three months are very reduced, in longer terms no references have been found.

The objective of the work is to forecast a year ahead of the prices for the forward market using models based on neural networks. For this, it is proposed to generate three prediction models. A first artificial base neural network model that will be the starting point of the others, hence its name. The second model is an artificial neural network model with feedback. This second model is proposed as an alternative to conventional models of neural networks, based on the concept of controls that are used to regulate the electrical system to guarantee the quality of the service. Finally, a cascade model is developed, where a first neural network receives certain inputs to generate its prediction, so that a second neural network processes as input variables those of the first network together with the output of it.

For the correct development of these prediction models, the necessary variables and parameters that will characterize them will be defined. The determination of the input variables will be carried out through a graphical analysis and an analysis of the sensitivity that determine the influence on the price of the electrical product of each input variable. Subsequently, the architecture of the prediction models will be determined and their operation will be described

.After this, we will proceed to describe how the different models are obtained. Once generated, its application will be made for the long-term prediction of the price of five products, each one belonging to one of the types that we find in the forward market according to the delivery period of the forward market. They will also apply to the prediction of the price of electricity in the daily market. Finally, the optimal prediction period of the models for each of the previous application cases will be determined by analyzing the results obtained.

## CONTENIDO DEL TRABAJO FINAL DE MÁSTER

- MEMORIA
- PRESUPUESTO

# DESARROLLO DE UN MODELO DE PREDICCIÓN DEL PRECIO DE LA ENERGÍA ELÉCTRICA PARA EL MERCADO A PLAZO MEDIANTE REDES NEURONALES.

-MEMORIA-





## ÍNDICE

1.	Introducción.....	9
1.1	Antecedentes.....	9
1.2	Motivación y justificación.....	9
1.3	Objetivos.....	10
1.4	Distribución del documento.....	11
2.	Estado del arte.....	13
2.1	Mercado de futuros y funcionamiento de OMIP.....	13
2.1.1	Introducción.....	13
2.1.2	Tipos de mercados.....	13
2.1.3	Productos y participantes del mercado a plazo.....	14
2.1.4	Fases de negociación del mercado a plazo.....	15
2.1.5	Funciones de OMIP.....	15
2.2	Evolución y situación actual en los métodos de predicción de precios de la electricidad.....	16
2.2.1	Introducción.....	16
2.2.2	Plazos en los que realizar predicciones de los precios de la energía eléctrica.....	16
2.2.3	Modelos de predicción del precio de la energía eléctrica.....	17
2.2.4	Modelos desarrollados de predicción del precio de la energía eléctrica mediante redes neuronales.....	19
2.2.5	Conclusiones del capítulo.....	20
3.	Metodología.....	21
3.1	Introducción.....	21
3.2	Factores a considerar.....	23
3.3	Datos de entrada.....	24
3.3.1	El día de la semana.....	25
3.3.2	La festividad.....	28
3.3.3	Reservas hidráulicas para generación eléctrica.....	31
3.3.4	Demanda eléctrica.....	33
3.3.5	Generación eléctrica empleando como fuente el carbón.....	37
3.3.6	Generación eléctrica empleando los ciclos combinados.....	39
3.3.7	Generación eléctrica con energía nuclear.....	41
3.3.8	Generación eléctrica con energía solar.....	43
3.3.9	Generación eléctrica con energía eólica.....	45

3.3.10	Generación eléctrica de origen hidráulico. ....	47
3.3.11	Futuros del petróleo Brent a más de un año .....	49
3.3.12	Futuros del gas natural a más de un año. ....	52
3.3.13	Relaciones entre productos del mercado eléctrico. ....	54
3.4	Desarrollo del modelo matemático de la red neuronal simple. ....	55
3.4.1	La neurona artificial.....	55
3.4.2	Estructura de la red neuronal artificial. ....	57
3.4.3	Entrenamiento de la red neuronal artificial. Sobre entrenamiento. ....	58
3.4.4	Método de entrenamiento. Regularización Bayesiana.....	59
3.5	Modelo de red neuronal con retroalimentación. ....	61
3.6	Modelo de red neuronal en cascada.....	64
3.7	Conclusiones del capítulo.....	64
4	Implementación de la red neuronal.....	67
4.1	Introducción. ....	67
4.2	Desarrollo de la red neuronal artificial en Matlab .....	67
4.2.1	Implementación de la red neuronal artificial base. ....	67
4.2.2	Implementación de la red neuronal artificial con retroalimentación.....	69
4.2.3	Implementación de la red neuronal en cascada. ....	71
4.3	Conclusiones del capítulo.....	72
5	Caso de aplicación. ....	73
5.1	Introducción. ....	73
5.2	Etapas de aprendizaje de la red neuronal artificial. ....	74
5.3	Aplicación real de la red neuronal artificial. Resultados y errores de los diferentes casos.....	78
5.3.1	Precio del futuro eléctrico a un año.....	80
5.3.2	Precio del futuro eléctrico a un cuatrimestre. ....	82
5.3.3	Precio del futuro eléctrico a un mes. ....	84
5.3.4	Precio del futuro eléctrico a una semana. ....	86
5.3.5	Precio del futuro eléctrico para el fin de semana. ....	88
5.3.6	Precio del futuro eléctrico para el precio diario del mercado SPOT.....	90
5.4	Conclusiones del capítulo.....	93
6	Conclusiones finales. ....	95
6.1	Conclusiones del trabajo. ....	95
6.2	Desarrollos futuros.....	96
7	Bibliografía .....	97

## Índice de ilustraciones

ILUSTRACIÓN 1. UBICACIÓN DE LOS OPERADORES DEL MERCADO A CORTO PLAZO Y DEL MERCADO A PLAZO EN LA PENÍNSULA IBÉRICA. FUENTE: DEL LIBRO “GENERACIÓN, TRANSPORTE Y DISTRIBUCIÓN DE ENERGÍA ELÉCTRICA.” [20].	14
ILUSTRACIÓN 2 DIAGRAMA DE BLOQUES SOBRE EL PROCEDIMIENTO DE TRABAJO. FUENTE: ELABORACIÓN PROPIA.	22
ILUSTRACIÓN 3. EVOLUCIÓN DE LA DEMANDA REAL EN ESPAÑA EN EL PERÍODO DE DOS SEMANAS. FUENTE: WWW.ESIOS.REE.ES	26
ILUSTRACIÓN 4. REPRESENTACIÓN GRÁFICA DE LOS DATOS DEL DÍA DE LA SEMANA FRENTE AL PRECIO DE LA ELECTRICIDAD EN EL FUTURO PARA EL AÑO SIGUIENTE. FUENTE: ELABORACIÓN PROPIA.	27
ILUSTRACIÓN 5. HISTOGRAMA DE LOS DATOS DE FESTIVIDAD.	29
ILUSTRACIÓN 6. REPRESENTACIÓN GRÁFICA DE LOS DATOS DE FESTIVIDAD FRENTE AL PRECIO DE LA ELECTRICIDAD EN EL FUTURO PARA EL AÑO SIGUIENTE. FUENTE: ELABORACIÓN PROPIA.	30
ILUSTRACIÓN 7. HISTOGRAMA DE LAS RESERVAS HIDRÁULICAS PARA EL PERIODO DE ENTRENAMIENTO.	31
ILUSTRACIÓN 8. GRÁFICA DE LAS RESERVAS HIDRÁULICAS FRENTE AL PRECIO DE LA ELECTRICIDAD EN EL MERCADO DIARIO. FUENTE: ELABORACIÓN PROPIA.	32
ILUSTRACIÓN 9. REPRESENTACIÓN GRÁFICA DE LAS RESERVAS HIDRÁULICAS PARA GENERACIÓN ELÉCTRICA UN AÑO ANTES FRENTE AL PRECIO DEL CONTRATO DEL FUTURO A UN AÑO. FUENTE: ELABORACIÓN PROPIA.	32
ILUSTRACIÓN 10. DEMANDA ELÉCTRICA REAL Y DEMANDA ELÉCTRICA PREVISTA ENTRE EL 28/09/2015 Y 27/09/2016. FUENTE: WWW.ESIOS.REE.ES	34
ILUSTRACIÓN 11. HISTOGRAMA DE LA DEMANDA ELÉCTRICA EN EL PERIODO DE ENTRENAMIENTO.	35
ILUSTRACIÓN 12. GRÁFICA DE LA DEMANDA ELÉCTRICA EL AÑO ANTERIOR FRENTE AL PRECIO DEL CONTRATO DEL FUTURO ELÉCTRICO A UN AÑO. FUENTE: ELABORACIÓN PROPIA.	36
ILUSTRACIÓN 13. HISTOGRAMA DE LOS VALORES DE GENERACIÓN DE ENERGÍA CON CARBÓN EN EL PERIODO DE ENTRENAMIENTO.	37
ILUSTRACIÓN 14. REPRESENTACIÓN DE PUNTOS DE LOS NIVELES DE GENERACIÓN ELÉCTRICA EMPLEANDO CARBÓN FRENTE AL PRECIO DEL FUTURO A UN AÑO. FUENTE: ELABORACIÓN PROPIA.	38
ILUSTRACIÓN 15. HISTOGRAMA DE LOS VALORES DE GENERACIÓN DE ENERGÍA CON CICLOS COMBINADOS EN EL PERIODO DE ENTRENAMIENTO.	39
ILUSTRACIÓN 16. REPRESENTACIÓN EN EL EJE VERTICAL DE LOS NIVELES DE GENERACIÓN CON CICLO COMBINADO FRENTE AL PRECIO DEL FUTURO A UN AÑO EN EL EJE HORIZONTAL. FUENTE: ELABORACIÓN PROPIA.	40
ILUSTRACIÓN 17. HISTOGRAMA DE LOS VALORES DE GENERACIÓN DE ENERGÍA DE ORIGEN NUCLEAR EN EL PERIODO DE ENTRENAMIENTO.	41
ILUSTRACIÓN 18. REPRESENTACIÓN DE PUNTOS CON LOS NIVELES DE GENERACIÓN DE ENERGÍA NUCLEAR EN EL EJE VERTICAL FRENTE AL PRECIO DE LOS CONTRATOS DE FUTUROS A UN AÑO EN EL EJE HORIZONTAL. FUENTE: ELABORACIÓN PROPIA.	42
ILUSTRACIÓN 19. HISTOGRAMA DE LOS VALORES DE GENERACIÓN DE ENERGÍA DE ORIGEN SOLAR EN EL PERIODO DE ENTRENAMIENTO.	43
ILUSTRACIÓN 20. REPRESENTACIÓN DE PUNTOS CON LOS NIVELES DE GENERACIÓN DE ENERGÍA SOLAR EN EL EJE VERTICAL FRENTE AL PRECIO DE LOS CONTRATOS DE FUTUROS A UN AÑO EN EL EJE HORIZONTAL. FUENTE: ELABORACIÓN PROPIA.	44
ILUSTRACIÓN 21. HISTOGRAMA DE LOS VALORES DE GENERACIÓN DE ENERGÍA DE ORIGEN EÓLICO EN EL PERIODO DE ENTRENAMIENTO.	45
ILUSTRACIÓN 22. REPRESENTACIÓN DE PUNTOS CON LOS NIVELES DE GENERACIÓN DE ENERGÍA EÓLICA EN EL EJE VERTICAL FRENTE AL PRECIO DE LOS CONTRATOS DE FUTUROS A UN AÑO EN EL EJE HORIZONTAL. FUENTE: ELABORACIÓN PROPIA.	46
ILUSTRACIÓN 23. HISTOGRAMA DE LOS VALORES DE GENERACIÓN DE ENERGÍA DE ORIGEN HIDRÁULICO EN EL PERIODO DE ENTRENAMIENTO.	47
ILUSTRACIÓN 24. REPRESENTACIÓN DE PUNTOS CON LOS NIVELES DE GENERACIÓN DE ENERGÍA DE ORIGEN HIDRÁULICO EN EL EJE VERTICAL FRENTE AL PRECIO DE LOS CONTRATOS DE FUTUROS A UN AÑO EN EL EJE HORIZONTAL. FUENTE: ELABORACIÓN PROPIA.	48
ILUSTRACIÓN 25. HISTOGRAMA DE LOS FUTUROS DEL PETRÓLEO.	50

ILUSTRACIÓN 26. REPRESENTACIÓN DE PUNTOS CON LOS PRECIOS DEL FUTURO DEL PETRÓLEO BRENT A MÁS DE UN AÑO EN EL EJE VERTICAL FRENTE AL PRECIO DE LOS CONTRATOS DE FUTUROS ELÉCTRICOS A UN AÑO EN EL EJE HORIZONTAL. FUENTE: ELABORACIÓN PROPIA. ....	51
ILUSTRACIÓN 27. HISTOGRAMA DE LOS FUTUROS DEL GAS NATURAL.....	52
ILUSTRACIÓN 28. REPRESENTACIÓN DE PUNTOS CON LOS PRECIOS DEL FUTURO DEL GAS NATURAL A MÁS DE UN AÑO EN EL EJE VERTICAL FRENTE AL PRECIO DE LOS CONTRATOS DE FUTUROS ELÉCTRICOS A UN AÑO EN EL EJE HORIZONTAL. FUENTE: ELABORACIÓN PROPIA. ....	53
ILUSTRACIÓN 29. PRECIO DEL MERCADO SPOT DIARIO EN EL EJE VERTICAL FRENTE AL PRECIO DEL FUTURO A UNA SEMANA EN EL EJE HORIZONTAL. FUENTE: ELABORACIÓN PROPIA. ....	55
ILUSTRACIÓN 30. IMAGEN DE UNA NEURONA ARTIFICIAL. FUENTE: ELABORACIÓN PROPIA.....	56
ILUSTRACIÓN 31. FUNCIÓN SIGMOIDAL. FUENTE: ELABORACIÓN PROPIA. ....	57
ILUSTRACIÓN 32. ESQUEMA DE LA APLICACIÓN DEL SISTEMA DE CONTROL PRIMARIO DE FRECUENCIA. FUENTE: APUNTES DE SISTEMAS ELÉCTRICOS DE POTENCIA DEL MÁSTER UNIVERSITARIO EN INGENIERÍA INDUSTRIAL (UNIVERSIDAD POLITÈCNICA DE VALÈNCIA). [26].....	62
ILUSTRACIÓN 33. DIAGRAMA DE BLOQUES DEL SISTEMA A IMPLEMENTAR CON REALIMENTACIÓN. FUENTE: ELABORACIÓN PROPIA. ....	63
ILUSTRACIÓN 34. EQUIVALENCIA DEL DIAGRAMA DE BLOQUES DE LA ILUSTRACIÓN ANTERIOR. FUENTE: ELABORACIÓN PROPIA. ....	63
ILUSTRACIÓN 35. ARQUITECTURA DE LA RED NEURONAL ARTIFICIAL BASE. FUENTE: MATLAB.....	68
ILUSTRACIÓN 36. DIAGRAMA DE BLOQUES DE LA RED NEURONAL. FUENTE: ELABORACIÓN PROPIA EN MATLAB.....	69
ILUSTRACIÓN 37. MODIFICACIÓN EXTERNA DEL DIAGRAMA DE LA RED NEURONAL PARA EL PROCESO DE APRENDIZAJE INCORPORANDO RETROALIMENTACIÓN. FUENTE: ELABORACIÓN PROPIA EN MATLAB.....	70
ILUSTRACIÓN 38. ESQUEMA DE LA RETROALIMENTACIÓN DE LA RED NEURONAL ARTIFICIAL. FUENTE: ELABORACIÓN PROPIA EN MATLAB. ....	70
ILUSTRACIÓN 39. SALIDA GRÁFICA CON LOS PARÁMETROS DEL ENTRENAMIENTO DE LA RED NEURONAL DE BASE PARA EL PRECIO DEL FUTURO A UN AÑO. FUENTE: ELABORACIÓN PROPIA EN MATLAB. ....	75
ILUSTRACIÓN 40. IMAGEN DE LA EVOLUCIÓN DE LA FUNCIÓN DEL ERROR QUE OPTIMIZA EL ALGORITMO DE REGULARIZACIÓN BAYESIANA. FUENTE: ELABORACIÓN PROPIA EN MATLAB. ....	76
ILUSTRACIÓN 41. HISTOGRAMA DE LA RED NEURONAL ARTIFICIAL. FUENTE: ELABORACIÓN PROPIA EN MATLAB. ....	77
ILUSTRACIÓN 42. GRÁFICAS DE LA REGRESIÓN DE LA SALIDA DE LA RED NEURONAL ARTIFICIAL RESPECTO DE LOS VALORES OBJETIVO. FUENTE: ELABORACIÓN PROPIA EN MATLAB. ....	78
ILUSTRACIÓN 43. GRÁFICA DE LOS PRECIOS OBTENIDOS PARA LOS DIFERENTES MODELOS DE PREDICCIÓN Y EL VALOR REAL PARA EL FUTURO A UN AÑO. FUENTE: ELABORACIÓN PROPIA. ....	81
ILUSTRACIÓN 44. GRÁFICA DE LOS PRECIOS OBTENIDOS PARA LOS DIFERENTES MODELOS DE PREDICCIÓN Y EL VALOR REAL PARA EL FUTURO A UN CUATRIMESTRE. FUENTE: ELABORACIÓN PROPIA. ....	84
ILUSTRACIÓN 45. GRÁFICA DE LOS PRECIOS OBTENIDOS PARA LOS DIFERENTES MODELOS DE PREDICCIÓN Y EL VALOR REAL PARA EL FUTURO A UN MES. FUENTE: ELABORACIÓN PROPIA.....	86
ILUSTRACIÓN 46. GRÁFICA DE LOS PRECIOS OBTENIDOS PARA LOS DIFERENTES MODELOS DE PREDICCIÓN Y EL VALOR REAL PARA EL FUTURO A UNA SEMANA. FUENTE: ELABORACIÓN PROPIA. ....	88
ILUSTRACIÓN 47. GRÁFICA DE LOS PRECIOS OBTENIDOS PARA LOS DIFERENTES MODELOS DE PREDICCIÓN Y EL VALOR REAL PARA EL FUTURO PARA EL FIN DE SEMANA. FUENTE: ELABORACIÓN PROPIA.....	90
ILUSTRACIÓN 48. GRÁFICA DE LOS PRECIOS OBTENIDOS PARA LOS DIFERENTES MODELOS DE PREDICCIÓN Y EL VALOR REAL PARA EL PRECIO DIARIO. FUENTE: ELABORACIÓN PROPIA. ....	92

## Índice de tablas

TABLA 1. SENSIBILIDAD DEL PRECIO DEL FUTURO A UN AÑO ANTE LA ENTRADA DEL DÍA DE LA SEMANA.....	27
TABLA 2. SENSIBILIDAD DEL PRECIO DEL FUTURO A UN AÑO ANTE LA ENTRADA DE LA FESTIVIDAD O LABORALIDAD DEL DÍA.	30
TABLA 3. SENSIBILIDAD DEL PRECIO DEL FUTURO A UN AÑO ANTE EL VALOR DE LA RESERVA HIDRÁULICA DE UN AÑO ANTES. .....	33
TABLA 4. TABLA DE SENSIBILIDAD DE LOS PRECIOS DE LOS CONTRATOS DE LOS FUTUROS A UN AÑO FRENTE A LA DEMANDA DEL AÑO ANTERIOR AL DÍA DE CONTRATACIÓN. ....	36
TABLA 5. TABLA DE LA SENSIBILIDAD DEL PRECIO DEL CONTRATO A UN AÑO FRENTE AL NIVEL DE GENERACIÓN EMPLEANDO COMO FUENTE DE ENERGÍA EL CARBÓN.....	38
TABLA 6. TABLA DE LA SENSIBILIDAD DEL PRECIO DEL CONTRATO DEL FUTURO A UN AÑO FRENTE A VARIACIONES EN EL NIVEL DE GENERACIÓN DE ENERGÍA ELÉCTRICA CON CICLOS COMBINADOS. ....	40
TABLA 7. TABLA DE SENSIBILIDAD DEL PRECIO DEL CONTRATO DEL FUTURO A UN AÑO ANTE VARIACIONES EN LOS NIVELES DE GENERACIÓN DE ENERGÍA NUCLEAR. ....	42
TABLA 8. TABLA DE SENSIBILIDAD DEL PRECIO DEL CONTRATO DEL FUTURO A UN AÑO ANTE VARIACIONES EN LOS NIVELES DE GENERACIÓN DE ENERGÍA SOLAR. ....	44
TABLA 9. TABLA DE SENSIBILIDAD DEL PRECIO DEL CONTRATO DEL FUTURO A UN AÑO ANTE VARIACIONES EN LOS NIVELES DE GENERACIÓN DE ENERGÍA EÓLICA. ....	46
TABLA 10. TABLA DE SENSIBILIDAD DEL PRECIO DEL CONTRATO DEL FUTURO A UN AÑO ANTE VARIACIONES EN LOS NIVELES DE GENERACIÓN DE ENERGÍA HIDRÁULICA.....	49
TABLA 11. TABLA DE SENSIBILIDAD DEL PRECIO DEL CONTRATO DEL FUTURO DE LA ELECTRICIDAD A UN AÑO ANTE VARIACIONES EN EL PRECIO DEL FUTURO A MÁS DE UN AÑO DEL PETRÓLEO BRENT. ....	51
TABLA 12. TABLA DE SENSIBILIDAD DEL PRECIO DEL CONTRATO DEL FUTURO DE LA ELECTRICIDAD A UN AÑO ANTE VARIACIONES EN EL PRECIO DEL FUTURO A UN AÑO DEL GAS NATURAL. ....	54
TABLA 13. TABLA DE ERRORES MEDIOS PARA REDES NEURONALES ARTIFICIALES CON DIFERENTES NÚMEROS DE NEURONAS EN LA PRIMERA CAPA. ....	58
TABLA 14. TABLA DE EJEMPLO DE CÓMO SE CONSTRUYE LA MATRIZ CON LAS VARIABLES MÍNIMAS DE ENTRADA EN LA RED NEURONAL. ....	68
TABLA 15. DATOS DE VALORES REALES Y PREDICCIONES DE LOS MODELOS EN EL FUTURO A UN AÑO, PARA TRES DÍAS DEL PERIODO DE PREVISIÓN, CON SUS DESVIACIONES EN VALOR ABSOLUTO.....	80
TABLA 16. ERROR DE LOS VALORES DE SALIDA DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL FUTURO A UN AÑO.....	81
TABLA 17. DATOS DE VALORES REALES Y PREDICCIONES DE LOS MODELOS EN EL FUTURO A UN CUATRIMESTRE, PARA TRES DÍAS DEL PERIODO DE PREVISIÓN, CON SUS DESVIACIONES EN VALOR ABSOLUTO. ....	82
TABLA 18. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 366 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL FUTURO A UN CUATRIMESTRE. ....	83
TABLA 19. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 188 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL FUTURO A UN CUATRIMESTRE. ....	83
TABLA 20. DATOS DE VALORES REALES Y PREDICCIONES DE LOS MODELOS EN EL FUTURO A UN MES PARA TRES DÍAS DEL PERIODO DE PREVISIÓN, CON SUS DESVIACIONES EN VALOR ABSOLUTO.....	84
TABLA 21. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 366 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL FUTURO A UN MES. ....	85
TABLA 22. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 188 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL FUTURO A UN MES. ....	85
TABLA 23. DATOS DE VALORES REALES Y PREDICCIONES DE LOS MODELOS EN EL FUTURO A UNA SEMANA PARA TRES DÍAS DEL PERIODO DE PREVISIÓN, CON SUS DESVIACIONES EN VALOR ABSOLUTO.....	86
TABLA 24. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 366 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL FUTURO A UNA SEMANA.....	87
TABLA 25. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 24 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL FUTURO A UNA SEMANA.....	87
TABLA 26. DATOS DE VALORES REALES Y PREDICCIONES DE LOS MODELOS EN EL FUTURO A UN FIN DE SEMANA PARA TRES DÍAS DEL PERIODO DE PREVISIÓN, CON SUS DESVIACIONES EN VALOR ABSOLUTO. ....	88

TABLA 27. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 366 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL FUTURO PARA EL FIN DE SEMANA. ....	89
TABLA 28. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 24 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL FUTURO PARA EL FIN DE SEMANA. ....	89
TABLA 29. DATOS DE VALORES REALES Y PREDICCIONES DE LOS MODELOS EN EL PRECIO DIARIO PARA TRES DÍAS DEL PERIODO DE PREVISIÓN, CON SUS DESVIACIONES EN VALOR ABSOLUTO. ....	90
TABLA 30. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 366 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL PRECIO DIARIO.....	91
TABLA 31. ERROR DE LOS VALORES DE SALIDA DEL PERIODO DE 5 DÍAS DE LOS MODELOS DE PREDICCIÓN RESPECTO DEL VALOR REAL PARA EL PRECIO DIARIO.....	92

## 1. Introducción.

### 1.1 Antecedentes.

El sistema eléctrico abarca el conjunto de infraestructuras cuyo objeto es entregar energía eléctrica a los consumidores en las condiciones de seguridad, fiabilidad y calidad adecuadas para su empleo por los usuarios del sistema. Su correcta gestión requiere considerar múltiples aspectos, siendo uno muy destacado la previsión de la demanda de energía eléctrica con anticipación. Para realizar esta previsión de la demanda de energía eléctrica se han implementado diferentes métodos y algoritmos para generar predicciones lo más aproximadas posibles a la realidad. Se busca ajustar la producción de energía eléctrica al consumo, garantizando el correcto suministro.

En el proceso de integración de los mercados eléctricos de la República de Portugal y el Reino de España, se ha producido la creación del denominado Mercado Ibérico de la Electricidad (MIBEL). Éste mercado eléctrico está constituido por un conjunto de mercados mayoristas organizados y no organizados en los que se realizan transacciones o contratos de energía eléctrica y en los que se negocian instrumentos financieros basados en la energía eléctrica. Así mismo existen otros productos acordados por las partes que intervienen.

Entre los agentes que participan en el mercado eléctrico se encuentran aquellos que participan en operaciones de compra y venta de la energía eléctrica. De esta forma en el MIBEL se puede comprar y vender la energía eléctrica por adelantado, en plazos de horas, días o años. Para obtener márgenes de beneficio en las operaciones de compra-venta de la electricidad, de modo análogo a los sistemas de previsión de la demanda eléctrica, se han desarrollado herramientas para realizar la previsión de los precios de la energía eléctrica con el objetivo de obtener rentabilidad por parte de los agentes que intervienen.

### 1.2 Motivación y justificación.

La necesidad de realizar nuevos planteamientos para la predicción de los precios de la energía eléctrica ha producido en los últimos tiempos un número cada vez mayor de publicaciones técnicas en este campo. Los trabajos que se han considerado en la bibliografía de este trabajo y a los que se hará referencia en puntos posteriores, normalmente realizan el análisis comparando entre diferentes métodos y la hibridación de los mismos, buscando realizar una mejor estimación a diferentes plazos del precio de la energía eléctrica o realizando estimaciones de la demanda eléctrica, minimizando en lo posible el nivel de error.

Este trabajo se ha planteado con el objetivo de desarrollar una herramienta de predicción del precio de la energía eléctrica en el mercado a plazo, realizando las estimaciones a un año vista. Para ello, se ha estudiado la diferente bibliografía que se ha localizado, junto con el Trabajo Final de Máster dirigido por **Manuel Alcázar Ortega** y realizado por **Diego Santos Martín [1]** en el curso 2017-2018. En la literatura consultada se ha encontrado pocas referencias a investigaciones en la predicción a más de tres meses del precio de la energía eléctrica, por lo

que se considera que es un campo abierto a nuevas aportaciones. Así mismo, se plantea la necesidad de evaluar variaciones en los modelos tradicionales basados en redes neuronales.

La motivación para centrarnos en el mercado a plazo es por su relevancia, pues se reducen los riesgos del mercado. Operando en este mercado los vendedores, fundamentalmente los generadores, buscan vender garantizando unos ingresos mínimos que les permitan amortizar costes, sin exponerse a la volatilidad del mercado diario. Los compradores en el mercado de futuros, especialmente comercializadoras y grandes consumidores, buscan comprar con precios que les generen márgenes de beneficio a unos o fijar los gastos del consumo eléctrico ante posibles subidas del precio a corto plazo, a los otros. Los compradores se cubren ante las posibles subidas de los precios, al asegurarse un precio fijo para un determinado periodo.

Un modelo para la predicción de los precios de la electricidad en el mercado a plazo puede ayudar a quienes compran y venden en él, aumentando la rentabilidad de sus operaciones. Los modelos de predicción de este trabajo permiten realizar predicciones del precio de la electricidad a largo plazo ante la falta de modelos que lo hagan a más de tres meses, lo que cubre una necesidad para quienes intervienen en el mercado de futuros.

En la elaboración de este documento se ha intentado aprovechar las consideraciones realizadas en el trabajo realizado por **Diego Santos Martín [1]**. En dicho trabajo se plantea el uso de un parámetro numérico para fijar si el día es festivo o laboral. Para mejorar esta precisión se ha implementado el impacto de las festividades en las regiones con mayor población, sobre uno de los parámetros a introducir. Por otro lado se ha modelado una curva de las reservas hidráulicas, plasmando los valores de las mismas para cada día, en vez de trabajar con los valores semanales estáticos en cada día, recomendación que se señala en dicho trabajo. Finalmente se ha realizado un esfuerzo para vincular la proyección de los datos al contexto económico, por cuanto en situaciones de reducción de la actividad industrial o su incremento, se modifica el consumo de energía eléctrica y por tanto los precios de la misma.

De la bibliografía consultada se considera un buen resultado reducir la desviación entre los valores reales y los valores de las predicciones por debajo del 5%, para cada uno de los productos sobre los que se realizarán predicciones. Con estos planteamientos se ha elaborado este documento a fin de mejorar los resultados y minimizar los errores cometidos.

### 1.3 Objetivos.

Con la realización en diferentes etapas de este Trabajo Final de Máster se ha buscado alcanzar lo que constituyen un abanico de metas y objetivos, realizando las consideraciones oportunas obtenidas a partir de la bibliografía. El objetivo principal de este trabajo es aportar una mejora en el campo de aplicación en el que se desarrolla este estudio, desarrollando alternativas para conseguir, *un modelo de predicción del precio de la energía a plazo con un reducido nivel de error en la predicción a un año vista válido para su aplicación por los agentes del mercado*. Siendo el anterior el principal objetivo, para alcanzarlo se fijan los siguientes puntos a alcanzar:

- *Revisar las herramientas de predicción de precios eléctricos a fin de determinar puntos de mejora.*



- *Establecer el estado del arte en los métodos de predicción de la demanda eléctrica y del precio de la energía a diferentes plazos temporales.*
- *Describir el funcionamiento del mercado a plazo en la Península Ibérica y de la gestión del denominado Operador del Mercado Ibérico de Portugal (OMIP).*
- *Determinar las variables y parámetros idóneos para desarrollar el modelo.*
- *Diseñar e implementar el modelo de predicción.*
- *Validar, evaluar y analizar el funcionamiento del modelo, describiendo la forma de ejecutarse, la arquitectura que presenta, los modos de aprendizaje y posibles mejoras del mismo.*

#### 1.4 Distribución del documento.

La estructura del Trabajo Final de Máster que se ha plasmado en parte en este documento, se ha descompuesto en diferentes puntos. El motivo de la descomposición realizada de este documento es tratar de transmitir de forma sintetizada y lo más clara posible, el proceso seguido a lo largo del desarrollo del trabajo. Por ello el documento consta de los siguientes apartados:

1. *Introducción.* En este punto se expone fundamentalmente los antecedentes de este trabajo, así como los motivos, objetivos y la nomenclatura del mismo.
2. *Estado del arte.* Se describe cómo es y cómo funciona el mercado a plazo dentro del sistema eléctrico que opera en España. En este punto el trabajo también se adentra en las referencias publicadas respecto a sistemas de predicción del precio de la energía eléctrica. Se hace énfasis en los modelos de redes neuronales artificiales.
3. *Metodología.* Se presentan y describen los parámetros de los modelos de predicción. Presentando diferentes variables de entrada y validando aquellas que se consideran más adecuadas para la predicción a largo plazo. Se fijará la arquitectura y características de los modelos empleados, planteando su funcionamiento.
4. *Implementación de la red neuronal.* Aquí se procederá a generar los modelos, explicando el proceso para obtenerlos.
5. *Caso de aplicación.* Una vez obtenidos los modelos se procederá a predecir los precios de diferentes productos eléctricos del mercado a plazo junto con el precio diario de la electricidad en el mercado diario. Analizando los valores obtenidos y comparando los resultados del error de los diferentes modelos para cada tipo de producto eléctrico, se optimizará el periodo inicial de predicción óptimo. Se procederá con todo esto a validar los modelos para cada producto, buscando el periodo de la predicción que minimiza el error cometido.
6. *Conclusiones finales.* Como finalización del trabajo se extrapolará las conclusiones del trabajo y se presentarán alternativas que puedan ser útiles para futuros trabajos.



## 2. Estado del arte.

### 2.1 Mercado de futuros y funcionamiento de OMIP.

#### 2.1.1 Introducción.

En el este apartado del documento, “Mercado de futuros y funcionamiento de OMIP”, se van a resumir los conocimientos que se han adquirido en lo relativo a los mercados a plazo de la energía eléctrica, así como la situación en el campo de la divulgación técnica relativa a la generación de modelos de predicción.

Para lo anteriormente reseñado, en esta parte del documento se ha procedido en primer lugar a la descripción de los mercados existentes dentro del Mercado Ibérico de Electricidad (MIBEL), además de señalar que entidades los gestiona. Posteriormente se ha descrito los productos y partícipes del mercado a plazo. A continuación se describen las fases de negociación del mercado y las funciones del gestor del mercado a plazo.

#### 2.1.2 Tipos de mercados.

El 1 de octubre de 2004, por el Convenio de Santiago de Compostela, se acordó el marco jurídico que dio origen al Mercado Ibérico de Electricidad (MIBEL), en el que participan España y Portugal para crear y desarrollar un mercado de electricidad común. Así en el ámbito del MIBEL se establece un sistema de mercados organizados y no organizados. De esta forma como se señala en [20], se tiene:

##### a) Mercados organizados:

- Mercado a plazo: establece transacciones vinculadas a bloques de energía con entrega más tarde del día siguiente al de la contratación. Puede ser con liquidación por entrega física o financiera.
- Mercado diario: establece transacciones vinculadas con bloques de energía con entrega física el día siguiente de la contratación. La liquidación debe ser por entrega física, (mercado spot).
- Mercado intradiario: las transacciones de liquidación se realizan por entrega física, (mercado spot).
- Mercados de operación: se realiza para garantizar las condiciones de calidad y seguridad en el suministro eléctrico, aplicando los programas de producción resultantes de la contratación de la energía eléctrica.

##### b) Mercados no organizados:

- Se encuentran en esta estructura los contratos bilaterales entre las entidades del MIBEL, por entrega física y financiera.



Ilustración 1. Ubicación de los operadores del mercado a corto plazo y del mercado a plazo en la península Ibérica.  
Fuente: del libro "Generación, transporte y distribución de energía eléctrica." [20].

El mercado diario e intradiario lo gestiona el denominado Operador del Mercado Ibérico de España (OMIE). Los mercados de operación son gestionados en España por Red Eléctrica de España, S.A. y en Portugal por Rede Electrica Nacional, S.A., mientras que el mercado a plazo es gestionado por el llamado Operador del Mercado Ibérico de Portugal (OMIP). La gestión económica del mercado a plazo la realiza OMIClear, que desempeña funciones de cámara de compensación, contraparte central y entidad gestora del sistema de liquidación.

### 2.1.3 Productos y participantes del mercado a plazo.

Según [18] mediante el decreto conjunto del Ministerio de Finanzas y del Ministerio de Economía, mediante el decreto 945/2004 de 28 de julio se consideran operaciones a plazo sobre energía eléctrica: los futuros, opciones y otras operaciones a plazo que tengan por activo subyacente la electricidad, productos de base energética y otros equivalentes, de naturaleza real o virtual, índices de electricidad, de productos de base energética o de otros equivalentes, con liquidación por entrega (física) o liquidación financiera. En el mercado a plazo existen cuatro tipos de contratos: futuros (admiten liquidación financiera o física), forwards (son de naturaleza física), swaps (son de naturaleza financiera) y opciones. Los contratos admitidos a negociación pueden a su vez ser:

- Semanales: están en negociación las 3 semanas siguientes y el primer día de cada semana se plantea un nuevo contrato.

- Mensuales: en cualquier momento hay en negociación de 3 a 5 contratos mensuales, abarcan desde el mes de negociación más cercano hasta el último mes del trimestre más próximo de negociación.
- Trimestrales: el primer día de negociación de cada año del calendario se plantean 4 contratos trimestrales cubriendo el año del calendario siguiente, teniendo en negociación de 4 a 7 contratos trimestrales
- Anuales: en negociación se plantean el contrato anual del próximo año y varios de los años siguientes.

Todos los contratos que existen son contratos de entrega de suministro para las 24 horas del día. Así mismo, la liquidación financiera de los contratos de futuros se rige por la diferencia entre el precio de referencia spot y el precio de referencia de negociación del contrato de futuros del último día de negociación, para cada una de las horas del periodo de entrega del contrato. El precio de referencia es el precio de la última transacción, pero puede definirse otro precio de referencia en caso de no cumplirse determinados requisitos o no existan transacciones. En este tipo de contrato la liquidación financiera se realiza diariamente.

En los contratos forwards y contratos swap, la liquidación financiera se realiza mensualmente y se corresponde a la diferencia entre el precio de referencia spot y el precio de cada operación.

Pueden participar en el mercado a plazo entidades tales como: intermediarios financieros y personas que sean idóneas y profesionalmente aptas, (tengan un nivel suficiente de capacidad y competencia de negociación, dispongan en el caso necesario, de mecanismos organizativos adecuados y posean recursos suficientes para las funciones a ejercer); productores en régimen ordinario; comercializadores y otros agentes del sector eléctrico.

#### 2.1.4 Fases de negociación del mercado a plazo.

El mercado a plazo funciona diariamente, conforme a un calendario definido por OMIP, transcurriendo las sesiones en un periodo comprendido entre las 8:00 y las 18:30, hora española. De modo que en las sesiones de negociación correspondientes a los cuatro primeros miércoles de cada mes existen las siguientes fases: de las 8:00 a las 9:00, fase de negociación previa; de las 9:00 a las 10:00, negociación por subasta; de las 10:00 a las 16:00, negociación en continuo; y de 16:00 a las 18:30 la fase de cierre previo. En el resto de sesiones de negociación se distinguen las siguientes fases: de las 8:00 a las 9:00, fase de negociación previa; de las 9:00 a las 9:10, fase de negociación por subasta; de las 9:10 a las 16:00, fase de negociación en continuo y finalmente de 16:00 a las 18:30 la fase de cierre previo.

#### 2.1.5 Funciones de OMIP.

Las funciones de la OMIP son la organización y gestión del Mercado, debiendo entre sus obligaciones: definir las reglas del mercado, admitir, suspender y excluir a miembros

negociadores, garantizar que los miembros respectivos cumplan las reglas del mercado, controlar las operaciones cerradas en el mercado, establecer los contratos admitidos y mantener el normal funcionamiento de la plataforma de negociación. Cooperando con OMIClear deberá registrar las operaciones realizadas en el mercado y fuera de él, pero que se registran en el mercado a plazo.

## 2.2 Evolución y situación actual en los métodos de predicción de precios de la electricidad.

### 2.2.1 Introducción.

En la década de los 90 se implementa en diferentes países, incluida España, la liberalización de los sectores energéticos, previamente regulados y controlados por los estados. Entre los sectores que iniciaron el camino para su gestión conforme a las reglas del mercado, destaca el sector eléctrico. Éste sector presenta particularidades difíciles de encontrar en otros bienes sometidos al arbitrio de los mercados. Es un bien que no se puede almacenar, que requiere de infraestructuras de generación y transporte estables, gestionadas de forma casi instantánea para garantizar el equilibrio entre la energía eléctrica demandada y la generada.

La difícil regulación de la generación en función de la demanda ha dado lugar a un campo de desarrollo de métodos de predicción de la demanda desde hace algunas décadas. La investigación de métodos para la predicción del precio de la energía eléctrica, más reciente, se ha nutrido de los conocimientos ya desarrollados como base de su aprendizaje. No obstante, las peculiaridades del mercado eléctrico y el interés en la previsión del precio de la electricidad han generado un incremento de las publicaciones en los últimos quince años.

Quienes realizan operaciones de compra-venta en los mercados eléctricos tienen en los métodos para la predicción de los precios de la energía eléctrica una zona de amplio interés, por cuanto la toma de decisiones se verá condicionada por las expectativas de beneficio. Los márgenes de beneficio en las operaciones en el mercado eléctrico necesitan de la predicción de los precios de la energía eléctrica con la mayor precisión posible.

### 2.2.2 Plazos en los que realizar predicciones de los precios de la energía eléctrica.

En la literatura se habla de predicciones a corto, medio o largo plazo.

De esta forma el corto plazo contempla el umbral de las previsiones a unos pocos minutos vista hasta varios días de anticipación. Estos análisis son útiles para realizar operaciones en el día, es decir, para intervenir en el mercado diario.

Cuando las previsiones se realizan en el medio plazo, se habla de un horizonte que va desde unos pocos días hasta uno o dos meses. Estas previsiones suelen tener como objetivo facilitar

los cálculos para la gestión de riesgos y las operaciones con productos derivados de los precios de la electricidad.

En las predicciones a largo plazo se habla de proyecciones de precios a meses, trimestres o años vista. Estas estimaciones permiten realizar análisis para planificar inversiones, bien en el empleo de centrales de generación o en las fuentes de energía, desde el punto de vista de la rentabilidad.

### 2.2.3 Modelos de predicción del precio de la energía eléctrica.

En el trabajo de **Rafal Weron [21]**, se describen dos planteamientos para desarrollar métodos de predicción del precio de la energía eléctrica. Por un lado métodos basados en sistemas estadísticos y por otro, métodos basados en la inteligencia computacional. Entre estos métodos de inteligencia computacional, se profundizará en la literatura en la que se desarrollan los métodos basados en redes neuronales, por cuanto es el procedimiento desarrollado en este trabajo.

La distinta metodología, según la literatura consultada, genera resultados diversos en función de los datos con los que se trabaja, los parámetros de los sistemas y el plazo en el que se realiza la predicción. Aunque con más frecuencia, los métodos de inteligencia computacional generan resultados más próximos a la realidad que los métodos basados en series estadísticas temporales.

No obstante se puede encontrar una mayor definición de modelos en la publicación de **R. Weron [2]**, donde se describen los siguientes grupos de modelado:

- Modelos multiagente (de simulación, teoría de juegos): es un modelo que recrea el funcionamiento del mercado, generando agentes y construyendo el proceso de fijación de precios. Este tipo de modelos son adecuados para mercados regulados donde hay poca incertidumbre en los precios. Entre la literatura se encuentra la publicación de **Ruibal y Mazumdar [3]**, titulada **“Forecasting the mean and the variance prices of electricity prices in deregulated markets”**. En este planteamiento, considerando como fuentes de incertidumbre la disponibilidad de generación la demanda, predice los precios de la electricidad por hora y los precios medios en un periodo. En los resultados obtenidos con este procedimiento, al reducir el número de agentes que intervienen en el mercado se observa un incremento de los precios.
- Modelos fundamentales (estructurales): estos sistemas modelan los precios de la electricidad en función de parámetros físicos y económicos. Destaca la publicación de **Coulon y Howison [4]**, de título **“Stochastic behaviour of the electricity bid stack: from fundamental drivers to power prices”**. Los modelos fundamentales se adaptan mejor a las predicciones a medio plazo que a corto plazo, debido a varios factores, como que los datos necesarios para crear el modelo son difíciles de obtener, encontrándose más habitualmente en intervalos semanales o mensuales. Al desarrollar el modelo se deben realizar suposiciones sobre las relaciones físicas

y económicas que intervienen en el mercado, siendo los modelos de predicción de los precios muy sensibles al mayor o menor acierto de estas suposiciones.

- Modelos reducidos (cuantitativos, estocásticos): Estos modelos establecen las propiedades de los precios de la electricidad mediante parámetros estadísticos distribuidos en el tiempo. Se emplean para la evaluación y gestión de los riesgos. Muy reseñada se encuentra en este contexto el anteriormente citado Weron. Así destaca la publicación de **Weron y Misiolek [5]** de título **“Forecasting spot electricity prices: a comparison of parametric and semiparametric time series models”**. Los análisis realizados sobre este tipo de modelos planteados para realizar la previsión del día siguiente manifiestan un rendimiento bajo.
- Modelos estadísticos (econométricos, análisis técnico): estos modelos aplican de forma directa las técnicas estadísticas para la realización de la previsión del mercado o de la demanda de electricidad. Estos métodos se suelen emplear en combinación con modelos más complejos como serían: ARIMA, ARFIMA, SARIMA, ARMA, GARCH, ARX, ARMAX, ARIMAX, SARIMAX y ARIMA-GARCH. Como ejemplo de estas aplicaciones se tiene el modelo ARIMA donde empleando la transformada discreta de la forma de onda se trabaja con los diferentes componentes en frecuencia de la señal. Este es el caso del modelo desarrollado por **Conejo, Plazas, Espinola y Molina [6]**, que se refleja en la publicación de 2005 titulada **“Day-ahead electricity Price forecasting using the wavelet transform and ARIMA models”**. Estos modelos emplean combinaciones matemáticas de los precios anteriores y de los datos de parámetros externos. Los resultados en las previsiones que se realizan con estos modelos depende de los algoritmos empleados, los datos analizados, así como de la capacidad de valorar factores importantes, (demanda histórica, climatología, costes). La presencia de picos en los valores de los datos de entrada en el modelo generan la pérdida de precisión, por lo que en las publicaciones existentes se sugieren procedimientos para tratar estos fenómenos.
- Modelos de inteligencia computacional (basados en inteligencia artificial, no lineales): las técnicas aplicadas en este modelo combinan los fundamentos del aprendizaje, la evolución de los datos y la aparente falta de relaciones de estos, para generar sistemas dinámicos complejos que faciliten soluciones precisas. Es en este grupo donde se incluyen los modelos basados en la aplicación de redes neuronales.

Por cuanto este trabajo se basa en el desarrollo de un modelo de predicción mediante redes neuronales, se profundizará en el siguiente punto en las publicaciones en la que se describen. Los modelos basados en redes neuronales presentan una gran capacidad de procesamiento de la información, estableciendo relaciones no lineales entre las entradas y las salidas para obtener predicciones. Se ha seleccionado como método de predicción los basados en redes neuronales en vista de lo anterior, una gran ventaja respecto al resto de modelos a la hora de realizar previsiones complejas y sin aparente relación con los datos de origen.



#### 2.2.4 Modelos desarrollados de predicción del precio de la energía eléctrica mediante redes neuronales.

Los trabajos desarrollados para la predicción de los precios de la electricidad mediante redes neuronales son relativamente recientes y poco abundantes. El primer trabajo encontrado a este respecto, es el publicado en 2010 *de Whei-Min Lin, Hon-Jey Gow y Ming-Tang Tsai [7]*, cuyo título es **“Electricity Price forecasting using Enhanced Probability Neural Networks”**. El trabajo que se desarrolla presenta una combinación de probabilidad de redes neuronales (PPN) y diseño ortogonal experimental (LMP), y se propone para la obtención de resultados una probabilidad aumentada mediante redes neuronales (EPNN). Este modelo permite realizar previsiones del precio de la electricidad hora a hora con una semana de anticipación.

Publicado en 2011, está el trabajo de *Deepak y Swarup [8]*, titulado **“Electricity price forecasting using artificial neural networks”**. El modelo de redes neuronales desarrollado, permite realizar previsiones del precio eléctrico con un día de anticipación.

Otro trabajo publicado en 2011, por *Fernando Villada, Edwin García y Juan D. Molina [9]*, cuyo título es **“Pronóstico del precio de la energía eléctrica usando redes neuro-difusas”**. En este modelo se realiza la previsión a un mes vista del precio de la energía eléctrica, para el sistema colombiano. Los resultados obtenidos se comparan con los obtenidos por dos modelos de redes neuronales y un modelo GARCH.

En el año 2016, se publicó el trabajo realizado por *Ioannis P. Panapakidis y Athanasios S. Dagoumas [10]*. Este complejo trabajo titulado **“Day-ahead electricity price forecasting via the application of artificial neural network based models”**, desarrolla múltiples modelos de redes neuronales. En el trabajo se realiza una búsqueda para determinar los parámetros de entrada y el modelo de redes neuronales que mejor se ajustan para realizar previsiones a cada hora con un día de anticipación.

Finalmente destacar el trabajo **“Desarrollo de un modelo de predicción del precio horario de la energía eléctrica para el mercado diario mediante redes neuronales”**, desarrollado por *Diego Santos Martín & Manuel Alcázar Ortega [1]* donde se realiza el pronóstico del precio diario para operar a corto plazo.

Algunos de los trabajos anteriores, partiendo del horizonte en el que trabajan, realizan proyecciones de sus modelos hacia previsiones a más largo plazo. Al aumentar el horizonte en el que se proyectan se incrementa de forma significativa el nivel de error de las predicciones. El estudio con mayor horizonte de proyección, fijando un plazo de hasta tres meses en sus estimaciones es el realizado por *Pao, H.T. [12]*, cuyo título es **“Forecasting electricity market pricing using artificial neural networks”**.

### 2.2.5 Conclusiones del capítulo.

En el este capítulo del trabajo, se ha hablado de los mercados que operan dentro del MIBEL. Entre esos mercados se ha explicado el funcionamiento del mercado a plazo. Para ello se ha descrito los productos y participantes en dicho mercado, las fases de negociación y las funciones del operador del mercado a plazo (OMIP).

En este capítulo también se ha analizado la literatura existente sobre modelos para predecir el precio de la energía eléctrica y se ha visualizado las publicaciones para el pronóstico de la demanda de energía eléctrica. Con ello se ha podido obtener una visión del campo de trabajo existente. Destaca el hecho de que pese al amplio desarrollo, tanto en el tiempo como en la literatura técnica de modelos para predecir la demanda de electricidad, es relativamente reciente la investigación en métodos de predicción del precio y muy reducida la literatura al respecto.

En la búsqueda de publicaciones sobre modelos de predicción del precio de la energía eléctrica no se ha encontrado ningún modelo basado en redes neuronales para realizar previsiones a largo plazo, es decir a más allá de unos meses. Existen trabajos desarrollados sobre modelos de redes neuronales para la previsión del precio de la electricidad a un día vista, a una semana vista e incluso a un trimestre vista, pero no se han hallado publicaciones que permitan pronosticar a un año vista. Por ello, el planteamiento de este trabajo, pese a las referencias existentes sobre la aplicación de diferentes modelos y de modelos de redes neuronales, se puede considerar como novedoso.

Un aspecto a considerar respecto de los diferentes modelos estudiados, es que no es factible realizar una comparación de los niveles de error de los diferentes modelos de forma directa. Esto es así, porque aunque coincidiendo en el horizonte de predicción, los factores de partida de los modelos frecuentemente son muy diferentes. En primer lugar y aunque los modelos de predicción se realizan para un número limitado de mercados eléctricos, estos presentan características propias. Estas diferencias implican que el funcionamiento diverge en su comportamiento, aunque el modelo de mercado eléctrico sea similar. Por otro lado, los parámetros de entrada de un modelo de predicción y otro presentan divergencias, no suelen ser iguales los parámetros escogidos ni el tamaño de la serie temporal. Y por otra parte, el tratamiento que los diferentes programas empleados para el desarrollo de los modelos de redes neuronales provoca diferentes resultados aún con los mismos factores de partida de los modelos.

### 3. Metodología.

#### 3.1 Introducción.

En este punto se justificarán las características de los modelos desarrollados. Los factores que afectan al modelo de predicción determinarán la precisión del modelo. Estos factores incluyen los datos de entrada del modelo, los horizontes de predicción del mismo en función del producto del mercado a plazo, así como las características propias de cada modelo.

De esta forma se analizarán los diferentes parámetros que pueden intervenir a la hora de fijar los valores económicos de la electricidad en el mercado a plazo. Para ello, se tomarán en consideración aquellos parámetros reseñados en la bibliografía analizada en el estado del arte, así como todos aquellos de los que se pueda generar una base de datos y tengan relación con los productos del mercado eléctrico.

Se realizará para ello un primer análisis gráfico para determinar las posibles correlaciones lineales entre los variables analizados con los valores a predecir, dentro de los datos de las series temporales en los que se entrenarán y testearán los sistemas de predicción. Posteriormente se realizará un análisis de la sensibilidad respecto de las variables de entrada seleccionadas para la salida del modelo. Partiendo del objetivo de trabajar en el mercado a plazo, se analizará el contrato con menor distancia temporal de entrega desde la fecha de negociación de cada producto en carga base, de entre todos los productos del mercado a plazo. Es decir para el producto a plazo para el fin de semana se analizará la previsión del primer fin de semana desde el día de negociación, para el producto semanal se realizará la previsión de los contratos de la semana siguiente al día de negociación. De modo análogo para el mes, el cuatrimestre y el año, se realizará la previsión para el inmediatamente posterior a la fecha en que se negocia el contrato del producto. Y finalmente se aplicará el modelo de previsión para el mercado diario, tratando de predecir el precio de la electricidad en el mercado spot.

El siguiente punto a desarrollar en este capítulo será el relativo al desarrollo matemático que se va a implementar para el modelo de red neuronal. En este trabajo se analizará el funcionamiento de tres modelos:

1. Un modelo de red neuronal simple.
2. Un modelo de red neuronal con realimentación
3. Un sistema de predicción basado en dos modelos de redes neuronales en cascada, donde el segundo afinará los resultados del primero.

No obstante para implementar los tres modelos se parte del mismo modelo simple. En el desarrollo de este capítulo se justificará el uso de los diferentes modelos al objeto de encontrar posibles mejoras en los sistemas de predicción.

El proceso de elección de los parámetros que definen los modelos se resume en el siguiente diagrama de bloques.

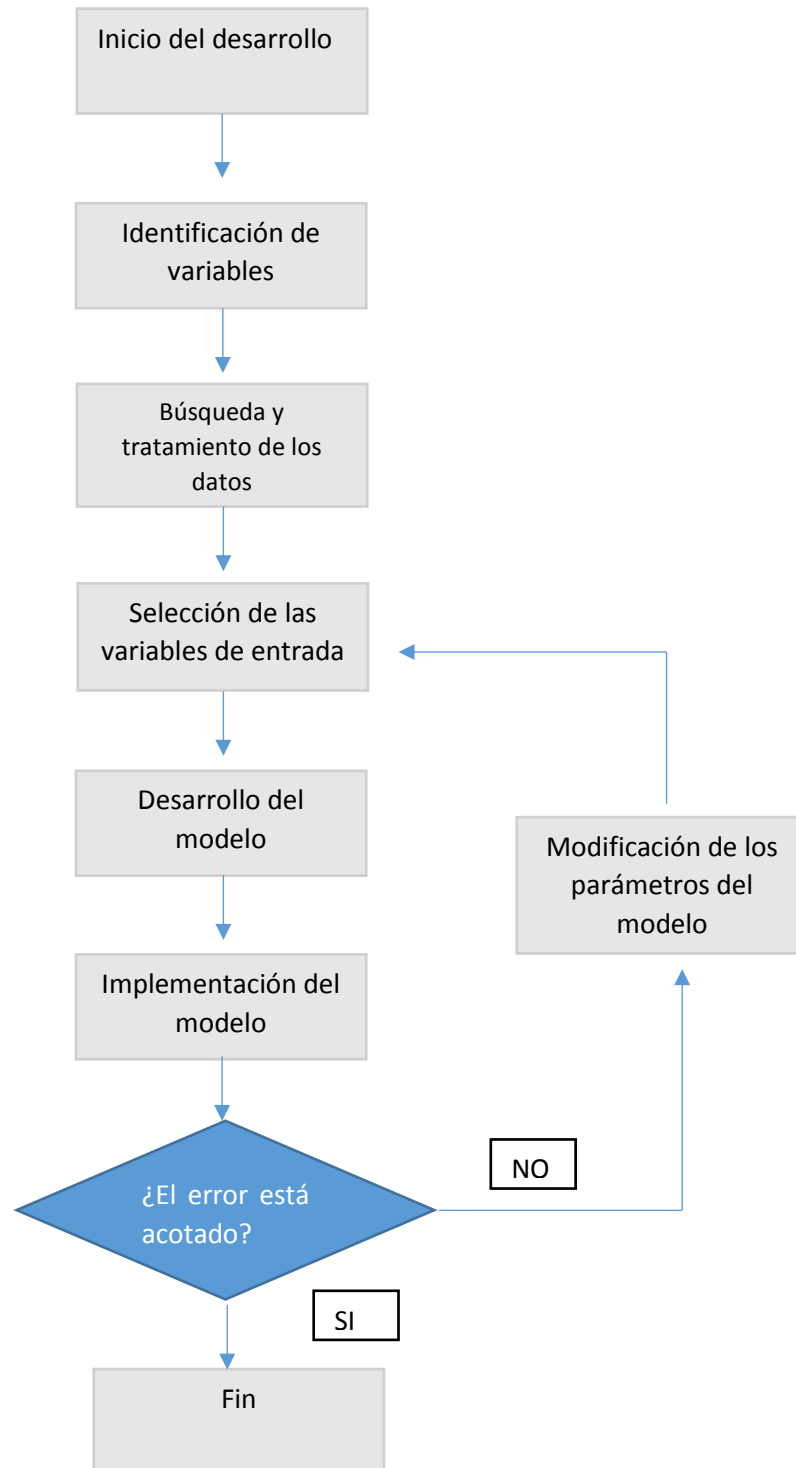


Ilustración 2 Diagrama de bloques sobre el procedimiento de trabajo. Fuente: elaboración propia.

Conforme al diagrama anterior, el procedimiento de trabajo una vez se inicia el desarrollo pasa por identificar las variables que intervienen en el modelo, seleccionándolas y gestionándolas en busca de mejorar la precisión del modelo. Entre otras cosas habrá que buscar los datos que se requieren para desarrollar el modelo, interpretándolos y preparándolos. Una vez generadas las series temporales de las variables de entrada, se trabajará en el análisis de las mismas y su relación con la salida del modelo para determinar las variables que resulten útiles.

Posteriormente se determinarán los parámetros iniciales del modelo. Con los parámetros y variables definidos se desarrollará e implementará el modelo. Una vez implementado se validará, verificará y analizará tanto el modelo como los resultados obtenidos. Se buscará minimizar el error, en el caso de no conseguirlo se modificarán los parámetros del modelo y reevaluarán los datos de entrada a fin de conseguir un resultado que presente un nivel error acotado.

### 3.2 Factores a considerar.

La búsqueda de los datos más relevantes para implementar la red neuronal se basa en la experiencia en el desarrollo de proyectos anteriores a los que se refiere la literatura localizada. Así mismo, se han añadido al análisis de variables series de datos, los futuros de otros productos energéticos, porque pueden ser determinantes en el precio de los contratos cuyas previsiones se busca. Entre las variables estudiadas se encuentran:

- El día de la semana, (lunes=1, martes =2, miércoles =3, jueves=4, viernes =5, sábado=6, domingo=7).
- Un indicador de festivos, (0= día laboral en todo el país, 1=festivo nacional).
- Reservas hidroeléctricas un año antes en hm<sup>3</sup>.
- Demanda eléctrica real un año antes en MW.
- Generación eléctrica de los siguientes tipos en MW de un año antes: carbón, ciclo combinado, nuclear, solar, eólica e hidráulica. Se han tomado en consideración por sus características, bien el peso en el mix de generación o por favorecer su uso costes mayores o menores en el mercado diario de la energía.
- Precios de los futuros del petróleo Brent y el gas natural en los mercados internacionales.

De las diferentes publicaciones que se han estudiado de la bibliografía, se ha constatado como necesario considerar el horizonte temporal en el que se quiere realizar las previsiones para determinar la dimensión de las series temporales de los datos de entrada. En los diferentes productos sobre los que se analizarán las redes neuronales desarrolladas, se realizará una previsión máxima a un año vista de la fecha de la primera negociación de los contratos. Por ello se justifica emplear dos años de series temporales de los datos de entrada para entrenar y testear la red, a fin de realizar un proyección de los precios de los contratos lo más ajustada posible a la realidad.

Respecto a las características de los modelos, éstos se fijarán para el modelo de red neuronal artificial de base y se extrapolarán a los diferentes sistemas de predicción que se desarrollan en este trabajo. El modelo que presenta realimentación, se desarrolla partiendo de las características del modelo simple. El modelo en cascada presenta una red neuronal artificial que será igual a la del modelo de red neuronal artificial de base y una segunda red neuronal similar a la anterior con una entrada más, que es la salida de la anterior. De esta forma, definiendo adecuadamente las características de la red neuronal del modelo de base se caracteriza adecuadamente los sistemas de predicción que se plantean en este trabajo.

### 3.3 Datos de entrada.

Se ha considerado el uso de doce datos de entrada en la evaluación de la red neuronal simple. Aunque se va a realizar la predicción de productos con un horizonte temporal diferente, se va a considerar principalmente el análisis para el producto con entrega más lejana desde el día de negociación, por cuanto es el que presenta mayor incertidumbre. Una buena interpretación de los datos de entrada para los contratos de futuros a un año, permitirá tener un adecuado punto de partida para trabajar con el resto de productos. Al reducir el periodo de entrega del contrato de los futuros la incertidumbre será inferior, pues la predicción del futuro de la electricidad con entrega a un año presenta mayor imprecisión que el futuro de la electricidad a un cuatrimestre, y así sucesivamente. Esto nos permitirá simplificar el procedimiento de análisis de los datos de entrada y no repetir el procedimiento de evaluación de forma reiterativa.

En el proceso para determinar la relevancia de los datos de entrada para las diferentes posibles salidas, se realizará una evaluación gráfica. En esta evaluación gráfica se representará por separado cada una de las variables de entrada frente al precio del producto eléctrico en su fecha de negociación, se tendrá así una gráfica para cada variable de entrada frente al precio del contrato a un año en carga base. El objetivo es poder visualizar zonas definidas de puntos que permitan hablar de una correlación lineal entre la entrada y la salida. La dispersión de los puntos puede ser un indicador de ausencia de correlaciones.

Finalmente y empleando un red neuronal simple de una capa con doce neuronas, (se justificará posteriormente la selección de este parámetro), e implementado la red neuronal por regularización Bayesiana (se justificará en este capítulo en puntos posteriores), se realizará un ensayo de la sensibilidad de los valores de salida ante cada una de las entradas analizadas. Para ello se establecerán modificaciones en el dato de entrada a estudiar en una fecha dada, (normalmente variaciones del -30%, -15%, -5%, +5%, +15%, +30%) y se realizará la previsión sobre el modelo de red neuronal simple anterior. Para determinar los parámetros de la sensibilidad se aplicarán las siguientes ecuaciones:

$$(1) \quad \Delta E(\%) = \frac{V_{em} - V_{er}}{V_{er}} \times 100$$

$$(2) \quad \Delta S(\%) = \frac{V_{sm} - V_{sr}}{V_{sr}} \times 100$$

$$(3) \quad \text{Sensibilidad}(\%) = \frac{\Delta S}{\Delta E} \times 100$$

Donde:

$V_{em}$  es el valor de la entrada de la red neuronal una vez modificado.

$V_{er}$  es el valor de la entrada real.

$\Delta E$  es el % porcentaje de variación de la entrada manipulada en el modelo de predicción respecto de la entrada real.

$V_{sm}$  es el valor de la salida de la red neuronal al modificar la entrada.

$V_{sr}$  es el valor de la salida de la red neuronal ante la entrada real.

$\Delta S$  es el % porcentaje de variación de salida al modificar la entrada, respecto de la salida empleando la entrada real.

El objetivo de estos ensayos es visibilizar la sensibilidad del valor del precio del contrato ante modificaciones de las entradas que se pretende analizar. Con la última ecuación, se obtiene el nivel de variación en % de la variable de salida en función de una variación unitaria de la variable de entrada.

Por último señalar que los datos con los que se trabaja como variables de entrada y los datos de los diferentes precios de los productos eléctricos en carga base, han presentado dificultades en su localización y preparación, siendo los datos y sus procedencias los siguientes:

- El día de la semana y la festividad se obtienen de calendarios laborales.
- El nivel de las reservas hidráulicas para la generación de electricidad provienen de Boletines Hidrológicos del Ministerio para la Transición Ecológica del Gobierno de España **[13]**
- Los valores de demanda eléctrica y de generación eléctrica de los diferentes tipos se han extraído de la página web [www.esios.ree.es](http://www.esios.ree.es), perteneciente al Sistema de Información del Operador del Sistema (ESIOS **[17]**).
- Los valores de los futuros del petróleo Brent y Gas Natural en los mercados internacionales se extraen de la página web [es.investing.com](http://es.investing.com) de información bursátil **[19]**.
- Los valores de los futuros de la electricidad en el mercado a plazo provienen del Operador del Mercado Ibérico de Portugal (OMIP **[18]**). Página web: [www.omip.pt](http://www.omip.pt).
- El precio de la electricidad en el mercado Spot diario se obtiene de la web anteriormente citada de ESIOS.

### 3.3.1 El día de la semana.

Este parámetro permite establecer una relación en la que se fija el día de la semana para la fecha de negociación del producto. Esta variable condiciona las relaciones de los parámetros, por cuanto la demanda de energía y la generación eléctrica de diferentes tipos que se han considerado en este trabajo varían en función del día de la semana.



Ilustración 3. Evolución de la demanda real en España en el período de dos semanas. Fuente: [www.esios.ree.es](http://www.esios.ree.es)

Como se puede observar en la imagen anterior, no hay la misma demanda si es jueves, (donde el día anterior y posterior normalmente será laboral), que si es sábado, (pues aunque el día anterior sea laboral hay un fin de semana por delante, se produce una reducción sensible de la demanda eléctrica y por ello de la generación). Las variaciones en la generación suelen traducirse en incrementos o reducciones de los precios de la electricidad. Como ya se ha señalado en el punto anterior, se han dado los siguientes valores: 1-lunes, 2-martes, 3-miércoles, 4-jueves, 5-viernes, 6-sábado, 7-viernes.

### 3.3.1.1 Correlación lineal entre el dato de entrada del día de la semana y el valor del precio del futuro a un año.

A continuación se realizará la representación gráfica de los datos de los días de la semana respecto a los valores de salida de la red, (siendo las salidas el precio del futuro a un año en carga base), en el periodo de datos que se estima para entrenar y testear la red, es decir para dos años.

La representación gráfica de esta serie frente a los futuros a un año, nos determinará una línea de puntos para cada día de la semana. Esto permite vislumbrar la relevancia de este dato para nuestros modelos de predicción. A continuación se realiza la representación gráfica del valor del día respecto al valor del futuro del año siguiente.



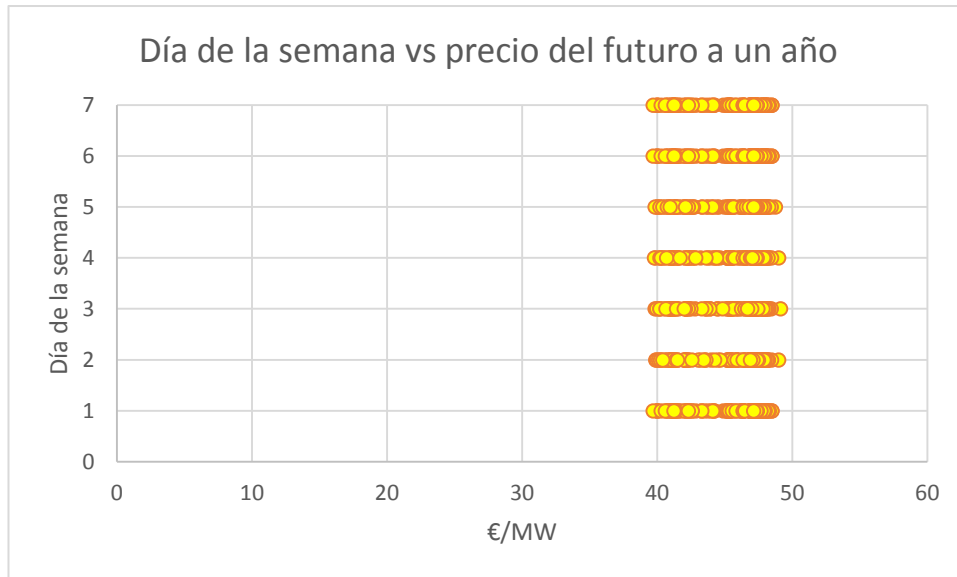


Ilustración 4. Representación gráfica de los datos del día de la semana frente al precio de la electricidad en el futuro para el año siguiente. Fuente: elaboración propia.

### 3.3.1.2 Análisis de sensibilidad del precio del futuro a un año frente al día de la semana.

Seguidamente se realiza un estudio del impacto en el valor que predice la red neuronal simple al realizar variaciones del valor del día. En la siguiente tabla se refleja la sensibilidad en la predicción del valor del futuro a un año con diferentes variaciones de la entrada. Las variaciones se realizan sobre el dato del día con fecha 6 de octubre de 2017, que se corresponde con un viernes (5). Los valores se obtienen a partir las ecuaciones anteriormente reseñadas:

Tabla 1. Sensibilidad del precio del futuro a un año ante la entrada del día de la semana.

Tabla de Sensibilidad precio/día	Valor entrada	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real de viernes 6/10/2017	5		43,50		
Dato incrementado	6	20,00	43,41	-0,2013	-1,006
Dato reducido	4	-20,00	43,60	0,2344	-1,172

De esta forma se refleja la relevancia de este dato para los propósitos de este trabajo, observándose una sensibilidad constante entre la entrada y la salida.

### 3.3.2 La festividad.

Este dato de entrada nos permite incorporar en nuestros modelos de predicción un parámetro sobre el nivel de actividad económica en el ámbito de estudio. Es decir, plasmar con un valor numérico comprendido entre 0 y 1 el nivel de actividad en el país. Este dato para el caso de un día laboral en toda España presenta un valor 0, si es un día festivo en todo el país su valor es 1.

En la construcción de este dato de entrada se han tomado en cuenta los festivos nacionales, los festivos de las diferentes comunidades autónomas y los festivos de las capitales de provincia. Se ha considerado un valor 1 para todo el país cuando es un festivo nacional, 1 para la comunidad autónoma con festividad y un coeficiente minorado de 0,8 en aquellas provincias con festividad en la capital de la misma. Se considera 0,8 para el festivo en la capital de provincia por cuanto el impacto en la actividad de la provincia es considerable y al implementar la red parece favorecer un mejor ajuste de la misma.

Aplicando estos coeficientes se pondera el nivel de actividad en base a la población de la comunidad autónoma, si es festivo en ella o de la provincia en cuya cabecera es festivo. Por ejemplo, el día 22 de enero es fiesta en la ciudad de Valencia, capital de provincia. La población de la provincia de Valencia es 2,541 millones de personas, al ser festivo en la capital de provincia se aplica un coeficiente de 0,8. La población de todo el país según el censo es de 46,572 millones. Para determinar el dato festividad para ese día se tiene.

$$(4) \quad Kf = \sum Kl * \frac{P_l}{P_n}$$

Donde:

Kf es el coeficiente de festividad del día a nivel de todo el país

Kl es el coeficiente de laboralidad para cada comunidad autónoma o provincia con fiesta en el día considerado.

P<sub>l</sub> es el término que hace referencia a la población de la provincia o comunidad con festividad, en millones de personas. El valor se obtiene del censo del año en cuestión.

P<sub>n</sub> es el término que hace referencia a la población total del país en millones de acuerdo con el censo del año en cuestión.

En nuestro caso:

$$(5) \quad Kf = 0,8 * \frac{2,541}{46,572} = 0,0436$$

A continuación se construye una gráfica que recoge en función del rango de los valores de la variable, la frecuencia en que se dan a lo largo del año. Este tipo de gráfico es un histograma. En el que se observa a continuación, se constata que la mayor parte de los valores tienen valor

0 (51,8%), que indica que son días laborales en todo el estado. Hay una pequeña distribución en los valores intermedios y una fuerte concentración en el valor 1 (31,9%), que se corresponde a los festivos en todo el país. Este pico es debido especialmente a los fines de semana.




Ilustración 5. Histograma de los datos de festividad.

### 3.3.2.1 Correlación lineal entre el dato de entrada de la festividad y el valor del precio del futuro a un año.

Al realizar la representación gráfica del valor de festividad frente a la salida, el precio del futuro a un año, se observa una distribución de puntos que se concentra entre el valor 0 y el 1, con algunos puntos dispersos entre ambos valores.




Ilustración 6. Representación gráfica de los datos de festividad frente al precio de la electricidad en el futuro para el año siguiente. Fuente: elaboración propia.

3.3.2.2 Análisis de sensibilidad del precio del futuro a un año frente a la festividad.

Seguidamente se evalúa la variación del precio del futuro a un año al realizar variaciones en el dato de la festividad. En la siguiente tabla se refleja la sensibilidad en la predicción del valor del futuro a un año con diferentes variaciones de la entrada. Las variaciones se realizan sobre el dato de la festividad con fecha del domingo 8 de octubre de 2017, festivo en toda España. Se han escalonado variaciones del valor de entrada para determinar el impacto en el valor de predicción del precio del contrato del futuro a un año.

Tabla 2. Sensibilidad del precio del futuro a un año ante la entrada de la festividad o laboralidad del día.

Tabla de Sensibilidad precio/festividad	Valor entrada	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 7/10/2017	1		44,63		
Dato -5%	0,95	-5,00	44,62	-0,027	0,535
Dato -15%	0,85	-15,00	44,59	-0,092	0,617
Dato -30%	0,7	-30,00	44,54	-0,222	0,741
Dato -50%	0,5	-50,00	44,43	-0,455	0,910
Valor mínimo	0	-100,00	44,04	-1,338	1,338

### 3.3.3 Reservas hidráulicas para generación eléctrica.

Este dato depende de la pluviometría, pues recoge el caudal de agua almacenado para producción de energía hidroeléctrica. Los datos se han obtenido a partir de los boletines hidrológicos que publica el ministerio competente del Gobierno de España [13]. En estos boletines se publica el valor de las reservas hidráulicas para generación eléctrica semanal. Para dar un mejor tratamiento a este dato y obtener valores diarios, se ha realizado la interpolación de los datos semanales mediante funciones splines. Esta interpolación ha permitido obtener una proyección de la evolución de las reservas hidráulicas día a día. El tratamiento dado a este dato era una de las propuestas del TFM de **Diego Santos Martín [1]**.

Este dato tiene un comportamiento diferenciado en función de los meses, alcanzándose los valores mínimos en los meses estivales por la falta de pluviometría. Al construir el histograma de la reserva hidráulica se observan dos puntos donde se acumula la distribución de valores. En el rango entre 9000-12000 se corresponde fundamentalmente a valores de primavera, verano y otoño. El rango mayor entre 13000-15000 abarca fundamentalmente el periodo de invierno y del inicio de la primavera. Lo que constata la temporalidad de esta variable.




Ilustración 7. Histograma de las reservas hidráulicas para el periodo de entrenamiento.

La disponibilidad de una mayor o menor reserva de agua para generación eléctrica posibilita una mayor o menor producción de energía hidroeléctrica. Una producción elevada de esta energía repercute en una reducción de los precios de ésta. En la gráfica siguiente se aprecia una relación entre el nivel de agua embalsada para generación eléctrica y el precio de la electricidad en el mercado Spot, a mayor reserva de agua menor precio en el mercado diario.




Ilustración 8. Gráfica de las reservas hidráulicas frente al precio de la electricidad en el mercado diario. Fuente: elaboración propia.

3.3.3.1 Correlación lineal entre el dato de entrada del nivel de las reservas hidráulicas para generación eléctrica y el valor del precio del futuro a un año.

En la siguiente gráfica se representan los puntos del volumen de agua embalsada para generación hidráulica un año antes frente al precio del contrato del futuro a un año.




Ilustración 9. Representación gráfica de las reservas hidráulicas para generación eléctrica un año antes frente al precio del contrato del futuro a un año. Fuente: elaboración propia.

Se observa una relación contradictoria de los datos, respecto a lo que se observa en la representación gráfica de la reserva hidráulica diaria, para generación eléctrica frente al precio en el mercado diario para las mismas fechas. En la ilustración anterior se puede observar que a menor reserva para generación hidroeléctrica, menor coste del contrato del futuro y al revés a mayor reserva mayor precio del contrato.

### 3.3.3.2 Análisis de sensibilidad del precio del futuro a un año frente al nivel de las reservas de agua para generación eléctrica.

En la tabla siguiente se aprecia la respuesta de la previsión del precio del contrato del futuro a un año, obtenido mediante una red neuronal de base, ante variaciones de las reservas hidráulicas de un año antes. Se aplican variaciones del valor del nivel de reservas de agua del año anterior al día en que se realiza la predicción, en este caso el 6 de octubre de 2017.

Tabla 3. Sensibilidad del precio del futuro a un año ante el valor de la reserva hidráulica de un año antes.

Tabla de Sensibilidad precio/reservas hidráulicas	Valor entrada (Hm3)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	8.632,176		43,50		
Dato +5%	9.063,784	5,00	43,80	0,695	13,901
Dato +15%	9.927,002	15,00	44,60	2,525	16,831
Dato +30%	11.221,828	30,00	45,93	5,575	18,584
Dato -5%	8.200,567	-5,00	43,27	-0,535	10,697
Dato -15%	7.337,349	-15,00	42,94	-1,283	8,551
Dato -30%	6.042,523	-30,00	42,56	-2,152	7,173

En este caso se aprecia una sensibilidad que no era predecible, pues al disminuir las reservas hidráulicas disminuye el valor del contrato del futuro a un año, y al aumentar las reservas el precio se encarece. La sensibilidad entre ambos parámetros es superior al 7% de variación de la salida por cada unidad porcentual de variación de la entrada.

### 3.3.4 Demanda eléctrica.

El consumo eléctrico real es un factor que caracteriza de forma significativa el precio de la energía eléctrica. Un mayor consumo implica un incremento del precio eléctrico, por cuanto para satisfacer el incremento de demanda será necesario incorporar al mix de generación eléctrica partidas de energía de mayores costes. Por el contrario, un menor consumo permite satisfacer la demanda con energías con menores precios.




Ilustración 10. Demanda eléctrica real y demanda eléctrica prevista entre el 28/09/2015 y 27/09/2016.  
Fuente: [www.esios.ree.es](http://www.esios.ree.es)

Esta variable presenta un comportamiento estacional que se caracteriza por diferentes cuestiones como las condiciones climáticas, los niveles de actividad económica,... A continuación se construye el histograma que recoge la distribución de los valores de la variable, es decir el número de veces que se dan los valores dentro de cada rango de demanda eléctrica. En dicho gráfico se describe una distribución de campana, donde se concentran la mayor parte de los valores en la horquilla entre 27500 y 30000 MW, que debe corresponderse a las condiciones de actividad normal. La distribución a la derecha del pico de la campana se reduce rápidamente conforme aumenta el límite del rango. A la izquierda y con valores cada vez menores se produce una reducción de la frecuencia más suave, que se corresponderán con la disminución de la actividad económica.






Ilustración 11. Histograma de la demanda eléctrica en el periodo de entrenamiento.

### 3.3.4.1 Correlación lineal entre el dato de entrada del nivel de demanda eléctrica y el valor del precio del futuro a un año.

En la gráfica que se presenta a continuación se representan los puntos de la demanda eléctrica de un año antes frente al valor del contrato del futuro a un año. En esta gráfica y aunque no existe dispersión no se aprecia de forma clara una correlación entre los valores representados.

El hecho de que se presenten tan agrupados los valores es un indicador de la vinculación de ambos parámetros, aunque no se puede determinar un comportamiento de un parámetro en función del otro.

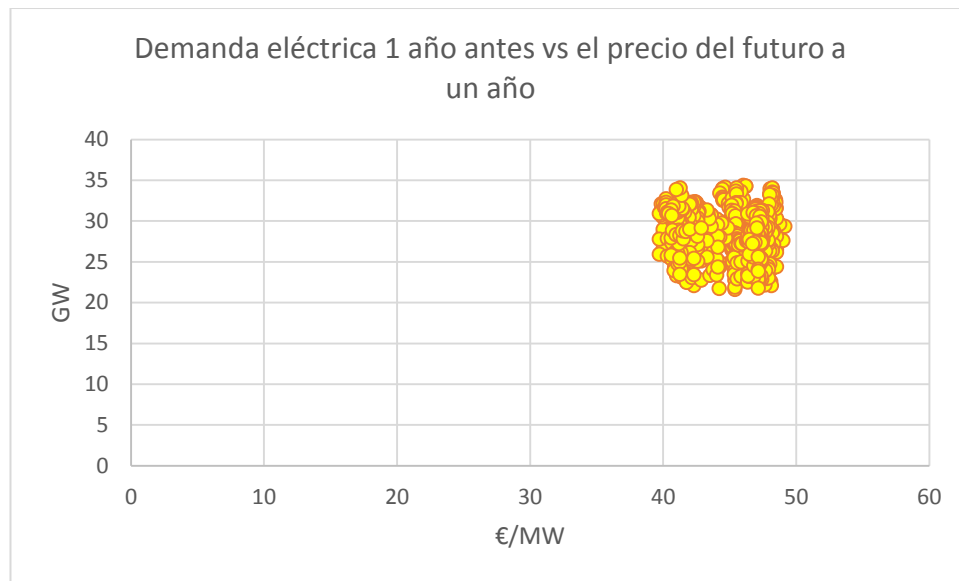


Ilustración 12. Gráfica de la demanda eléctrica el año anterior frente al precio del contrato del futuro eléctrico a un año. Fuente: elaboración propia.

#### 3.3.4.2 Análisis de sensibilidad del precio del futuro a un año frente a la demanda eléctrica de un año antes.

A continuación se presenta la tabla realizada para analizar la sensibilidad del precio del contrato del futuro a un año frente a variaciones del valor de entrada de la demanda eléctrica para el año anterior. Se realizará la estimación sobre la fecha de contratación del 6 de octubre de 2017, dentro de los valores en los que realiza la predicción la red neuronal.

Tabla 4. Tabla de sensibilidad de los precios de los contratos de los futuros a un año frente a la demanda del año anterior al día de contratación.

Tabla de Sensibilidad precio/demanda eléctrica	Valor entrada (MW)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	28.896,174		43,50		
Dato +5%	30.340,983	5,00	43,01	-1,131	-22,622
Dato +15%	33.230,600	15,00	41,98	-3,488	-23,256
Dato +30%	37.565,026	30,00	40,49	-6,919	-23,063
Dato -5%	27.451,365	-5,00	43,96	1,068	-21,350
Dato -15%	24.561,748	-15,00	44,77	2,929	-19,528
Dato -30%	20.227,322	-30,00	45,60	4,831	-16,105

La tabla anterior refleja que ante un incremento de la demanda eléctrica del año anterior al día de contratación se genera una reducción del precio del futuro a un año. Inversamente al

establecerse una sensibilidad negativa, al reducirse la demanda eléctrica se incrementa el precio de la contratación. La sensibilidad se estabiliza entorno a un valor del -20%.

### 3.3.5 Generación eléctrica empleando como fuente el carbón.

Se ha tomado en consideración como variable de entrada el carbón, como fuente de generación eléctrica, por su peso dentro del mix de generación eléctrico. El carbón es una fuente de energía eléctrica que en los últimos tiempos se está viendo penalizada por las administraciones por sus costes ecológicos. Sin embargo el precio del carbón mineral es relativamente bajo con respecto al precio de otros productos energéticos como el petróleo por lo que su uso es abundante.

La distribución de valores según rangos de generación, su histograma, presenta dos zonas de acumulación. Una zona valores bajos y otra de valores altos. La zona de valores bajos se corresponde con días con poca demanda eléctrica. Al contrario, cuando la demanda es alta se requiere la generación con carbón. Esto indica que es una energía que se emplea cuando no se cubre la demanda con otras energías, es una opción de generación de energía complementaria.

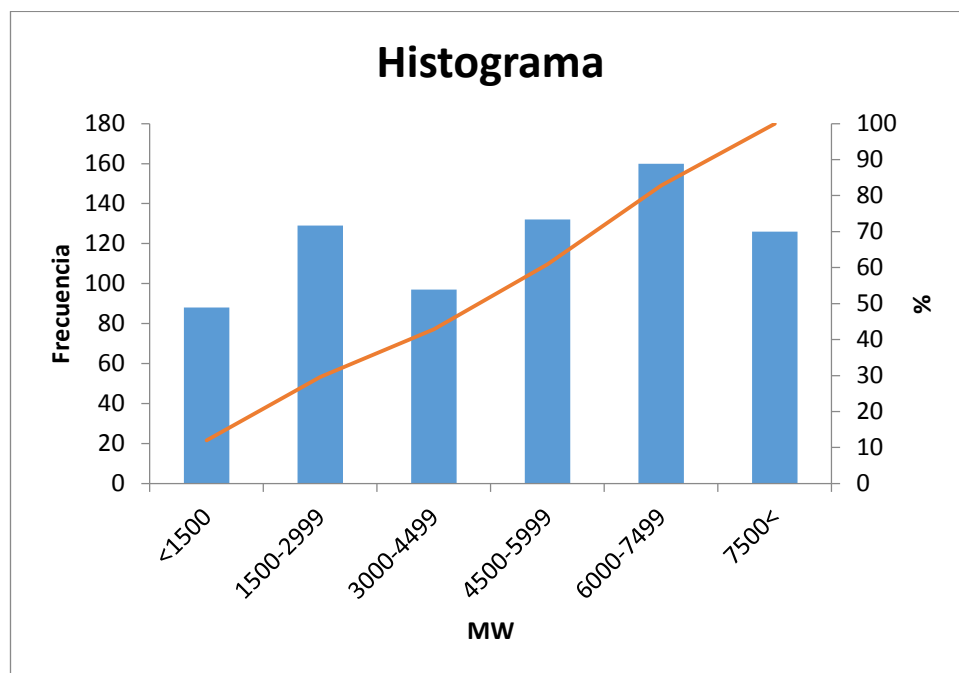


Ilustración 13. Histograma de los valores de generación de energía con carbón en el periodo de entrenamiento.

#### 3.3.5.1 Correlación lineal entre el dato de entrada del nivel de generación con carbón y el valor del precio del futuro a un año.

En la gráfica siguiente se representan como puntos los precios de la contratación de los futuros a un año frente al nivel de generación del carbón del año anterior. Se observa la concentración

de puntos dentro de la horquilla de valores que toma el precio del producto sin confirmar un patrón.




Ilustración 14. Representación de puntos de los niveles de generación eléctrica empleando carbón frente al precio del futuro a un año. Fuente: elaboración propia.

### 3.3.5.2 Análisis de sensibilidad del precio del futuro a un año frente al nivel de generación empleando carbón como fuente de energía de un año antes.

Se presenta a continuación la tabla de sensibilidad construida para los valores del día 6 de octubre de 2017 como fecha de contratación de los futuros. Los valores de los niveles de generación eléctrica empleando como fuente de energía carbón se corresponden con los valores del año anterior.

Tabla 5. Tabla de la sensibilidad del precio del contrato a un año frente al nivel de generación empleando como fuente de energía el carbón.

Tabla de Sensibilidad precio/generación con carbón	Valor entrada (MW)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	6.282,917		43,50		
Dato +5%	6.597,063	5,00	43,61	0,243	4,862
Dato +15%	7.225,355	15,00	43,83	0,762	5,082
Dato +30%	8.167,792	30,00	44,24	1,709	5,696
Dato -5%	5.968,771	-5,00	43,40	-0,240	4,805
Dato -15%	5.340,479	-15,00	43,18	-0,734	4,894
Dato -30%	4.398,042	-30,00	42,82	-1,569	5,229

La sensibilidad tomada como el valor de la variación de la entrada frente a la salida se estabiliza entorno a un valor del 5%. Esto implica que aumentos de la generación eléctrica empleando carbón producen aumentos del precio del futuro a un año y al contrario.

### 3.3.6 Generación eléctrica empleando los ciclos combinados.

Se ha considerado el ciclo combinado por su peso por su peso en el mix eléctrico. Las centrales térmicas de ciclo combinado para generación eléctrica consisten en centrales que aprovechan la energía térmica del combustible mediante el uso de dos ciclos termodinámicos. En el sistema eléctrico español las centrales de ciclo combinado suelen emplear gas natural como fuente de energía.

Al construir el histograma para los valores de generación, se constata la concentración de valores en rangos bajos. Se puede justificar esta circunstancia por el elevado coste de generación con ciclos combinados, empleándose las mayores generaciones con picos de demanda de energía.




Ilustración 15. Histograma de los valores de generación de energía con ciclos combinados en el periodo de entrenamiento.

#### 3.3.6.1 Correlación lineal entre el dato de entrada del nivel de generación con ciclo combinado y el valor del precio del futuro a un año.

En la representación gráfica del nivel de generación con ciclo combinado frente al precio del futuro a un año no se puede establecer una correlación clara. Los puntos se encuentran distribuidos en una franja, en la que se puede apreciar una aparente disminución del precio del futuro al reducirse la generación con ciclo combinado.




Ilustración 16. Representación en el eje vertical de los niveles de generación con ciclo combinado frente al precio del futuro a un año en el eje horizontal. Fuente: elaboración propia.

3.3.6.2 Análisis de sensibilidad del precio del futuro a un año frente al nivel de generación empleando ciclos combinados de un año antes.

La tabla de sensibilidad nuevamente se ha construido sobre variaciones del día 6 de octubre de 2017, que se corresponde a la serie de datos de la predicción de la red neuronal evaluada. En la tabla se obtiene una sensibilidad del orden de 6%, por lo que incrementos de la generación con ciclo combinado producen incrementos en el precio del futuro a un año y viceversa.

Tabla 6. Tabla de la sensibilidad del precio del contrato del futuro a un año frente a variaciones en el nivel de generación de energía eléctrica con ciclos combinados.

Tabla de Sensibilidad precio/generación con ciclos combinados	Valor entrada (MW)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	5.130,375		43,50		
Dato +5%	5.386,894	5,00	43,64	0,320	6,396
Dato +15%	5.899,931	15,00	43,91	0,939	6,263
Dato +30%	6.669,488	30,00	44,29	1,827	6,090
Dato -5%	4.873,856	-5,00	43,36	-0,327	6,548
Dato -15%	4.360,819	-15,00	43,06	-1,009	6,724
Dato -30%	3.591,263	-30,00	42,58	-2,109	7,031

### 3.3.7 Generación eléctrica con energía nuclear.

La energía nuclear supone un importante porcentaje de la energía diaria consumida en los hogares españoles, siendo su producción estable. Esto último quiere decir que su producción es habitual que se corresponda con la máxima instalada, reduciéndose su nivel de generación con las paradas debidas a mantenimiento o menos frecuentemente a incidencias en las centrales de generación. Es por ello que es una energía cuyos niveles de generación son predecibles con mucha anticipación.

En la distribución de valores de generación con energía nuclear, la distribución se concentra en los valores mayores. Esto se explica por cuanto la energía nuclear es una de las energías base del mix de generación del sistema eléctrico español. Es una de las energías más económicas y con ciclos de arranque y parada complejos, por lo que se maximiza su empleo.

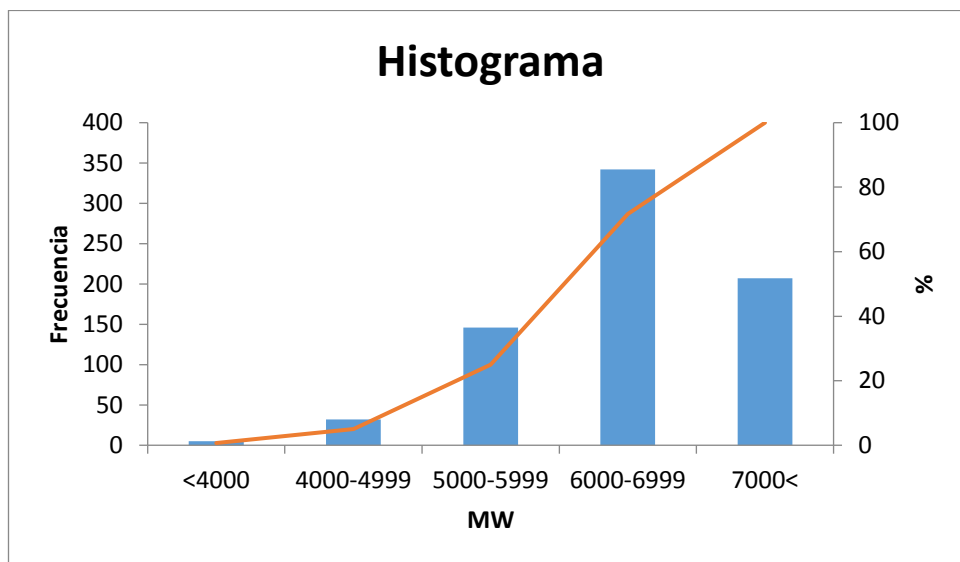


Ilustración 17. Histograma de los valores de generación de energía de origen nuclear en el periodo de entrenamiento.

#### 3.3.7.1 Correlación lineal entre el dato de entrada del nivel de generación con energía nuclear y el valor del precio del futuro a un año.

De la representación gráfica de la generación de energía nuclear frente al precio de los contratos de los futuros a un año no se puede establecer una correlación gráfica clara. Los puntos se hayan acotados en un área del gráfico.




Ilustración 18. Representación de puntos con los niveles de generación de energía nuclear en el eje vertical frente al precio de los contratos de futuros a un año en el eje horizontal. Fuente: elaboración propia.

### 3.3.7.2 Análisis de sensibilidad del precio del futuro a un año frente al nivel de generación empleando energía nuclear.

Al generar la tabla de sensibilidades para el 6 de octubre de 2017 de la predicción del precio del futuro a un año frente a la generación con energía nuclear, no se aprecia un comportamiento estable. Al tratar de parametrizar las relaciones entre ambas variables no se detecta un comportamiento que se pueda abstraer de los valores obtenidos. Al subir la generación eléctrica a partir de la generación de energía nuclear se aprecia una reducción de los valores de los precios de los contratos. Sin embargo al reducirse la generación la tendencia también tiende a reducirse el precio de los contratos. Este extraño comportamiento puede ser debido a que la red neuronal artificial no sabe cómo interpretar la variación de los niveles generación de energía nuclear ante la estabilidad del valor, se estabiliza entorno a los 7000 Megawattios en la casi totalidad de los días.

Tabla 7. Tabla de sensibilidad del precio del contrato del futuro a un año ante variaciones en los niveles de generación de energía nuclear.

Tabla de Sensibilidad precio/generación con energía nuclear	Valor entrada (MW)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	7.001,368		43,50		
Dato +5%	7.351,436	5,00	43,51	0,017	0,341
Dato +15%	8.051,573	15,00	43,34	-0,377	-2,516
Dato +30%	9.101,778	30,00	42,61	-2,056	-6,853
Dato -5%	6.651,300	-5,00	43,44	-0,128	2,567
Dato -15%	5.951,163	-15,00	43,27	-0,538	3,588
Dato -30%	4.900,958	-30,00	43,23	-0,624	2,080



### 3.3.8 Generación eléctrica con energía solar.

La energía solar como fuente de generación eléctrica es variable en los días en función de condiciones climáticas que son previsible en el corto plazo. Sin embargo, en periodos superiores a dos o tres días las previsiones de generación ya no suelen ser tan precisas. No obstante se hace la consideración de tomar los valores de producción de energía solar del año anterior al considerar que puede existir cierta estacionalidad en su generación.

El histograma de los valores de generación con energía solar presenta una distribución extraña. Con alta frecuencia en los rangos medios, y muy baja en los rangos máximos y mínimos. Se puede justificar por la variabilidad de las condiciones de generación en función de disponer de días más o menos despejados, aprovechándose toda la capacidad de generación de la que se dispone.




Ilustración 19. Histograma de los valores de generación de energía de origen solar en el periodo de entrenamiento.

#### 3.3.8.1 Correlación lineal entre el dato de entrada del nivel de generación con energía solar y el valor del precio del futuro a un año.

A partir de la representación gráfico de los puntos de los niveles de generación de energía solar para un año antes en el eje vertical y del precio de los contratos de futuros a un año en el eje horizontal, no se aprecian tendencias. Por ello, no se puede determinar una correlación entre ambos valores, observándose una gran variación en los niveles de generación solar en la secuencia de datos valorada.




Ilustración 20. Representación de puntos con los niveles de generación de energía solar en el eje vertical frente al precio de los contratos de futuros a un año en el eje horizontal. Fuente: elaboración propia.

### 3.3.8.2 Análisis de sensibilidad del precio del futuro a un año frente al nivel de generación empleando energía solar.

La construcción de la tabla de sensibilidad se ha realizado para el día 6 de octubre de 2017. Los valores de los precios de los contratos de los futuros a un año se han obtenido de la predicción hecha por la red neuronal artificial indicada. Del análisis de los valores de la tabla se deduce que no tiene un impacto claro la producción solar del año anterior sobre el precio de los contratos.

Tabla 8. Tabla de sensibilidad del precio del contrato del futuro a un año ante variaciones en los niveles de generación de energía solar.

Tabla de Sensibilidad precio/generación con energía solar	Valor entrada (MW)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	1.484,132		43,50		
Dato +5%	1.558,339	5,00	43,50	-0,006	-0,122
Dato +15%	1.706,752	15,00	43,48	-0,049	-0,329
Dato +30%	1.929,372	30,00	43,42	-0,191	-0,635
Dato -5%	1.409,925	-5,00	43,50	-0,004	0,083
Dato -15%	1.261,512	-15,00	43,48	-0,043	0,286
Dato -30%	1.038,892	-30,00	43,42	-0,174	0,582

### 3.3.9 Generación eléctrica con energía eólica.

De modo análogo a la energía solar, la originada en la fuerza del viento depende de las condiciones climáticas. Esto permite prever la producción de energía eólica con bastante precisión en el corto plazo, más allá de unos días es poco previsible. No obstante las condiciones de viento pueden presentar cierta estacionalidad, por lo que ante la dificultad de realizar la previsión de las condiciones de generación de energía eólica se han tomado los datos del año anterior al día de negociación de los contratos.

A continuación se presenta el histograma de la generación eólica. La energía eólica presenta una distribución en campana, donde la mayor parte de los días se genera energía en rangos bajos. Se dan circunstancias similares al caso de la energía solar, con un incremento en la curva de la campana para los rangos de generación mayores.




Ilustración 21. Histograma de los valores de generación de energía de origen eólico en el periodo de entrenamiento.

#### 3.3.9.1 Correlación lineal entre el dato de entrada del nivel de generación con energía eólica y el valor del precio del futuro a un año.

En la representación de los puntos del nivel de generación de energía eólica un año antes, (eje vertical), frente al precio final del futuro a un año el día de negociación no se determina la existencia de patrones. De esta forma, no se puede determinar que exista una correlación clara entre ambas variables, los puntos se hallan diseminados en un área determinada.




Ilustración 22. Representación de puntos con los niveles de generación de energía eólica en el eje vertical frente al precio de los contratos de futuros a un año en el eje horizontal. Fuente: elaboración propia.

3.3.9.2 Análisis de sensibilidad del precio del futuro a un año frente al nivel de generación empleando energía eólica.

Para este análisis se toma de referencia nuevamente el día 6 de octubre de 2017. Se introducen variaciones en los niveles de la variable de entrada dependiente del viento en la red neuronal, obteniendo una respuesta definida en las previsiones del precio de los contratos para el día evaluado. Ante variaciones del nivel de generación eólica se producen variaciones ligeramente superiores del 1% por cada unidad porcentual de variación de la entrada, sin presentar variaciones significativas.

Tabla 9. Tabla de sensibilidad del precio del contrato del futuro a un año ante variaciones en los niveles de generación de energía eólica.

Tabla de Sensibilidad precio/generación con energía eólica	Valor entrada (MW)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	2.855,681		43,50		
Dato +5%	2.998,465	5,00	43,52	0,055	1,104
Dato +15%	3.284,033	15,00	43,57	0,163	1,089
Dato +30%	3.712,385	30,00	43,64	0,320	1,065
Dato -5%	2.712,897	-5,00	43,48	-0,056	1,119
Dato -15%	2.427,329	-15,00	43,43	-0,170	1,134
Dato -30%	1.998,977	-30,00	43,35	-0,347	1,156

### 3.3.10 Generación eléctrica de origen hidráulico.

Pese a tomar en cuenta como variable de entrada los niveles de reserva de agua para generación de electricidad en los pantanos, se ha querido realizar un análisis del impacto de la generación hidráulica sobre el precio de los contratos de futuros. Esto se ha hecho al observar que tener niveles elevados de reservas de agua embalsada no implica necesariamente el aprovechamiento energético del recurso.

Así mismo, la energía de origen hidráulico supone un componente importante del mix de generación eléctrica. Se observa estacionalidad de la generación, análogamente con los niveles de agua embalsada, siendo reducida su aportación al sistema eléctrico en los meses secos. En el histograma siguiente se observa una campana desplazada ligeramente hacia los rangos menores. La frecuencia de días en que la producción hidráulica es menor de 2000 MW se reduce muy rápidamente al reducir el rango. Se llega incluso a encontrar días con valores negativos que se corresponden con días en que se bombea más agua hacia los embalses (hay gasto energético), de la que se turбина (se produce generación eléctrica). Al crecer los rangos de generación se reduce más lentamente la frecuencia de días en los que se utiliza el agua para generar electricidad. Se constata un uso destacado de la energía hidráulica por los valores más frecuentes de generación.

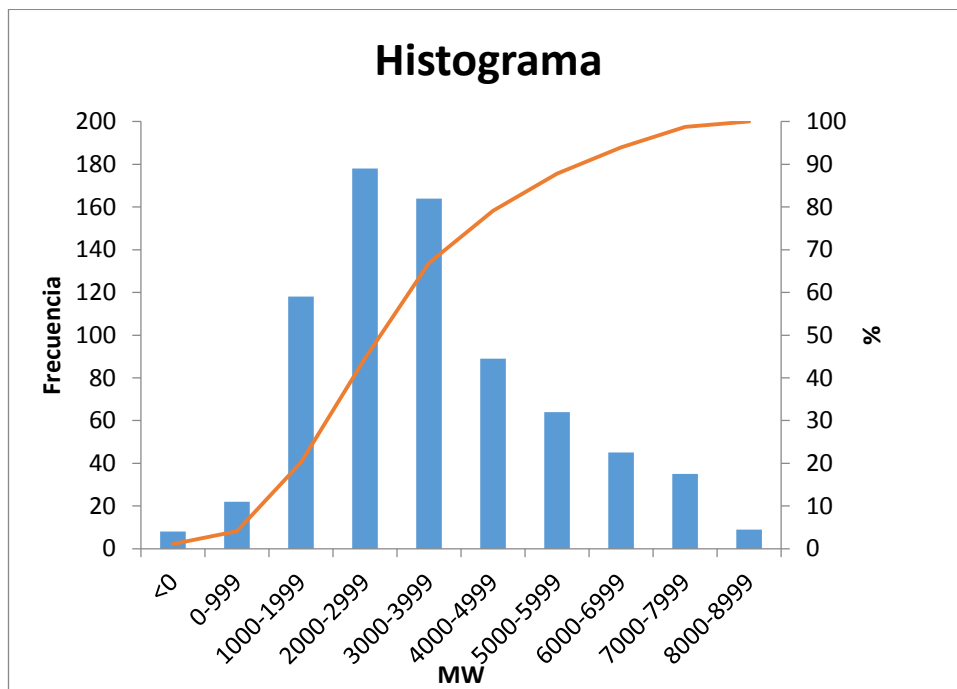


Ilustración 23. Histograma de los valores de generación de energía de origen hidráulico en el periodo de entrenamiento.

3.3.10.1 *Correlación lineal entre el dato de entrada del nivel de generación con energía hidráulica y el valor del precio del futuro a un año.*

Para la interpretación de las correlaciones se ha representado en el eje vertical los niveles de generación hidráulica del año anterior y en el eje horizontal los precios de los futuros a un año. Al representar los puntos de generación hidráulica del año anterior con respecto al precio del futuro se observa un patrón. Se puede asignar una formación de pico en la zona donde se concentra los mayores niveles de producción con esta energía que se corresponde con los precios menores. Así mismo, se constata la formación de un pico que concentra puntos con menores valores de generación y que se corresponde con los mayores precios. También se observa que la gráfica presenta valores negativos, lo que se atribuye a procesos de bombeo de agua hacia los embalses.




Ilustración 24. Representación de puntos con los niveles de generación de energía de origen hidráulico en el eje vertical frente al precio de los contratos de futuros a un año en el eje horizontal. Fuente: elaboración propia.

3.3.10.2 *Análisis de sensibilidad del precio del futuro a un año frente al nivel de generación empleando energía hidráulica.*

Se toma para el análisis de sensibilidad los valores de la predicción del precio del futuro en el día 6 de octubre de 2017, realizada por la red neuronal artificial. A la vista de la tabla de sensibilidad se observa que la sensibilidad que presenta el precio del futuro es inferior al 1% en valor absoluto, por cada unidad porcentual que varía la generación hidráulica, pero presenta un comportamiento definido.

Tabla 10. Tabla de sensibilidad del precio del contrato del futuro a un año ante variaciones en los niveles de generación de energía hidráulica.

Tabla de Sensibilidad precio/generación con energía hidráulica	Valor entrada (MW)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	2.782,931		43,50		
Dato +5%	2.922,078	5,00	43,49	-0,018	-0,351
Dato +15%	3.200,371	15,00	43,47	-0,068	-0,453
Dato +30%	3.617,810	30,00	43,42	-0,189	-0,629
Dato -5%	2.643,784	-5,00	43,51	0,013	-0,262
Dato -15%	2.365,491	-15,00	43,51	0,028	-0,187
Dato -30%	1.948,052	-30,00	43,51	0,030	-0,102

### 3.3.11 Futuros del petróleo Brent a más de un año

El valor del barril Brent es una variable de alta incidencia en los ámbitos económicos de las naciones. Incrementos del precio del petróleo incrementan los costes en las actividades económicas, suponiendo un aumento de los costes de producción de multitud de productos. El precio del crudo influye en sectores importantes como pueden ser: el transporte de mercancías y personas, la industria química, la generación eléctrica en el caso de que se empleen centrales de fuel-oíl,...

El hecho de que tanto el petróleo como la electricidad sean activos energéticos, pone de manifiesto la estrecha relación entre estos productos. Las previsiones de consumo de unas y otras mantienen relación y dichas previsiones generan incrementos o disminuciones de los precios de estos productos en los mercados.

El considerar el precio del futuro del barril Brent a más de un año puede ayudar a determinar las tendencias de los costes de los diferentes productos energéticos. Las tendencias del precio de los futuros del Brent vienen dadas por aspectos como las previsiones de crecimiento de la economía mundial, (mayores tasas de crecimiento proyectan un mayor consumo de crudo), las previsiones de producción de petróleo, circunstancias de origen político...

Estas tendencias para los futuros del petróleo también afectarán en los precios de los productos energéticos y serán más semejantes cuanto más se asemejen los plazos de entrega de los mismos. Por ello, se considera conveniente considerar la relación entre los precios de los futuros del petróleo Brent con los productos eléctricos del mercado a plazo.

En el histograma de esta variable se observa una alta frecuencia de días con valores entorno a los 48 dólares para los futuros del petróleo. Es difícil justificar los valores del petróleo sin analizar las circunstancias políticas, económicas o de explotación del petróleo. Pero se puede observar un incremento del precio del petróleo debido a las previsiones de crecimiento

económico y a las intenciones de los países productores de reducir la extracción de crudo provocando un incremento de precios hasta más allá de los 90 dólares.




Ilustración 25. Histograma de los futuros del petróleo.

3.3.11.1 Correlación lineal entre el dato de entrada de los futuros del petróleo Brent a más de un año y el valor del precio del futuro de la electricidad a un año.

En la representación de puntos del futuro a más de un año del petróleo Brent y de la electricidad a un año, se observa una clara correlación. Aunque no se describe una forma claramente definida, se observa una acumulación de puntos en una figura particular.

La figura descrita presenta una peculiar forma de gancho en la horquilla en que ambos productos presentan un precio menor. En la zona con mayores precios del producto eléctrico, los precios de los productos eléctricos se elevan rápidamente hasta formar una línea vertical. En la zona intermedia pero próxima a los valores elevados del futuro de la electricidad se genera una zona de acumulación de puntos. Se concreta que a mayores precios del futuro del petróleo se obtiene un precio mayor del precio del futuro de la electricidad y a la inversa.






Ilustración 26. Representación de puntos con los precios del futuro del petróleo Brent a más de un año en el eje vertical frente al precio de los contratos de futuros eléctricos a un año en el eje horizontal. Fuente: elaboración propia.

### 3.3.11.2 Análisis de sensibilidad del precio del futuro a un año frente a variaciones en el precio del futuro a más de un año del petróleo Brent.

La sensibilidad del futuro de la electricidad frente al futuro del petróleo Brent se ha determinado por las proyecciones de la electricidad en la red neuronal ensayada, ante variaciones del valor del futuro del petróleo en el día 6 de octubre de 2017.

En las proyecciones del precio de los contratos de futuros de la electricidad a un año se aprecia un aumento al incrementarse el precio de los futuros del petróleo. Al reducirse el precio del petróleo se reduce el de la electricidad. Se constata así una clara relación entre ambas variables, determinándose una sensibilidad del orden del 5% del valor del precio del futuro de la electricidad por unidad porcentual que varía el precio del petróleo.

Tabla 11. Tabla de sensibilidad del precio del contrato del futuro de la electricidad a un año ante variaciones en el precio del futuro a más de un año del petróleo Brent.

Tabla de Sensibilidad precio/futuros del petróleo Brent	Valor entrada (Dólares)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	52,510		43,50		
Dato +5%	55,136	5,00	43,61	0,264	5,275
Dato +15%	60,387	15,00	43,85	0,805	5,369
Dato +30%	68,263	30,00	44,20	1,611	5,369
Dato -5%	49,885	-5,00	43,39	-0,255	5,091
Dato -15%	44,634	-15,00	43,19	-0,720	4,798
Dato -30%	36,757	-30,00	42,96	-1,235	4,117

### 3.3.12 Futuros del gas natural a más de un año.

El gas natural junto con el petróleo y la electricidad es un producto fundamental de la cesta energética. La economía de las naciones se ve afectada directamente con el coste de esta materia prima. Tanto por el impacto de este producto en el consumo doméstico como en el industrial. No obstante, el coste del gas natural no es tan significativo en los parámetros de la actividad de un país como con el petróleo o la electricidad. Sin embargo, las mismas tendencias que determinan el precio del gas natural afectan a los precios de la electricidad. Esto es así en el sistema eléctrico español pues una parte significativa del mix de generación de energía eléctrica proviene del empleo de gas natural como combustible, por su empleo frecuente en las centrales de ciclos combinados.

De modo análogo al caso del futuro del petróleo, se ha considerado los futuros a más de un año del gas natural por verse condicionados por múltiples parámetros vinculados con las expectativas económicas, los niveles de extracción de gas natural, circunstancias políticas y otros aspectos que marcan el mayor o menor consumo de gas natural y por ello de sus precios. Esta tendencia hace de los futuros del gas natural una variable interesante a la hora de realizar previsiones de los futuros eléctricos.

La distribución de los valores de los precios de los futuros del gas natural presenta una gran estabilidad. En el periodo de dos años analizado, los precios de los futuros varían entre los 2 y los 4 dólares.

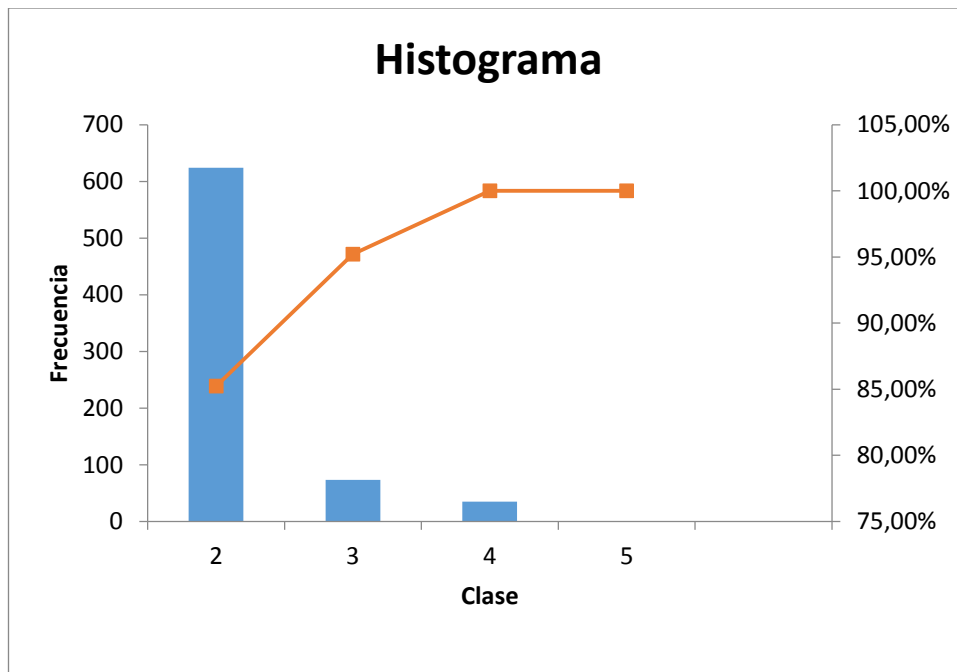


Ilustración 27. Histograma de los futuros del gas natural.

3.3.12.1 *Correlación lineal entre el dato de entrada de los futuros del gas natural a más de un año y el valor del precio del futuro de la electricidad a un año.*

Al representar los valores de los futuros del gas natural y los del precio de los futuros de la electricidad se genera algo parecido a una forma de A. Coincidiendo los puntos de menor coste de la electricidad con la mayor parte de los puntos de menor precio del gas natural en una de las ramas de la inferiores de la A. La otra rama que presenta puntos con costes menores del gas natural tiene una pendiente próxima a la vertical. En el punto de unión de ambas ramas se produce una concentración de puntos con valores intermedios de ambos productos. Tras una ligera separación tras subir por la A, aparece el pico superior de la letra con los precios mayores de ambos productos. Se estima así un comportamiento que correlaciona ambas variables.




Ilustración 28. Representación de puntos con los precios del futuro del gas natural a más de un año en el eje vertical frente al precio de los contratos de futuros eléctricos a un año en el eje horizontal. Fuente: elaboración propia.

3.3.12.2 *Análisis de sensibilidad del precio del futuro a un año frente a variaciones en el precio del futuro a más de un año del gas natural.*

La construcción de la tabla de sensibilidad se realiza introduciendo variaciones en la variable de entrada de la red neuronal que es el futuro del gas natural, para realizar la previsión de los contratos del futuro a un año de la electricidad para el día 6 de octubre de 2017. De la tabla se constata una fuerte sensibilidad entre ambos parámetros con valores de variación superiores al 25% de la variable de salida por cada unidad que varía la variable de entrada en porcentaje. Ante subidas del precio del futuro a más de un año se obtiene un incremento del precio del futuro de la electricidad y a la inversa, cuando se reduce el precio del gas natural se constata una reducción del precio de la electricidad.

Tabla 12 Tabla de sensibilidad del precio del contrato del futuro de la electricidad a un año ante variaciones en el precio del futuro a un año del gas natural.


Tabla de Sensibilidad precio/futuros del gas natural	Valor entrada (Dólares)	Variación entrada (AE)	Valor salida (€/MW)	Variación salida (AS)	AS/AE
Dato real del 6/10/2017	3,049		43,50		
Dato +5%	3,201	5,00	44,69	2,729	54,575
Dato +15%	3,506	15,00	46,90	7,815	52,099
Dato +30%	3,964	30,00	49,45	13,680	45,600
Dato -5%	2,897	-5,00	42,34	-2,671	53,411
Dato -15%	2,592	-15,00	40,45	-7,001	46,671
Dato -30%	2,134	-30,00	40,22	-7,545	25,149

### 3.3.13 Relaciones entre productos del mercado eléctrico.

Finalmente se ha procedido a evaluar las relaciones entre diferentes productos eléctricos, ante la posibilidad de emplear la previsión de un producto con un plazo de entrega dado para obtener la previsión de otro. Dada la naturaleza de las secuencias de datos de estos productos, se ha decidido analizar los secuencias de datos que corresponden al periodo de aprendizaje de la red neuronal, es decir los 2 primeros años de datos. Por ello, únicamente se ha realizado una representación gráfica de los puntos de un producto eléctrico frente a otro. Con ello se puede observar la existencia de correlaciones entre los diferentes productos. Se ha tomado en consideración como ya se ha señalado en la introducción del capítulo los productos eléctricos para carga base:

- Precio en el mercado Spot diario.
- Precio del futuro del fin de semana siguiente más próximo al día de negociación.
- Precio del futuro de la semana siguiente más próximo al día de negociación.
- Precio del futuro del mes siguiente más próximo al día de negociación.
- Precio del futuro del cuatrimestre siguiente más próximo al día de negociación.
- Precio del futuro del año siguiente más próximo al día de negociación.

Del análisis de correlaciones se determina un comportamiento vinculado entre todas las variables anteriores, siendo más definidas cuanto el periodo entrega desde la fecha de negociación entre una variable y otra sea más próximas. Se puede apreciar como ejemplo cierta linealidad en las representaciones entre las variables del mercado Spot y los del futuro a una semana. Esto se observa en la siguiente ilustración:



Ilustraci3n 29. Precio del mercado Spot diario en el eje vertical frente al precio del futuro a una semana en el eje horizontal. Fuente: elaboraci3n propia.

Para mejorar los resultados de las predicciones de los precios de los productos elctricos se estudiará las relaciones entre estas variables.

### 3.4 Desarrollo del modelo matemático de la red neuronal simple.

En este punto se va a proceder a desarrollar la descripci3n de los aspectos básiacos de la red neuronal que se empleará para realizar la predicci3n de los precios de los contratos de los futuros elctricos con un a1o de anticipaci3n. Para ello se explicará la configuraci3n de la red, el proceso de aprendizaje de la red, la forma en que se llega a los valores de salida y la estimaci3n del error en la predicci3n.

#### 3.4.1 La neurona artificial.

La red neuronal artificial (RNA) está compuesta por lo que se denominan neuronas artificiales, células o autómatas. Estos elementos se caracterizan por poseer un estado interno llamado nivel de activaci3n. Mediante una funci3n de la neurona, (llamada funci3n de activaci3n) y de las se1ales que recibe, cambia de nivel de activaci3n. Este nivel de activaci3n no está vinculado a anteriores estados de activaci3n.




Ilustración 30. Imagen de una neurona artificial. Fuente: elaboración propia.

Un grupo de entradas  $x_1, x_2, \dots, x_n$  alcanzan la neurona artificial  $k$  en forma de vector de señales  $\bar{X}$ . Las señales recibidas se multiplican por un peso  $w_{kn}$  asociado a cada una de ellas, y que constituye un vector  $\bar{W}$ . En este parámetro el sufijo  $k$  se refiere a la neurona y el sufijo  $n$  a la entrada. Una vez realizada la ponderación de las señales se realiza un sumatorio de las entradas ponderadas, de forma que se genera una salida  $E$ . Conforme a [14] y [23]:

$$(6) \quad E = x_1 * w_{k1} + x_2 * w_{k2} + \dots + x_n * w_{kn}$$

Existe un parámetro adicional llamado umbral o sesgo ( $b$ ), que se define como un factor de comparación para generar la salida. Cada célula de una red se caracteriza por un determinado valor de umbral. La activación de la neurona se compone de la suma ponderada de la entrada menos el valor de umbral. La señal de activación es procesada por la función de activación de la neurona artificial para producir la salida de la neurona  $y$ . En el caso que se aplica, la función de activación que es empleada es la función sigmoideal. Esta función  $f$  es una función creciente continua en el rango  $[0,1]$  y con derivada definida en todo el intervalo. La derivabilidad de la función de activación es fundamental en la aplicación del algoritmo de aprendizaje.



Ilustración 31. Función sigmoide. Fuente: elaboración propia.

La expresión, siendo  $x$  un parámetro dado, de la función sigmoide es la siguiente:

$$(7) \quad f(x) = \frac{1}{1+e^x}$$

Una neurona únicamente genera un valor de salida al mismo tiempo. Matemáticamente el procedimiento por el que la red obtiene el valor de la salida, se realiza conforme se explicó anteriormente. Para la neurona  $k$  y las  $n$  variables de entrada:

$$(8) \quad y_k = f\left(\sum_{i=1}^n w_{ki} * x_i + b_k\right)$$

### 3.4.2 Estructura de la red neuronal artificial.

Una red neuronal está constituida por un conjunto de neuronas conectadas entre sí de acuerdo con un patrón de conexión o lo que se denomina arquitectura de la red. La estructura básica de interconexión entre las neuronas de una red es la denominada red multicapa. Las redes neuronales artificiales cuentan con unas neuronas de entrada que reciben y procesan los datos de entrada y neuronas de salida que generan las predicciones. Pueden darse la circunstancia de que las neuronas de entrada y salida no estén directamente conectadas, se hablaría de neuronas ocultas en una o varias capas.

En este trabajo se ha optado por trabajar con una capa de entrada y una de salida al objeto de no construir una estructura excesivamente compleja que emplease capas ocultas. Los textos consultados señalan que no necesariamente una estructura más compleja o con un mayor número de neuronas genera un resultado mejor. Una arquitectura más compleja implicaría una mayor conectividad que podría complicar el aprendizaje de la red. Por ello, el número de capas se suele dejar al criterio del diseñador y su conocimiento.

Respecto a la evaluación del número de neuronas de la red se han obtenido los mejores resultados con las redes neuronales artificiales de 7, 12 y 14 neuronas. No obstante aumentando el número de neuronas a partir de 16 se obtienen buenos resultados, aunque no de forma significativa. A continuación se representa la tabla con los resultados del error medio de los datos proyectados para los contratos de futuros a un año. Se toma como valor del error medio para una proyección de  $n$  valores:

$$(9) \quad e_m = \frac{\sum_1^n \text{abs}(y_{\text{real}} - y_{\text{estimado}})}{n}$$

Tabla 13. Tabla de errores medios para redes neuronales artificiales con diferentes números de neuronas en la primera capa.

Errores medios cometidos con diferentes números de neuronas en la primera capa para un Red neuronal simple para predicción del precio del contrato del futuro a un año (732 Muestras Entrenamiento, Validación y testeo-366 Previsiones)	
Número de neuronas	Error medio cometido en la predicción (€/MW)
6	2,43
7	1,80
8	1,81
9	2,54
10	2,34
11	2,51
12	1,31
13	2,03
14	1,33
15	2,04
16	1,90

### 3.4.3 Entrenamiento de la red neuronal artificial. Sobre entrenamiento.

El correcto funcionamiento de una red neuronal artificial requiere de un proceso de aprendizaje. Este aprendizaje se realiza mediante la modificación de los pesos que las diferentes neuronas ( $w_{ki}$ ) otorgan a las diferentes informaciones que reciben. Las redes neuronales artificiales modifican los pesos en el proceso de aprendizaje. Este proceso o etapa se denomina entrenamiento de la red neuronal artificial.



Para iniciar el entrenamiento se debe facilitar una secuencia de datos de entrada y la secuencia de los datos de salida. Durante el proceso de entrenamiento la red neuronal artificial realiza la estimación de los valores de salida y los compara con el valor de salida que se le facilita y que toma como referencia. Empleando esta comparación entre el valor de salida que predice la red y el valor de referencia (secuencia de valores objetivo), evalúa el error que comete la red neuronal artificial y ajusta los pesos al objeto de minimizar el error. Entre las posibles opciones de aprendizaje de la red neuronal se empleará el Algoritmo de Regularización Bayesiana. Se constata tanto en el trabajo de **Murat Kayri [14]**, titulado **“Predictive abilities of Bayesian Regularization and Levenberg-Marquardt Algorithms in Artificial Neural Networks: a comparative empirical study on social data.”** de 2016, como en los ensayos realizados en este trabajo como la opción disponible con mejores resultados.

El número de muestras a emplear para el entrenamiento de la red debe ser comedido, por cuanto un entrenamiento excesivo de la red es contraproducente para la capacidad de predecir las salidas. El problema se presenta cuando la red memoriza la secuencia de muestras, ajustando la red a los valores que se introducen y perdiendo capacidad de generalización. En estos casos aparece el denominado sobre entrenamiento.

#### 3.4.4 Método de entrenamiento. Regularización Bayesiana.

El algoritmo de Regularización Bayesiana minimiza una combinación de los pesos ( $w_{ki}$ ) y de una función basada error cuadrático medio. La función basada en el error cuadrático medio se construye como:

$$(10) \quad MSE_d(D - w, M) = \frac{1}{N} \sum_{b=1}^N (y_{estimado-b} - y_{real-b})^2$$

Donde:

D es la secuencia de datos de entrada-salida.

M es la definición de la arquitectura de la red.

$y_{estimado-b}$  es el valor b de n elementos de los valores estimados.

$y_{real-b}$  es el valor b de la secuencia de valores reales que busca la red como objetivo.

El siguiente término refleja el impacto de la suma de los cuadrados de los pesos ( $w_b$ ) de la red en una nueva función de pesos. El desarrollo de las expresiones, conforme a **[14]**:

$$(11) \quad MSE_d(w - M) = \frac{1}{N} \sum_{b=1}^N (w_b)^2$$

Con los términos anteriores se construye la función que el algoritmo buscará minimizar, que en la bibliografía se designa como la función de costes del algoritmo. El criterio de parada del algoritmo se obtiene al minimizar esta función, cuya expresión es:

$$(12) \quad MSE = \beta * MSE_d(w - M) + \alpha * MSE_w(D - w, M)$$

Donde

$\alpha$  y  $\beta$  son parámetros que hay que ajustar según los métodos Bayesianos de MacKay [15 y 16].

Según la publicación de **Murat Kayri [14]** de 2016, titulada “**Predictive abilities of Bayesian Regularization and Levenberg-Marquardt Algorithms in Artificial Neural Networks: a comparative empirical study on social data**”. Hay diferentes comportamientos de la red en función de los parámetros  $\alpha$  y  $\beta$ . En el caso de que  $\alpha \ll \beta$  el algoritmo de entrenamiento hará que los errores sean más pequeños. En el caso de que  $\alpha \gg \beta$  el algoritmo de buscará la reducción de la función de los pesos sacrificando la reducción de la función dependiente de los errores. Esto implica que el error de la red se ve perjudicado en favor de una respuesta menos brusca de la red.

La distribución de los pesos de la red neuronal artificial se actualiza conforme a la regla de Bayes, Para ello se emplean las funciones correspondientes de probabilidad:

$$(13) \quad P(w - D, \alpha, \beta, M) = \frac{P(D|w, \beta, M) * P(w|\alpha, M)}{P(D - \alpha, \beta, M)}$$

$$(14) \quad P(w|\alpha, M) = \left(\frac{\alpha}{2\pi}\right)^{m/2} * \exp\left(-\frac{\alpha}{2} w' * w\right)$$

Donde  $w$  es el vector de pesos de la red. Antes del inicio de la estimación de valores, la función de probabilidad  $P(w|\alpha, M)$  parametriza los pesos. La función de probabilidad que determina la probabilidad de los sucesos, generando los pesos de la red viene dada por  $P(D|w, \beta, M)$ . El algoritmo Bayesiano de regularización, optimiza los pesos al maximizar la probabilidad posterior  $P(w|D, \alpha, \beta, M)$ . Al maximizar esta última probabilidad de  $w$ , se consigue minimizar la función objetivo dado por la ecuación 10. Según **MacKay [15 y 16]**,

$$(15) \quad P(D - \alpha, \beta, M) = \frac{P(D|w, \beta, M) * P(w|\alpha, M)}{P(w|D, \alpha, \beta, M)} = \frac{Z_F(\alpha, \beta)}{\left(\frac{\pi}{\beta}\right)^{n/2} * \left(\frac{\pi}{\alpha}\right)^{m/2}}$$

Siendo  $n$  el número de muestras y  $m$  el número de variables de la red. La aproximación de Laplace de la ecuación 13 genera la ecuación:

$$(16) \quad Z_F(\alpha, \beta) \propto |H^{MAP}|^{-\frac{1}{2}} * \exp((-F(w^{MAP}))$$

$H^{MAP}$  es la matriz Hessiana de la función objetivo, en la que MAP indica que es para el máximo a posteriori.

$$(17) \quad H = J' * J$$

La matriz Hessiana se puede aproximar con la ecuación 15, donde J es la matriz jacobiana que se construye con la derivada primera de los errores de la red neuronal artificial con respecto a las variables de la misma, siendo estas variables los pesos y los sesgos que presenta la red.

$$(18) \quad J = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \dots & \frac{\partial e_1(w)}{\partial w_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial e_N(w)}{\partial w_1} & \dots & \frac{\partial e_N(w)}{\partial w_n} \end{bmatrix}$$

En el procedimiento se emplea un simple cálculo del método de backpropagation para permitir el cálculo de la matriz jacobiana. El método de backpropagation aplica el proceso de cálculo desde la capa de salida hacia la capa de entrada, pasando sucesivamente por las capas intermedias. Finalmente cada variable es ajustada conforme a Levenberg-Marquardt. De esta forma para la obtención de las variables en la iteración  $n$  se hace:

$$(19) \quad w^{n+1} = w^n - [J^T J + \mu I]^{-1} J^T e$$

Tomando:

$\mu$  como factor de amortiguación, que es un parámetro ajustable en cada iteración.

I es la matriz identidad.

### 3.5 Modelo de red neuronal con retroalimentación.

Al objeto de plantear mejoras en los modelos de previsión basados en redes neuronales se ha planteado la aplicación de un modelo de red neuronal con sistema de realimentación. Se busca generar un proceso de reentrenamiento de la red neuronal de base, de modo que se produzca una corrección donde se ajusten las variables de la red con una mayor precisión, para mejorar la generalización del modelo y posteriormente general previsiones más precisas.

La idea surge a raíz de la observación de los sistemas de control en tensión y en frecuencia, (contenido impartido en la asignatura de Sistemas Eléctricos de Potencia del Máster

Universitario en Ingeniería Industrial de la ETSII en la Universidad Politécnica de Valencia [26]). Estos sistemas de control se implementan en el sistema eléctrico al objeto de mantener la tensión y frecuencia dentro de unos parámetros que garanticen la calidad de servicio en los puntos de consumo.

La estructura de control del sistema eléctrico para la regulación en tensión y frecuencia se presenta de forma jerárquica y desacoplada. Se distingue:

- Control primario: tiene lugar a nivel local.
- Control secundario: tiene lugar a nivel a área o zona.
- Control terciario: engloba las acciones de control a nivel del sistema.

En este trabajo se planteará únicamente el control primario sobre el sistema de la red neuronal, basándonos en el esquema siguiente, extraído de [26]:

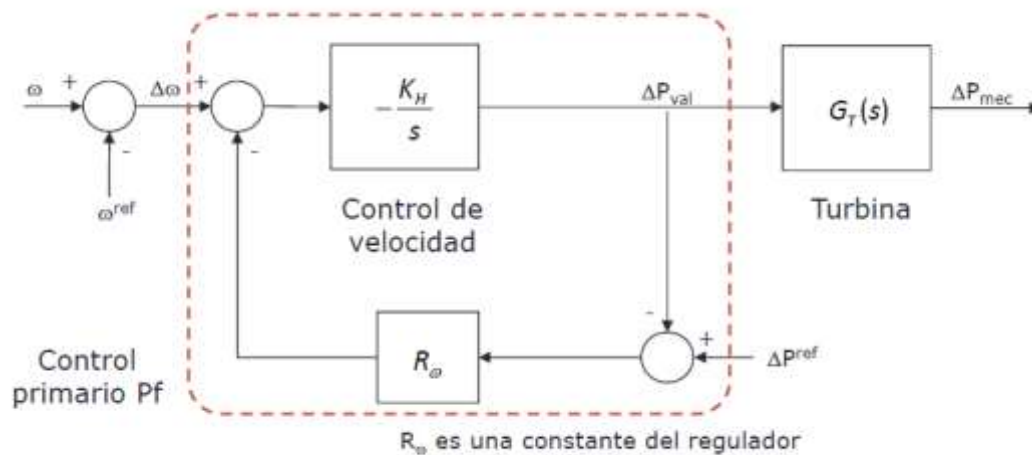


Ilustración 32. Esquema de la aplicación del sistema de control primario de frecuencia. Fuente: Apuntes de Sistemas Eléctricos de Potencia del Máster Universitario en Ingeniería Industrial (Universidad Politécnica de Valencia). [26]

El sistema de control del esquema de la ilustración anterior corresponde al control primario de frecuencia que se emplea para controlar la frecuencia. Este sistema de control permite en el sistema eléctrico mantener la frecuencia del sistema y modificar a voluntad la potencia activa generada. Este sistema de regulación se aplica de forma física al sistema mediante el control de la velocidad de giro de los generadores conectados al sistema eléctrico.

Este sistema de control se puede implementar cuando se dispone de referencias en las salidas del sistema, permitiendo un control con buenas prestaciones. Aunque no asegura que el sistema tenga el régimen adecuado.

El ajuste en nuestro modelo se realiza implementando la relación entre el valor objetivo de la salida y el obtenido por la red, aplicando una ganancia en la realimentación. La ganancia aplicada será una constante, por cuanto el tiempo de respuesta se pretende que sea inmediato

en el sistema que se quiere controlar. El modelo implementado se resume en el siguiente esquema:

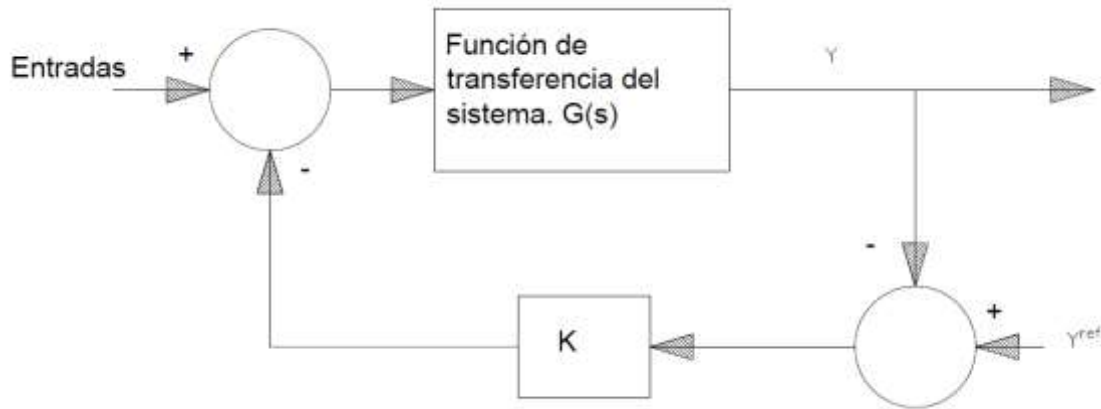


Ilustración 33. Diagrama de bloques del sistema a implementar con realimentación. Fuente: elaboración propia.

El sistema de bloques anterior es equivalente a:

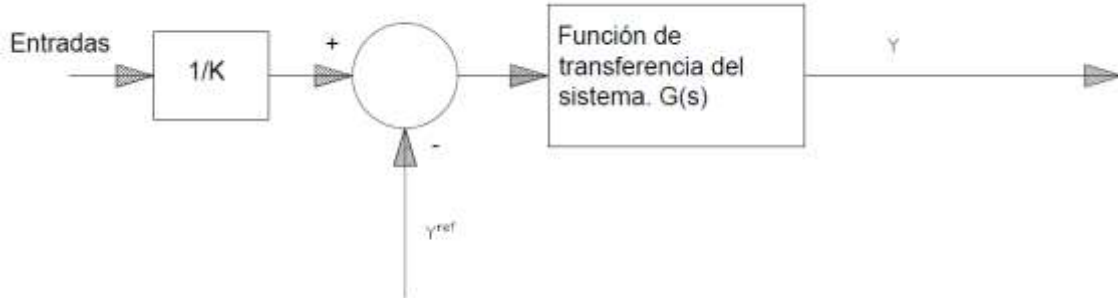


Ilustración 34. Equivalencia del diagrama de bloques de la ilustración anterior. Fuente: elaboración propia.

Y a partir del diagrama de bloques se obtiene la ecuación en el dominio complejo, que nos determinará la salida a implementar:

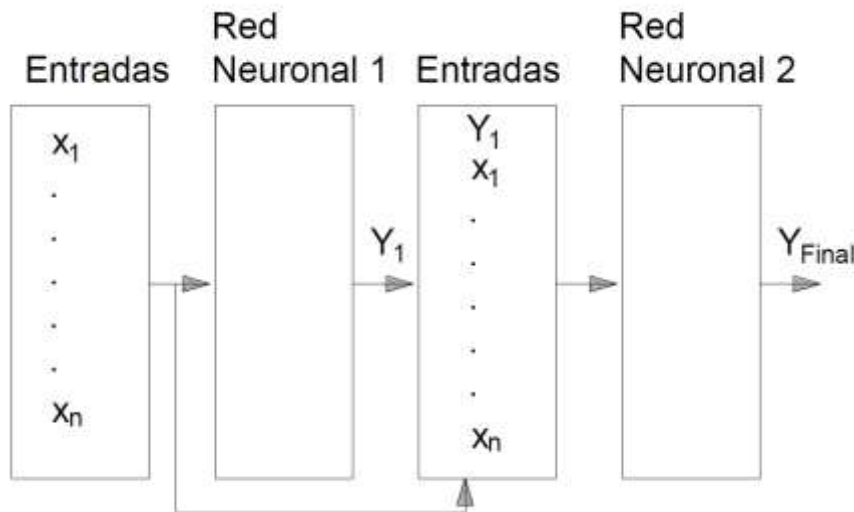
$$(20) \quad Y(S) = G(s) * (Y^{ref} - \frac{1}{K} Entradas)$$

### 3.6 Modelo de red neuronal en cascada.

La red neuronal artificial en cascada se genera al concatenar dos redes neuronales siendo la primera una red neuronal artificial con los datos de entrada considerados. Esta red neuronal generará una salida. A continuación de esta red neuronal se implementará una segunda red neuronal en cuyas entradas se encuentran las mismas variables de entrada que en la red neuronal anterior junto con la serie de valores obtenidos en la salida.

El objetivo es obtener una salida final en la segunda red neuronal artificial en que se realice una ponderación de las diferentes entradas, con los valores de salida de la primera red incluida, de modo que se favorezca un mejor ajuste de precios de la salida del modelo. Se desea con ello obtener una salida refinada que mejore la generalización y pueda ajustar con mayor precisión los valores de la predicción a los valores reales.

El esquema de funcionamiento sería el siguiente:



Ecuación 1. Esquema de sistema de predicción basado en red neuronal en cascada. Fuente: elaboración propia.

### 3.7 Conclusiones del capítulo.

Al realizar el análisis por correlaciones y sensibilidad de las variables de entrada que se tomaron de partida, se toman las siguientes conclusiones:

- Se descarta emplear como entradas las variables de generación con energía nuclear y con energía solar por no poder determinar una interacción definible con la salida de la red que sería el precio del futuro eléctrico a un año.
- Se toma en consideración emplear el resto de variables analizadas para las entradas de la red neuronal artificial, pues aunque no tienen igual impacto en la variable de

salida y presentan diferentes sensibilidades, queda definida una correlación entre estas entradas y las salidas estudiadas. Así las variables de entrada de la red neuronal serán de partida las siguientes 10 como mínimo:

- El día de la semana.
  - La festividad
  - Reservas hidráulicas del año anterior.
  - Demanda eléctrica del año anterior.
  - Generación eléctrica empleando el carbón del año anterior.
  - Generación eléctrica empleando ciclos combinados del año anterior.
  - Generación eléctrica empleando energía eólica del año anterior.
  - Generación eléctrica empleando energía hidráulica del año anterior.
  - Futuros del petróleo Brent a más de un año.
  - Futuros del gas Natural a más de un año.
- Al objeto de mejorar las previsiones de los precios de los productos eléctricos se valorará introducir como nueva entrada la proyección de un producto eléctrico que con misma fecha de negociación tenga plazo de entrega lo más próxima posible.

Una vez realizado el análisis de los parámetros de la red neuronal artificial que será la base de los métodos de predicción de este trabajo se ha determinado el empleo de una red con 12 neuronas y que emplee el algoritmo de Regularización Bayesiana. Para ello se ha constatado experimentalmente el número óptimo de neuronas. En el análisis del funcionamiento de las neuronas, las redes neuronales artificiales y el algoritmo de aprendizaje, la decisión de optar por el algoritmo de Regularización Bayesiana parecía el óptimo conforme a las referencias bibliográficas entre las opciones disponibles en el software empleado.





## 4 Implementación de la red neuronal

### 4.1 Introducción.

Se conocen las variables de entrada en la red neuronal artificial de base empleada en este trabajo, se emplearán como mínimo diez entradas. La definición de los parámetros de la red neuronal artificial se establece con una arquitectura en la red neuronal de una capa de entrada de doce neuronas y una capa de salida con una única neurona. El desarrollo de la red neuronal se basará en los conceptos desarrollados en el capítulo anterior.

Aunque existen diferentes formas de implementar la red neuronal para la predicción del precio de los futuros de la electricidad en el mercado a plazo, se ha optado por emplear como software de trabajo MATLAB R2017a.

La decisión de emplear este programa de ordenador se basa en primer lugar en el conocimiento que los alumnos de la Escuela Técnica Superior de Ingenieros Industriales (ETSII) de la Universidad Politécnica de Valencia (UPV) tiene sobre él, pues se emplea en múltiples asignaturas de las diferentes titulaciones como herramienta de aprendizaje. En segundo lugar este programa es un instrumento de trabajo extremadamente útil por la multitud de aplicaciones de simulación y cálculo que presenta, teniendo aplicaciones específicas para la simulación de redes neuronales artificiales. Finalmente, la disponibilidad de este software para el empleo del alumnado de la UPV facilitaba y simplificaba el proceso de desarrollo de la red neuronal.

### 4.2 Desarrollo de la red neuronal artificial en Matlab

#### 4.2.1 Implementación de la red neuronal artificial base.

En la implementación de la red neuronal artificial se empleará un ordenador TOSHIBA Intel(R) Core™ i7\*4710HQ CPU @ 2.50GHz con 16 GB de memoria RAM. El software empleado es MATLAB R2017a, como ya se ha mencionado. Dentro de este software existen múltiples aplicaciones para la generación de redes neuronales artificiales y diferentes formas de implementarlas.

Dado que en este trabajo se ha optado por simular una red neuronal artificial con una capa de entrada y una de salida, se empleará la aplicación **Neural Fitting app**. Esta aplicación simplifica de forma considerable el procedimiento para desarrollar la red neuronal, requiriendo para su implementación como punto de partida los datos de entrada para el periodo de entrenamiento y los datos objetivo, a los que se debe ajustar la salida de la red neuronal para el periodo de aprendizaje.

Los datos de entrada se cargan en el programa en forma de matriz, donde las filas corresponden a la secuencia de datos de cada variable. Cada columna referenciará la fecha

que corresponde al valor adecuado de las diferentes secuencias de datos de las variables, con lo que consta con los valores que se quieren introducir para un día dado.

Los inputs en MATLAB se corresponden con la matriz de las variables de entrada y los targets son las variables que se emplearán para el proceso de entrenamiento. La forma de la matriz con los valores de la entrada quedará como se refleja en la tabla siguiente:

Tabla 14. Tabla de ejemplo de cómo se construye la matriz con las variables mínimas de entrada en la red neuronal.

Fecha	28/09/2015	29/09/2015	30/09/2015	01/10/2015	02/10/2015	03/10/2015	04/10/2015
Día de la semana	1,00	2,00	3,00	4,00	5,00	6,00	7,00
Festivo	0,00	0,00	0,00	0,00	0,00	1,00	1,00
Reservas hidráulicas energía (Hm3)	11.236,39	11.232,83	11.228,36	11.223,04	11.216,93	11.210,07	11.202,54
Demanda eléctrica 1 año antes (MW)	22.550,76	27.175,52	27.903,19	28.073,72	28.260,06	27.968,69	24.793,13
Generación Carbón 1 año antes (MW)	6.612,44	7.596,76	7.942,85	7.798,56	7.765,36	7.844,35	7.255,86
Generación Ciclo Combinado 1 año antes (MW)	2.632,22	4.533,24	4.044,60	2.876,67	3.395,56	3.789,99	2.331,05
Generación de energía eólica 1 año antes (MW)	1.441,82	410,68	2.001,00	4.148,15	3.602,06	1.473,12	2.051,45
Generación de energía hidráulica (MW)	1.343,85	3.208,01	2.587,54	2.084,92	2.078,67	2.724,63	1.660,31
Futuros petroleo Brent de 1 año antes (\$)	97,20	97,20	94,67	94,16	93,42	92,31	92,31
Futuros Gas Natural 1 año antes (\$)	4,15	4,15	4,12	4,02	3,93	4,04	4,04

Una vez introducidas las variables de entrada y objetivo se introducirán los parámetros de la red neuronal artificial quedando definida la arquitectura de la red neuronal artificial base de la siguiente manera.

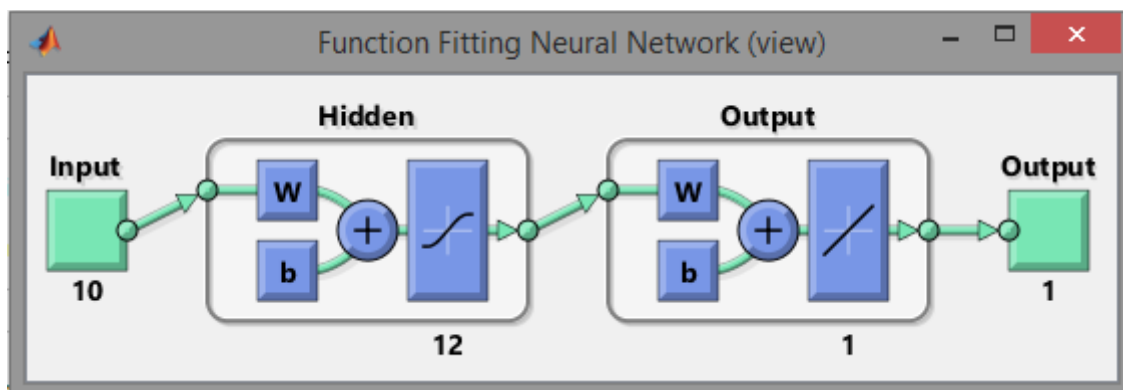


Ilustración 35. Arquitectura de la red neuronal artificial base. Fuente: MATLAB.

Con la arquitectura de la red ya establecida, se inicializará el aprendizaje de la red empleando el algoritmo de Regularización Bayesiana, que en la aplicación se llama **trainbr**. Los datos de

entrada y objetivo se emplearán en el aprendizaje de la red en tres fases. En una primera fase para entrenar la red, en esta se ajustarán los valores de la red. En la fase siguiente se validará la red, estimando la capacidad de generalización, deteniéndose cuando la generalización deja de mejorar el aprendizaje. Y finalmente se producirá el testeo de la red, etapa en la que se evalúa la precisión de la red neuronal durante y después del entrenamiento. Esta última etapa no produce modificaciones en las variables de la red. No obstante, la aplicación puede mezclar los procedimientos o modificar el orden en el que se procesan estas tres fases en función del algoritmo empleado

Para el aprendizaje de la red se tomará una muestra de los valores de entrada y el valor objetivo de unos 2 años hasta sumar 732 días o muestras. Se emplearán 586 muestras para entrenar la red (80% del total), 73 para validar (10% del total) y otras 73 para testear la red. La proyección de la red se realizará para 366 días.

#### 4.2.2 Implementación de la red neuronal artificial con retroalimentación.

La construcción de esta red neuronal ha requerido la implementación de la red neuronal que se emplea de base. Una vez construida la red neuronal la aplicación permite obtener la red neuronal en varios formatos para aplicar las proyecciones. Empleando la opción de desarrollar o simular la red neuronal en Simulink se obtienen los diagramas de la red neuronal sobre los que trabajar. Se generará el siguiente diagrama en Simulink.




Ilustración 36. Diagrama de bloques de la red neuronal. Fuente: elaboración propia en MATLAB.

Es necesario la edición los bloques de la red neuronal a fin de posibilitar los ajustes de los pesos de la red. Se deberá implementar la estructura de retroalimentación. Para ello se procederá modificando los bloques para facilitar el procesamiento de las variables de entrada (INPUTSS3) y objetivo (OUTPUTSS3), así como los bloques interiores de la red neuronal para permitir el reentrenamiento y la implementación de la red con retroalimentación. El proceso de retroalimentación se desarrolla tal y como se justificó en el capítulo anterior.

La constante empleada en la retroalimentación se ha obtenido empleando una función que se ha programado en el área de trabajo de Matlab. Esta función buscará la constante que minimice el valor del error cuadrado de la salida de la red neuronal respecto a los valores objetivo. El aspecto de la red neuronal que se obtiene se representa en las dos imágenes siguientes:




Ilustración 37. Modificación externa del diagrama de la red neuronal para el proceso de aprendizaje incorporando retroalimentación. Fuente: elaboración propia en MATLAB.

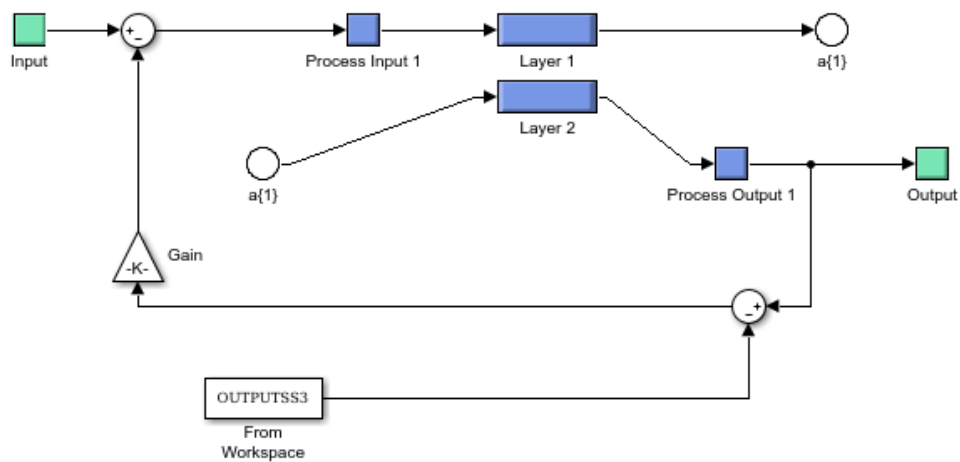


Ilustración 38. Esquema de la retroalimentación de la red neuronal artificial. Fuente: elaboración propia en MATLAB.

#### 4.2.3 Implementación de la red neuronal en cascada.

El desarrollo de la red neuronal en cascada no implica mayor dificultad que emplear la red neuronal artificial de base (red 1) y obtener las proyecciones de la salida. A partir de los valores de la entrada de la red neuronal anterior, se creará una nueva red neuronal artificial que incorporará una variable más en las entradas. Esta entrada que se añade será la salida de la red neuronal 1.

Esta segunda red neuronal (red 2) se implementará de forma análoga a la red neuronal de base, con la diferencia de que introducirá la salida de la red 1, la red 2 establecerá así correlaciones entre la entrada nueva que se aporta y la salida. El objetivo es mejorar el ajuste de las previsiones al aprender la red a correlacionar los nuevos parámetros. Esta red 2 tendrá doce neuronas, once variables de entrada y aplicará el algoritmo de aprendizaje de Regularización Bayesiana.

### 4.3 Conclusiones del capítulo.

Realizado el proceso de búsqueda, preparación y selección de los datos de entrada y la comprensión del funcionamiento de la red neuronal artificial su implementación es un trabajo ameno. El programa MATLAB facilita su desarrollo, modificación y aplicación de forma sencilla.

Resalta la complejidad de implementar el modelo de red neuronal artificial con retroalimentación, dada la dificultad de conseguir que dicho modelo implemente la modificación de los pesos por acción de la retroalimentación. Este trabajo ha requerido una revisión en profundidad del diagrama de bloques, editándolos y revisándolo. Ha sido necesario recordar conceptos vistos a lo largo de la formación académica recibida. No obstante la aplicación de este modelo una vez aplicada la retroalimentación para un caso práctico es relativamente sencilla gracias al software con el que se trabaja.

El último modelo a implementar no presenta ninguna complejidad, pues el generar el modelo de predicción de red neuronal en cascada únicamente requiere reprocesar los datos de salida de una primera red neuronal en una segunda.

## 5 Caso de aplicación.

### 5.1 Introducción.

En este capítulo se validarán los modelos descritos hasta ahora. En primer lugar se evaluarán los valores que genera el software en el aprendizaje de la red neuronal artificial base para la predicción de los precios de los futuros de la electricidad a un año. Con ello se tratará de visualizar la aplicación del proceso de desarrollo de los diferentes modelos de predicción. Los modelos de predicción que se desarrollan son de tres tipos: el modelo de red neuronal artificial, el modelo de red neuronal con retroalimentación y el modelo de red neuronal en cascada.

El proceso de aprendizaje de los diferentes modelos de predicción de la red comprende desde el 28 de septiembre de 2015 hasta el 28 de septiembre de 2017, contabilizando dos años, es decir 732 muestras o días. La aplicación de los modelos para obtener las predicciones de los precios de los diferentes productos abarca aproximadamente un año, sumando un total de 366 días.

El desarrollo de los tres modelos de predicción se realizara para cada uno de los seis tipos de productos eléctricos sobre los que se quiere obtener predicciones de sus precios para carga base, siendo estos diarios, de fin de semana, semanales, mensuales, cuatrimestrales y anuales. Se evaluará el producto de menor distancia temporal de entrega desde la fecha de negociación de cada producto en carga base, de entre todos los productos del mercado a plazo. Es decir para el producto a plazo para el fin de semana se analizará la previsión del primer fin de semana desde el día de negociación, para el producto semanal se realizará la previsión de los contratos de la semana siguiente al día de negociación. De modo análogo para el mes, el cuatrimestre y el año, se realizará la previsión para el inmediatamente posterior a la fecha en que se negocia el contrato del producto. El listado de productos a analizar se ordena desde el de periodo de entrega más lejano, (futuros a un año), hasta el precio de la electricidad en el mercado Spot diario. Se ha procedido así para reducir la incertidumbre temporal, quedando el orden de los resultados con el siguiente orden:

- Precio del futuro del año siguiente más próximo al día de negociación.
- Precio del futuro del cuatrimestre siguiente más próximo al día de negociación.
- Precio del futuro del mes siguiente más próximo al día de negociación.
- Precio del futuro de la semana siguiente más próximo al día de negociación.
- Precio del futuro del fin de semana siguiente más próximo al día de negociación.
- Precio en el mercado Spot diario.

En el capítulo se presenta la comparación de los tres modelos de redes para cada producto eléctrico de los resultados y errores medios obtenidos.

## 5.2 Etapa de aprendizaje de la red neuronal artificial.

En este punto del trabajo se mostrará la implementación del modelo la red neuronal artificial de base para el predecir el precio del futuro de la electricidad a un año. Para ello se mostrará el proceso de aprendizaje empleando las salidas de las herramientas gráficas de MATLAB. El proceso de aprendizaje se realiza introduciendo como entradas la secuencia temporal de como mínimo las siguientes diez variables:

- El día de la semana.
- La festividad.
- Las reservas hidráulicas (Hm<sup>3</sup>) de un año antes.
- Demanda eléctrica (MW) de un año antes.
- Generación eléctrica con carbón (MW) de un año antes.
- Generación eléctrica con ciclos combinados (MW) de un año antes.
- Generación eléctrica con energía eólica (MW) de un año antes.
- Generación eléctrica de origen hidráulico (MW) de un año antes.
- Futuros del Petróleo Brent a más de un año (dólares).
- Futuros del Gas Natural a más de un año (dólares).

Y se toma como valores objetivo de la red, la secuencia de precios que se quiere predecir. Las diferentes secuencias de datos se corresponden al periodo comprendido entre el 28 de septiembre de 2015 hasta el 28 de septiembre de 2017. Esto supone disponer de secuencias de datos, de cada una de las variables anteriores y de la salida que se quiere predecir para 2 años, sumando así 732 muestras o días. Períodos de entrenamiento menores pueden influir en una menor precisión del modelo. Con periodos mayores los modelos pueden llegar a un sobre-entrenamiento por exceso de muestras. En este último caso, se perdería capacidad de generalización del modelo. Con el objetivo de realizar predicciones a un año vista de los precios de los productos eléctricos se considera vital tomar dos años de muestras para el entrenamiento de la red, al objeto de permitir el correcto funcionamiento de la red neuronal de base.

El proceso de aprendizaje es análogo para las múltiples redes neuronales, pues en la mayor parte de los casos la variación se producirá al emplear datos objetivo diferentes para los diferentes productos. La diferencia entre el modelo de la red neuronal de base y la red neuronal con retroalimentación se encuentra en que en la segunda se produce un reentrenamiento de la red donde se producirá un reajuste de las variables del modelo forzadas por la retroalimentación. En el caso del modelo de red neuronal en cascada únicamente hay que implementar una segunda red, similar a la red neuronal de base en la que se incorporan a las variables de entrada la salida de la red neuronal de base.

La salida gráfica del software que realiza la presentación gráfica de los resultados del entrenamiento de nuestro modelo de red artificial de base es el de la imagen siguiente.



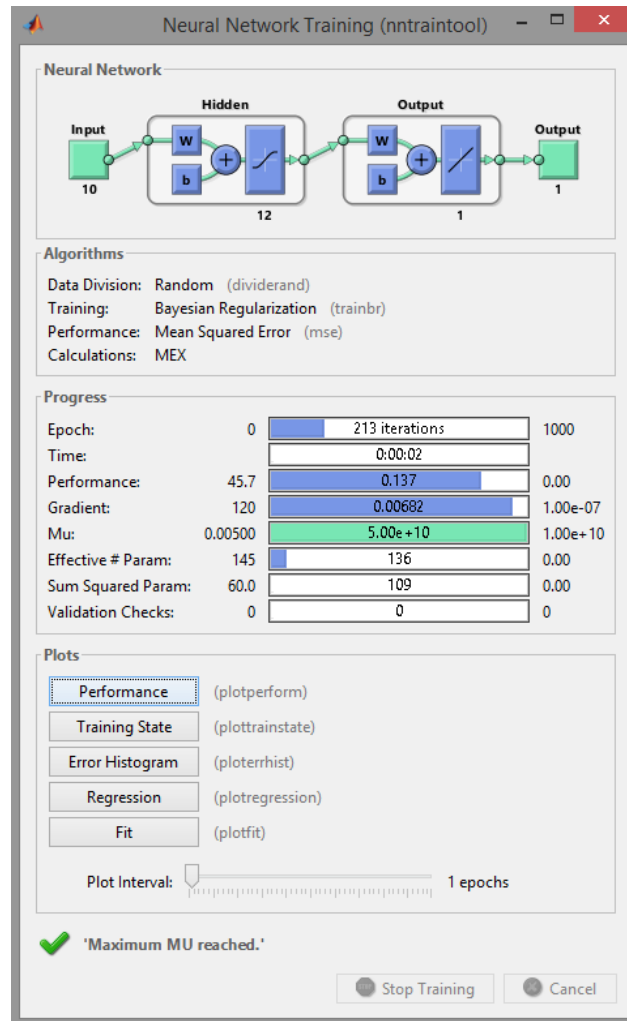


Ilustración 39. Salida gráfica con los parámetros del entrenamiento de la red neuronal de base para el precio del futuro a un año. Fuente: elaboración propia en MATLAB.

El software implementa esta red en aproximadamente 2 segundos, realizando 213 iteraciones para el proceso de aprendizaje empleando el algoritmo de Regularización Bayesiana. Este es el número de iteraciones en que se obtiene el valor mínimo de la función que optimiza la red, dicha función se presenta en la **ecuación 12** del capítulo 3. En ese momento se cumple el criterio de parada del algoritmo. Un mayor número de iteraciones daría lugar a un peor desempeño en la capacidad de generalización de la red entrando en una fase de sobreentrenamiento.





Ilustración 40. Imagen de la evolución de la función del error que optimiza el algoritmo de Regularización Bayesiana. Fuente: elaboración propia en MATLAB.

En la imagen anterior se constata la evolución del proceso de ajuste de los parámetros de la red, minimizando la función de costes del algoritmo. Tanto en el entrenamiento como en el testeo del modelo se constata la reducción rápida de la función de costes conforme se inicia el proceso iterativo. Avanzando el proceso iterativo las funciones convergen hacia el mínimo de la función que se alcanza en la iteración 213. A partir de este momento se aplica el criterio de parada del algoritmo. Con ello quedan balanceados los pesos y los errores del modelo. En el caso de que se continuará realizando iteraciones se podría llegar a producir sobreentrenamiento.

En la imagen siguiente se presenta la distribución del error cometido en los valores de salida, tomando como este error la diferencia entre la salida objetivo y la salida de la red. El valor central se corresponde con el error nulo, observando una distribución gráfica en forma de campana. Esta forma es debido al desempeño en el proceso de aprendizaje de la red, concentrándose la mayor parte de los valores de error en la zona central de la gráfica, al ser la mayor parte de los valores de error próximos a cero. Se observa con ello que proceso de ajuste es idóneo para el modelo, reduciendo el error que se comete.



Il·lustració 41. Histograma de la red neuronal artificial. Fuente: elaboración propia en MATLAB.

La última salida gráfica que se presenta a continuación facilita el análisis del ajuste de la salida de la red neuronal artificial generada y entrenada, respecto de la salida objetivo. Se compara la aproximación a la salida objetivo de los resultados de la fase de entrenamiento (recta azul), de la fase de testeo de la red (recta verde) y el ajuste de la suma de las dos fases anteriores (recta roja). El análisis se genera en base al valor de la regresión R, que establece la correlación entre la salida y la salida objetivo. Un resultado óptimo implica una relación cerrada y genera un valor de  $R=1$ . En el caso de que la correlación se deba a la casualidad  $R$  valdrá 0.

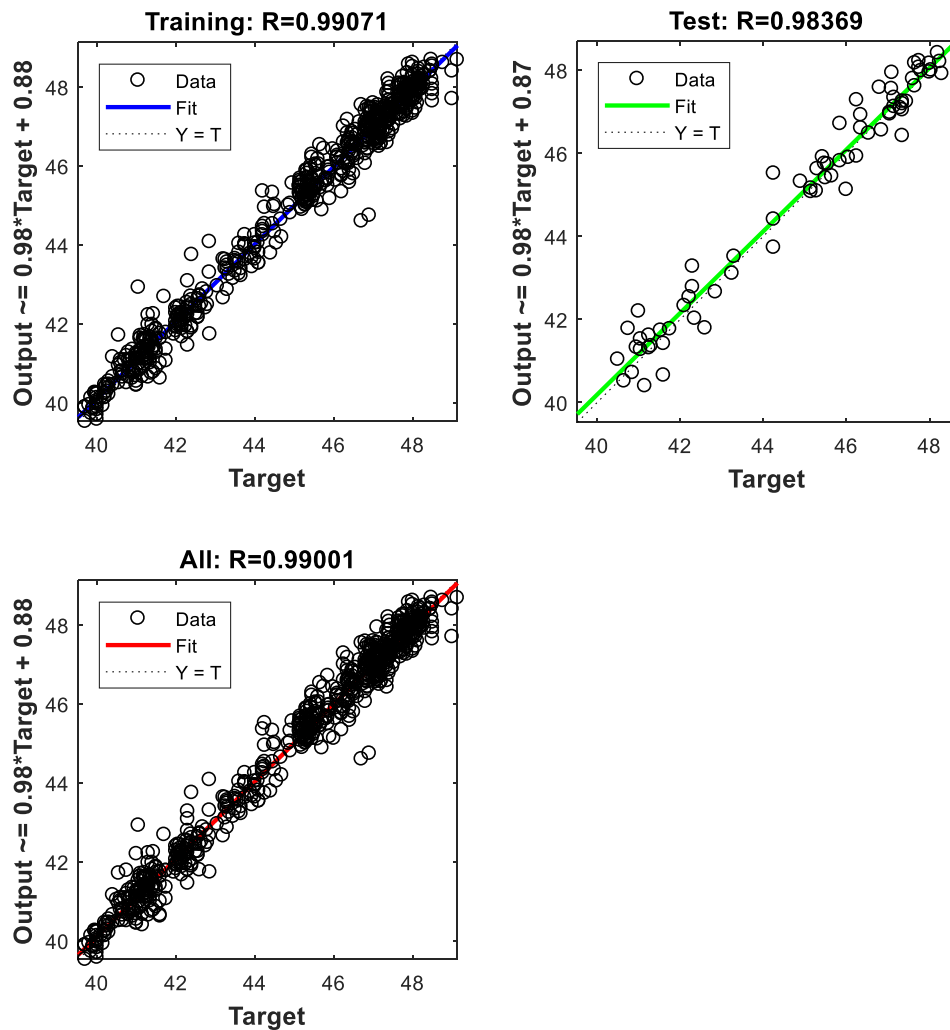


Ilustración 42. Gráficas de la regresión de la salida de la red neuronal artificial respecto de los valores objetivo.  
Fuente: elaboración propia en MATLAB.

El ajuste de la red, tanto en el entrenamiento como en el test para generar el valor del precio del producto eléctrico, es satisfactorio por cuanto es prácticamente 1. Esto indica que el modelo en su salida ajusta a la salida objetivo que queríamos obtener con precisión.

### 5.3 Aplicación real de la red neuronal artificial. Resultados y errores de los diferentes casos.

En este apartado se desarrolla la predicción para cada uno de los tres modelos de que se presentan en este trabajo, para cada uno de los tipos de productos eléctricos del mercado a plazo según el periodo de entrega y para el precio del mercado Spot diario en carga base. Para cada tipo de producto eléctrico se ha trabajado sobre el que presenta menor plazo de entrega

desde la fecha de negociación. Los productos sobre los que nos centramos para el periodo base, son por orden los siguientes

- Precio del futuro del año siguiente más próximo al día de negociación.
- Precio del futuro del cuatrimestre siguiente más próximo al día de negociación.
- Precio del futuro del mes siguiente más próximo al día de negociación.
- Precio del futuro de la semana siguiente más próximo al día de negociación.
- Precio del futuro del fin de semana siguiente más próximo al día de negociación.
- Precio en el mercado Spot diario.

Así mismo, junto con los tres modelos diseñados en este trabajo, se plantea incorporar una alternativa basada en el modelo de red neuronal artificial de base que incorpore como una entrada más la salida del modelo de una red neuronal de base de otro producto eléctrico con plazo de entrega inmediatamente superior o inmediatamente inferior. Esto último se considera interesante al constatar correlaciones entre los precios de los productos con plazo de entrega próximo desde la fecha de negociación, lo que podría ayudar a mejorar los resultados del modelo de predicción.

En este punto y dado que la predicción se realiza para los precios de diferentes productos eléctricos para 366 días desde el (28/09/2017 hasta el 28/09/2018), se omite presentar la totalidad de los valores reales y de las predicciones de los diferentes modelos. Esto implicaría incorporar tablas excesivamente extensas de números. En su lugar se presentan tablas de cada uno de los productos, con los datos reales y las predicciones para cada uno de los modelos para tres días de los 366 días en que se realiza la proyección. En dichas tablas se incorporará el cálculo del desajuste entre el valor real y el de la predicción en valor absoluto. Se ha tomado los valores para tres días uno de alta demanda (20/12/2017), uno de baja demanda (20/03/2018) y otro de media demanda (20/06/2018), dentro del periodo de valoración.

Por otro lado, se realizará la presentación de los errores medios de los diferentes modelos para cada producto, así como una comparación gráfica entre los valores proyectados en la salida de los diferentes modelos, junto con el valor real.

$$(21) \quad e_m = \frac{\sum_1^n \text{abs}(y_{real} - y_{estimado})}{n}$$

$$(22) \quad e_m(\%) = \frac{\sum_1^n \text{abs}(y_{real} - y_{estimado})}{\sum_1^n y_{real}}$$

La estimación del error medio se realiza conforme a la ecuación que se presentó en el punto 3.4.2. El error medio en porcentaje se presenta en la última ecuación, en función del valor medio de la muestra.

### 5.3.1 Precio del futuro eléctrico a un año.

Entre los futuros de los productos eléctricos a más de un año, se ha realizado la predicción del que presenta plazo de entrega a menor plazo desde la fecha de negociación, así se ha considerado trabajar con el futuro a un año. Se ha tomado esta decisión a fin de trabajar con la menor incertidumbre ante situaciones que son ajenas al mercado eléctrico y que pudieran perjudicar la precisión de los resultados de forma que no predecible.

Además de los tres modelos diseñados se ha realizado la construcción de un modelo de red neuronal artificial de base, tomando como entrada adicional la predicción del modelo de red neuronal artificial de base del futuro a un cuatrimestre.

*Tabla 15. Datos de valores reales y predicciones de los modelos en el futuro a un año, para tres días del periodo de previsión, con sus desviaciones en valor absoluto.*

Futuro a 1 año	20/12/2017	Desviación (%)	20/03/2018	Desviación (%)	20/06/2018	Desviación (%)
Precio real (€/MWh)	44,85		42,45		44,59	
Previsión red neuronal de base (€/MWh)	45,07	0,50	42,61	0,37	45,90	2,93
Previsión red neuronal con retroalimentación	46,94	4,65	46,58	9,72	47,54	6,60
Previsión red neuronal en cascada (€/MWh)	45,40	1,23	46,22	8,87	47,76	7,10
Previsión red neuronal con entrada de la proyección de otro modelo (€/MWh)	45,78	2,07	48,15	13,44	47,76	7,10

La tabla anterior muestra los valores reales del futuro a un año y las predicciones de los modelos. Los valores reales apenas muestran variación, con un ligero descenso en el día de menor demanda (20/03/2018). Esta estabilidad del valor real permite que los modelos se aproximen a él, sin desviarse excesivamente. Los valores de los modelos presentan una aparente tendencia a alejarse del valor real conforme nos alejamos de la fecha de inicio de la predicción (28/09/2017), pero dada la estabilidad del valor real la predicción de los modelos es buena como veremos con el análisis de los errores. La alta incertidumbre para el periodo de predicción se compensa por la reducida variabilidad del valor real que queremos predecir.

Los resultados tanto de los errores medios, como las salidas gráficas se presentan a continuación.

Tabla 16. Error de los valores de salida de los modelos de predicción respecto del valor real para el futuro a un año.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	1,30	2,94
Red neuronal con retroalimentación	2,25	5,09
Red neuronal en cascada	2,21	4,98
Red neuronal con entrada añadida de proyección del precio del futuro a un cuatrimestre	1,87	4,23




Ilustración 43. Gráfica de los precios obtenidos para los diferentes modelos de predicción y el valor real para el futuro a un año. Fuente: elaboración propia.

Los resultados del error medio son mejores para el modelo de predicción con red neuronal artificial de base en el análisis de la muestra de 366 días. Aparentemente el ajuste de la gráfica en este caso con respecto a la realidad es muy regular, siendo la mayor desviación respecto del valor real de 4,56 €/MWh. Los otros tres modelos presentan un error medio peor y similar entre ellos.

El modelo con retroalimentación presenta picos respecto de los valores reales en determinadas circunstancias, con una desviación máxima del valor real de 6,49 €/MWh. El modelo genera el mayor error medio debido a los picos.

El modelo en cascada presenta una evolución muy suave de los valores de salida, sin embargo la máxima desviación es de 5,57 €/MWh. Finalmente el modelo en el que se emplea una entrada adicional que es la salida de la predicción del modelo de red neuronal artificial del futuro a un cuatrimestre, presenta un resultado con picos excesivos. La desviación máxima respecto del valor real es de 7,44 €/MWh.

### 5.3.2 Precio del futuro eléctrico a un cuatrimestre.

En este punto se realiza la predicción del futuro para el primer cuatrimestre desde el día de negociación. Así mismo, se ha introducido un cuarto modelo de predicción que emplea la salida del modelo de red neuronal artificial de base para el futuro a un mes. La decisión se ha tomado por ser el que presenta la menor diferencia en el plazo de entrega desde el día de negociación.

Los resultados de la aplicación para una muestra de tres días dentro del periodo de predicción son los siguientes:

*Tabla 17. Datos de valores reales y predicciones de los modelos en el futuro a un cuatrimestre, para tres días del periodo de previsión, con sus desviaciones en valor absoluto.*

Futuro a 1 cuatrimestre	20/12/2017	Desviación (%)	20/03/2018	Desviación (%)	20/06/2018	Desviación (%)
Precio real (€/MWh)	55,00		47,32		63,28	
Previsión red neuronal de base (€/MWh)	59,88	8,88	41,08	13,18	43,30	31,58
Previsión red neuronal con retroalimentación (€/MWh)	53,07	3,50	48,85	3,24	50,87	19,62
Previsión red neuronal en cascada (€/MWh)	53,57	2,59	47,22	0,22	42,07	33,52
Previsión red neuronal con entrada de la proyección de otro modelo (€/MWh)	51,31	6,71	47,92	1,27	42,67	32,57

En la tabla anterior se observa una importante variación de los valores reales en función del día de negociación. Las predicciones en general ajustan bien para las primeras fechas del periodo de predicción y se desvían de forma importante para la fecha más alejada. En un periodo inferior al año de predicción el ajuste de las predicciones a los valores reales es mejor para los valores iniciales. Ante la mayor variabilidad de los valores reales y la gran extensión del periodo los modelos pierden ligeramente capacidad de generalización.



Tabla 18. Error de los valores de salida del periodo de 366 días de los modelos de predicción respecto del valor real para el futuro a un cuatrimestre.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	13,09	22,55
Red neuronal con retroalimentación	12,30	21,19
Red neuronal en cascada	11,75	20,24
Red neuronal con entrada añadida de proyección del precio del futuro a un mes	11,95	20,58

La tabla anterior presenta unos malos resultados en general, lo que es indicador de que el periodo óptimo de los modelos es inferior a las muestras de 366 días. Por ello, se ha descartado valorar en profundidad estos resultados y se ha buscado el periodo máximo en el que el error está acotado. La muestra en esta segunda evaluación se ha realizado para algo más de la primera mitad del año (188 días):

Tabla 19. Error de los valores de salida del periodo de 188 días de los modelos de predicción respecto del valor real para el futuro a un cuatrimestre.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	3,05	5,88
Red neuronal con retroalimentación	2,38	4,28
Red neuronal en cascada	2,96	5,40
Red neuronal con entrada añadida de proyección del precio del futuro a un mes	3,11	6,13

En la tabla anterior se constata que los modelos presentan una buena estimación en un plazo inferior de tiempo. Los modelos no han respondido de forma idónea en la predicción de 366 días ante la variación brusca de los precios del futuro a un cuatrimestre a mitad del periodo, tal y como se aprecia en la gráfica siguiente. No obstante los errores que presentan los modelos en un plazo inferior ajustan de forma correcta.

La red neuronal artificial de base presenta un buen resultado del error medio, siendo la desviación máxima en el periodo de 188 días de 8,12 €/MWh. El comportamiento del modelo con retroalimentación, presenta sobreoscilaciones pero su ajuste parece el óptimo en el periodo de 188 días, con el menor error medio. La máxima desviación que presenta respecto del valor real es de 5,84 €/MWh. Reflejando globalmente el mejor comportamiento.

Las redes en cascada y con la entrada extra del futuro a un mes empeoran el valor del error medio del modelo con retroalimentación. Siendo la desviación máxima en el periodo de 188 días de 11,30 y 12,78 €/MWh respectivamente.




Ilustración 44. Gráfica de los precios obtenidos para los diferentes modelos de predicción y el valor real para el futuro a un cuatrimestre. Fuente: elaboración propia.

### 5.3.3 Precio del futuro eléctrico a un mes.

En este punto se procede de forma análoga al caso anterior. El cuarto modelo de predicción se realiza con una entrada extra que es la salida del modelo de red neuronal artificial de base para el futuro a un cuatrimestre. La siguiente tabla presenta un muestreo de las salidas de los modelos y los valores reales para tres días.

Tabla 20. Datos de valores reales y predicciones de los modelos en el futuro a un mes para tres días del periodo de previsión, con sus desviaciones en valor absoluto.

Futuro a 1 mes	20/12/2017	Desviación (%)	20/03/2018	Desviación (%)	20/06/2018	Desviación (%)
Precio real (€/MWh)	59,33		41,92		57,75	
Previsión red neuronal de base (€/MWh)	51,18	13,74	46,77	11,57	40,77	29,41
Previsión red neuronal con retroalimentación (€/MWh)	49,23	17,02	50,45	20,35	50,30	12,90
Previsión red neuronal en cascada (€/MWh)	51,59	13,05	46,63	11,23	40,83	29,31
Previsión red neuronal con entrada de la proyección de otro modelo (€/MWh)	57,37	3,31	51,69	23,31	45,64	20,97

Los valores reales presentan cierta volatilidad que los modelos no son capaces de predecir de forma correcta para las fechas que analizamos. Aumenta la desviación de las predicciones respecto de los valores reales conforme nos alejamos de la fecha de la primera predicción (28/09/2017). La capacidad de generalización se diluye al reducirse el periodo de entrega del producto al considerar un periodo de predicción para todo un año.

Los resultados de los errores para el periodo de 366 días se muestran en la tabla:

Tabla 21. Error de los valores de salida del periodo de 366 días de los modelos de predicción respecto del valor real para el futuro a un mes.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	10,11	18,22
Red neuronal con retroalimentación	10,41	18,75
Red neuronal en cascada	10,14	18,28
Red neuronal con entrada añadida de proyección del precio del futuro a un cuatrimestre	11,13	20,06

Nuevamente carece de sentido entrar en un análisis en profundidad de los resultados de los modelos de la predicción para 366 días. Por ello se ha acotado un periodo óptimo de funcionamiento de las redes que toma los primeros 188 días. Para este nuevo periodo los resultados del error medio son los siguientes:

Tabla 22. Error de los valores de salida del periodo de 188 días de los modelos de predicción respecto del valor real para el futuro a un mes.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	5,90	11,04
Red neuronal con retroalimentación	5,79	10,83
Red neuronal en cascada	5,76	10,77
Red neuronal con entrada añadida de proyección del precio del futuro a un cuatrimestre	6,53	12,21

En este caso los resultados de los errores medios son muy semejantes, siendo el peor resultado el que presenta el modelo de predicción que añade como entrada el resultado de la predicción del futuro a un cuatrimestre.

Las desviaciones máximas respecto del valor real es de 15,62 €/MWh para la red neuronal artificial de base, 13,20 para el modelo con retroalimentación, 15,354 para el modelo en cascada y 23,013 para el modelo con la entrada extra del futuro a un cuatrimestre.




Ilustración 45. Gráfica de los precios obtenidos para los diferentes modelos de predicción y el valor real para el futuro a un mes. Fuente: elaboración propia.

### 5.3.4 Precio del futuro eléctrico a una semana.

Nuevamente se procede a la aplicación al caso real para los tres modelos para hallar los precios del futuro semanal, para la primera semana desde el día de negociación. Se plantea un cuarto modelo con la entrada adicional de la salida de la red neuronal artificial de base para la predicción a un mes.

Tabla 23. Datos de valores reales y predicciones de los modelos en el futuro a una semana para tres días del periodo de previsión, con sus desviaciones en valor absoluto.

Futuro a 1 semana	20/12/2017	Desviación (%)	20/03/2018	Desviación (%)	20/06/2018	Desviación (%)
Precio real (€/MWh)	59,33		41,92		57,75	
Previsión red neuronal de base (€/MWh)	70,46	18,76	29,74	20,53	43,46	32,87
Previsión red neuronal con retroalimentación (€/MWh)	48,08	18,96	39,34	4,35	50,11	17,58
Previsión red neuronal en cascada (€/MWh)	67,49	13,75	29,99	20,11	41,57	37,23
Previsión red neuronal con entrada de la proyección de otro modelo (€/MWh)	82,32	38,76	33,50	14,19	41,77	36,78

Los valores reales presentan una variación importante de sus valores en función del día, que las predicciones no son capaces de ajustar. Al alejarse de la fecha del primer día de predicción (28/09/2017), la desviación de las predicciones se incrementa de forma significativa. Existe excesiva incertidumbre al alejarnos de las fechas iniciales para que los modelos generalicen con suficiente predicción. A continuación se muestra la tabla de los errores para los modelos.

Tabla 24. Error de los valores de salida del periodo de 366 días de los modelos de predicción respecto del valor real para el futuro a una semana.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	14,14	25,47
Red neuronal con retroalimentación	16,74	30,17
Red neuronal en cascada	13,79	24,84
Red neuronal con entrada añadida de proyección del precio del futuro a un mes	14,72	26,52

Los resultados para el periodo de 366 días no se consideran adecuados. Por ello, se ha vuelto a evaluar un periodo de la muestra que incorpora los primeros 24 días de las predicciones.

Tabla 25. Error de los valores de salida del periodo de 24 días de los modelos de predicción respecto del valor real para el futuro a una semana.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	1,99	3,57
Red neuronal con retroalimentación	7,87	14,10
Red neuronal en cascada	2,06	3,70
Red neuronal con entrada añadida de proyección del precio del futuro a un mes	17,74	31,80

En este caso la red neuronal artificial de base junto con el modelo en cascada presentan los mejores resultados, siendo similares. El error del modelo con retroalimentación no es capaz de ajustarse a los valores reales de forma suficiente. Análogamente al caso anterior, la red que incorpora la salida del futuro a un mes no se ajusta al valor real, probablemente el elevado error que presentaba la salida del futuro a un mes ha perjudicado al resultado obtenido.

Los valores de desviación máxima son de 4,49 €/MWh para el primer modelo, 13,25 para el modelo con retroalimentación, 4,30 para el modelo en cascada y para el último caso de 32,02 €/MWh.




Ilustración 46. Gráfica de los precios obtenidos para los diferentes modelos de predicción y el valor real para el futuro a una semana. Fuente: elaboración propia.

### 5.3.5 Precio del futuro eléctrico para el fin de semana.

Procediendo como en los puntos anteriores se aplican los modelos a un caso real, en este caso la predicción para el primer fin de semana desde el día de negociación. Se obtienen los resultados para los tres modelos y se aplica un cuarto modelo con la salida del modelo de predicción para el futuro a una semana.

Los resultados de los modelos para una muestra de tres días del periodo donde se realizan las previsiones son los siguientes:

Tabla 26. Datos de valores reales y predicciones de los modelos en el futuro a un fin de semana para tres días del periodo de previsión, con sus desviaciones en valor absoluto.

Futuro a 1 fin de semana	20/12/2017	Desviación (%)	20/03/2018	Desviación (%)	20/06/2018	Desviación (%)
Precio real (€/MWh)	55,00		33,25		48,54	
Previsión red neuronal de base (€/MWh)	71,08	29,23	45,81	37,78	41,82	13,85
Previsión red neuronal con retroalimentación (€/MWh)	80,73	46,78	32,09	3,48	23,79	50,99
Previsión red neuronal en cascada (€/MWh)	61,15	11,18	44,43	33,64	37,75	22,23
Previsión red neuronal con entrada de la proyección de otro modelo (€/MWh)	76,55	39,19	21,13	36,46	45,10	7,08

De la tabla anterior se constata la variabilidad de los valores reales, y las desviaciones elevadas de los modelos respecto al precio real. La desviación es alta para las tres fechas en general, mostrando puntualmente algún modelo una buena aproximación al valor real. Al reducirse el periodo de entrega del producto se reduce de forma sensible la capacidad de predicción del modelo como en los casos anteriores. Los resultados de los errores para todo el periodo se muestran a continuación.

Tabla 27. Error de los valores de salida del periodo de 366 días de los modelos de predicción respecto del valor real para el futuro para el fin de semana.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	13,16	26,03
Red neuronal con retroalimentación	17,51	34,64
Red neuronal en cascada	11,92	23,59
Red neuronal con entrada añadida de proyección del precio del futuro a una semana	15,12	29,91

Dados los malos resultados anteriores se busca acotar un periodo donde se minimice el error medio de los diferentes modelos. Para ello se ha seleccionado un período que abarca los primeros 24 días.

Tabla 28. Error de los valores de salida del periodo de 24 días de los modelos de predicción respecto del valor real para el futuro para el fin de semana.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	3,34	6,33
Red neuronal con retroalimentación	11,18	21,22
Red neuronal en cascada	2,54	4,82
Red neuronal con entrada añadida de proyección del precio del futuro a una semana	9,15	17,37

Se repite el mejor comportamiento del modelo de red neuronal artificial de base y del modelo en cascada. Aunque el modelo en cascada presenta un comportamiento más ajustado a los valores reales para los 24 primeros días.

Las desviaciones máximas son de 9,94 €/MWh para el modelo base, 25,12 para el modelo con retroalimentación, 7,51 para el modelo en cascada y para el último modelo de 18,79 €/MWh.




Ilustración 47. Gráfica de los precios obtenidos para los diferentes modelos de predicción y el valor real para el futuro para el fin de semana. Fuente: elaboración propia.

### 5.3.6 Precio del futuro eléctrico para el precio diario del mercado SPOT.

Finalmente se ha evaluado el resultado de los modelos proyectados para el precio de la electricidad en el mercado diario. Se han aplicado los tres modelos proyectados, así como un cuarto modelo que incorpora una entrada extra que es la salida del modelo de predicción del futuro a una semana. Los valores reales, de las previsiones y sus desviaciones para la muestra de tres días son los siguientes:

Tabla 29. Datos de valores reales y predicciones de los modelos en el precio diario para tres días del periodo de previsión, con sus desviaciones en valor absoluto.

Precio diario	20/12/2017	Desviación (%)	20/03/2018	Desviación (%)	20/06/2018	Desviación (%)
Precio real (€/MWh)	55,00		33,25		48,54	
Previsión red neuronal de base (€/MWh)	46,05	16,28	48,20	44,95	50,18	3,38
Previsión red neuronal con retroalimentación (€/MWh)	41,22	25,06	47,48	42,79	47,19	2,78
Previsión red neuronal en cascada (€/MWh)	46,22	15,97	48,00	44,36	49,22	1,41
Previsión red neuronal con entrada de la proyección de otro modelo (€/MWh)	70,46	28,11	29,74	10,56	43,46	10,46



En los precios diarios reales se observa la fuerte variación con un precio reducido para el día de menor demanda. Los modelos presentan una alta desviación de los reales salvo para el 20/06/2018, muy alejado del primer día de negociación. Analizando estos valores es difícil justificar la alta precisión de los modelos en esta fecha. Aparentemente es una fecha en la que los precios de los dos años anteriores, (periodo de aprendizaje de los modelos), eran similares por lo que los modelos han extrapolado los valores en condiciones similares. Los resultados del error medio para el periodo de 366 días se exponen en la siguiente tabla:

*Tabla 30. Error de los valores de salida del periodo de 366 días de los modelos de predicción respecto del valor real para el precio diario.*

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	10,01	19,80
Red neuronal con retroalimentación	10,322	20,42
Red neuronal en cascada	9,95	19,68
Red neuronal con entrada añadida de proyección del precio del futuro a una semana	12,76	25,24

Dado que los resultados no son todo lo buenos que sería deseable, se ha procedido a evaluarlos en un periodo de tiempo inferior donde se minimice el error medio. Este periodo engloba los primeros 5 días de predicciones.

Tabla 31. Error de los valores de salida del periodo de 5 días de los modelos de predicción respecto del valor real para el precio diario.

Modelo de predicción	Error medio (€/MWh)	Error medio (%)
Red neuronal artificial de base	8,60	16,76
Red neuronal con retroalimentación	9,58	18,68
Red neuronal en cascada	8,70	16,95
Red neuronal con entrada añadida de proyección del precio del futuro a una semana	1,10	2,15

El modelo de red neuronal artificial que incorpora una nueva entrada que es la predicción del futuro a una semana, presenta unos resultados claramente superiores al resto de modelos. Las desviaciones máximas de los tres primeros modelos son respectivamente: 9,25 €/MWh, 9,93 €/MWh y 9,32 €/MWh.

El buen resultado del modelo que incorpora como salida la predicción a una semana reduce la desviación máxima a 2,07 €/MWh.




Ilustración 48. Gráfica de los precios obtenidos para los diferentes modelos de predicción y el valor real para el precio diario. Fuente: elaboración propia.

#### 5.4 Conclusiones del capítulo.

En este capítulo se ha evaluado el funcionamiento de los tres modelos de predicción planteados en el trabajo para la previsión de los precios de diferentes productos eléctricos. Aprovechando las salidas más idóneas del modelo de la red neuronal artificial de base de unos productos en otros se ha presentado un cuarto modelo.

En este trabajo los modelos se han proyectado para que su comportamiento fuera el idóneo en la predicción de los precios de los contratos en el mercado a plazo. No obstante, uno de los modelos ha presentado un comportamiento excelente en la predicción del precio diario de la electricidad para los primeros 5 días. Esto a pesar de que las variables de entrada se correspondían en la mayoría de los casos a datos del año anterior, con lo que lo esperable era un mal ajuste para este caso.

El trabajo se realizó con la selección de variables y parámetros que optimizaban la predicción del precio del futuro a un año. Este hecho destaca por los buenos resultados de los cuatro modelos para el futuro a un año de la electricidad para los 366 días de previsión en que se aplica. Para el resto de productos del mercado, se encuentra algún modelo que ajusta con notable precisión siempre que se tome un periodo de días de predicción adecuado para cada producto. Esto se cumple con la excepción de los intentos de predecir el precio del futuro a un mes. En este caso no se puede minimizar el error medio de forma que esté acotado por debajo de los 5,5 €/MWh. En el resto de casos siempre se obtiene algún modelo cuyo error medio sea inferior a los 3 €/MWh.

El modelo de red neuronal artificial de base plantea buenos resultados en la predicción del precio de todos los productos, (escogiendo el periodo inicial adecuado), salvo para el precio del futuro a un mes y el precio diario de la electricidad.

El modelo de red neuronal artificial con retroalimentación funciona de bastante bien para la predicción del futuro a un año y seleccionando un periodo inicial adecuado, se optimiza su respuesta para el futuro a un cuatrimestre. Presenta un comportamiento en el resto de casos que induce a creer que ha perdido capacidad de predicción a causa de sobre-entrenamiento.

El modelo en cascada se comporta de forma bastante similar al modelo de base, con mayor suavidad y en los productos con menor plazo de entrega la iguala o mejora. Este resultado era de esperar por cuanto se asemeja al modelo base y recicla la salida de ésta.

El modelo en que se aprovecha la predicción de la red de base de un producto para predecir otro, es el de peor comportamiento. No obstante presenta una gran precisión en la predicción del precio diario de la electricidad tomando como entrada adicional las previsiones del futuro a una semana.



## 6 Conclusiones finales.

### 6.1 Conclusiones del trabajo.

El objetivo del trabajo era el de predecir el precio de los productos eléctricos del mercado a plazo, implementando modelos de predicción basados en redes neuronales artificiales.

Se ha procedido a realizar la presentación del mercado a plazo y a realizar una búsqueda exhaustiva para determinar el punto en que se encontraba el estudio de la predicción de los precios eléctricos a largo plazo. En la búsqueda documental, las referencias encontradas de modelos de predicción del precio de productos eléctricos a más de un mes eran reducidas, no encontrándose en el momento de realizar este trabajo documentación relativa a la estimación del precio de productos eléctricos a un año de plazo. Este trabajo llena un vacío existente en la predicción a más de tres meses realizando un estudio en profundidad de los modelos implementados.

El análisis de la bibliografía consultada lleva a la conclusión de que resulta extremadamente complejo realizar la comparación entre modelos de predicción. Esto es así, dadas las diferencias de los sistemas y mercados eléctricos, así como de los modelos de predicción tanto por su arquitectura como del tamaño de las secuencias de datos de entrada y del periodo en que se realizan las previsiones. Por ello, ante las referencias conocidas se considera un buen resultado trabajar con un error inferior al 5%.

El análisis de diferentes variables de entrada ha llevado a realizar un análisis que establezca las relaciones entre estas y los valores a predecir. Este análisis ha permitido optimizar los datos de entrada a incorporar en los modelos sin descartar que pudieran existir otras variables que pudieran ayudar a mejorar las predicciones. En la bibliografía se encontró referencias a la necesidad de validar las entradas como forma de no perjudicar la capacidad de generalizar de las redes neuronales artificiales.

El estudio de la arquitectura de la red neuronal artificial nos ha llevado a un red inicial de dos capas, con una capa de entrada de 12 neuronas con entre 10 y 11 variables de entrada, dependiendo del modelo, con un secuencia de entrenamiento de 732 muestras. El algoritmo de aprendizaje desarrollado en la red era el algoritmo de Regularización Bayesiana, cuya base matemática se ha planteado.

Partiendo de la arquitectura anterior se ha implementado un nuevo modelo de predicción, basándonos en la observación de la forma de regular el suministro eléctrico en tensión y frecuencia para garantizar su calidad de servicio. El control que se quiere implementar es similar al control primario en frecuencia. Este sistema de control permite en el sistema eléctrico mantener la frecuencia del sistema y modificar a voluntad la potencia activa generada. Tratando de implementar un modelo similar se ha generado una red neuronal artificial que aplica un proceso de retroalimentación en una fase de entrenamiento.

Como otra alternativa, se ha considerado la aplicación de modelos de predicción que aprovechen la salida de la red de base para un producto, incorporándola como entrada adicional de otra red neuronal. El objetivo era mejorar el comportamiento de las predicciones al favorecer las correlaciones de las variables de entrada con la salida.

En esta línea, finalmente se ha considerado emplear las salidas de la red de base de un producto a plazo como entrada adicional en un modelo de predicción de otro producto eléctrico con plazo de entrega diferente.

Aunque el comportamiento de los diferentes modelos ha sido dispar, el resultado ha sido satisfactorio con la predicción de todos los productos eléctricos evaluados salvo con el futuro a un mes. En el futuro a un mes, el error medio ha sido superior en todos los casos al 10%. En el resto de caso siempre existe un modelo que obtenga un error inferior al 5% que se toma como referencia, simplemente considerando las previsiones para un número de días desde el inicio determinado.

Aunque como se ha justificado no se puede realizar una comparación válida por los diferentes días de predicción (5 días en este trabajo frente a 16 días) y los parámetros en que se aplican cada uno, se ha considerado comparar los resultados obtenidos en este trabajo para el precio diario de la electricidad con el de **Diego Santos Martín** tutorizado por **Manuel Alcázar Ortega [1]**. En su trabajo se obtiene un error mínimo de 2,07 € (4,7%) en comparación con los valores reales. En este trabajo, el menor error medio para el precio diario de la electricidad es de 1,10 € (2,149%).

Este trabajo resulta novedoso en su campo de aplicación, al existir una carencia en el mismo en cuanto a modelos de predicción por encima de los tres meses. Esto planteaba la necesidad de realizar este estudio. Con este trabajo se pretende ayudar a la generación de modelos basados en redes neuronales para la previsión de los precios de los futuros de la electricidad que tengan precisión en periodos a largo plazo. Por esta razón su implementación puede llegar a ser útil para los participantes en el mercado a plazo, ayudando a aumentar los beneficios en sus operaciones de compra-venta.

## 6.2 Desarrollos futuros.

Para futuros estudios similares a éste se considera interesante la posibilidad de considerar entre las variables de entrada a emplear, los intercambios energéticos entre España y otros países vecinos, ante la posibilidad de que tengan un impacto en la variación de los precios.

La relación de los precios de los productos eléctricos con la mayor o menor demanda eléctrica, y la relación de la demanda con parámetros macroeconómicos y de actividad, sugieren la posibilidad de buscar una entrada basada directamente en estos parámetros. No obstante no se ha encontrado un índice que refleje estas relaciones y que se pueda aplicar en este proyecto.

Otra posible forma de mejorar la previsión de los modelos de predicción, aunque supondría aumentar la complejidad del modelo, sería experimentar con redes neuronales con arquitecturas más complejas. Este paso requiere una cierta experiencia para emplear capas ocultas de neuronas de forma que se mejoren los resultados obtenidos.

## 7 Bibliografía

- [1] D. Santos Martín y M. Alcázar Ortega. Desarrollo de un modelo de predicción del precio horario de la energía eléctrica para el mercado diario mediante redes neuronales. Trabajo Fin de Máster ETSII Universidad Politècnica de Valencia 2016/17.
- [2] R. Weron. Modeling and forecasting electricity loads and prices: a statistical approach. Chichester: Wiley. (2006).
- [3] C.M. Ruibal y M. Mazumdar. Forecasting the mean and the variance prices of electricity prices in deregulated markets. IEEE Transactions on Power Systems. (2008).
- [4] M. Coulon y S. Howison. Stochastic behaviour of the electricity bid stack: from fundamental drivers to power prices. Journal of Energy Markets. (2009).
- [5] R. Weron. y A. Misiorek. Forecasting spot electricity prices: a comparison of parametric and semiparametric time series models. International Journal of Forecasting. (2008).
- [6] A.J. Conejo, M.A. Plazas, R.Espínola y A.B. Molina. Day-ahead electricity Price forecasting using the wavelet transform and ARIMA models. IEEE Transaction on power systems. (2005).
- [7] Whei-Min Lin, Hong-Jey Gow y Ming-Tang Tsai. Electricity Price forecasting using Enhanced Probability Neural Networks. Energy Conversion and Management. (2010).
- [8] D. Singhal y K.S. Swarup. Electricity price forecasting using artificial neural networks. Electrical power and energy systems. (2011).
- [9] F. Villada, E. García y J.D. Molina. Pronóstico del precio de la energía eléctrica usando redes neuro-difusas. Información tecnológica. (2011).
- [10] I.P. Panapakidis y A.S. Dagoumas. Day-ahead electricity price forecasting via the application of artificial neural network based models. Applied energy. (2016).

- [11] Manuel Martín-Merino Acera. Técnicas neuronales y estadísticas para la predicción de la demanda eléctrica.
- [12] H.T. Pao. Forecasting electricity market pricing using artificial neural networks. Energy Convers Manage. (2007).
- [13] Boletines hidrológicos. Ministerio para la Transición Ecológica, Gobierno de España.
- [14] M. Kayri. Predictive abilities of Bayesian Regularization and Levenberg-Marquardt Algorithms in Artificial Neural Networks: a comparative empirical study on social data. Mathematical and computational applications. (2016).
- [15] D.J.C. MacKay. Bayesian interpolation. Neural Comput. (1992).
- [16] D.J.C. MacKay. A practical bayesian framework for backpropagation networks. Neural Comput. (1992).
- [17] Datos diarios de demanda eléctrica y de generación de los diferentes tipos provenientes del Sistema de Información del Operador del Sistema (ESIOS). Web: [www.esios.ree.es](http://www.esios.ree.es)
- [18] Datos de precios de los contratos de los futuros de la electricidad en carga base provienen de Operador del Mercado Ibérico del Portugal (OMIP), así como documentos explicativos del funcionamiento de los mercados eléctricos. Web: [www.omip.pt](http://www.omip.pt)
- [19] Cotizaciones de los futuros del petróleo Brent y del Gas Natural en los mercados internacionales procedentes de la web de información bursátil. Web: [es.investing.com](http://es.investing.com).
- [20] M. Alcázar Ortega, C.S. Cañas Peñuelas, G. Escrivá Escrivá, V. Fuster Roig, J. Roger Folch. Generación, transporte y distribución de energía eléctrica. Editorial Universidad Politécnica de Valencia. (2019).
- [21] R. Weron. Electricity Price forecasting: A review of the state of the art with a look into the future. International Journal of Forecasting. (2014).
- [22] S.N. Sivannandam, S. Sumathi, S.N. Deepa. Introduction to neural networks using Matlab 6.0. McGraw-Hill Education India. (2006).



[23] E.N. Sánchez Camperos, A.G. Alma Yolanda y E.S. Alma Alanís. Redes neuronales: conceptos fundamentales y aplicaciones a control automático. Pearson Educación. (2006).

[23] P. Isasi Viñuela, I.M. Galván León. Redes de neuronas artificiales: un enfoque práctico. Pearson Education. (2004).

[24] M. Martín-Merino Acera, V. Alonso Secades y J.A. Román Gallego. Técnicas neuronales y estadísticas para la predicción de la demanda eléctrica.

[25] F. Mateo Jiménez, R. Gadea Gironés, Rafael y J. Martínez Pérez. Redes neuronales y preprocesado de variables para modelos y sensores en bioingeniería. Tesis doctoral del Departamento de Ingeniería Electrónica de la Universidad Politécnica de Valencia.

[26] Apuntes de Sistemas Eléctricos de Potencia del Master Universitario de Ingeniería Industrial de la ETSII (Universidad Politécnica de Valencia).



# DESARROLLO DE UN MODELO DE PREDICCIÓN DEL PRECIO DE LA ENERGÍA ELÉCTRICA PARA EL MERCADO A PLAZO MEDIANTE REDES NEURONALES.

-PRESUPUESTO-

## ÍNDICE

1. Planteamiento del presupuesto.....	3
2. Coste de la mano de obra. ....	3
3. Coste de equipos y software. ....	4
4. Coste de dietas.....	4
5. Desglose del presupuesto por partidos. ....	4
6. Presupuesto total.....	6

## 1. Planteamiento del presupuesto.

Este presupuesto se realiza para valorar los costes de desarrollo del proyecto realizado, evaluando todas las fases del proyecto. Se evaluará el presupuesto por capítulos en función de cada fase del trabajo. Los recursos que se evalúan son:

- Costes de mano de obra: en que se recoge el esfuerzo económico que supone la dedicación de quienes han trabajado en este proyecto.
- Costes de amortización de equipos y software: en el que se agrupan los materiales empleados en el proyecto, necesarios para el correcto desempeño. Aquí se incluye recursos materiales como el ordenador empleado y los diferentes programas empleados.
- Costes de dietas: este grupo recoge los costes de los desplazamientos y comidas.

Los recursos se evalúan conforme a precios extraídos de la base de datos del Instituto Valenciano para la Edificación (IVE), para la Comunidad Valenciana en 2018. Sólo se recogen los costes anteriores, descartando los costes indirectos que engloban aspectos como los costes de internet u otros costes similares. Se considera que este tipo de costes están amortizados.

## 2. Coste de la mano de obra.

En los costes de mano de obra se recogen los gastos que supone la dedicación del alumno y del tutor como ingenieros y profesionales.

Tabla 1. Coste de la mano de obra.

Recurso	Tarea	Unidades (h)	Coste Unitario (€/h)	Coste (€)
Ingeniero Industrial (Alumno)	Recopilación de documentación.	35,00	30,18	1056,30
	Búsqueda y tratamiento de datos.	85,00	30,18	2565,30
	Análisis y elección de datos	30,00	30,18	905,40
	Modelado experimental y programación informática.	60,00	30,18	1810,80
	Análisis de resultados.	25,00	30,18	754,50
	Redacción del proyecto.	50,00	30,18	1509,00
	Tutorías/Reuniones con el tutor.	15,00	30,18	452,70
	<b>Mano de obra de Ingeniero Industrial</b>			<b>9.054,00 €</b>
Ingeniero Industrial (Tutor)	Tutorías/Reuniones con el tutor.	15,00	54,32	814,86
	Corrección del proyecto.	40,00	54,32	2172,96
	<b>Mano de obra de Ingeniero Industrial</b>			<b>2.987,82 €</b>
	<b>TOTAL Mano de Obra</b>			<b>12.041,82 €</b>

### 3. Coste de equipos y software.

Se estima aquí los costes del equipo informático empleado y las licencias de software que se han necesitado para finalizar el proyecto.

Tabla 2. Costes de equipos y software.

Recurso	Unidades (h)	Coste Unitario (€/h)	Coste (€)
Ordenador TOSHIBA Intel(R) Core™ i7*4710HQ CPU	1,00	715,00	715,00
Sistema operativo	1,00	145,00	145,00
Office hogar y estudiantes	1,00	149,00	149,00
MATLAB R2017a	1,00	412,00	412,00
	TOTAL		1.421,00 €

### 4. Coste de dietas.

En este apartado se recogen los gastos debidos a desplazamientos del entorno de desarrollo del trabajo al Campus para actividades vinculadas al trabajo, (búsqueda de documentación y reuniones) con el tutor del proyecto. También se recogen los gastos en comida en los días que fue necesario.

Tabla 3. Coste de dietas.

Recurso	Unidades (h)	Coste Unitario (€/h)	Coste (€)
Desplazamientos	20,00	1,70	34,00
Comidas	20,00	5,00	100,00
	TOTAL		134,00 €

### 5. Desglose del presupuesto por partidos.

Los costes anteriores se evaluarán por capítulos realizando el desglose del presupuesto. No se consideran en estos capítulos los costes de los equipos y software, por cuanto son costes unitarios que no se pueden dividir.

**Tabla 4. Capítulo 1. Introducción.**

Capítulo	Recurso	Tarea	Unidades (h)	Coste Unitario (€/h)	Coste (€)
1. Introducción	Ingeniero Industrial (Alumno)	Recopilación de documentación.	5,00	30,18	150,90
		Redacción del proyecto.	5,00	30,18	150,90
		Tutorías/Reuniones con el tutor.	3,00	30,18	90,54
		<b>Mano de obra de Ingeniero Industrial</b>			<b>392,34 €</b>
	Ingeniero Industrial (Tutor)	Tutorías/Reuniones con el tutor.	3,00	54,32	162,97
		Corrección del proyecto.	2,00	54,32	108,648
			<b>Mano de obra de Ingeniero Industrial</b>		<b>162,97 €</b>
		<b>TOTAL Mano de Obra</b>		<b>434,59 €</b>	

**Tabla 5. Capítulo 2. Estado del arte.**

Capítulo	Recurso	Tarea	Unidades (h)	Coste Unitario (€/h)	Coste (€)
2. Estado del arte	Ingeniero Industrial (Alumno)	Recopilación de documentación.	5,00	30,18	150,90
		Redacción del proyecto.	8,00	30,18	241,44
		Tutorías/Reuniones con el tutor.	3,00	30,18	90,54
		<b>Mano de obra de Ingeniero Industrial</b>			<b>482,88 €</b>
	Ingeniero Industrial (Tutor)	Tutorías/Reuniones con el tutor.	3,00	54,32	162,972
		Corrección del proyecto.	8,00	54,32	434,592
			<b>Mano de obra de Ingeniero Industrial</b>		<b>597,56 €</b>
		<b>TOTAL Mano de Obra</b>		<b>1.080,44 €</b>	

**Tabla 6. Capítulo 3. Metodología.**

Capítulo	Recurso	Tarea	Unidades (h)	Coste Unitario (€/h)	Coste (€)
3. Metodología	Ingeniero Industrial (Alumno)	Recopilación de documentación.	10,00	30,18	301,80
		Búsqueda y tratamiento de datos.	85,00	30,18	2565,30
		Análisis y elección de datos	30,00	30,18	905,40
		Redacción del proyecto.	15,00	30,18	452,70
		Tutorías/Reuniones con el tutor.	2,00	30,18	60,36
		<b>Mano de obra de Ingeniero Industrial</b>			<b>4.285,56 €</b>
	Ingeniero Industrial (Tutor)	Tutorías/Reuniones con el tutor.	2,00	54,32	108,648
		Corrección del proyecto.	12,00	54,32	651,888
			<b>Mano de obra de Ingeniero Industrial</b>		<b>760,54 €</b>
		<b>TOTAL Mano de Obra</b>		<b>5.046,10 €</b>	

**Tabla 7. Capítulo 4. Implementación de la red.**

Capítulo	Recurso	Tarea	Unidades (h)	Coste Unitario (€/h)	Coste (€)
4. Implementación de la red.	Ingeniero Industrial (Alumno)	Recopilación de documentación.	5,00	30,18	150,90
		Modelado experimental y programación informática.	40,00	30,18	1207,20
		Redacción del proyecto.	10,00	30,18	301,80
		Tutorías/Reuniones con el tutor.	2,00	30,18	60,36
		<b>Mano de obra de Ingeniero Industrial</b>			<b>1.720,26 €</b>
	Ingeniero Industrial (Tutor)	Tutorías/Reuniones con el tutor.	2,00	54,32	108,648
		Corrección del proyecto.	9,00	54,32	488,916
			<b>Mano de obra de Ingeniero Industrial</b>		<b>597,56 €</b>
		<b>TOTAL Mano de Obra</b>		<b>2.317,82 €</b>	

**Tabla 8. Capítulo 5. Caso de aplicación.**

Capítulo	Recurso	Tarea	Unidades (h)	Coste Unitario (€/h)	Coste (€)
5. Caso de aplicación	Ingeniero Industrial (Alumno)	Recopilación de documentación.	5,00	30,18	150,90
		Modelado experimental y programación informática.	20,00	30,18	603,60
		Análisis de resultados.	15,00	30,18	452,70
		Redacción del proyecto.	10,00	30,18	301,80
		Tutorías/Reuniones con el tutor.	2,00	30,18	60,36
		<b>Mano de obra de Ingeniero Industrial</b>			<b>1.569,36 €</b>
	Ingeniero Industrial (Tutor)	Tutorías/Reuniones con el tutor.	2,00	54,32	108,648
		Corrección del proyecto.	8,00	54,32	434,592
			<b>Mano de obra de Ingeniero Industrial</b>		<b>543,24 €</b>
			<b>TOTAL Mano de Obra</b>		<b>2.112,60 €</b>

Tabla 9. Capítulo 6. Conclusiones finales.

Capítulo	Recurso	Tarea	Unidades (h)	Coste Unitario (€/h)	Coste (€)
6. Conclusiones finales	Ingeniero Industrial (Alumno)	Recopilación de documentación.	5,00	30,18	150,90
		Análisis de resultados.	10,00	30,18	301,80
		Redacción del proyecto.	5,00	30,18	150,90
		Tutorías/Reuniones con el tutor.	3,00	30,18	90,54
			<b>Mano de obra de Ingeniero Industrial</b>		<b>694,14 €</b>
	Ingeniero Industrial (Tutor)	Tutorías/Reuniones con el tutor.	3,00	54,32	162,972
		Corrección del proyecto.	1,00	54,32	54,324
			<b>Mano de obra de Ingeniero Industrial</b>		<b>217,30 €</b>
			<b>TOTAL Mano de Obra</b>		<b>911,44 €</b>

## 6. Presupuesto total.

El coste total se suma de las partidas de costes de mano de obra, costes de equipos y software, y los costes de dietas. El presupuesto total estima los gastos generales, el beneficio industrial y el 21% de I.V.A.

PRESUPUESTO TOTAL	Coste (€)
Coste de la mano de obra	12.041,82 €
Coste de equipos y software	1.421,00 €
Coste de dietas	134,00 €
<b>TOTAL EJECUCIÓN MATERIAL</b>	<b>13.596,82 €</b>
13% Gastos Generales	1.767,59 €
6% Beneficio Industrial	815,81 €
<b>TOTAL EJECUCIÓN POR CONTRATA</b>	<b>16.180,22 €</b>
21% I.V.A.	3.397,85 €
<b>TOTAL PRESUPUESTO C/IVA</b>	<b>19.578,06 €</b>