



Universidad Politécnica
de Madrid

**Escuela Técnica Superior de
Ingenieros Informáticos**



Grado en Matemáticas e Informática

Trabajo Fin de Grado

**Predicción de Demanda de Gas y
Electricidad Utilizando Técnicas
Estadísticas Avanzadas e Inteligencia
Artificial**

Autor: Guillermo Filgueira Fernández
Tutores: Belén Ríos Sánchez
Javier Reneses Guillén

Madrid, Junio 2024

Este Trabajo Fin de Grado se ha depositado en la ETSI Informáticos de la Universidad Politécnica de Madrid para su defensa.

Trabajo Fin de Grado
Grado en Matemáticas e Informática

Título: Predicción de Demanda de Gas y Electricidad Utilizando Técnicas Estadísticas Avanzadas e Inteligencia Artificial

Junio 2024

Autor: Guillermo Filgueira Fernández

Tutores: Javier Reneses Guillén

SimularT

Belén Ríos Sánchez

Departamento de Matemática Aplicada
a las TIC

Escuela Técnica Superior de Ingenieros Informáticos
Universidad Politécnica de Madrid

Resumen

Este Trabajo de Fin de Grado (TFG) trata sobre la predicción de demanda de electricidad, desarrollando diversos tipos de modelos, de corto y medio plazo. También se abordará la predicción de la demanda de otras fuentes de energía, ya que muchos factores son comunes, y el desarrollo de los modelos presenta muchas similitudes.

Antes de iniciar la implementación de los modelos, se llevó a cabo una investigación sobre el estado del arte, examinando cuáles son los modelos más utilizados, los más recientes, y cuáles son los resultados y el rendimiento de estos. También nos ocupamos de obtener los datos necesarios para el desarrollo de los modelos, asegurándonos de que sean datos de alta calidad.

Una vez estudiada la situación general y obtenidos los datos, se pasó a la implementación de modelos concretos. Se tratan en primer lugar los modelos de regresión múltiple. Se comienza revisando la literatura actual y los aspectos teóricos, para luego desarrollar distintos modelos y analizar los resultados. Posteriormente, se realiza un análisis de las variables que proporcionan una mayor capacidad predictiva, además de un análisis de correlación.

Posteriormente, se trabaja con modelos basados en series temporales. Para ello, se estudia primero su funcionamiento, luego se observan aquellos ya existentes y los distintos modelos de referencia para utilizarlos como base a mejorar. Finalmente, se desarrollan varios modelos, comparando los resultados y los errores.

Finalmente, se utiliza la inteligencia artificial para desarrollar modelos de redes neuronales de predicción de demanda de electricidad. Se examinan las distintas técnicas existentes y los diferentes tipos de modelos que se pueden utilizar, para luego desarrollar varios modelos de redes neuronales. Posteriormente, se realiza un análisis de resultados, variables y correlación.

Una vez desarrollados todos los modelos, se comparan las distintas técnicas utilizadas y se concluye evaluando qué modelos ofrecen mejores resultados y una mejor capacidad predictiva.

Los objetivos de este trabajo, principalmente, son los siguientes:

- Comparar distintos tipos de modelos para ver cuáles se ajustan mejor a la predicción de demanda de electricidad.
- Obtener un modelo que nos permita predecir la demanda de electricidad de

forma eficaz mejorando los resultados de otros modelos actuales.

- Analizar cuáles son las variables que nos ofrecen una mayor capacidad predictiva y cuáles son aquellas que apenas nos aportan información y son desechables.

Abstract

This Final Degree Project (TFG) deals with electricity demand forecasting, developing different types of short and medium term models. It will also deal with the prediction of demand for other energy sources, since many factors are common, and the development of the models has many similarities.

Before starting the work, an investigation of the state of the art is carried out, examining which are the most used models, the most recent ones, and what are the results and performance of these models. We will also take care of obtaining the data necessary for the development of the models, making sure that the data is of high quality.

Next, we will first discuss multiple regression models. We will start by reviewing the current literature and theoretical issues, and then develop different models and analyse the results. Subsequently, an analysis of the variables that provide a greater predictive capacity is carried out, in addition to a correlation analysis.

Subsequently, We will move on to working with multiple regression models. We will start again by reviewing the current literature and theoretical aspects, and then develop different models and analyse the results. Subsequently, we will analyse the variables that provide us with the greatest predictive capacity, in addition to a correlation analysis.

Finally, artificial intelligence is used to develop electricity demand forecasting models. The different existing techniques and the different types of models that can be used are examined, and then several neural network models are developed. Subsequently, an analysis of results, variables and correlation is carried out.

Once all the models have been developed, the different techniques used are compared and it is concluded by evaluating which models offer better results and a better predictive capacity.

The main objectives of this work are the following:

- To compare different types of models to see which ones are best suited to electricity demand forecasting.
- To obtain a model that allows us to predict electricity demand efficiently, improving the results of other current models.

- To analyse which variables offer us greater predictive capacity and which are those that barely provide us with information and are disposable.

Tabla de contenidos

1. Introducción	1
1.1. Objetivos	3
1.2. Planificación del trabajo	3
1.3. Estructura de la memoria	4
2. Estado del Arte	5
2.1. Mercado eléctrico	5
2.2. Modelos de Predicción	8
3. Fundamentos Técnicos	11
3.1. Metodología	11
3.2. Obtención de los datos	12
3.3. Preprocesamiento de los datos	13
3.4. Desarrollo de los modelos	13
3.4.1. Modelos basados en regresión lineal múltiple	13
3.4.2. Modelos basados en series temporales	14
3.4.3. Modelos basados en Redes Neuronales	16
3.5. Métricas	22
4. Entrenamiento y Resultados	25
4.1. Modelos basados en regresión lineal múltiple	25
4.2. Modelos basados en series temporales	33
4.2.1. Modelos ARIMA y derivados	33
4.2.2. Modelo TBATS	41
4.3. Modelos basados en Redes Neuronales	47
4.3.1. Multilayer Perceptron (MLP)	47
4.3.2. Convolutional Neural Network (CNN)	52
4.3.3. Long Short-Term Memory (LSTM) Network	57
4.3.4. Modelo híbrido LSTM-DNN	58
4.3.5. Modelo Transformer Encoder	63
4.3.6. Métricas de error para los modelos de redes neuronales	66
4.4. Comparativa	67
5. Conclusiones y trabajo futuro	69
6. Análisis de impacto	71

TABLA DE CONTENIDOS

Bibliografía

73

Capítulo 1

Introducción

La predicción de la demanda energética siempre ha sido una tarea de cierto interés, ya que puede proporcionar numerosos beneficios. En las últimas décadas, se han hecho grandes esfuerzos por desarrollar y perfeccionar distintas técnicas para cumplir con este objetivo, con mayor o menor acierto. Sin embargo, en los últimos años, debido a varios factores, esta tarea se ha vuelto más compleja. Entre las causas se encuentran un mayor número de fuentes de energía gracias a las energías renovables, el aumento de los factores que influyen en la demanda, y una mayor variabilidad en los mismos [1][2]. Cabe añadir el complejo marco regulatorio. Por consiguiente, el interés de obtener mejores modelos de predicción en este campo se ha disparado. Además, el mercado se ha vuelto más dinámico, y en los últimos 10 años, se han desarrollado y probado múltiples métodos para la predicción de demanda de gas y electricidad [3].

Del mismo modo la predicción de la demanda de electricidad es un proceso esencial en la gestión eficiente del sistema eléctrico. A través de modelos y técnicas avanzadas, se anticipa cuánta energía será requerida por los consumidores en un período futuro. Esta predicción tiene un impacto significativo en la planificación de la generación, la distribución y la estabilidad del suministro eléctrico. La demanda de electricidad varía a lo largo del día, la semana y las estaciones del año. La predicción precisa es crucial para evitar desequilibrios entre la oferta y la demanda. Si se subestima la demanda, podrían producirse apagones, mientras que si se sobreestima, se desperdiciarían recursos [4][5].

De esta manera, el pronóstico de la carga eléctrica es sumamente importante para garantizar la generación de electricidad suficiente y confiable para satisfacer la demanda futura. La precisión en las predicciones de carga resulta en mejoras en la eficiencia energética, reducción de costos operativos y aumento de los ingresos para las empresas eléctricas. Investigaciones previas han subrayado la relevancia de reducir los errores en el pronóstico de carga, ya que incluso una disminución del 1% en el error puede resultar en ahorros significativos, de incluso millones de euros, lo que subraya la necesidad de desarrollar métodos de pronóstico más precisos y efectivos [6].

Dependiendo del horizonte temporal para el que se desarrollen los modelos, las

Capítulo 1. Introducción

aplicaciones de los mismos y sus posibles utilidades serán distintos. Los que acabamos de mencionar son sobre todo para el corto o incluso medio plazo. Es ciertamente subjetivo definir las fronteras entre los distintos horizontes, ya que se trata de una variable continua y las distinciones son difusas. Cuanto menor sea el horizonte temporal, mayor impacto tendrán los modelos en la planificación energética a corto plazo. Esto influirá, por ejemplo, en la optimización de los recursos disponibles por particulares, o en que la industria pueda optimizar sus operaciones diarias. Mientras que cuanto más lejano sea el horizonte temporal, los modelos tendrán un mayor valor para la planificación a largo plazo y la gestión de la infraestructura [7].

Por otro lado, los modelos pueden tener grandes repercusiones tanto a largo como a corto plazo, como ya se ha visto anteriormente. En primer lugar, en el corto plazo, las buenas predicciones pueden generar beneficios por distintas vías, tanto ayudando en la programación de operaciones a corto plazo de cargas industriales para minimizar los costos, como para realizar operaciones en el mercado de la electricidad, aumentando los beneficios progresivamente a medida que aumenta la calidad de las predicciones, especialmente en industrias con un alto coste energético [8]. Por otra parte, la predicción de la demanda a largo plazo influye en la planificación de inversiones en infraestructuras eléctricas, tanto para iniciativas privadas como estatales. Las empresas o instituciones anticipan la demanda futura para construir nuevas plantas generadoras o ampliar las existentes de manera eficiente. Así, evalúan la rentabilidad de las inversiones antes de su realización [9].

Además, cabe mencionar que dependiendo de la fuente de energía, aunque se comportan de manera similar, existen ciertas particularidades. En este trabajo se trabajará principalmente con la electricidad, y aunque su comportamiento es parecido al de, por ejemplo, el gas, hay pequeñas diferencias. En el caso del gas natural, la predicción de la demanda es crucial para equilibrar la oferta y la demanda en los sistemas de suministro de gas, evitando costosos errores en las estimaciones que podrían resultar en pérdidas económicas significativas para las Compañías de Distribución Local (LDCs). Además, una predicción precisa es fundamental para evitar interrupciones en el servicio, la extracción costosa de gas de almacenamiento o la compra adicional de gas en el mercado, lo que puede generar perjuicios económicos para las LDCs [10].

En este trabajo, se va a abordar en profundidad la predicción de la demanda de electricidad en España. No obstante, el comportamiento que tiene la demanda de gas es muy parecido. Por tanto, los procedimientos y análisis que se han realizado en este trabajo se pueden trasladar a la predicción de la demanda de gas. Los patrones estacionales y las causas de las variaciones de la demanda tienden a converger, y es probable que también lo hagan para otras fuentes de energía. Por tanto, en este trabajo se desarrollan en específico modelos para la predicción de la demanda de electricidad, pero debemos generalizar esta forma de proceder para la predicción de la demanda de gas, ya que si un tipo de modelo es bueno para pronosticar la demanda de electricidad, también lo hará bien para la demanda de gas, y viceversa.

Es decir, aunque en este trabajo se muestren solo ejemplos para la demanda de electricidad, con los conocimientos adquiridos, se podrían desarrollar modelos de predicción de demanda de gas de manera bastante sencilla.

1.1. Objetivos

El objetivo principal de este trabajo es obtener un modelo de predicción de demanda de electricidad que nos permita obtener resultados que se ajusten lo máximo posible a la realidad, permitiéndonos hacer predicciones a corto plazo con cierta seguridad. Para ello, tendremos una serie de objetivos intermedios:

- Obtención de los datos necesarios para el desarrollo de los modelos, y preprocesamiento de los mismos para tener un conjunto de datos fiable, suficientemente grande, y con datos de alta calidad que nos permita establecer unas bases sólidas.
- Estudio de la literatura actual, que nos permita tener ciertos modelos como referencia, para saber qué resultados son aceptables y con qué se está trabajando actualmente.
- Desarrollo de varios modelos de regresión lineal múltiple para la predicción de demanda de electricidad, utilizando el dataset ya obtenido.
- Desarrollo de varios modelos basados en series temporales para la predicción de demanda de electricidad, utilizando el dataset ya obtenido.
- Desarrollo de varios modelos utilizando distintas técnicas de inteligencia artificial para la predicción de demanda de electricidad, utilizando el dataset ya obtenido.
- Comparación y análisis de todos los modelos ya desarrollados para obtener aquel o aquellos que nos ofrecen los mejores resultados. Estudio y análisis de las variables utilizadas para el desarrollo de los distintos modelos, viendo cuales de ellas nos ofrecen una mayor capacidad predictiva, permitiéndonos crear modelos de mayor calidad. Análisis de autocorrelación de variables.
- Escritura de una memoria que recoja todo lo hecho anteriormente.

1.2. Planificación del trabajo

Para este trabajo de fin de grado, la distribución del tiempo planeada para la realización de las distintas tareas es la siguiente:

- Estudio bibliográfico de la literatura actual desde una perspectiva general para adquirir un conocimiento básico de los distintos modelos y técnicas para la predicción de la demanda de gas y electricidad (24 horas).
- Obtención y preprocesamiento de los datos a utilizar para el entrenamiento de los modelos (30 horas).

Capítulo 1. Introducción

- Estudio y desarrollo de modelos de predicción de demanda de electricidad utilizando regresión lineal múltiple (60 horas).
- Estudio y desarrollo de modelos de predicción de demanda de electricidad utilizando series temporales (60 horas).
- Estudio y desarrollo de modelos de predicción de demanda de electricidad utilizando técnicas de inteligencia artificial (60 horas).
- Análisis de resultados y comparación de modelos utilizando métricas comunes (30 horas).
- Escritura de la memoria (60 horas).

1.3. Estructura de la memoria

La memoria del trabajo seguirá la siguiente estructura:

- Capítulo 2: Estado del arte. En él se recogen los distintos modelos y tecnologías existentes actualmente, realizando una breve explicación de las mismas, así como sus resultados. En este capítulo también se detallarán las distintas técnicas que utilizaremos posteriormente, así como también se cubrirán los distintos conceptos más técnicos que necesitaremos conocer para el entendimiento del trabajo.
- Capítulo 3: Fundamentos técnicos. En este capítulo se muestran los detalles técnicos de los modelos a utilizar, la metodología a seguir, y las métricas de error a utilizar. En cuanto a los modelos, en primer lugar se hace una breve descripción técnica de cada modelo, y se detalla brevemente cómo se utilizará en nuestro problema.
- Capítulo 4: Implementación y Resultados. En este capítulo desarrollaremos todos los modelos, por lo que se detallará el proceso de implementación de los mismos, mostrando los pasos seguidos en cada momento y explicando los razonamientos que motivan las distintas decisiones. Además se realizará una comparación de los distintos modelos desarrollados utilizando varias métricas de medición de errores, y se llevará a cabo un análisis de aquellas variables que tienen un mayor impacto en los modelos.
- Capítulo 5: Conclusiones. Basándose en el trabajo realizado previamente, se detallarán las conclusiones obtenidas, así como las fortalezas y debilidades de los modelos, y las vías que explorar en el futuro.
- Capítulo 6: Análisis de impacto. En este capítulo se detallará el impacto que pueda tener el trabajo, tanto para la empresa y el sector energético, como para la sociedad y el medio ambiente.

Capítulo 2

Estado del Arte

En este capítulo se va a tratar los trabajos previos que debemos hacer antes de empezar a desarrollar los modelos. Empezaremos explicando brevemente el funcionamiento del mercado eléctrico para crear contexto, tratando aspectos técnicos. Seguiremos profundizando en el estado del arte actual, explorando que modelos se utilizan actualmente, los resultados con los que se está trabajando actualmente en la industria, y visualizando las distintas opciones. Finalizaremos definiendo las métricas con las que vamos a operar en este trabajo.

2.1. Mercado eléctrico

El mercado eléctrico español tiene una forma de funcionar, y ciertas particularidades que vamos a mostrar ahora, que son interesantes conocer para tener perspectiva. Está gestionado por el OMIE (Operador del Mercado Ibérico de Energía), que es la entidad encargada de gestionar el mercado, garantizar el equilibrio entre oferta y demanda, y asignar la energía a las comercializadoras. OMIE gestiona la totalidad de los mercados eléctricos (diarios e intradiarios) de toda la Península Ibérica. Su forma de operar es similar a la aplicada por muchos otros mercados europeos. A través de OMIE, se realizan subastas horarias para determinar el precio de la energía eléctrica. Los generadores ofertan la energía que han producido, y los precios se fijan según la oferta y la demanda [11].

El mercado eléctrico español se caracteriza por ser un sistema bifronte, compuesto por un mercado mayorista y un mercado minorista.

Mercado mayorista

En el mercado mayorista se produce la subasta de la energía, regulada por el OMIE. Las subastas determinan el precio de la energía eléctrica. Estas subastas se realizan de manera periódica y permiten a los agentes del mercado adquirir la energía necesaria para satisfacer la demanda de los consumidores. Durante la subasta, los generadores ofertan la energía que han producido, y los precios se fijan según la oferta y la demanda. Esto influye directamente en los precios que pagamos en nuestras facturas de luz, aunque influyen muchos factores más,

Capítulo 2. Estado del Arte

que veremos por encima después, por ello a veces vemos que la electricidad se está negociando a un precio de 0, pero la acabamos pagando más cara [11] [12].

Las subastas eléctricas son cruciales para equilibrar la oferta y la demanda en tiempo real. Si se subestima o sobreestima la demanda, podría haber apagones o desperdicio de recursos. Además, estas subastas afectan la planificación de inversiones en infraestructuras eléctricas. Las empresas deben anticipar la demanda futura para construir o ampliar plantas generadoras de manera eficiente [13].

En el mercado eléctrico participan los distintos agentes de mercado:

- **Generadores:** Son las empresas que producen electricidad a partir de diferentes fuentes de energía, como centrales térmicas, nucleares, hidráulicas, eólicas y solares. También puede haber generadores particulares, pero suponen una parte menor de la cantidad ofertada [12].
- **Comercializadoras:** Son las empresas que compran la electricidad en el mercado mayorista para venderla a los consumidores finales. A estas es a las que les contratamos la electricidad. Hay empresas que son tanto generadores como comercializadoras, se les denomina empresas integradas. Tenemos ejemplos como Endesa, Iberdrola o Naturgy [12].

El mercado mayorista funciona de la siguiente manera:

- **Subasta diaria:** Cada día, las comercializadoras presentan sus ofertas de compra indicando la cantidad de electricidad que necesitan para cada hora del día siguiente. Por su parte, los generadores presentan sus ofertas de venta indicando la cantidad de electricidad que pueden producir a cada precio [12] [13].
- **Precio único:** El OMIE realiza una subasta para cada hora del día siguiente, donde se fija un precio único para la electricidad en función de la oferta y demanda. Este precio es el mismo para todos los agentes que participan en el mercado [12] [13].
- **Casamiento de ofertas:** El OMIE asigna la energía a las comercializadoras que hayan presentado las ofertas más competitivas, cubriendo primero las ofertas con menor precio. Las comercializadoras no cubiertas en la subasta pueden comprar energía al precio de ajuste, que suele ser más elevado [12] [13].

Mercado minorista

Es en el que compra la energía la mayoría de los hogares y gran parte de los particulares. En este mercado participan los siguientes agentes:

- **Comercializadoras:** Son las mismas empresas que operan en el mercado mayorista, pero en este caso ofrecen diferentes tarifas a los consumidores finales [13].

2.1. Mercado eléctrico

- Consumidores: Son los particulares, hogares y empresas, que utilizan la electricidad [13].

El mercado minorista funciona de la siguiente manera. Los consumidores pueden elegir libremente la comercializadora con la que quieren contratar su suministro eléctrico. Las comercializadoras fijan libremente sus tarifas, dentro de un marco regulatorio establecido por el Gobierno. Existen diferentes tipos de tarifas, como la tarifa regulada (PVPC) o las tarifas a precio de mercado. Los consumidores pagan a la comercializadora la electricidad consumida, según la tarifa contratada. La factura incluye el precio de la energía, los peajes de la red eléctrica y otros cargos [14].

Por último, cabe resaltar que hay muchos más factores que influyen sobre el precio que se acaba pagando en la factura de electricidad, cómo los impuestos, regulaciones estatales, distintos tipos de acuerdos o compromisos que garantizan el suministro, o coberturas a largo plazo que hacen las propias empresas. Un ejemplo son los PPA (Power Purchase Agreement), que es un acuerdo de compraventa de energía limpia a largo plazo a un precio prefijado entre un desarrollador renovable y un consumidor [15]. En la figura 2.1 podemos observar gráficamente el funcionamiento del mercado eléctrico en España.

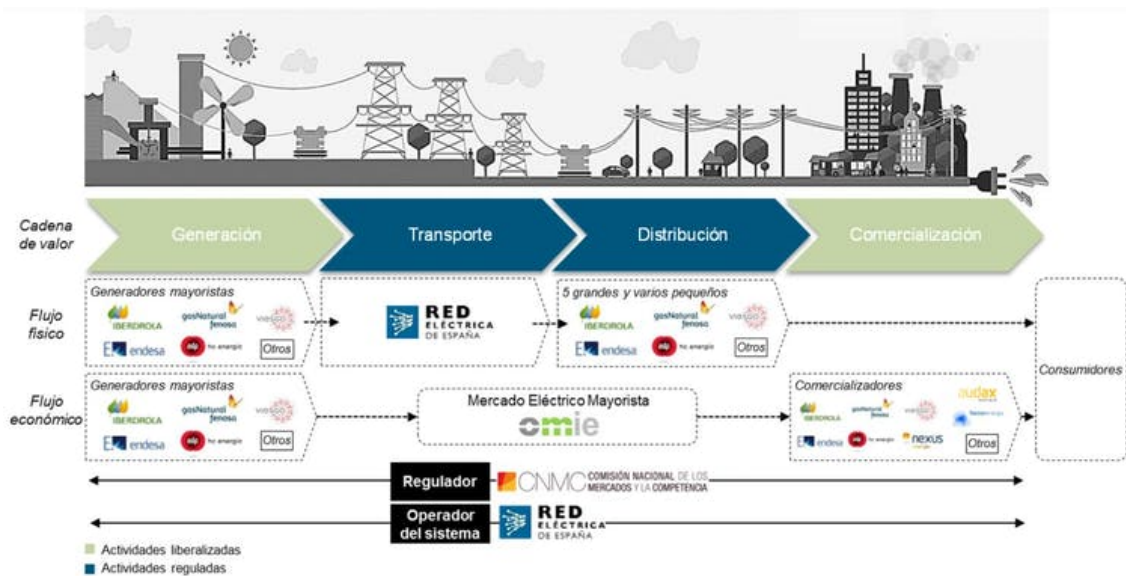


Figura 2.1: Mercado eléctrico en España

La generación eléctrica utiliza diversas tecnologías y materias primas: Centrales térmicas: Utilizan carbón, gas o fuelóleo para generar vapor y producir energía eléctrica. Centrales hidráulicas: Aprovechan la energía del agua en ríos o embalses mediante generadores. Centrales nucleares: Basadas en la fusión de núcleos de uranio. Generación eólica y solar: Aprovechan la energía cinética del viento y la radiación solar. Biomasa: Utiliza combustibles orgánicos. Energías del mar y geotermia: Aprovechan mareas, corrientes, cambios de temperatura y calor bajo la superficie terrestre.

2.2. Modelos de Predicción

Antes de empezar a desarrollar los modelos de predicción de la demanda, se analizó la situación actual en lo que se refiere a este tipo de modelos. Veremos qué técnicas se utilizan, qué resultados se manejan, y cual es la forma de trabajar. Así, tendremos una base con la que empezar a trabajar, y luego desarrollar, y podremos tener algún modelo como base o referencia, para luego compararlo con nuestros propios modelos y ver si son buenos.

En función del horizonte temporal de las predicciones, podemos distinguir entre modelos de muy corto plazo, de corto plazo, de medio plazo y de largo plazo [16].

- Modelos de muy corto plazo. Intentan predecir la demanda a muy corto plazo, desde segundos o minutos hasta varias horas. Estos modelos se utilizan generalmente para controlar el flujo energético. Son útiles para el control automático de la generación de energía y su gestión. Se espera de ellos que sean muy precisos [6].
- Modelos de corto plazo. Se enfocan en predecir la demanda a corto plazo, generalmente para el día siguiente o para las próximas horas, o incluso una semana. Consideran factores como la hora del día, el día de la semana, las condiciones climáticas a corto plazo, eventos especiales y los últimos precios de la energía. Se utilizan sobre todo para la gestión operativa de los sistemas de energía, como la programación de la generación de energía y la asignación de recursos [17].
- Modelos de medio plazo. Se utilizan para predecir la demanda a medio plazo, generalmente para las próximas semanas o meses. Consideran factores adicionales a los del corto plazo, como tendencias estacionales, patrones de consumo históricos, factores económicos y sociales, y pronósticos de condiciones climáticas a medio plazo. Se utilizan para la planificación de la compra de electricidad, la gestión del inventario y la asignación de recursos energéticos de manera más eficiente [17].
- Modelos de largo plazo. Se utilizan para predecir la demanda a largo plazo, generalmente para el próximo año o varios años. Consideran factores que influyen en la demanda a largo plazo, como el crecimiento económico, los cambios demográficos, las políticas energéticas, los avances tecnológicos y los escenarios climáticos, así como los cambios regulatorios. Se utilizan para la planificación de la inversión en infraestructura energética, la expansión de la capacidad de generación y la elaboración de estrategias energéticas a largo plazo [17].

En general, cuanto menor es el horizonte de predicción, mejores se espera que sean las predicciones, y a medida que aumenta este horizonte, aumenta progresivamente la variabilidad, y por tanto, menos fiables son las predicciones, ya que pueden suceder numerosos eventos no predecibles que pueden afectar de manera decisiva a la demanda. A su vez, los modelos de más corto plazo suelen estar basados en métodos estadísticos, como las series temporales, los modelos de regresión, modelos de inteligencia artificial, etc. Por otra parte, para el

medio/largo plazo, suelen ser más utilizados los métodos fundamentales, como modelos estructurales, o de equilibrio de mercado (teoría de juegos, Cournot, equilibrio oferta/demanda...) [17].

Para este trabajo, nos vamos a centrar en los modelos de predicción de corto y medio plazo. Como punto de partida es necesario tener unos modelos que sirvan como referencia, para evaluar si los resultados de los modelos propuestos son buenos. En el sector, se suelen utilizar los modelos de Tao Hong como referencia para el desarrollo. Se trata de modelos robustos, que ofrecen unos resultados bastante buenos y tienen una gran trayectoria [18]. Investigando los resultados que se suelen obtener, hemos encontrado una investigación que muestra los resultados de modelos de regresión lineal múltiple no muy complejos, basados en las variables más importantes, y vemos que para el horizonte desde un día hasta una semana, se obtienen unas métricas de error MAPE de alrededor del 5% [19].

En cuanto a las técnicas utilizadas hemos revisado de distintos tipos, haciendo énfasis en las más utilizadas. En primer lugar, las series temporales. Estos modelos utilizan datos históricos de demanda para identificar patrones y tendencias que luego se extrapolan al futuro. Los métodos de series temporales, según lo que hemos visto, más utilizados, son los ARIMA, ARMAX y SARIMA [17]. También tenemos modelos econométricos, que incorporan factores económicos y sociales que influyen en la demanda, como el precio de la energía, las condiciones climáticas, los días de la semana y los días festivos. Los modelos econométricos más comunes son los modelos de regresión lineal y modelos de vectores autorregresivos (VAR) [20].

Otros modelos muy utilizados y que ofrecen grandes resultados son los modelos de aprendizaje automático, debido a su capacidad para manejar grandes conjuntos de datos complejos y no lineales. Algunos de los algoritmos de aprendizaje automático o inteligencia artificial más utilizados son [20]:

- Redes neuronales artificiales (RNA): Las RNA son particularmente útiles para modelar dependencias temporales en los datos de demanda. Las redes neuronales recurrentes (RNN) y las redes neuronales convolucionales (CNN) son arquitecturas de RNA comunmente utilizadas en la predicción de la demanda.
- Árboles de decisión: Los árboles de decisión crean reglas de decisión jerárquicas para predecir la demanda en función de variables de entrada como la hora del día, el día de la semana, las condiciones climáticas y los precios de la energía.
- Máquinas de soporte vectorial (SVM): Las SVM son clasificadores que pueden usarse para encontrar patrones en los datos de demanda y luego predecir la demanda futura.

Por último, se encuentran los modelos híbridos. Los modelos híbridos combinan elementos de modelos tradicionales y de aprendizaje automático para aprovechar las ventajas de ambos enfoques. Por ejemplo, un modelo híbrido podría utilizar un modelo de series temporales para identificar tendencias a largo plazo

Capítulo 2. Estado del Arte

en la demanda y luego usar una red neuronal artificial para modelar las variaciones en el corto plazo. Este tipo de modelos son muy interesantes, y ofrecen resultados muy prometedores [20].

Capítulo 3

Fundamentos Técnicos

En este capítulo se detallarán los modelos de predicción a utilizar, así como la metodología empleada para el desarrollo de los mismos y los datos a utilizar.

3.1. Metodología

Para el desarrollo de los modelos en este trabajo, después de estudiar las distintas opciones, se ha decidido utilizar los siguientes lenguajes y herramientas. La mayor parte del trabajo se ha realizado en python[21], por ser un lenguaje de amplio uso, con muchas posibilidades, y fácilmente exportable. En él, desarrollaremos modelos basados tanto en regresión lineal múltiple e inteligencia artificial, como en series temporales. Para trabajar en python, utilizaremos el entorno de desarrollo *Jupyter Notebook*[22], por ser un entorno altamente interactivo y fácilmente exportable, que nos permitirá ver de manera fácil y visual los resultados.

Dentro de python, utilizaremos numerosas librerías que nos ayudarán a crear los modelos. En esta sección solo haremos mención a las principales, mientras que más adelante se especificará el resto conforme hagamos uso de las mismas. Las librerías utilizadas incluyen:

- Utilizaremos los *Dataframe* de Pandas[23] y los *array* de Numpy[24] para el correcto manejo de los datos y el preprocesamiento de los mismos, así como para algunas operaciones matemáticas y transformaciones con los datos.
- Utilizaremos Sklearn[25] para el desarrollo de los modelos basados en regresión lineal múltiple.
- Vamos a utilizar la función *autoarima* de la librería de python llamada *pm-darima* [26].
- Gracias a la librería *Tbats*, podremos desarrollar modelos de series temporales en python teniendo en cuenta diversos factores como la tendencia o la doble estacionalidad. Esto se explicará más adelante en mayor profundidad.

- Por último, se utilizará la librería Tensorflow[27] para crear los modelos de redes neuronales.

Además de python, también se utilizará R para implementar los modelos de series temporales ARIMA y SARIMA, en el entorno de desarrollo RStudio. Este cambio de lenguaje se debe a que en la empresa en la que se está desarrollando este trabajo, se tiene bastante experiencia en la utilización de R para este tipo de modelos, por lo que esta opción es muy interesante, tanto para los intereses de la empresa, ya que están más habituados a utilizar R, como para este trabajo, ya que nos podremos nutrir de sus conocimientos.

3.2. Obtención de los datos

Para el desarrollo de los modelos, será imprescindible contar con datos para realizar los entrenamientos. Pero estos datos, deben cumplir ciertos requisitos. En primer lugar, deben ser de calidad, es decir, deben ser correctos y corresponderse con la realidad que representan. Por tanto, lo óptimo es que beban de una fuente oficial primaria.

En segundo lugar, estos datos deben ser suficientes para realizar nuestro entrenamiento. Los modelos necesitan de una gran cantidad de datos para poder establecer los patrones generales. Además, si el conjunto de datos es pequeño, pueden tener un ligero sesgo debido a circunstancias específicas de ese periodo temporal, y el modelo al entrenarse adquirirá dicho sesgo. Mientras que si los datos tienen cierto tamaño, acaba produciéndose una regresión a la media y se minimizan las situaciones atípicas.

Por último, los datos deben ser equilibrados. Esto quiere decir que no debe existir una representación excesiva de ningún tipo de datos. En nuestro caso, la mejor forma de evitar esto es no tener huecos en nuestra serie temporal, y buscar que exista una representación igual entre datos de días, meses u horas distintas.

En este trabajo, los datos primarios que vamos a utilizar son los datos de demanda y los datos de temperatura. Las demás variables beben de estos mismos datos y de factores temporales.

En cuanto a la temperatura, hemos obtenido los datos de la Agencia Estatal de Meteorología(AEMET)[28]. Se trata de los datos más fiables que hemos podido obtener para documentar el histórico de temperatura en España. La calidad de los datos obtenidos era muy buena, no había espacios temporales entre los datos, y se han conseguido datos desde julio de 2020 hasta principios de 2024.

En lo relativo a los datos históricos de demanda en España, que serán el núcleo de este trabajo, los hemos obtenido de la api de ESIOS, provenientes de red eléctrica[29]. Cabe mencionar que también se han conseguido datos desde julio de 2020 hasta principios de 2024. Se ha decidido empezar a recoger datos desde entonces, debido a causa de la pandemia y a todas las medidas económicas y políticas tomadas entonces, se marca un antes y un después en el comportamiento de la demanda. Además, los meses desde marzo hasta junio de 2020 son

excepcionales por las medidas de confinamiento.

3.3. Preprocesamiento de los datos

En total contamos con alrededor de 30000 datos horarios de demanda y temperatura. En general, la calidad de los datos es buena, y no se requiere demasiado preprocesamiento. Pero los datos horarios tienen un pequeño hueco de 1 hora cada vez que se produce un cambio horario, cada 12 meses más o menos. Por tanto, para esa hora restante, se ha interpolado haciendo la media entre la demanda de la hora anterior y la siguiente.

Además de eso, después de realizar un análisis de valores atípicos y de visualizar los datos, no se han detectado valores erróneos que debamos eliminar. Las transformaciones que se han tenido que realizar están más relacionadas con la unificación de los formatos de fechas, la extracción de las variables a partir de las fechas, y la unificación de todos los datos en una única tabla para su posterior utilización en los modelos. Se han realizado además algunas transformaciones para obtener las interacciones entre ciertas variables. En la siguiente figura 3.1, procederemos a mostrar los datos de demanda del conjunto de datos de entrenamiento.




Figura 3.1: Datos horarios de demanda a lo largo del tiempo

3.4. Desarrollo de los modelos

Una vez que tenemos unos datos fiables y listos para poder trabajar, pasaremos a la implementación de los distintos tipos de modelos.

3.4.1. Modelos basados en regresión lineal múltiple

Empezaremos trabajando con los modelos basados en regresión lineal múltiple. Los modelos de regresión lineal múltiple son una técnica estadística utilizada para analizar la relación entre una variable dependiente y dos o más variables

Capítulo 3. Fundamentos Técnicos

independientes. En el contexto de la carga eléctrica, estos modelos permiten predecir la demanda de energía eléctrica en función de múltiples factores, como la temperatura, la hora del día o el día de la semana, entre otros [30]. La ecuación de un modelo de regresión lineal múltiple se expresa como una combinación lineal de las variables independientes, ponderadas por coeficientes que se estiman a partir de los datos [31]. Un modelo de regresión lineal múltiple se define mediante esta ecuación:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_{p-1} X_{i,p-1} + e_i \quad (1)$$

donde $\beta_0 \dots \beta_{p-1}$ son los parámetros, $X_{i1} \dots X_{i,p-1}$ son las constantes conocidas y e_i es la variable independiente normalmente distribuida ($N(0, \sigma^2)$). La función de respuesta del modelo es:

$$E[Y] = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_{p-1} X_{p-1} \quad (2)$$

donde $X_1 \dots X_{p-1}$ son las $p - 1$ variables predictivas.

Si bien existen otras técnicas de pronóstico más avanzadas, como los modelos de redes neuronales artificiales, los modelos de regresión lineal múltiple siguen siendo ampliamente utilizados en la industria eléctrica debido a su robustez, facilidad de implementación y capacidad para proporcionar información interpretable sobre los factores que afectan la demanda de energía. Los modelos de regresión lineal múltiple permiten no solo predecir la carga eléctrica en función de múltiples variables, sino también identificar la contribución relativa de cada variable independiente en la variabilidad de la demanda [31].

De ahora en adelante, para ajustar y validar los modelos, vamos a dividir el conjunto de datos en una parte dedicada al entrenamiento de los modelos, y otra que utilizaremos para la parte de validar los resultados y evaluar los modelos. De esta forma, evaluaremos los resultados de una forma más realista, ya que si evaluamos los modelos con los mismos datos con los que están siendo entrenados, en muchas ocasiones obtendremos resultados muy buenos, pero no reflejarían el comportamiento del modelo en un escenario real. Además, si el modelo peca de sobreajuste, nos saldrían unas métricas utópicamente buenas, en modelos con una capacidad predictiva que no estaría a la altura. Por ello, el tener unos datos de entrenamiento y otros de validación, nos puede también ayudar a comparar entre ambas métricas de error, para así poder detectar si los modelos están sobreajustados, algo que es probable que nos acabe pasando, sobre todo en modelos más complejos como aquellos basados en redes neuronales.

Hemos elegido una distribución de datos de 80% para el entrenamiento, y 20% para la validación.

3.4.2. Modelos basados en series temporales

A continuación se estudiaron los modelos basados en series temporales para intentar predecir la demanda. Los modelos de series temporales son modelos

estadísticos, como los modelos de regresión lineal, que funcionan identificando patrones en la evolución de los datos de una variable a lo largo del tiempo. Estos patrones se utilizan para hacer predicciones sobre el futuro. Hay muchos tipos diferentes de modelos de series temporales. En este trabajo vamos a trabajar principalmente con los modelos ARIMA y sus derivados.

Modelos ARIMA y derivados

Los modelos ARIMA (acrónimo del inglés autoregressive integrated moving average) son de los más populares y más utilizados dentro de los modelos de series temporales. Su origen está en el principio de Box-Jenkins [32]. Como se puede deducir de su nombre, los modelos ARIMA están formados por la combinación de tres componentes, el modelo autorregresivo (AR), el modelo de media móvil (MA) y el proceso de diferenciación. Se define a través de la siguiente fórmula [33]:

$$\hat{Y}_t = \delta + \phi_1 Y_{t-1} + \psi_1 e_{t-1} + \dots + \phi_p Y_{t-p} + \psi_q e_{t-q}$$

VARIABLES Y PARÁMETROS DE ARIMA:

Y_t : Variable dependiente

ϕ_p : Parámetro del proceso autorregresivo

δ : Constante

ψ_q : Parámetro de media móvil

e_{t-q} : Error

Los modelos ARIMA se definen para series temporales estacionarias. Si la serie que tenemos es no estacionaria, entonces se debe diferenciar los datos hasta que la serie se vuelva estacionaria [6]. Decimos que una serie de datos es estacionaria si sus propiedades estadísticas permanecen constantes a lo largo del tiempo. Técnicamente, se definen las series entre no estacionarias, con estacionariedad débil o estacionariedad completa. En este caso, para este problema, será importante que la media y la varianza se mantengan en un rango estrecho y controlado. Esto quiere decir que la serie no presente tendencias, ni cambios considerables en la variabilidad de los datos [34]. Para estabilizar la media, podremos aplicar la diferenciación, mientras que para estabilizar la varianza se aplica el proceso de Box-Cox.

Dado que los datos de la serie temporal que tenemos tienen estacionalidad (en concreto poseen dos estacionalidades principalmente, una estacionalidad semanal y otra diaria), vamos a empezar por ajustar un modelo SARIMA, que se corresponde con *Seasonal* ARIMA, para captar la estacionalidad [35]. La doble estacionalidad de los datos nos dificultará bastante la labor del ajuste de estos modelos, pero buscaremos soluciones.

Modelo TBATS

Por otro lado, vamos a intentar modelar este problema de una forma más precisa utilizando el modelo TBATS. El modelo TBATS (Trigonometric Box-Cox Autoregressive Trend and Seasonal components) es un método estadístico avanzado para analizar y modelar series temporales, que tiene en cuenta distintos factores y nos permite abordar problemas más complejos [36]. TBATS es un acrónimo que representa los componentes clave del modelo, donde cada letra representa:

- B: Transformación Box-Cox: Se aplica para estabilizar la varianza y hacer que los datos sean más normales. Esto es útil cuando la serie temporal presenta una variabilidad que depende de la variable tiempo en la serie, es decir, datos con heteroscedasticidad (varianzas desiguales en diferentes valores).
- T: Tendencia. Se utilizan para establecer la tendencia los splines, que son funciones que permiten modelar tendencias no lineales. En TBATS, los splines ayudan a capturar cambios suaves en la tendencia a lo largo del tiempo, por tanto, podremos capturar la tendencia general de la serie, ya sea lineal o no lineal, pudiendo así identificar y modelar tendencias a largo plazo en los datos.
- A: Errores ARMA. El modelo TBATS incorpora componentes autoregresivos para capturar la dependencia entre los valores pasados de la serie y los futuros. Esto es vital en el modelado de series temporales, ya que los valores anteriores suelen tener una gran influencia en los valores próximos.
- T: Estacionalidad trigonométrica. Este componente se utiliza para modelar la estacionalidad de forma eficiente. A diferencia de los modelos tradicionales, TBATS utiliza funciones trigonométricas para capturar patrones estacionales complejos y de diferentes frecuencias.
- S: Componentes estacionales. TBATS es capaz de manejar múltiples frecuencias estacionales. Esto es particularmente útil en datos que presentan estacionalidad en varias escalas de tiempo (por ejemplo, diaria, semanal, y anual). En nuestro caso, tenemos principalmente estacionalidad semanal y diaria, por lo que nos será de ayuda.

3.4.3. Modelos basados en Redes Neuronales

Los modelos de redes neuronales son una herramienta muy poderosa para la predicción de la demanda de electricidad, y para la modelización de muchos otros problemas en general, debido a su capacidad para aprender patrones complejos a partir de grandes conjuntos de datos. Estos modelos tienen la gran ventaja de poder capturar relaciones no lineales entre variables que son difíciles de identificar con métodos tradicionales, lo que les permite realizar predicciones más precisas y en nuestro caso, quizás reconocer más patrones para explicar el comportamiento de la demanda.

Las redes neuronales artificiales son un tipo de modelo de aprendizaje automático de inteligencia artificial inspirado en el funcionamiento del cerebro humano.

3.4. Desarrollo de los modelos

Están compuestas por un gran número de unidades interconectadas llamadas neuronas artificiales, que procesan y transmiten información. Las neuronas artificiales se organizan en capas, y cada capa puede tener un número diferente de neuronas. En general, encontramos tres tipos de capas, una primera de entrada, una o varias capas intermedias o capas ocultas y una capa de salida, todas ellas compuestas de neuronas que tienen pesos y sesgos [37].

En nuestro caso, la capa de entrada tendrá la dimensión del número de variables que tengamos en nuestros datos, variables como la temperatura, la demanda de la semana pasada, el día de la semana, la hora del día, etc. Esta capa recibe los datos y los empieza a procesar. Luego pasamos a unas capas intermedias, donde se procesan y analizan los datos de entrada, que puede estar formada por varias capas con un número variable de neuronas en función de la arquitectura que diseñemos. Las neuronas en las capas ocultas utilizan funciones de activación y unos pesos para procesar los datos. No todas las redes neuronales cuentan con capa intermedia. Por último, tenemos una capa de salida, que es la que devuelve el resultado final, y cuya dimensión, activación y tipo de salida dependerá del problema que estemos trabajando. En esta situación, devolverá la predicción de la demanda para los datos de entrada [38]. En la figura 3.2 se puede observar la arquitectura de una red neuronal básica.

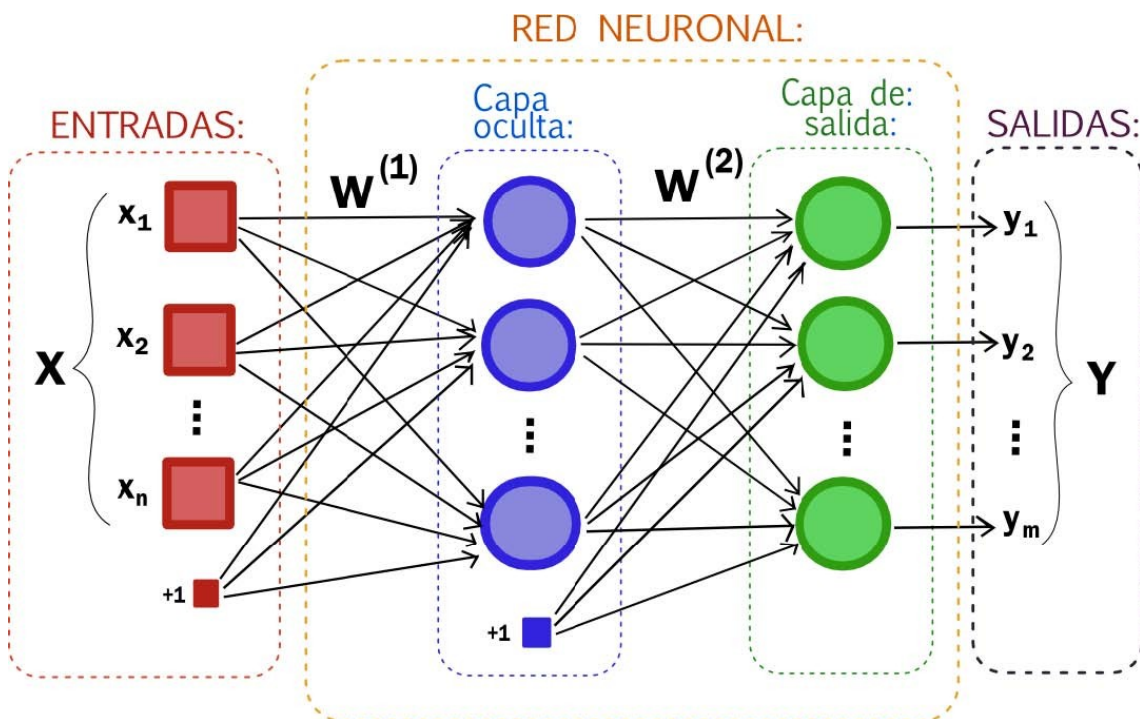


Figura 3.2: Arquitectura de una red neuronal

Las redes neuronales pueden tener distintas arquitecturas, cambiando así el número de capas y neuronas, y con ello el número de parámetros a optimizar. Además, una misma arquitectura puede utilizar distintas funciones de activación. En conclusión, en nuestro entrenamiento, podemos y debemos hacer cierta optimización de hiperparámetros, pero también es necesario tener cuidado, ya

Capítulo 3. Fundamentos Técnicos

que si optimizamos demasiado los hiperparámetros, podemos acabar con un modelo sobreajustado, un modelo que se adapta demasiado a los datos de entrenamiento y no es capaz de generalizar ante nuevos datos no vistos [39]. Por ello, queremos que todo aquello que modificamos tenga cierto sentido lógico, como por ejemplo, dar parámetros de entrada útiles, o utilizar una arquitectura que se adapte al problema.

También, a la hora de ajustar otros parámetros, debemos hacerlo con cierta coherencia. No suele ser demasiado útil optimizar cada uno de los parámetros [40]. En general, si nos pasamos a la hora de ajustar estos parámetros, llegará un momento en el que podamos disminuir el error en el conjunto de entrenamiento de una manera irrealista, pero luego al aplicar el modelo en el conjunto de evaluación el error permanezca igual o incluso aumente. En la siguiente figura 3.3, se muestra este fenómeno de forma muy simple y visual en un problema más sencillo. Por tanto, para evitar esto en nuestros modelos, debemos estar atentos en la optimización de nuestro modelo para parar justo antes de que alcancemos el momento de rendimientos decrecientes o incluso negativos.




Figura 3.3: Ejemplo sobreajuste contra subajuste

Por ello, nosotros para encontrar el mejor modelo posible para nuestro problema, vamos a dividir el proceso en dos partes. La primera ha sido encontrar las mejores arquitecturas de redes neuronales para nuestro problema, basándonos en factores técnicos y lógicos, así como depurándolas a través de ciertas pruebas. Luego optimizaremos ligeramente los parámetros de entrada para el entrenamiento del modelo, intentando quedarnos lo más cerca del punto perfecto de ajuste. Finalizaremos comparando los resultados de los distintos modelos y argumentando cuál de ellos nos parece mejor. Antes de mostrar los tipos de redes que utilizaremos, vamos a empezar explicando qué parámetros podríamos optimizar [41]:

- Número de epochs: Un epoch es una iteración completa sobre el conjunto de datos de entrenamiento. Demasiados epochs pueden llevar al sobreajuste que explicamos antes, y en los entrenamientos se suele llegar a un punto en el que ya apenas se mejoran los resultados, por lo que intentaremos parar en ese momento. Se puede configurar automáticamente un 'Early Stopping' en base a unos parámetros de parada personalizados, pero nosotros lo haremos manualmente. Pararemos en el momento que tengamos varias

iteraciones que no mejoren los resultados de la validación.

- **Tamaño del Batch (Batch Size):** El número de muestras que se utilizan para calcular el gradiente a la hora de actualizar los pesos. Los valores típicos pueden variar entre 32 y 256. Tamaños de batch grandes proporcionan estimaciones más precisas del gradiente, pero requieren más memoria. Por tanto, en este caso lo mejor será utilizar el mayor número posible que permita nuestro equipo y mantenga una velocidad de entrenamiento aceptable.
- **Función de Activación:** Función que determinan la salida de una neurona dada una entrada. Se pueden probar diferentes funciones de activación como ReLU, Leaky ReLU, tanh, y sigmoid en diferentes capas. En general para las capas ocultas la mejor opción suele ser ReLU, mientras que para la capa de salida suele funcionar una función lineal.
- **Ritmo de aprendizaje (Learning Rate):** Controla el tamaño de los pasos que da el optimizador durante la actualización de los pesos en las neuronas artificiales. En general, cuanto mayor sea más rápido aprenderá el modelo inicialmente, pero le costará más llegar a resultados más precisos, ya que los pasos pequeños permiten un ajuste más fino en la fase final del entrenamiento. Tampoco es bueno un valor demasiado pequeño, ya que puede provocar un estancamiento en mínimos locales.
- **Tipo de optimizador:** Los optimizadores son algoritmos o métodos utilizados para cambiar los atributos del modelo, como los pesos y los sesgos, con el fin de reducir la función de pérdida. Los más utilizados son Adam, SGD, o RMSprop, pero se pueden utilizar bastantes más. Para nuestro problema el optimizador Adam debería funcionar bien, ya que es muy robusto y se adapta a este tipo de problemas.
- También estaría la arquitectura del modelo, pero eso lo haremos en la parte de selección del modelo, donde escogeremos la mejor arquitectura, estableciendo el número de capas, así como el número de neuronas por capa.

A continuación se detallará el desarrollo y perfeccionamiento de nuestros modelo basados en redes neuronales para la predicción de la demanda.

Multilayer Perceptron (MLP)

Un modelo Multilayer Perceptron (MLP), es un tipo de red neuronal artificial (RNA) muy utilizada en el campo de los modelos de inteligencia artificial. Un modelo MLP está compuesto por una o más capas ocultas entre la capa de entrada y la capa de salida. Las neuronas en las capas se conectan entre sí mediante sinapsis, que tienen un peso asociado que determina la fuerza de la conexión. Las neuronas en cada capa se encuentran completamente conectadas entre sí, lo que significa que cada neurona recibe información de todas las neuronas de la capa anterior. Los modelos MLP son útiles para problemas de regresión, por lo que se adaptan a nuestro problema [38].

Convolutional Neural Network (CNN)

Las redes neuronales convolucionales (Convolutional Neural Networks, CNN) son un tipo de red neuronal artificial que han sido especialmente diseñadas para procesar y analizar datos estructurados en forma espacial o temporal regular, donde los datos se organizan en una matriz bidimensional o multidimensional, como imágenes, señales de audio y series temporales. Aunque las CNN se han utilizado tradicionalmente en el procesamiento de imágenes, su capacidad para extraer características relevantes y patrones complejos también las hace muy útiles para aplicarlas en la predicción de series temporales, en nuestro caso para la demanda de electricidad [42]. En el contexto de la predicción de demanda de energía, las CNNs pueden capturar patrones contextuales y temporales en la demanda de electricidad, como la influencia de el clima, los días festivos, el tiempo de la demanda y otros factores.

Entre las ventajas más destacadas de este tipo de redes neuronales tenemos la adaptabilidad a las series temporales, la capacidad de trabajar con grandes conjuntos de datos y la reducción de el ruido en los datos [43]. Las CNN se componen principalmente de cinco tipos de capas:

- **Capas Convolucionales:** Estas capas aplican filtros (kernels) a los datos de entrada para extraer sus características locales. Sobre estos filtros convolucionales, cada filtro es una matriz de pesos pequeña, y se calculan un producto escalar entre los valores de entrada y los pesos del filtro en cada posición.
- **Capas de Pooling:** Estas capas reducen la dimensionalidad de los datos, conservando la información más importante. Esto ayuda a reducir el número de parámetros y a controlar el posible sobreajuste.
- **Capas de Aplanamiento:** Transforma la salida de las capas convolucionales y de pooling en un vector unidimensional, que podrá ser utilizado posteriormente por las capas completamente conectadas.
- **Capas Completamente Conectadas (Fully Connected Layers):** Al final de la red, una o más capas completamente conectadas combinan la información extraída por las capas convolucionales y de pooling para generar las predicciones finales. Estas capas son similares a las utilizadas en los modelos MLP que vimos antes.
- **Capas de Activación:** Introducen la no linealidad en la red, permitiendo que aprenda funciones más complejas que las transformaciones lineales. Sin capas de activación, nuestra red solo podría realizar transformaciones lineales, lo que limitaría considerablemente su capacidad para modelar relaciones complejas entre las variables de entrada y la salida.

En concreto, nuestra red neuronal convolucional está diseñada para procesar datos unidimensionales (por ejemplo, series temporales) y realizar una tarea de regresión (predicción de la demanda). Comienza con una capa convolucional, que aplica filtros a la entrada, buscando patrones específicos. La función de activación ReLU asegura que solo se pasan valores positivos a la siguiente capa.

Sigue por una capa de agrupación que reduce la dimensionalidad de la salida, previa a una capa de aplanamiento que convierte la salida tridimensional en un vector unidimensional para que la siguiente capa, una capa densa, pueda procesarla. En esta capa, la función de activación ReLU introduce la no linealidad. Por último, otra capa densa de una sola neurona produce la predicción final del modelo.

Long Short-Term Memory (LSTM) Network

Las redes neuronales artificiales Long Short-Term Memory (LSTM) son un tipo de redes neuronales recurrentes diseñadas para procesar y analizar datos secuenciales, como series temporales. En el contexto de la predicción de demanda de electricidad, las redes LSTM han demostrado ser una herramienta efectiva para capturar patrones a largo plazo y dependencias temporales en los datos históricos de demanda, lo que las convierte en una opción muy buena para mejorar la precisión de las predicciones [44].

Una red LSTM se compone de celdas de memoria LSTM, que son unidades recurrentes que permiten almacenar y procesar información a largo plazo. Cada celda tiene cuatro compuertas principales:

- Puerta de entrada: Controla la cantidad de información nueva que se agrega a la celda de memoria.
- Puerta de olvido: Controla la cantidad de información que se elimina de la celda de memoria.
- Puerta de salida: Controla la cantidad de información de la celda de memoria que se utiliza para generar la salida.
- Celda de memoria: Almacena la información a largo plazo.

Modelo híbrido LSTM-DNN

Los modelos híbridos son modelos que combinan diferentes tipos de redes neuronales. Un ejemplo de este tipo de modelo es la combinación de redes neuronales recurrentes Long Short-Term Memory (LSTM) y redes neuronales densas (Dense Neural Network - DNN). Este tipo de arquitectura intentará recoger las ventajas de cada tipo de red neuronal, para mejorar las predicciones actuales. No se va a ahondar demasiado en las características de este tipo de red, puesto que ya han sido intriducidas anteriormente. El modelo híbrido LSTM-DNN se compone de dos etapas principales [45]:

- Etapa LSTM: La primera etapa utiliza una red neuronal recurrente Long Short-Term Memory (LSTM) para capturar las dependencias temporales en los datos históricos de demanda de electricidad. Las redes LSTM son adecuadas para modelar patrones a largo plazo y tendencias en series temporales, lo que las convierte en ideales para modelar la parte del comportamiento de la demanda que se ve influenciado por factores que ocurren en el pasado.

Capítulo 3. Fundamentos Técnicos

- Etapa DNN: La segunda etapa utiliza una red neuronal densa (Dense Neural Network - DNN) para procesar las salidas de la red LSTM y extraer características generales de los datos. Las DNN son eficientes para capturar relaciones no lineales entre las variables y pueden aprender patrones complejos en los datos preprocesados por la LSTM.

Modelo Transformer Encoder

El modelo de red neuronal Transformer Encoder es un modelo altamente utilizado en diversas tareas de procesamiento del lenguaje natural (NLP), y su potencial se ha extendido a otros campos, incluyendo la predicción de series temporales. A diferencia de las redes neuronales recurrentes (RNNs) como LSTM, que procesan secuencias de datos de forma secuencial, Transformer Encoder utiliza una arquitectura basada en la atención que le permite el procesamiento en paralelo. Procesa toda la secuencia de entrada de forma simultánea, lo que puede mejorar la eficiencia computacional, especialmente para series temporales largas.[46].

Un modelo Transformer Encoder típico está formado por dos componentes principales:

- Encoder: El encoder procesa la secuencia de entrada (datos históricos de demanda de electricidad) y genera una representación contextual de cada elemento en la serie.
 - Atención: El mecanismo de atención permite que el encoder se centre en las partes más relevantes de la secuencia de entrada para generar la representación contextual. Funciona de la siguiente manera. Cada elemento de la secuencia se transforma en consultas (Q), claves (K) y valores (V). Los pesos de atención se calculan como el producto escalar de Q y K, seguido de una normalización con softmax. Estos pesos se aplican a V para obtener la salida de la atención. La atención permite que el modelo se enfoque más en ciertas partes de la secuencia según el contexto, lo que es crucial para capturar relaciones a largo plazo [47].
 - Capas de feedforward: Se utilizan capas de redes neuronales completamente conectadas (FFNNs) para procesar la representación contextual y extraer características más complejas.
- Decoder: El decoder (opcional en la predicción de demanda) se utiliza para generar una secuencia de salida (predicciones de demanda de electricidad).

3.5. Métricas

En el contexto de la predicción de demanda de electricidad, las métricas de error son herramientas esenciales para evaluar el rendimiento de los modelos de pronóstico. Cada métrica ofrece una perspectiva distinta sobre la precisión de las predicciones, y la elección de las métricas adecuadas depende de los objetivos específicos del análisis. No existe una métrica de error perfecta de manera uni-

versal. Cada una nos ofrece algunas ventajas y desventajas, y dependiendo del contexto unas pueden ser más útiles que otras. Para esta tarea, hemos elegido varias, para obtener distintas perspectivas a la hora de comparar los modelos. A continuación, presentaremos brevemente las cuatro métricas de error que vamos a utilizar.

Error absoluto medio (MAE)

El MAE es una medida simple y directa del error promedio en las predicciones. Se calcula como la suma de los valores absolutos de las diferencias entre los valores reales y predichos, dividida por el número de observaciones. Un MAE bajo indica que las predicciones son, en promedio, cercanas a los valores reales. Es un indicador robusto frente a valores atípicos (outliers), pero como consecuencia, no penaliza errores grandes tanto como otras métricas, como el RMSE [48][49]. Se calcula de la siguiente manera, siendo REVISAR los valores reales y las predicciones respectivamente:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|$$

Error porcentual absoluto medio (MAPE)

El MAPE es una medida del error relativo, expresado como un porcentaje. Es útil cuando se comparan predicciones de diferentes magnitudes, o cuando se comparan errores de conjuntos de datos de distinto tamaño, ya que normaliza el error en relación con la magnitud y la dimensión de los valores reales. Un MAPE alto indica que las predicciones tienen una desviación significativa de los valores reales, especialmente para valores pequeños. Es sensible a valores atípicos (outliers), y no se define para valores reales iguales a cero [48][49]. Se calcula de la siguiente manera:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{Y_i} \times 100\%$$

Raíz cuadrada del error cuadrático medio (RMSE)

El RMSE es una medida del error cuadrático promedio. Se calcula como la raíz cuadrada del error cuadrático medio (MSE), que es la suma de los cuadrados de las diferencias entre los valores reales y predichos, dividida por el número de observaciones. Se utiliza comúnmente en la evaluación de modelos de regresión. Penaliza mucho los errores grandes, algo que dependiendo del contexto puede ser más o menos útil, ya que es muy sensible a valores atípicos (outliers). Además, las unidades del RMSE son las mismas que las de los valores reales, lo que puede dificultar la interpretación [50][48]. Se calcula de la siguiente manera:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}$$

Coefficiente de determinación (R2)

El R2, también conocido como coeficiente de determinación, es una medida de la bondad de ajuste del modelo. Indica qué proporción de la variabilidad de los valores reales es explicada por el modelo de predicción. Toma valores entre 0 y 1. Un R2 alto (cercano a 1) indica que el modelo explica una gran parte de la variabilidad de los valores reales, mientras que un R2 bajo (cercano a 0) indica que el modelo no explica bien la variabilidad de los valores reales. Proporciona una medida de la capacidad del modelo para explicar la variabilidad de los datos. Es fácil de interpretar y es muy útil para comparar con otros modelos [51]. Se calcula de la siguiente manera:

$$R2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$$

Capítulo 4

Entrenamiento y Resultados

En este capítulo se detallará la implementación concreta de los modelos de predicción, mostrando los pasos realizados y los factores que se tienen en cuenta para el desarrollo de los mismos. También se verán los resultados obtenidos de la implementación de los modelos de predicción, mostrando las métricas en cada caso, visualizando las predicciones y analizando los residuos. Esto ayuda a justificar y explicar por qué se toman ciertas decisiones.

4.1. Modelos basados en regresión lineal múltiple

Vamos a empezar construyendo un modelo muy simple, utilizando como variable únicamente la hora del día. Después de ajustar el modelo con los datos de entrenamiento, vamos a utilizar el modelo para predecir los valores horarios de la demanda de electricidad en una semana del conjunto de validación, y compararlos con los valores reales de demanda de esa misma semana. Utilizaremos la semana desde el 15 de Octubre hasta el 22 de Octubre de 2023. A partir de ahora, utilizaremos este mismo periodo para mostrar gráficamente una muestra del comportamiento del resto de modelos. Veamos gráficamente en la figura 4.1 la predicción del modelo en comparación con los datos reales.

Capítulo 4. Entrenamiento y Resultados

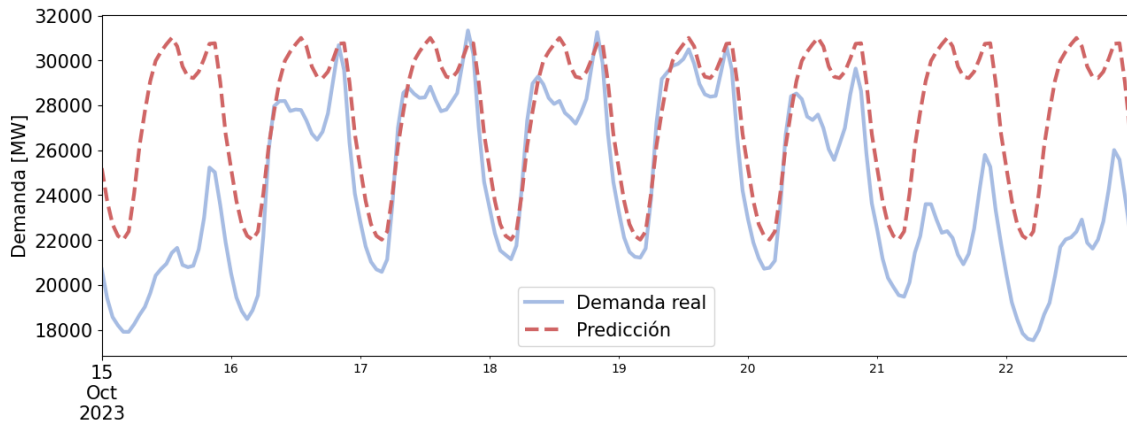


Figura 4.1: Demanda real contra la predicción del modelo en un periodo de tiempo

Pese a ser un modelo tan básico, podemos ver en el gráfico cómo capta gran parte del comportamiento de la demanda. Esto se debe a que la hora del día es uno de los factores más determinantes en la demanda de electricidad, debido principalmente a las pautas de consumo de los particulares, y a los horarios de funcionamiento de la industria y de la actividad económica del país.

Otra variable relacionada estrechamente con lo que acabamos de comentar es el día de la semana. También relacionada con los comportamientos del consumo de familias y empresas, podemos observar en la demanda real, cómo los valores de demanda son notablemente inferiores en sábado o en domingo, comparado con el resto de días de la semana. Para terminar con las variables que podríamos clasificar como *temporales*, tenemos la variable mensual. Esta variable también recibe influencia de comportamientos demográficos como las anteriores, pero en menor medida (la actividad económica puede fluctuar entre el verano y el invierno). Sin embargo, esta variable, quizás recibe una mayor influencia de otros factores como la temperatura, las precipitaciones, las horas de luz, etc. Vamos a implementar otro modelo de regresión lineal múltiple incluyendo estas variables.

4.1. Modelos basados en regresión lineal múltiple




Figura 4.2: Demanda real contra la predicción de varios modelos en un periodo de tiempo

Podemos observar en la figura 4.2 una comparativa entre la predicción del modelo anterior, únicamente con la hora del día como entrada, y los dos nuevos modelos, incluyendo en primer lugar el día de la semana y en segundo el mes del año, siempre de manera agregada. Viendo el comportamiento de las distintas predicciones en contraste con la demanda real, en una semana del periodo de validación, vemos cómo mejoran los pronósticos de la demanda con las nuevas inclusiones, sobre todo gracias a trabajar con el día de la semana, aunque las variables mensuales también mejoran ligeramente los resultados.

Cabe resaltar, que como los modelos han sido entrenados con datos hasta enero de 2023, y las predicciones las estamos realizando para una semana de octubre, estamos realizando predicciones horarias a 10 meses vista, ya que las variables que estamos utilizando las sabemos de antemano (no sucederá lo mismo cuando trabajemos con otros datos que se tienen con semanas, o incluso días de antelación). Esto nos muestra cómo estos modelos tan básicos pueden hacer predicciones horarias relativamente acertadas a bastante largo plazo, donde la incertidumbre en teoría es bastante mayor.

Una vez hemos trabajado ya con las variables temporales, vamos a incluir en los modelos otro tipo de entradas. Utilizando estos modelos como base, se explorarán otros factores con el fin de mejorarlos y hacerlos más precisos. Vamos a empezar trabajando con la temperatura. Vamos a importar datos de temperatura horarios de España de *AEMET*, y en *python* vamos a mostrar gráficamente la relación entre la temperatura y la demanda de electricidad. Podemos ver los resultados en la figura 4.3.

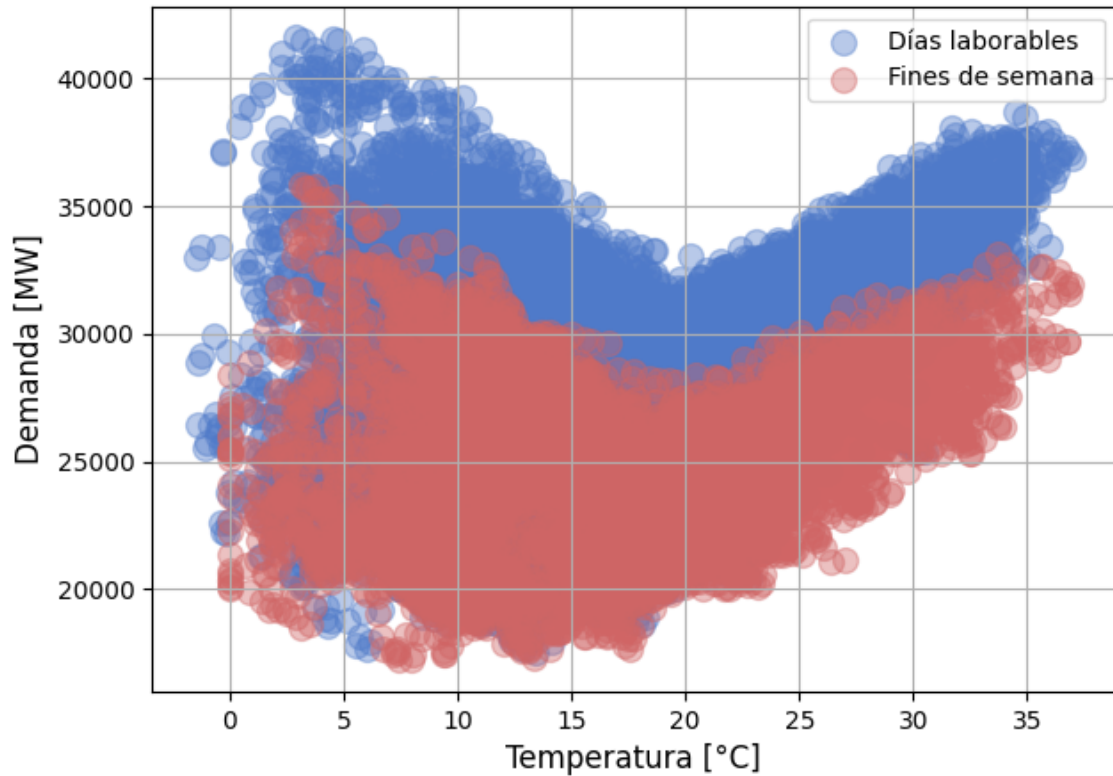


Figura 4.3: Relación entre la demanda y la temperatura

Como podemos observar en el gráfico, vemos que existe una correlación entre la demanda y la temperatura. No es una correlación directa, de a mayor temperatura más demanda, sino que la demanda de electricidad se dispara en los extremos de temperatura, mientras que tiende a ser menor en los valores medios de temperatura. Para comprobar que existe causalidad, y que no es solo correlación, tendremos que ver si aumenta la capacidad predictiva de nuestros modelos. Ahora bien, el sentido común nos indica que pueden existir razones que expliquen este comportamiento. En concreto, tanto en los ambientes laborales como en los hogares, se tiende a aumentar el consumo energético para regular la temperatura cuando esta se aleja de la temperatura de confort de los seres humanos, alrededor de los 20°. Por otro lado, por aportar otro ejemplo, la maquinaria suele funcionar de forma más eficiente en temperaturas más suaves.

Ahora, vamos a entrenar un nuevo modelo de regresión lineal múltiple utilizando el conjunto de datos, esta vez incluyendo también la temperatura.

4.1. Modelos basados en regresión lineal múltiple




Figura 4.4: Demanda real contra la predicción del modelo en un periodo de tiempo

Podemos ver en la figura 4.4 cómo agregar los datos de temperatura agrega una mayor precisión a nuestras predicciones. Por ello, es una variable que se suele utilizar bastante en este tipo de modelos, ya que casos de temperaturas que se salgan de los rangos considerados como normales, pueden causar un aumento de la demanda considerable, mientras que datos más moderados la suelen mantener más estable.

El único problema de utilizar la temperatura en el modelo está relacionado con el horizonte temporal de las predicciones y la calidad de las mismas. Hasta ahora, estábamos utilizando variables que tenemos disponibles para un horizonte indeterminado, ya que son variables temporales que ya sabemos cómo van a ser. Sin embargo, al utilizar la temperatura, solo podremos predecir la demanda para el horizonte para el que tengamos datos de temperatura. Con datos públicos, se pueden llegar a predecir hasta 2 semanas de forma sencilla, pero tenemos constancia de que algunas empresas del sector contratan a mayores servicios de predicción meteorológicos, que ofrecen más y mejores datos. La calidad de la predicción de temperatura, también será tremendamente importante para que las predicciones del modelo tengan máxima precisión.

El siguiente factor con el que vamos a trabajar será la tendencia. Es un factor que se suele utilizar bastante y que debemos tener en cuenta, ya que puede llegar a explicar una parte del comportamiento de la demanda. Esto se debe, a que a largo plazo, es normal que exista una tendencia en la demanda, generalmente creciente, debido a varias causas. Estas pueden ser, una mayor actividad económica, un aumento de la población, el crecimiento o desarrollo de la industria, etc. Vamos a ver en la siguiente figura 4.5 las predicciones del modelo utilizando la tendencia.

Capítulo 4. Entrenamiento y Resultados




Figura 4.5: Demanda real contra la predicción del modelo en un periodo de tiempo

A simple vista, no se nota demasiado cambio respecto a las predicciones anteriores, y si comparamos las métricas de error, vemos que empeoran al incluir la tendencia. Esto nos sugiere que no existe una tendencia clara en la evolución de la demanda en España en los últimos años. Si nos volvemos a la figura 3.1, podemos observar los datos de demanda sin manipular en los últimos años, y se podría afirmar que no existe ninguna tendencia en los datos de demanda, ni creciente ni decreciente, ya que permanecen en un rango de valores más o menos constante. Por tanto, en este caso, seguramente sea mejor no utilizar la tendencia.

Ahora, para finalizar, vamos a utilizar como variables de predicción distintos tipos de demanda *retrasada*. Esta entrada ayuda mucho a la predicción, ya que los valores de demanda de la semana o el día anterior, pueden ser muy útiles para predecir la demanda del día o semana siguiente. Por otro lado, por definición, si queremos dar como entrada los valores de demanda de la semana anterior, las predicciones se podrán hacer con horizonte de una semana, y si queremos dar como entrada los valores del día anterior, las predicciones solo se podrán hacer con horizonte de un día. Por tanto, disminuye el horizonte de predicción, algo que por otro lado, tampoco sería demasiado grave, ya que queremos desarrollar modelos de predicción principalmente de corto plazo, que casa con el horizonte de entre 1 día y 1 semana.

También cabe puntualizar una cosa. Aunque demos de beber al modelo de los datos de la demanda de hace 24 horas, se pueden hacer predicciones a más largo plazo, por ejemplo una o más semanas, con ese mismo modelo. Esto se hace a través de predicciones encadenadas. Es decir, se predicen con el modelo las 24 horas siguientes, y para predecir las 48 horas siguientes, se utiliza como entrada del modelo las predicciones hechas de esas 24 horas, y así sucesivamente. Se obtienen buenos resultados y es bastante útil, pero aumenta la incertidumbre, ya que nos estaremos basando en hipótesis.

Vamos a implementar estas variables. Nosotros hemos elegido dos de las posibles

4.1. Modelos basados en regresión lineal múltiple

maneras de hacerlo: de forma directa, utilizando el dato de demanda de hace 24 horas, y realizando una pequeña transformación para utilizar la media de demanda de las 24 horas anteriores.

Empezaremos por incluir un desfase de 1 semana para la predicción. Vamos a ver en la figura 4.6 la comparativa de las predicciones con los valores reales una vez hecho en el entrenamiento.




Figura 4.6: Demanda real contra la predicción del modelo en un periodo de tiempo

En este caso, vemos como esta variable vuelve a mejorar las métricas de error, y gráficamente podemos observar cómo las predicciones se ajustan más a los valores reales. Vamos a incluir ahora los valores retrasados 24 horas para entrenar el modelo, y mostraremos los resultados en la figura 4.7. Ahora la precisión debería aumentar significativamente.




Figura 4.7: Demanda real contra la predicción del modelo en un periodo de tiempo

Efectivamente, podemos ver gráficamente que las predicciones son bastante mejores, como es lógico, ya que el horizonte de predicción es muy cercano, por tanto la información que tenemos es mayor. Esto se ve también acompañado con unas

Capítulo 4. Entrenamiento y Resultados

métricas de error significativamente mejores. Ahora vamos a incluir la última variable a nuestros modelos de regresión lineal múltiple. En este caso, utilizaremos la media de la demanda del día anterior. Vamos a mostrar de nuevo, en la figura 4.8, las predicciones de este último modelo.




Figura 4.8: Demanda real contra la predicción del modelo en un periodo de tiempo

Esta vez, podemos apreciar que la diferencia no es sustancial, aunque existe cierta mejora, ya que al final, este dato es muy parecido a el desfase de 24 horas. El aumento en la precisión se podría deber a que esta media del día anterior, nos puede dar una mayor información del contexto, siendo más estable, y menos contaminada por valores atípicos. Sin embargo, luego vemos que en las métricas de validación, empeoran ligeramente al incluir este dato, lo que nos dice que es un dato que realmente no aporta mucho. Se podría a llegar a dejar, pero para el modelo definitivo, nosotros hemos decidido dejarlo fuera.

Ahora, para finalizar con los modelos de regresión lineal múltiple, vamos a mostrar en una tabla las métricas de error de todos los modelos, tanto para el conjunto de datos de entrenamiento como para el de validación. Como comentamos antes, las métricas de error utilizadas serán MAPE, RMSE, MAE y R2. Empezaremos mostrando los resultados del entrenamiento.

Modelo	MAPE	RMSE	MAE	R2
Modelo hora	8.377047	2960.007821	2265.145469	0.528261
Modelo mes+día+hora	5.506252	1950.715603	1475.340574	0.795118
Modelo mes+día x hora	4.500920	1720.324375	1235.145439	0.840655
Modelo temperatura	3.377571	1360.529231	915.507476	0.900337
Modelo tendencia	3.272235	1328.785451	885.714420	0.904934
Modelo retraso 1 semana	3.015135	1245.756042	816.567249	0.916376
Modelo retraso 1 día	2.114003	962.763451	572.786937	0.950053
Modelo media día	2.109092	961.671127	571.736835	0.950167
Modelo definitivo	2.139647	970.168001	580.017294	0.949282

4.2. Modelos basados en series temporales

Ahora, en comparación, vamos a mostrar los resultados con la parte de los datos reservada para la validación. Estos resultados son los más importantes, más fiables, y más realistas, ya que simulan cómo actuaría el modelo con datos nuevos reales, sin haber aprendido antes de ellos.

Modelo	MAPE	RMSE	MAE	R2
Modelo hora	11.922151	3703.516473	2901.148611	0.258249
Modelo mes+dia+hora	9.165248	2798.002730	2249.162787	0.576624
Modelo mes+dia x hora	8.303778	2638.018360	2066.262299	0.623656
Modelo temperatura	6.815966	2196.071151	1682.529449	0.739191
Modelo tendencia	8.048174	2472.610426	1978.602672	0.669371
Modelo retraso 1 semana	6.132796	1970.743717	1509.770938	0.790866
Modelo retraso 1 dia	3.259271	1191.949136	806.339860	0.923497
Modelo media dia	3.328888	1202.479735	821.206096	0.922139
Modelo Definitivo	2.890573	1113.041040	718.650954	0.933291

Viendo los resultados del modelo, podemos observar como logramos alcanzar un MAPE del 2% en los datos del entrenamiento, y logramos bajar del 3% en la validación. El modelo definitivo alcanza una precisión muy buena, logrando predecir la demanda de electricidad en España de manera bastante fiable. Además, con un R2 alto (por encima de 0.7 o 0.8), el modelo explica una gran proporción de la variación de la variable dependiente, lo que significa que las variables independientes son buenos predictores de la variable dependiente. En nuestro caso, el R2 supera el 0.93, por tanto el modelo es bastante bueno.

En cuanto a las variables utilizadas, hemos visto que todas mejoraban los modelos, en mayor o menor medida, excepto la tendencia y la media diaria, que hemos acabado dejando fuera en el modelo definitivo. Si tuviésemos que escoger las variables más decisivas para las predicciones, además de la hora, serían la temperatura y la demanda del día anterior.

Hay que mencionar que los modelos de referencia que mostramos al principio lograban un 5% de MAPE con el conjunto de datos de entrenamiento, por lo que hemos conseguido superar dichos resultados de forma muy holgada. Posteriormente, en el desarrollo de los siguientes tipos de modelos, veremos si podemos mejorar estos resultados.

4.2. Modelos basados en series temporales

4.2.1. Modelos ARIMA y derivados

En primer lugar, se va a trabajar con los modelos ARIMA. Vamos a utilizar la función ya mencionada *autoarima* de la librería *pmdarima*. Esta función realiza una optimización de los hiperparámetros que recibe el modelo, y nos devuelve el modelo que obtiene unos mejores resultados. Ajusta los parámetros **p**, **d** y

Capítulo 4. Entrenamiento y Resultados

q , que son, respectivamente, el orden del parámetro autorregresivo, de la diferenciación, y de el parámetro de media móvil. Se ajustan tanto los parámetros regulares, que se suelen mostrar en minúscula, como los estacionales, que se muestran en mayúscula. Vamos a ajustar el modelo con estacionalidad diaria, es decir, el valor estacional será de 24 para los datos horarios.

Tras aplicar la función nos selecciona el modelo SARIMAX(0, 1, 4)x(2, 0, [], 24), con las siguientes métricas:

Log Likelihood: -154699.373

AIC: 309412.747

BIC: 309468.168

HQIC: 309430.867

De estos valores, el más importante quizás sea el AIC, que será mejor cuanto más bajo sea. Ahora haremos un test de coeficientes. Los valores que obtenemos son:

coef	std err	z	P> z
ma.L1	0.5128	0.004	126.028
ma.L2	0.2146	0.006	38.966
ma.L3	-0.0465	0.006	-7.951
ma.L4	-0.0581	0.007	-8.686
ar.S.L24	0.6269	0.005	125.719
ar.S.L48	0.2400	0.006	42.992

Vamos a observar el p-valor de los coeficientes. Si es menor o igual que 0.05, el término asociado es relevante. Sin embargo, se supera ampliamente este valor, por lo que el modelo seguramente no será muy bueno. Si vemos la comparativa entre las predicciones del modelo y los valores, como se va a mostrar ahora en la siguiente figura 4.9, se confirma que el modelo es bastante mejorable.

4.2. Modelos basados en series temporales




Figura 4.9: Demanda real contra la predicción del modelo en un periodo de tiempo

Además, si calculamos las métricas de error que ya utilizamos en el apartado anterior, vemos que son bastante peores para este modelo que para cualquiera de los desarrollados basados en regresión lineal múltiple. Incluso el más básico de ellos supera a este, ya que tenemos un MAPE de casi un 20 %, un coeficiente R^2 de -1.57, o un error medio absoluto de 5659. Por tanto, vamos a probar otras soluciones.

Ahora, para intentar obtener un modelo mejor, vamos a probar utilizando un valor de estacionalidad en el modelo SARIMA de orden semanal, de 168 para datos horarios, utilizando a su vez valores de \mathbf{p} , \mathbf{d} y \mathbf{q} seleccionados bajo un razonamiento lógico, en vez de buscados por fuerza bruta. Empezaremos por el parámetro \mathbf{D} de diferenciación estacional para acabar con la estacionalidad de nuestros datos. Probaremos con un valor de 1 para acabar con la estacionalidad diaria. Si no es suficiente, habrá que diferenciar dos veces. Utilizaremos el mismo valor de 1 para la diferenciación regular de \mathbf{d} , deberíamos así acabar con cualquier tipo de estacionalidad. Para los siguientes parámetros, nos será muy útil tener los correlogramas de la serie temporal, el ACF y el PACF. Por tanto, vamos a calcularlos y a mostrarlos en la siguiente figura 4.10.

Capítulo 4. Entrenamiento y Resultados

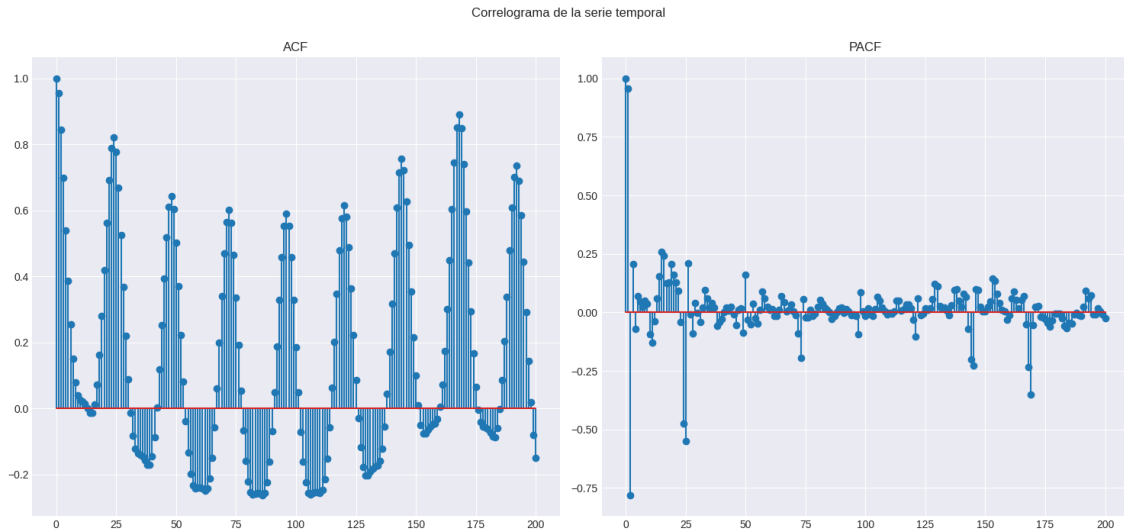


Figura 4.10: Correlogramas de la serie temporal

Seguiremos con el orden autorregresivo \mathbf{p} . Para obtener el mejor valor para este parámetro, deberemos fijarnos en la función de autocorrelación parcial, ya que al aislar el efecto independiente de los valores pasados sobre el valor actual, suele ser más fiable en este caso. Como se puede observar, el último gran pico podría estar en el segundo o en el tercer valor. Como después del tercer valor la función se acerca rápidamente a cero, nos quedaremos con $p = 3$. Para el caso de \mathbf{P} , vemos en funciones de autocorrelación parcial de mayor longitud que existen picos en los múltiplos de 168. Por tanto, será recomendable un $P > 1$.

Por último, trataremos los órdenes de media móvil. Para el orden regular \mathbf{q} es más importante observar la función de autocorrelación regular. Como vemos que tenemos varios picos en los primeros valores, será mejor utilizar un valor mayor que 1. En este caso utilizaremos un orden 2. Para el orden estacional \mathbf{Q} , como el primer pico es en el múltiplo 1 de 168, se utilizará un valor de 1.

Así, procederemos a ajustar nuestro modelo SARIMA(3,1,2)(2,1,1)[168]. Vamos a mostrar gráficamente en la figura 4.11 la predicción de la demanda de la primera semana del conjunto de datos de validación, frente a los datos reales de esa semana.

4.2. Modelos basados en series temporales




Figura 4.11: Demanda real contra la predicción del modelo en un periodo de tiempo

Podemos ver a simple vista que los resultados que obtenemos son bastante mejores que los anteriores. Sin embargo, si analizamos objetivamente los datos a través de las métricas de error, vemos, que pese a que estas mejoran, no lo hacen de manera significativa, ya que por ejemplo, tenemos un MAPE de un 13.074%, un coeficiente R2 de 0.15, o un error medio absoluto de 3256 para el conjunto de validación.

Si analizamos los resultados en mayor profundidad vemos que esto se debe a que la precisión de las predicciones disminuye con el tiempo, y por tanto, aunque vemos que las predicciones en la primera semana son tremendamente precisas, las métricas de error son un tanto mediocres, ya que hacen promedio con todas las semanas del conjunto de validación. Esto es lógico, ya que como comentamos anteriormente, a medida que aumenta el horizonte temporal, aumenta la incertidumbre y como consecuencia las predicciones tenderán a ser menos precisas. Vamos a mostrar para verlo, por ejemplo, las predicciones del modelo contra la demanda real en la última semana de los datos de evaluación.

Capítulo 4. Entrenamiento y Resultados




Figura 4.12: Demanda real contra la predicción del modelo en un periodo de tiempo

Podemos comprobar en la figura 4.12 que las predicciones para esta última semana son sustancialmente peores que para la primera semana. Para poder cuantificar esta afirmación con datos más precisos, hemos calculado el MAPE para estas dos semanas. Tenemos que el MAPE al principio de la evaluación es del 2.06%, un dato muy bueno teniendo en cuenta los números que solemos manejar, mientras que acaba siendo del 25.56% al final, por eso nos sale ese valor medio alrededor del 13%. Para observar cómo se desvían las predicciones de los valores reales a medida que se aleja el horizonte de predicción, vamos a calcular el MAPE para cada una de las semanas del año de validación, y vamos a mostrar en un gráfico la evolución del mismo. Se mostrará lo obtenido en la siguiente figura 4.13.

4.2. Modelos basados en series temporales

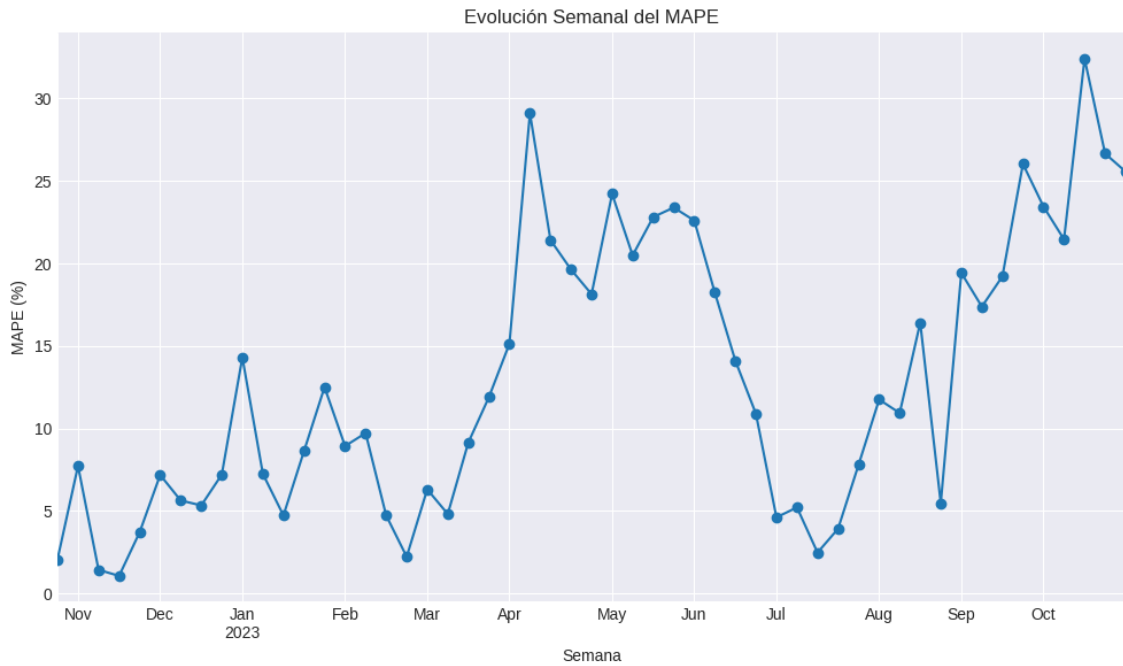


Figura 4.13: Evolución del MAPE en el periodo de evaluación

Vemos cómo el MAPE es realmente bueno en el primer mes llegando a bajar del 2% en dos semanas. A partir de aquí, existe una clara tendencia creciente, con subidas y bajadas, pero ya estaríamos hablando de resultados quizás no suficientemente buenos. Sin embargo, esto no tiene por qué ser un problema, ya que estamos desarrollando modelos de predicción de demanda de electricidad de medio y corto plazo, que suelen ir desde horas hasta días o semanas, por lo que este modelo nos sería muy útil para esta tarea. Además, estamos hablando de modelos que no requieren más información que la propia evolución de la demanda, por lo que se necesitan pocos datos.

Para terminar de validar el modelo, vamos a estudiar el comportamiento de los residuos, es decir, la diferencia entre el valor real de la demanda y la predicción. Vamos a empezar calculándolos y mostrándolos gráficamente, en la figura 4.14.

Capítulo 4. Entrenamiento y Resultados




Figura 4.14: Residuos del modelo en el periodo de evaluación

En un escenario óptimo, los residuos deberían ser algo parecido a un *ruido blanco*, que es una secuencia de valores aleatorios que no presentan ninguna correlación entre sí y tienen media y varianza constante a lo largo del tiempo, donde los valores futuros de la serie son impredecibles basándose únicamente en los valores pasados [52]. Así a simple vista no se aprecia ningún patrón estacional en los residuos, y la varianza permanece más o menos constante, pero la media presenta una ligera tendencia creciente. Esto no tiene por qué ser preocupante, ya que estamos hablando de los residuos en la validación, y los residuos en el entrenamiento no sí que se parecen más a un *ruido blanco*. Además, como ya comentamos antes, eventos que no podemos controlar de índole económica o política pueden causar cambios en el comportamiento de la demanda a medio y largo plazo principalmente, provocando incrementos o disminuciones de la misma.

Para finalizar, vamos a obtener el histograma de los residuos, que debería mostrar una distribución normal. Se muestra en la siguiente figura 4.15. Aunque el centro de la distribución, en vez de acumularse en cero, se desplaza hacia el lado positivo del eje, debido a la tendencia creciente que apreciamos en los residuos, el comportamiento parece el de una distribución *gaussiana*, por lo que por esta parte no existe ningún problema. En definitiva, parece que el modelo captura de forma precisa el comportamiento de la demanda y sin sesgos, y no aparenta dejar variables sin explicar.

4.2. Modelos basados en series temporales




Figura 4.15: Histograma de los residuos en el periodo de evaluación

4.2.2. Modelo TBATS

Vamos a empezar descargando la librería TBATS[53] e importándola para trabajar con ella en *python*. Vamos a ajustar el modelo con el conjunto de datos de entrenamiento, y para ello, vamos a utilizar como parámetro de entrada del modelo, los patrones estacionales diarios y semanales. Para los datos horarios que tenemos, será una estacionalidad de 24 y 168 periodos. Una vez entrenado el modelo, vamos a calcular los residuos para realizar un análisis de los mismos.

Capítulo 4. Entrenamiento y Resultados

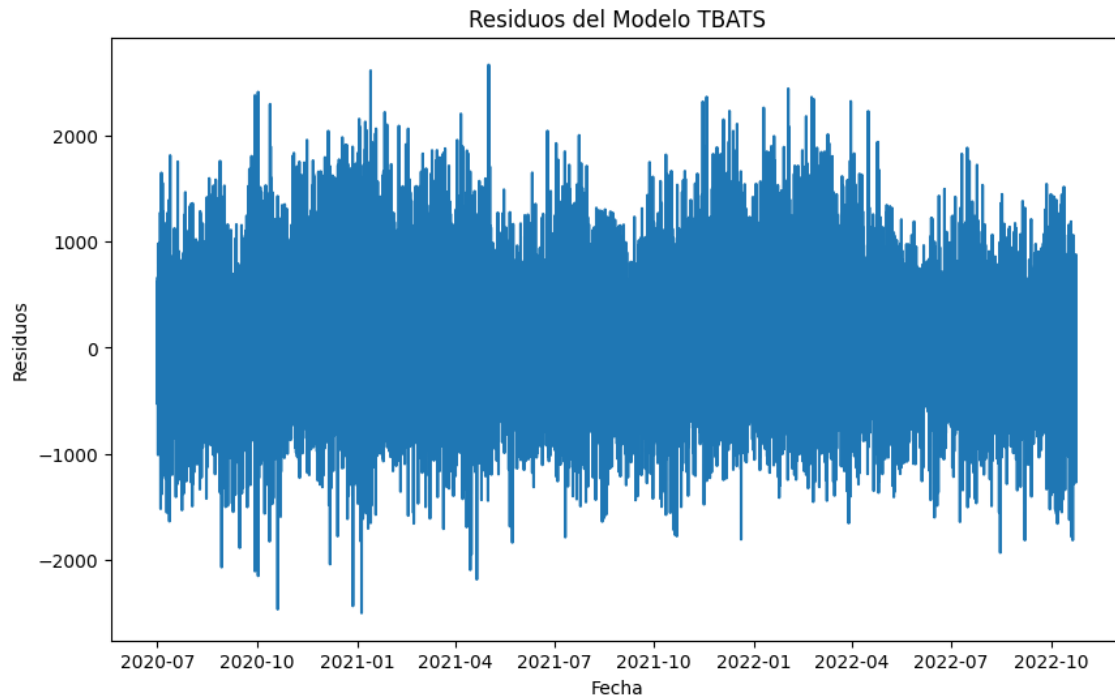


Figura 4.16: Residuos en los datos de entrenamiento

Si observamos los residuos en la figura anterior 4.16 vemos que se parecen considerablemente a un *ruido blanco*. La media está centrada en 0, la varianza parece bastante estable, y no se aprecia ningún patrón estacional. Por este lado, parece que el modelo no ha desarrollado ningún sesgo sospechoso, ni deja factores del comportamiento de la demanda por explicar. Ahora vamos a calcular los correlogramas de los residuos, para 168 periodos aproximadamente, para ver esto de una forma más clara y cuantificable. Los mostraremos en la siguiente figura 4.17.

4.2. Modelos basados en series temporales

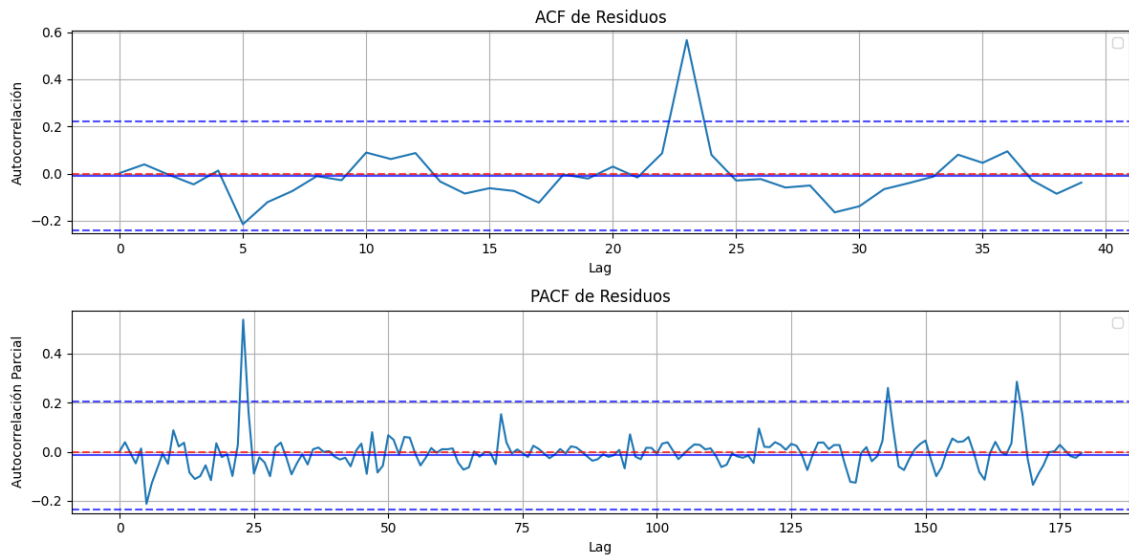


Figura 4.17: Correlogramas de los residuos en los datos de entrenamiento

Vemos que tanto para la función de autocorrelación regular como para la de autocorrelación parcial, los valores permanecen más o menos estables alrededor del 0, y solo se rebasa el umbral de ± 0.2 en muy contadas ocasiones, por lo que por esta parte también es correcto el análisis de residuos. El modelo no deja sin explicar relaciones ni comportamientos de la demanda basados en valores anteriores, y no aparenta tener ningún sesgo reseñable.

Ahora vamos a mostrar gráficamente en la figura 4.18 la predicción de este nuevo modelo contra los datos reales en la primera semana de los datos de validación, para evaluar la calidad del modelo.

Capítulo 4. Entrenamiento y Resultados

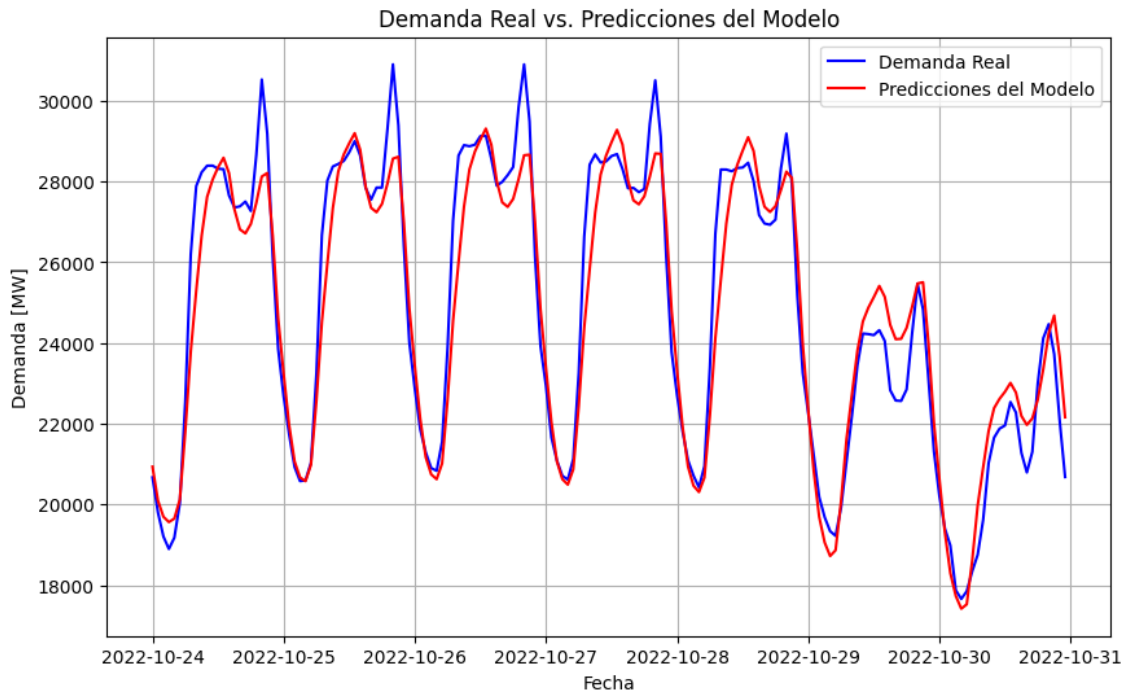


Figura 4.18: Demanda real contra la predicción del modelo en un periodo de tiempo

Se puede apreciar que los resultados del modelo para esta primera semana son muy buenos, y si consultamos los datos a través de las métricas de error vemos que se mejoran los resultados de los anteriores modelos de series temporales. En efecto, para el conjunto de evaluación, el MAPE es de 8.409%, el coeficiente R^2 es de 0.52, y el error medio absoluto es 2282. Como ya vimos anteriormente, es bastante probable que los resultados empeoren progresivamente a medida que avanza el tiempo en la predicción, y las métricas de error sean bastante peores al final en comparación con el inicio. No obstante, si vemos las predicciones del modelo en una semana de las últimas del conjunto de validación en la siguiente figura 4.19, podemos argumentar que las predicciones son más o menos precisas, al menos en comparación con, por ejemplo, el modelo SARI-MA(3,1,2)(2,1,1)[168] en la misma situación.

4.2. Modelos basados en series temporales




Figura 4.19: Demanda real contra la predicción del modelo en un periodo de tiempo

Vamos entonces a ver la evolución del error a lo largo del tiempo para este modelo TBATS, para conocer si esta evolución se comporta de una manera distinta en comparación con otros modelos. En primer lugar, vemos como el MAPE en la primera semana es de 1.6615%, lo que nos indica que el modelo realiza predicciones bastante buenas a corto plazo, pero si calculamos el MAPE para la última semana, nos sale 1.6654%, que es prácticamente igual. Por tanto, esto nos sugiere que este modelo tiene un comportamiento a largo plazo distinto. Vamos a mostrar, para ser capaces de ver la evolución, el MAPE para todas las semanas del conjunto de evaluación gráficamente en la figura 4.20.

Capítulo 4. Entrenamiento y Resultados




Figura 4.20: Evolución del MAPE en el periodo de evaluación

En este caso, analizando la evolución del MAPE, no se aprecia ninguna tendencia clara. De hecho, en el final del conjunto de validación y a mediados del mismo, se obtienen resultados tan buenos como al principio. Sin embargo, si que se puede intuir un patrón estacional, o al menos la posibilidad de su existencia. Utilizando el razonamiento lógico, podríamos pensar que como el modelo se adapta para realizar las mejores predicciones en las semanas más próximas, obtendrá mejores resultados en aquellas semanas que se parezcan más a las mismas. Por lo que, al tener un año completo validar, es normal que las predicciones sean muy buenas al final, ya que se empiezan a alcanzar las condiciones iniciales, que en este caso son otoñales.

También observamos que en primavera los resultados son también buenos, lo que podría explicarse porque las condiciones son similares a las de otoño, siendo las dos épocas de entretiempo, mientras que las peores predicciones se dan en verano y en invierno, con condiciones climáticas más extremas y condiciones generales bastante diferentes a las de otoño. Por tanto, podríamos defender que en la evolución del MAPE existe una estacionalidad semestral. Si quisiéramos hacer un modelo que intentase predecir la demanda horaria de todo el año, que no es el caso, quizás una buena solución sería hacer un modelo de entretiempo y otro de condiciones extremas, o uno para cada estación. En cualquier caso, esto debería probarse y demostrarse.

Para acabar con este modelo, vamos a calcular y analizar los residuos en la ventana de validación. Como se puede observar en la figura 4.21, no parece existir ninguna señal que nos indique algún sesgo que invalide el modelo o sugiera que quedan factores por explicar. Es decir, la media está más o menos centrada en

4.3. Modelos basados en Redes Neuronales

0, por lo que el modelo no sobrestima la demanda o viceversa, y la varianza parece relativamente estable. Si que podemos extraer, como acabamos de comentar, que las estaciones podrían tener cierta influencia en los residuos, o que el modelo tiende a sobrestimar ligeramente la demanda en épocas más cálidas, mientras que a subestimarla en momentos más fríos, pero es algo normal ya que el modelo no bebe de datos de temperatura.




Figura 4.21: Residuos del modelo en el periodo de evaluación

4.3. Modelos basados en Redes Neuronales

4.3.1. Multilayer Perceptron (MLP)

Ahora procederemos a entrenar esta red neuronal. Se ha realizado un pequeño ajuste de los hiperparámetros de la forma que se ha comentado anteriormente, y se ha puesto a entrenar el modelo con un número muy elevado de epochs, que pararemos en el momento que consideremos oportuno. Para ello, se ha establecido una semilla aleatoria para poder replicar los resultados del entrenamiento y poder volver a entrenarlo hasta el punto que se considere oportuno. Se mostrará a continuación la evolución de la función de pérdida a lo largo del entrenamiento, tanto para los datos de entrenamiento como para aquellos de validación.

Capítulo 4. Entrenamiento y Resultados

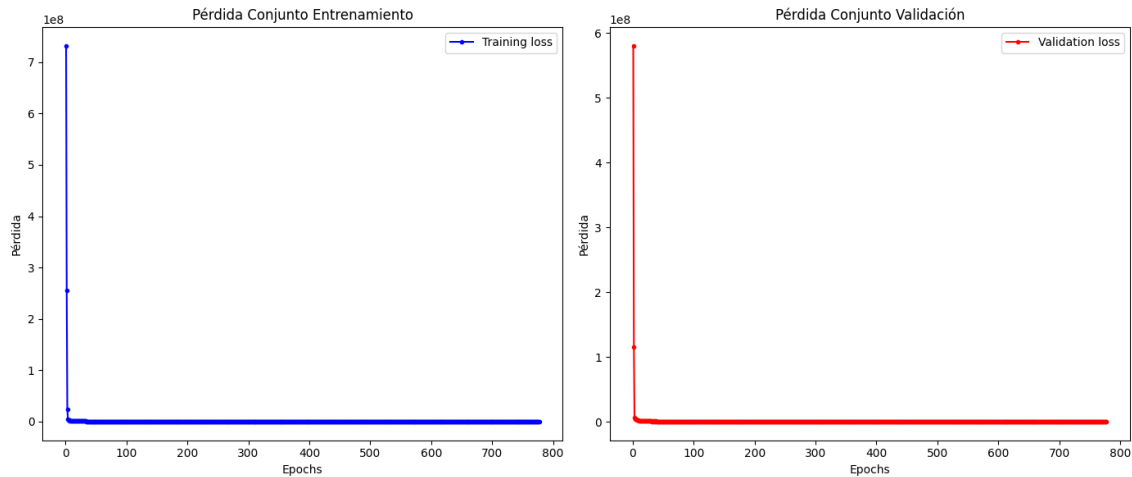


Figura 4.22: Evolución de la función de pérdida a lo largo de cada epoch

Si intentamos analizar la figura 4.22, es difícil extraer alguna conclusión de los datos, ya que el elevado valor de pérdida inicial nos impide distinguir la diferencia entre los valores siguientes. Por ello, a partir de ahora, para mostrar este tipo de gráficas, utilizaremos escala logarítmica y omitiremos los primeros 10 valores. Vamos a mostrar las gráficas con estas transformaciones en la figura 4.23.

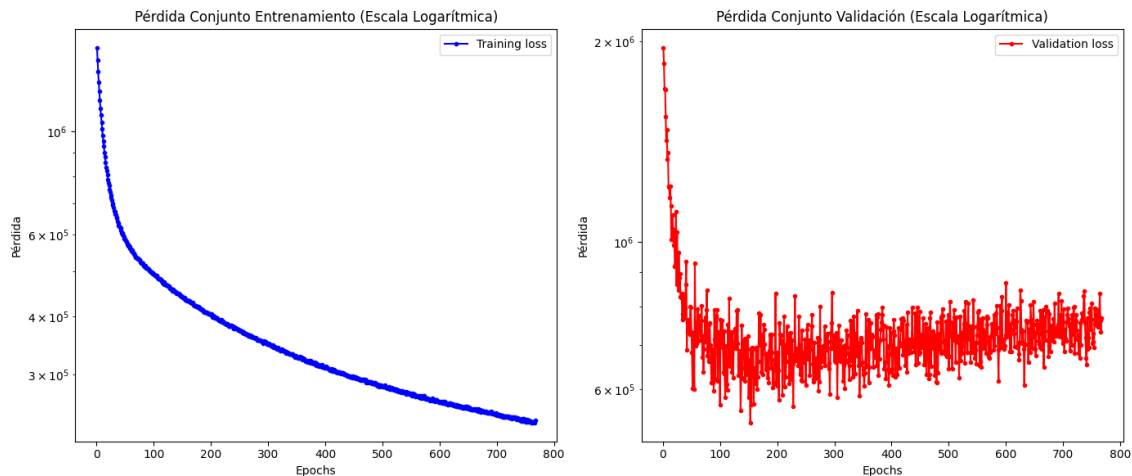


Figura 4.23: Evolución de la función de pérdida a lo largo de cada epoch en escala logarítmica

Podemos observar que la pérdida en el conjunto de entrenamiento no deja de disminuir a lo largo de todas las epochs, aunque si nos fijamos en la evolución de la pérdida en el conjunto de validación, alcanza un mínimo alrededor de la epoch número 150, y a partir de ahí presenta una tendencia ligeramente creciente. Por tanto, se va a parar el entrenamiento más o menos en ese punto, ya que suponemos que a partir de ahí, el modelo deja de aumentar su capacidad predictiva, y comienza a sobreajustarse a los datos de entrenamiento.

4.3. Modelos basados en Redes Neuronales

Ahora que ya tenemos nuestro modelo MLP definitivo, vamos a analizar los resultados y a ver cómo son las predicciones del modelo. A nivel cuantitativo, hemos detectado que los resultados son bastante similares a los de el modelo definitivo de regresión lineal múltiple, ya que, por aportar contexto, el MAPE es de alrededor del 2.8% para el conjunto de datos de demanda guardados para la evaluación. Para poder tener una imagen de la calidad de las predicciones de este modelo, se mostrará en la próxima figura 4.24 el contraste entre las predicciones del modelo y los valores reales en una semana del periodo de evaluación.




Figura 4.24: Demanda real contra la predicción del modelo en un periodo de tiempo

Se puede apreciar que las predicciones de la demanda tienden a ser bastante fidedignas. No se observan desviaciones demasiado importantes de los valores reales, y las pequeñas desviaciones que existen las podemos justificar como que existen factores que son muy difícilmente controlables o directamente incontrolables. Sin embargo, creemos que existe cierto margen de mejora, algo que intentaremos demostrar con los siguientes modelos.

Por último, nos quedaría hacer un análisis de los residuos del modelo, para ver si nos quedan factores por analizar, o si nuestro modelo cuenta con ciertos sesgos. En primer lugar, mostraremos todos los residuos en el intervalo de tiempo de evaluación para ver si se aprecia algún comportamiento extraño a simple vista. Como se comentó anteriormente, debería parecerse a un *ruido blanco*.

Capítulo 4. Entrenamiento y Resultados




Figura 4.25: Residuos del modelo en el periodo de evaluación

En efecto, en un primer vistazo a la figura 4.25, parece que los residuos tienen un comportamiento bastante parecido al *ruido blanco*. La media parece bastante centrada en 0, la varianza no se altera demasiado a lo largo de la ventana de datos, y no se percibe ningún patrón estacional, al menos a simple vista. Para asegurarnos de todo ello, vamos a demostrar esto a nivel de datos. Se mostrará a continuación, en las figuras 4.26 y 4.27, el histograma de los residuos y los correlogramas.

4.3. Modelos basados en Redes Neuronales




Figura 4.26: Histograma de los residuos en el periodo de evaluación

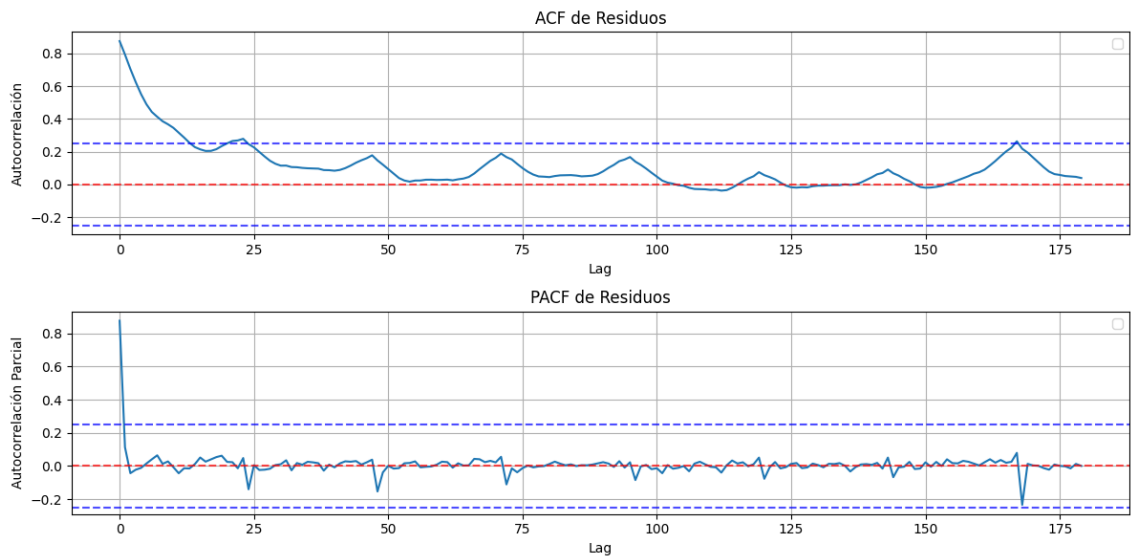


Figura 4.27: Correlogramas de los residuos en el periodo de evaluación

Capítulo 4. Entrenamiento y Resultados

En el histograma de residuos, observamos que se parece a una distribución normal, y aunque la media no está centrada en cero, sino que tiende ligeramente a el eje positivo, está muy cercana a el punto medio. Esto nos dice que el modelo no tiene ningún comportamiento extraño, pero tiene un ligero sesgo a sobreestimar la demanda, al menos en el periodo de evaluación.

Por la parte de los correlogramas, tampoco tenemos ningún factor que nos invalide el modelo. Centrándonos en la función de autocorrelación regular vemos que comienza en valores un poco elevados, pero disminuye a ritmo moderado y permanece en nuestro rango objetivo, cercano a 0. Puede tener sentido que exista cierta correlación entre residuos cercanos, ya que si hemos sobreestimado la demanda de una hora, es bastante probable que hayamos sobreestimado también la de la hora siguiente. Por el lado de la función de autocorrelación parcial, tiene un comportamiento similar, pero en este caso disminuye más rápido hacia 0, y permanece mucho más fija y mucho más cercana a valores nulos. Por tanto, el modelo no parece dejar factores importantes por explicar, ya que no existen patrones en los picos.

Cabe añadir que se ha realizado también un análisis pormenorizado de los residuos, obteniendo aquellos momentos donde las desviaciones son mayores, y reflexionando acerca de qué factores pueden haber causado esos grandes errores. En este análisis no se ha apreciado nada reseñable. Eran, días cercanos a periodos festivos, como navidades o Semana Santa, o días de agosto, donde la demanda tiene un comportamiento más extraño ya que cambian numerosos factores. Pero también eran días regulares, y, en general, no se apreciaba ningún patrón concreto que se pueda capturar. Además, si la causa del error no está clara, no deberíamos hacer nada, ya que al hacer transformaciones concretas para disminuir el error de la validación, estaríamos sobreajustando el modelo.

4.3.2. Convolutional Neural Network (CNN)

Una vez ya se ha construido la arquitectura definitiva para este modelo con el que vamos a trabajar, procedemos a entrenar el modelo y a realizar los distintos ajustes, parecidos a los que realizamos para la anterior red neuronal, siguiendo lo que se definió al principio de la sección. Mostraremos a continuación la evolución de la función de pérdida a lo largo del entrenamiento, tanto para los datos de entrenamiento como para aquellos de validación, como ya realizamos en el anterior modelo. Utilizaremos escala logarítmica y omitiremos los primeros 10 valores, como ya comentamos antes, para facilitar nuestra labor de análisis.

4.3. Modelos basados en Redes Neuronales

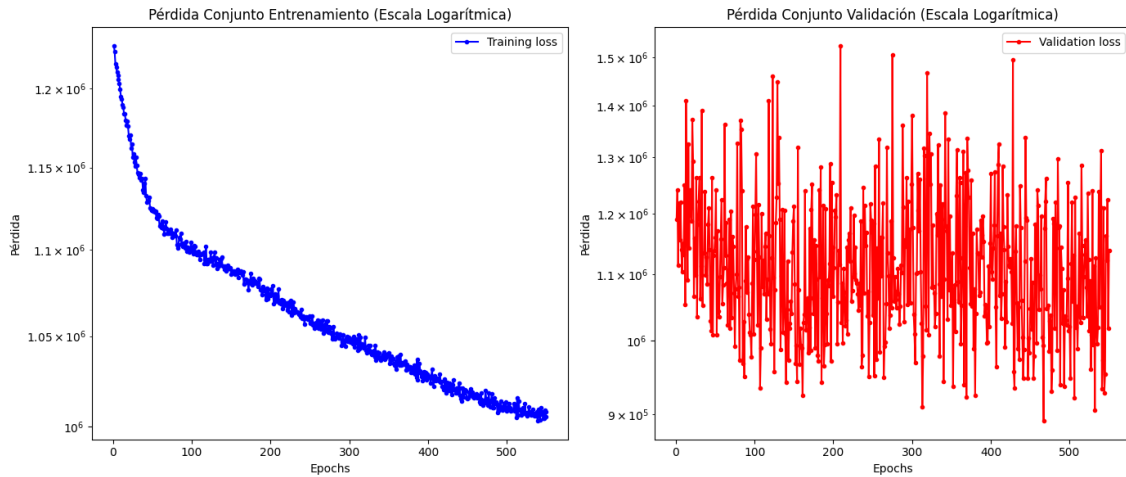


Figura 4.28: Evolución de la función de pérdida a lo largo de cada epoch en escala logarítmica

En este caso, en la figura 4.28 se observa que la pérdida en el conjunto de entrenamiento disminuye a lo largo de todas las epochs, mientras que si nos fijamos en la evolución de la pérdida en el conjunto de validación, no podemos llegar a decir que la pérdida comienza a aumentar a partir de cierto punto, pero se puede afirmar que existe un claro estancamiento, sin que la pérdida llegue a aumentar o disminuir de forma clara. Sin embargo, tampoco se puede decir que el modelo se llegue a sobreajustar, y los mejores resultados en los datos de validación, aunque con una ligera diferencia, se dan al final de las epochs. Debido a esto, se ha considerado llegar hasta el final del entrenamiento para este modelo. No se valora hacer un entrenamiento más extenso, ya que casi desde el principio, se produce un estancamiento bastante claro.

Una vez hemos entrenado nuestro modelo CNN definitivo, se va a analizar los resultados y ver cómo son las predicciones. A nivel de datos objetivos, este modelo ofrece peores resultados que la red neuronal anterior MLP, con un MAPE de alrededor del 3.3% para el conjunto de datos de demanda de evaluación. No es una diferencia sustancial, pero sí que es una diferencia clara que nos permite discernir cuál de los dos modelos ofrece mejores resultados. Procederemos a mostrar en la próxima figura 4.29 el contraste entre las predicciones del modelo y los valores reales en una semana del periodo de evaluación.

Capítulo 4. Entrenamiento y Resultados




Figura 4.29: Demanda real contra la predicción del modelo en un periodo de tiempo

Como para el anterior modelo, se puede apreciar que las predicciones de la demanda tienden a ser bastante precisas, y a nivel visual, apenas se aprecia diferencia, por lo que el análisis que realizamos viene a ser prácticamente el mismo. Por tanto, procederemos directamente a hacer un análisis de los residuos del modelo. En primer lugar, en la figura 4.30 mostraremos todos los residuos en el intervalo de tiempo de evaluación.

4.3. Modelos basados en Redes Neuronales




Figura 4.30: Residuos del modelo en el periodo de evaluación

Los residuos emulan en esta ocasión de forma mucho más clara la aleatoriedad del *ruido blanco*. La media está totalmente centrada en 0, la varianza es constante a lo largo del tiempo, y no se perciben patrones estacionales. Además, en esta ocasión, se aprecia una varianza menor, con menos cantidad de residuos que se alejan considerablemente del 0. Para asegurarnos de todo ello, vamos a demostrar esto a nivel de datos. Se mostrará a continuación en las figuras 4.31 y 4.32 el histograma de los residuos y los correlogramas.

Capítulo 4. Entrenamiento y Resultados




Figura 4.31: Histograma de los residuos en el periodo de evaluación

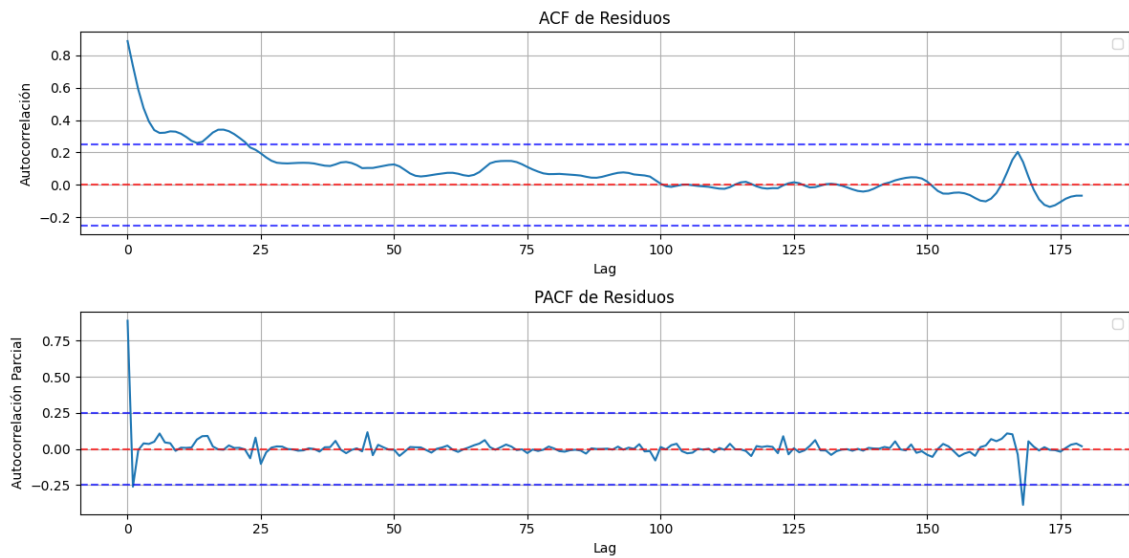


Figura 4.32: Correlogramas de los residuos en el periodo de evaluación

4.3. Modelos basados en Redes Neuronales

Si nos fijamos en el histograma de residuos, en este modelo sigue a una distribución normal, y en esta ocasión la media parece totalmente centrada en cero. Además los residuos parecen estar más estables y cercanos al valor medio. Siendo precisos, la media es de 274 y la desviación estándar es 1092.

Por la parte de los correlogramas, todos los parámetros parecen correctos. La función de autocorrelación regular que comienza en valores un poco elevados, pero disminuye y se estabiliza en nuestro rango objetivo, cercano a 0, como sucedió en el modelo MLP. Mientras que la función de autocorrelación parcial, disminuye más rápido hacia 0, y permanece mucho más fija y mucho más cercana a valores nulos, también como en el anterior modelo. Por tanto, el modelo no parece dejar factores relacionales por explicar.

Resumiendo, tenemos que este modelo ofrece resultados ligeramente peores que el anterior, aunque son relativamente precisos. Además parece un modelo más estable, con un menor sesgo, y con errores más constantes. Cabe añadir que la cantidad de residuos que superan el rango normal es menor en este modelo. Sin embargo, la diferencia de métricas de error parece pesar más en la elección del modelo, y este modelo parece inferior a la red neuronal MLP.

4.3.3. Long Short-Term Memory (LSTM) Network

Ahora procederemos a implementar este nuevo modelo y a su entrenamiento. Pese a que sobre el papel pudiese parecer que el modelo LSTM sería útil para nuestro problema, los resultados después del ajuste nos indican lo contrario. Además, se ha tratado de un modelo muy lento y pesado de entrenar, con una duración de 3 horas para tan solo 40 epochs. En la figura 4.33 se va a mostrar la evolución de la pérdida, que permanece constante prácticamente en el conjunto de validación. A continuación, se mostrarán en la figura 4.34 las predicciones del modelo contra los valores reales.




Figura 4.33: Evolución de la función de pérdida a lo largo de cada epoch en escala logarítmica

Capítulo 4. Entrenamiento y Resultados




Figura 4.34: Demanda real contra la predicción del modelo en un periodo de tiempo

Se observa de manera clara que no existe una mejoría en los resultados del entrenamiento, por lo que no tiene sentido probar con entrenamientos más potentes. Además, las predicciones nos indican que este modelo no es apropiado en esta ocasión. Estas redes teóricamente tienen capacidad para capturar patrones a largo plazo y dependencias temporales en los datos históricos de demanda, y pueden captar patrones complejos incluso cuando las relaciones entre las variables son no lineales. Pese a ello, no han demostrado ser útiles para la predicción de demanda de electricidad, quizás porque son más apropiadas para datos de largo plazo, con un funcionamiento distinto.

4.3.4. Modelo híbrido LSTM-DNN

A lo largo de los entrenamientos realizados hasta este momento, se ha probado a establecer un tasa de aprendizaje (learning rate) distinto, para ver si se llega a resultados mejores. En general, no ha aportado demasiado (de hecho al utilizar tasas mayores los resultados que se llegaban a obtener eran peores, pese a que el entrenamiento avanzaba más rápidamente al principio), y se ha decidido dejar el valor que el entorno utiliza por defecto. Sin embargo, en este modelo, al utilizar la tasa por defecto, la evolución de la pérdida en la validación era bastante extraña. Disminuía muy rápidamente hasta valores muy bajos, y a partir de ahí, volvía a subir mucho casi hasta el punto inicial, para luego comenzar a bajar de nuevo, sin llegar a alcanzar cotas tan bajas como en el primer impulso bajista.

En contraste, al utilizar un learning rate específico, de magnitud inferior, el com-

4.3. Modelos basados en Redes Neuronales

portamiento de la pérdida era más claro, y los resultados obtenidos llegaban a ser mejores. Por tanto, se va a utilizar dicha tasa para el modelo híbrido definitivo. Vamos a ver cómo evoluciona la pérdida en los conjuntos de entrenamiento y validación.

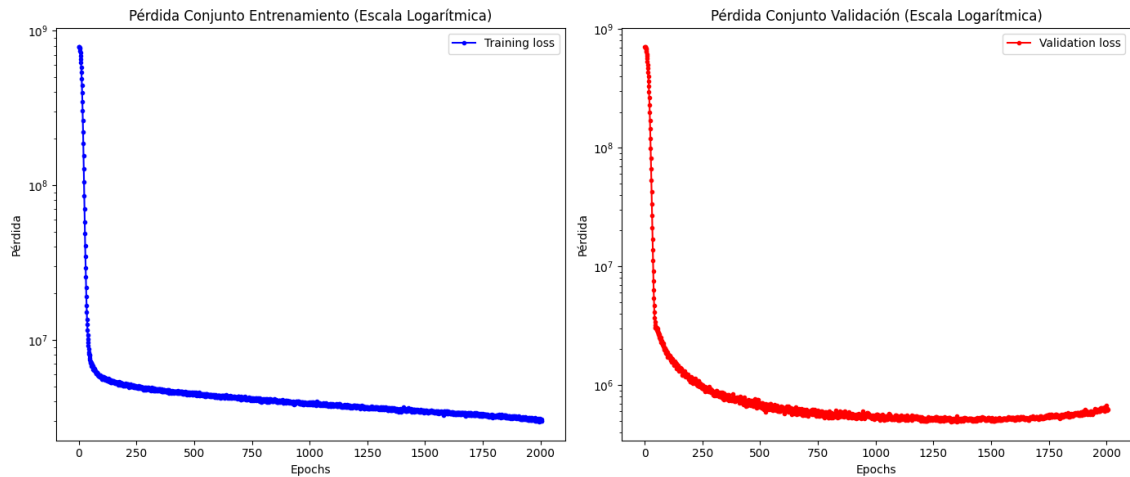


Figura 4.35: Evolución de la función de pérdida a lo largo de cada epoch en escala logarítmica

Si observamos la figura 4.35 situada anteriormente, podemos observar que, en comparación con otros entrenamientos, la pérdida en los conjuntos de entrenamiento y validación evoluciona de forma bastante simétrica. Disminuye muy rápido inicialmente, para luego aumentar el esfuerzo necesario para reducir la pérdida paulatinamente. En cierto punto, la pérdida en el conjunto de validación se estabiliza, y parece que comienza a incrementarse ligeramente. Por ello, en tal momento, parece lo más indicado pausar el entrenamiento, ya que el modelo deja de generalizar y comienza a sobreajustarse. Una vez visto esto, se procederá a mostrar las predicciones del modelo híbrido definitivo en una semana del conjunto de evaluación en la siguiente ilustración 4.36.

Capítulo 4. Entrenamiento y Resultados




Figura 4.36: Demanda real contra la predicción del modelo en un periodo de tiempo

Si nos fijamos en las predicciones, lo primero que podemos extraer es que los resultados parecen muy buenos, en contraste con los obtenidos en el modelo LSTM. Parece que se confirma que la combinación de las redes neuronales recurrentes LSTM, con las redes neuronales densas, ha resultado exitosa, y se logra aprovechar las ventajas de ambas redes, obteniendo un modelo bastante preciso. Si se observan los datos, se llega a la conclusión que los resultados de dicho modelo híbrido son los mejores de todos los modelos obtenidos hasta ahora, con un MAPE de alrededor del 2.7%. Es cierto que en los modelos de series temporales, se lograba una precisión incluso mayor, pero en semanas específicas. Por tanto, si los residuos no nos muestran nada extraño, este modelo parece ser bastante fiable.

4.3. Modelos basados en Redes Neuronales




Figura 4.37: Residuos del modelo en el periodo de evaluación

Analicemos la figura 4.37 que nos muestra los residuos en bruto. En concordancia con los datos que esperamos, los residuos siguen el comportamiento de *ruido blanco*, de la misma forma que observamos en los residuos de modelos anteriores. Ahora pasaremos a analizar los datos. Para ello en primer lugar se mostrará en las figuras 4.38 y 4.39 el histograma de los residuos y los correlogramas.

Capítulo 4. Entrenamiento y Resultados




Figura 4.38: Histograma de los residuos en el periodo de evaluación

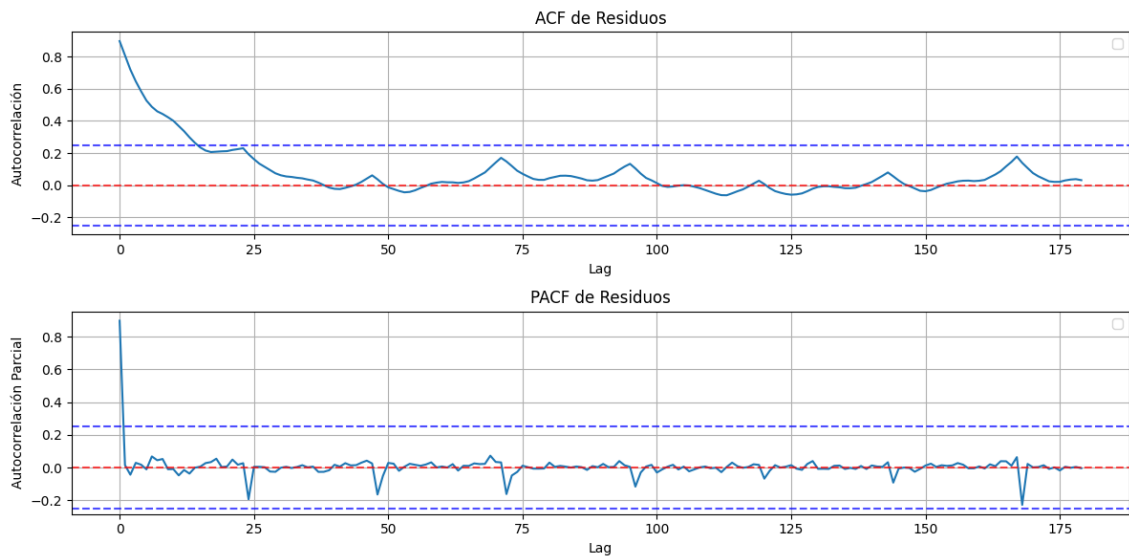


Figura 4.39: Correlogramas de los residuos en el periodo de evaluación

4.3. Modelos basados en Redes Neuronales

Comenzaremos analizando el histograma. Parece el más limpio de todos los mostrados hasta ahora. La media es de -5.22 , prácticamente en 0, la más centrada con bastante diferencia de las medias de residuos observadas hasta ahora. De hecho, es la única ocasión en la que nuestro modelo no realiza predicciones sesgadas por el lado de los excesos. Además, la desviación estándar es 963.93 , bastante parecida a las anteriores. En general, el histograma nos deja sensaciones bastante optimistas en lo que respecta a la corrección y fiabilidad del modelo.

El análisis de las funciones de autocorrelación regular y autocorrelación parcial es prácticamente el mismo que todos los realizados hasta entonces, por lo que no nos pararemos demasiado. La única diferencia observable es que los valores se adentran dentro de nuestro rango objetivo más rápidamente, por lo demás no se observa nada reseñable. En conclusión, el análisis de residuos nos parece indicar que el modelo es bastante bueno. Si recordamos que los resultados de este modelo son los mejores hasta ahora, este modelo resulta muy interesante.

4.3.5. Modelo Transformer Encoder

Procedemos al entrenamiento del último modelo. Como se ha realizado hasta ahora, mostraremos en la figura 4.40 la evolución de la función de pérdida.

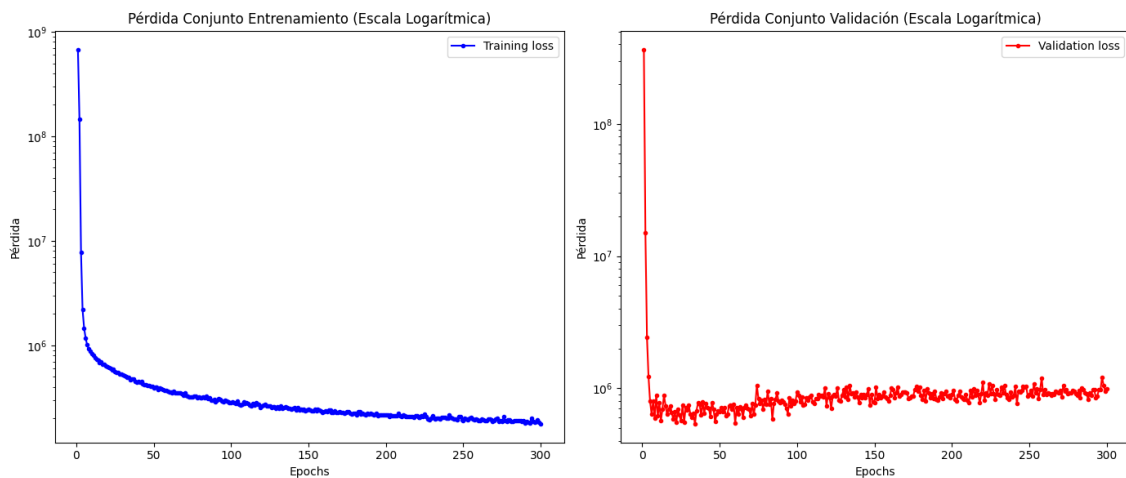


Figura 4.40: Evolución de la función de pérdida a lo largo de cada epoch en escala logarítmica

Vemos cómo la pérdida disminuye de forma muy rápida en las primeras epochs, y pronto se estabiliza y comienza a reducirse drásticamente la velocidad de bajada. Podemos afirmar que el entrenamiento se podría parar entre la epoch 20 y la 60. A partir de entonces, comienza a aumentar ligeramente de forma constante. Ahora una vez tenemos entrenado el modelo final, vamos a ver qué predicciones realiza.

Capítulo 4. Entrenamiento y Resultados




Figura 4.41: Demanda real contra la predicción del modelo en un periodo de tiempo

En las predicciones de la figura 4.41 se aprecia a simple vista que el funcionamiento de este modelo parece bastante interesante. A nivel estadístico, el MAPE en el conjunto de evaluación es de alrededor del 2.7%, parecido al de el anterior modelo.

Una vez hemos visto que el modelo parece ofrecer buenas predicciones, vamos a realizar un pequeño análisis de residuos. En las próximas 3 ilustraciones 4.42, 4.43 y 4.44, podemos ver los residuos en bruto, el histograma de residuos, y los correlogramas de los mismos respectivamente.

4.3. Modelos basados en Redes Neuronales




Figura 4.42: Residuos del modelo en el periodo de evaluación




Figura 4.43: Histograma de los residuos en el periodo de evaluación

Capítulo 4. Entrenamiento y Resultados




Figura 4.44: Correlogramas de los residuos en el periodo de evaluación

Para evitar caer en la redundancia, ya que el análisis va a ser prácticamente igual que para el anterior modelo, vamos a explicar el análisis de residuos muy brevemente. En general, los residuos no muestran ningún aspecto negativo del modelo. Los residuos se parecen a un *ruido blanco*, el histograma sigue una distribución normal, con media muy centrada en 0, en 74.49 exactamente, y desviación típica de 1006,7. Por último, los correlogramas parecen no mostrar patrones temporales, y se centran en torno a 0. Por tanto, sumado a que los resultados son bastante exactos, se podrá contar con este modelo.

4.3.6. Métricas de error para los modelos de redes neuronales

Ahora vamos a mostrar en una tabla todas las métricas de error que ya establecimos en un inicio, para todos los modelos de redes neuronales. Estas métricas son, en todos los casos, para las predicciones del modelo en la ventana de evaluación.

Modelo	MAPE	RMSE	MAE	R2
Modelo MLP	2.8679	994.3958	728.2055	0.9467
Modelo CNN	3.3419	1108.6235	835.9513	0.9338
Modelo LSTM	15.9509	4599.7448	3797.7956	-0.1392
Modelo LSTM-DNN	2.7039	963.9478	694.6747	0.9499
Modelo Transformer Encoder	2.7505	1009.4555	706.9914	0.9451

Queda bastante claro que, basándonos en dichas métricas de error, el mejor modelo de redes neuronales para este problema es el modelo híbrido LSTM-DNN, ya que alcanza el valor más óptimo de entre todos los modelos para cada una de las

métricas de error. Este modelo, que combina las redes neuronales recurrentes LSTM, y las redes neuronales densas(DNN), ha demostrado ser bastante efectivo para la predicción de la demanda.

4.4. Comparativa

Después de trabajar con distintos tipos de modelos, se va a finalizar el trabajo realizando una comparación global entre todos ellos, y escogiendo cuál de ellos sería el mejor que se pueda utilizar para predecir la demanda de electricidad en España. Esto lo podremos hacer de manera sencilla gracias a unificar las métricas de error para todos los tipos de modelos. En primer lugar, vamos a mostrar tabularmente los resultados de los modelos finales desarrollados.

Modelo	MAPE	RMSE	MAE	R2
Modelo Regresión Lineal	2.8905	1113.0410	718.6509	0.9332
Modelo AUTOARIMA[24]	19.9245	7475.9348	5659.0482	-1.5762
Modelo SARIMA[168]	13.0745	4103.8204	3256.7802	0.1532
Modelo TBATS	8.4093	2895.0712	2282.5819	0.5217
Modelo MLP	2.8679	994.3958	728.2055	0.9467
Modelo CNN	3.3419	1108.6235	835.9513	0.9338
Modelo LSTM	15.9509	4599.7448	3797.7956	-0.1392
Modelo LSTM-DNN	2.7039	963.9478	694.6747	0.9499
Modelo Transformer Encoder	2.7505	1009.4555	706.9914	0.9451

Si nos centramos meramente en las métricas de error, podemos concluir, que después de todo este proceso de desarrollo e investigación, el mejor modelo que hemos logrado obtener, es el modelo de redes neuronales híbrido LSTM-DNN. Además, la ventana de evaluación es muy extensa, de 1 año de duración, por lo que podemos afirmar con bastante seguridad que este modelo es fiable y bastante preciso, al menos hasta donde nos indican las métricas de error. Se trata de alrededor de 10000 predicciones, en todos los tipos de meses, días, horas, estaciones, u otras circunstancias específicas. Por tanto, estos resultados no se dan por casualidad, y podemos esperar que se mantenga una precisión parecida a lo largo de los próximos meses.

Sin embargo, esta comparación es ciertamente injusta para los modelos de series temporales. Mientras que en el resto de modelos, las predicciones se hacían teniendo en cuenta las variables y factores de corto plazo para todo el periodo de evaluación, en los modelos de series temporales, por la definición y el entrenamiento de los mismos, las predicciones se hacían desde el periodo 1 a un año vista. Por tanto, los resultados acababan siendo bastante mediocres, pero el objetivo del trabajo no era realizar predicciones a largo plazo.

En contraste, si vemos las predicciones de los modelos SARIMA y TBATS, en las primeras semanas de la ventana temporal, llegaban a obtener una precisión

Capítulo 4. Entrenamiento y Resultados

excepcional, llegando a tener un MAPE inferior al 2%. Esto es más sorprendente si cabe teniendo en cuenta que estos modelos solo utilizan como variable la propia evolución de la demanda. No obstante, tampoco se puede poner a estos modelos por encima, ya que sólo contamos con unas pocas semanas para validar este dato, mientras que para los otros modelos contamos con 52.

Capítulo 5

Conclusiones y trabajo futuro

A lo largo de este trabajo se han estudiado, implementado y analizado distintos modelos para la predicción de la demanda de electricidad, aunque estos mismos procedimientos se pueden utilizar para desarrollar modelos de predicción de demanda de otras fuentes de energía. En concreto, se ha trabajado con modelos de regresión lineal múltiple, series temporales y redes neuronales.

En primer lugar, se ha cumplido con el principal objetivo de este trabajo, que consistía en la obtención de un modelo de predicción de demanda de electricidad que nos permita hacer predicciones a corto plazo con cierta precisión.

Además, se han alcanzado también los objetivos intermedios, cuyo cumplimiento ha sido clave para la realización de la tarea global. Para ello, se ha estudiado el estado del arte, se han obtenido y procesado los datos, se han desarrollado e implementado los distintos tipos de modelos, se han comparado sus resultados, y por último, se ha escrito esta memoria que describa todo el trabajo.

Tras analizar los resultados obtenidos, podemos concluir que el modelo que podemos seleccionar con mayor confianza dada su precisión es el modelo híbrido de redes neuronales. No obstante, parecen bastante interesantes los modelos de series temporales, y se debería intentar validar sus resultados con un mayor volumen de datos que sostengan las buenas métricas. Para ello se necesitarán más datos de demanda a futuro, y realizar más ajustes de los modelos, lo que será un proceso arduo, ya que el tiempo de entrenamiento para estos tipos de modelos es del orden de 4 a 6 horas.

En lo que se refiere a los trabajos futuros, quedan varios campos que explorar, y todavía se puede profundizar más en aquellos que se han visto en este trabajo.

En primer lugar, se podría estudiar la segmentación del problema. Es decir, se podría dividir el problema por, por ejemplo, comunidades autónomas. Establecer un modelo por cada comunidad, y luego calcular la demanda total como la suma de todas las particulares. Esto podría mejorar las predicciones por distintas vías. Una de ellas tiene relación con las diferencias térmicas. La evolución del clima puede tener variaciones diarias importantes a lo largo de la península, y por tanto, la variable temperatura, al establecer una media, puede dejar una parte

Capítulo 5. Conclusiones y trabajo futuro

por explicar. Por otro lado, los festivos autonómicos también pueden tener una influencia en la demanda, sobre todo en las comunidades más pobladas. Por último, también pueden existir pequeñas diferencias de comportamiento entre las distintas regiones. El principal obstáculo de esta misión sería la obtención de los datos. Los datos por región serán más difíciles de obtener de forma fiable, y no se tiene constancia de su existencia. Además este enfoque supondría bastante más trabajo.

Por otro lado, se podrían inspeccionar los modelos híbridos, combinando modelos de regresión lineal, series temporales e inteligencia artificial indistintamente. Esto conllevaría cierto trabajo, ya que no es sencillo realizar esta combinación para obtener estructuras útiles. Esta hibridación debe ser realizada gracias a un análisis lógico previo, y no siempre nos llevará a modelos competentes. Sin embargo, si se realiza la tarea correctamente, se puede llegar a grandes modelos que aprovechen las ventajas de ambas técnicas.

Asimismo, es prometedora la exploración de nuevas variables para utilizar como parámetros de entrada de los modelos. Es complicado encontrar variables que nos aporten capacidad predictiva, pero es probable que existan algunas más que nos ayuden a perfeccionar los modelos. Sería interesante comenzar revisando variables relacionadas con el impulso económico, la renta disponible, o el precio de la energía. Las principales trabas de esta tarea serán la dificultad de encontrar datos fiables para estas variables, los posibles costes asociados a los datos, y el tiempo invertido en encontrar variables que realmente nos ayuden a predecir la demanda con mayor precisión.

Por último, se podrían perfeccionar los modelos ya existentes, o profundizar dentro de las mismas técnicas. En cuanto a la profundización dentro de las mismas técnicas, no queda demasiado por investigar, ya que se han explorado numerosos tipos de modelos. Además de todos los mostrados, se han probado modelos adicionales que no han cumplido las expectativas. Parece que queda un mayor potencial por explorar por la parte de la optimización de los tipos de modelos ya trabajados. Se pueden utilizar estructuras distintas, quizás más complejas, y quizás ajustar mejor los hiperparámetros, pese a que ya se han optimizado bastante en este trabajo. No obstante, existen muchos parámetros para modificar, y dedicando un mayor número de horas probablemente se puedan mejorar las predicciones.

Capítulo 6

Análisis de impacto

Los modelos de predicción de demanda de energía tienen el potencial de generar un impacto importante en varios contextos. A nivel personal, pueden optimizar el consumo energético personal y reducir la factura energética. A nivel empresarial, pueden ayudar a reducir costes operativos y mejorar la eficiencia energética. En el ámbito social, pueden contribuir a educir la pobreza energética, y mejorar el acceso a la energía para comunidades vulnerables. En referencia a lo económico, la buena previsión de demanda mejora la planificación y la gestión de recursos energéticos en el país, promueve la inversión en energías renovables y contribuye al crecimiento económico. Por último, a nivel medioambiental, puede ayudar promover la eficiencia en el uso de recursos energéticos y contribuir a la protección del planeta.

Los beneficios esperables pueden ser los siguientes:

- Mejora de la eficiencia energética gracias a identificar áreas de ineficiencia energética y sugerir medidas para mejorarla, lo que contribuye a optimizar el consumo de energía.
- Reducción de las emisiones de CO₂ y de gases de efecto invernadero al optimizar el consumo de energía y reducir el consumo.
- Mejora de la fiabilidad del suministro energético al ayudar a las empresas energéticas a anticipar la demanda y ajustar la producción en consecuencia, reduciendo el riesgo de apagones.
- Promoción de la energía renovable, optimizando su uso y facilitando la transición hacia un sistema energético más sostenible.

En cuanto a los posibles efectos adversos, podrían ser una falta de participación de todas las partes interesadas en la implementación de estos modelos, una dependencia de la tecnología, o desigualdades en el acceso a la tecnología.

Los modelos de predicción de demanda de electricidad, gas u otras fuentes de energía pueden contribuir al logro de varios Objetivos de Desarrollo Sostenible (ODS), principalmente: ODS 7 (Energía asequible y no contaminante), ODS 13

Capítulo 6. Análisis de impacto

(Acción por el clima), ODS 9 (Industria, innovación e infraestructura), ODS 11 (Ciudades y comunidades sostenibles).

Bibliografía

- [1] V. D. Simona Filipova-Petrakieva. «Short-Term Forecasting of Hourly Electricity Power Demand». (2022), dirección: <https://www.etasr.com/index.php/ETASR> (visitado 02-06-2024).
- [2] E. Zhou, S. Gadzanku, C. Hodge, M. C. N. R. E. L. S. de la Rue du Can y J. Z. L. B. N. Laboratory. «BEST PRACTICES IN ELECTRICITY LOAD MODELING AND FORECASTING FOR LONG-TERM POWER SYSTEM PLANNING». (2023), dirección: <https://www.nrel.gov/usaaid-partnership/> (visitado 02-06-2024).
- [3] D. K. S. Ivan Smajla Domagoj Vulin. «Short-term forecasting of natural gas consumption by determining the statistical distribution of consumption data». (2023), dirección: <https://www.sciencedirect.com/journal/energy-reports> (visitado 01-06-2023).
- [4] R. Eléctrica. «Red Eléctrica. Demanda y producción en tiempo real». (2024), dirección: <https://www.ree.es/es/actividades/demanda-y-produccion-en-tiempo-real> (visitado 01-06-2023).
- [5] I. de Ingeniería del Conocimiento (IIC). «Predicción de la demanda de electricidad Servicio de predicción de demanda de electricidad basado en técnicas de aprendizaje automático y Redes Neuronales Artificiales.» (2024), dirección: <https://www.iic.uam.es/soluciones/energia/prediccion-demanda-energia/prediccion-demanda-electricidad/> (visitado 01-06-2023).
- [6] H. M. M. Medhat A. Rostum Amr A.Zamel e I. E. Ziedan. «Electrical Load Forecasting: A methodological overview». (2020), dirección: <https://www.sciencepubco.com/index.php/IJET> (visitado 02-06-2024).
- [7] Y.-H. Hsiao. «Household Electricity Demand Forecast Based on Context Information and User Daily Schedule Analysis From Meter Data». (2014), dirección: <https://ieeexplore.ieee.org/document/6926785> (visitado 02-06-2024).
- [8] H. Zareipour, C. A. C. F. IEEE y K. B. S. M. IEEE. «Economic Impact of Electricity Market Price Forecasting Errors: A Demand-side Analysis». (2009), dirección: https://www.researchgate.net/profile/Hamidreza-Zareipour/publication/224608398_Economic_Impact_of_Electricity_Market_Price_Forecasting_Errors_A_Demand-Side_Analysis/links/5735057908ae9ace8409587d/Economic-Impact-of-Electricity-

BIBLIOGRAFÍA

- Market-Price-Forecasting-Errors-A-Demand-Side-Analysis.pdf (visitado 02-06-2024).
- [9] W. LABYS, *Modelling Mineral and Energy Markets*. Kluwer Academic, 1999.
- [10] V. Sharma, Ü. Cali, B. Sardana, M. Kuzlu, D. Banga y M. Pipattanasomporn. «Data-driven short-term natural gas demand forecasting with machine learning techniques». (2021), dirección: <https://www.elsevier.com/locate/petrol> (visitado 02-06-2024).
- [11] OMIE. «OMIE». (2024), dirección: <https://www.omie.es/> (visitado 01-06-2023).
- [12] R. Eléctrica. «Red Eléctrica». (2024), dirección: <https://www.ree.es/es> (visitado 01-06-2023).
- [13] CNMC. «CNMC Mercado Eléctrico». (2024), dirección: <https://www.cnmc.es/ambitos-de-actuacion/energia/mercado-electrico> (visitado 01-06-2023).
- [14] Endesa. «Endesa. ¿Cómo funciona el mercado eléctrico?» (2024), dirección: <https://www.endesa.com/es/la-cara-e/sector-energetico/como-funciona-el-mercado-electrico-en-espana> (visitado 01-06-2023).
- [15] Iberdrola. «Iberdrola. Contratos PPA». (2024), dirección: <https://www.iberdrola.com/conocenos/contrato-ppa-energia> (visitado 01-06-2023).
- [16] L. Hernandez, C. Baladron, J. M. Aguiar et al. «A survey on electric power demand forecasting: future trends in smart grids, microgrids and smart buildings». (2014), dirección: https://www.researchgate.net/publication/264937761_A_Survey_on_Electric_Power_Demand_Forecasting_Future_Trends_in_Smart_Grids_Microgrids_and_Smart_Buildings (visitado 02-06-2024).
- [17] R. V. Klyuev, I. D. Morgoev, A. D. Morgoeva et al. «Methods of Forecasting Electric Energy Consumption: A Literature Review». (2022), dirección: <https://www.mdpi.com/1996-1073/15/23/8919> (visitado 02-06-2024).
- [18] T. Hong. «Short Term Electric Load Forecasting.» (2010), dirección: <https://repository.lib.ncsu.edu/server/api/core/bitstreams/2f574ab7-59eb-4001-b869-10abf40fbd7d/content> (visitado 02-06-2024).
- [19] T. Hong, P. Wang y H. L. Willis. «A Naïve Multiple Linear Regression Benchmark for Short Term Load Forecasting». (2011), dirección: <https://ieeexplore.ieee.org/document/6038881> (visitado 02-06-2024).
- [20] L. Hernández-Callejo, C. B. Z. J. M. Aguiar, B. Carro, A. J. Sanchez-Esguevillas, J. Lloret y J. Massana. «A Survey on Electric Power Demand Forecasting: Future Trends in Smart Grids, Microgrids and Smart Buildings». (2014), dirección: https://www.researchgate.net/publication/264937761_A_Survey_on_Electric_Power_Demand_Forecasting_Future_Trends_in_Smart_Grids_Microgrids_and_Smart_Buildings (visitado 02-06-2024).
- [21] «Python». (2024), dirección: <https://www.python.org/> (visitado 01-06-2023).
- [22] «Jupyter». (2024), dirección: <https://jupyter.org/> (visitado 01-06-2023).


- [23] «Pandas». (2024), dirección: <https://pandas.pydata.org/> (visitado 01-06-2023).
- [24] «Numpy». (2024), dirección: <https://numpy.org/> (visitado 01-06-2023).
- [25] «Scikit-Learn». (2024), dirección: <https://scikit-learn.org/stable/> (visitado 01-06-2023).
- [26] «Pmdarima». (2024), dirección: <https://pypi.org/project/pmdarima/> (visitado 01-06-2023).
- [27] «Tensorflow». (2024), dirección: <https://www.tensorflow.org/?hl=es-419> (visitado 01-06-2023).
- [28] A. E. de Meteorología. «AEMET». (2024), dirección: <https://www.aemet.es/es/> (visitado 01-06-2023).
- [29] R. Eléctrica. «ESIOS». (2024), dirección: <https://api.esios.ree.es/> (visitado 01-06-2023).
- [30] T. Hong, J. Wilson y J. Xie. «Long Term Probabilistic Load Forecasting and Normalization With Hourly Information». (2014), dirección: <https://ieeexplore.ieee.org/document/6595138> (visitado 02-06-2024).
- [31] T. Hong, M. Gui, M. E. Baran y H. L. Willis. «Modeling and Forecasting Hourly Electric Load by Multiple Linear Regression with Interactions». (2010), dirección: <https://ieeexplore.ieee.org/document/5589959> (visitado 02-06-2024).
- [32] G. E. Box y G. M. Jenkins, *Time series analysis: Forecasting and control San Francisco*. Calif: Holden-Day, 1976.
- [33] A. O. Akyuz, M. Uysal, B. A. Bulbul y M. O. Uysal. «Ensemble Approach for Time Series Analysis in Demand Forecasting». (2017), dirección: <https://ieeexplore.ieee.org/document/8001123> (visitado 02-06-2024).
- [34] G. E. Box y G. M. Jenkins. «Time series analysis: Forecasting and control San Francisco». (1976), dirección: <https://ieeexplore.ieee.org/document/5589959> (visitado 02-06-2024).
- [35] M. G. Pinheiro, S. C. Madeira y A. P. Francisco. «Short-term electricity load forecasting—A systematic approach from system level to secondary substations». (2023), dirección: <https://www.sciencedirect.com/science/article/pii/S0306261922017500> (visitado 02-06-2024).
- [36] O. ABOTALEB, T. MAKAROVSKIKH, A. YONAR et al. «State of the art in wind speed in England using BATS ,TBATS , Holt's Linear and ARIMA model». (2022), dirección: <http://103.215.208.102/index.php/MAUSAM/article/view/598> (visitado 02-06-2024).
- [37] M. Akpınar, M. F. Adak y N. Yumusak. «Day-Ahead Natural Gas Demand Forecasting Using Optimized ABC-Based Neural Network with Sliding Window Technique: The Case Study of Regional Basis in Turkey». (2017), dirección: <https://www.mdpi.com/1996-1073/10/6/781> (visitado 02-06-2024).

BIBLIOGRAFÍA

- [38] A. Graves, S. Fernandez y J. Schmidhuber. «Multi-Dimensional Recurrent Neural Networks». (2013), dirección: <https://arxiv.org/pdf/0705.2011> (visitado 02-06-2024).
- [39] Y. Han, G. Huang, S. Song, L. Yang, H. Wang e Y. Wang. «Dynamic Neural Networks: A Survey». (2022), dirección: <https://www.sciencedirect.com/science/article/pii/S0306261922017500> (visitado 02-06-2024).
- [40] E. Zhou, S. Gadzanku, C. Hodge y M. Campton. «BEST PRACTICES IN ELECTRICITY LOAD MODELING AND FORECASTING FOR LONG-TERM POWER SYSTEM PLANNING». (2023), dirección: <https://buildings.lbl.gov/publications/best-practices-electricity-load> (visitado 02-06-2024).
- [41] A. Sung. «Ranking importance of input parameters of neural networks». (1998), dirección: https://www.sciencedirect.com/science/article/pii/S0957417498000414?casa_token=iGWflUep7WgAAAAA:ZopELpgG1Vttr16zTaflopA (visitado 02-06-2024).
- [42] J. Koushik. «Understanding Convolutional Neural Networks». (2016), dirección: <https://arxiv.org/pdf/1605.09081> (visitado 02-06-2024).
- [43] R. C. Gonzalez. «Deep Convolutional Neural Networks». (2018), dirección: https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=8496892&casa_token=G81q2FuA5xMAAAAA:gHwzRj1KiiIoUGZHtONReUHjRUq_g7_ALGGVEYYUWahydMHsx4oWoqL9a14XuMs7jNB2D-88iA (visitado 02-06-2024).
- [44] Y. Wang. «A New Concept using LSTM Neural Networks for Dynamic System Identification». (2017), dirección: https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=7963782&casa_token=FI53S8faX3YAAAAA:dVo7y0BN8KqBXNNxFYcxxcu4YtBEkMAf0fRmDhQUt1l93u4HyxJ9KoMlrdp0dXRFhbN0F3kLI (visitado 02-06-2024).
- [45] J. Ospina, A. Newaz y M. O. Faruque. «Forecasting of PV plant output using hybrid wavelet-based LSTM-DNN structure model». (2019), dirección: <https://ietresearch.onlinelibrary.wiley.com/doi/pdfdirect/10.1049/iet-rpg.2018.5779> (visitado 02-06-2024).
- [46] A. Vaswani, N. Shazeer, N. Parmar et al. «Attention Is All You Need». (2017), dirección: <https://arxiv.org/pdf/1706.03762> (visitado 02-06-2024).
- [47] G.-K. Wu, J. Xu, Y.-D. Zhang, B.-Y. Wen y B.-P. Zhang. «Weighted feature fusion of dual attention convolutional neural network and transformer encoder module for ocean HABS classification». (2024), dirección: https://www.sciencedirect.com/science/article/pii/S095741742303381X?casa_token=X-a3dJ4TOvgAAAAA:66njWzYA5NXcnycA1IG5pmByOdT-tMYzJBJJtAxW-tCjYylgCiFetvO86fOMM4rf0qNrcUDfdw (visitado 02-06-2024).
- [48] C. Chen, J. Twycross y J. M. Garibaldi. «A new accuracy measure based on bounded relative error for time series forecasting». (2017), dirección: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5365136/> (visitado 02-06-2024).

- [49] A. Chugh. «MAE, MSE, RMSE, Coefficient of Determination, Adjusted R Squared — Which Metric is Better?» (2020), dirección: <https://medium.com/analytics-vidhya/mae-mse-rmse-coefficient-of-determination-adjusted-r-squared-which-metric-is-better-cd0326a5697e> (visitado 01-06-2023).
- [50] T. O. Hodson. «Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not». (2022), dirección: <https://gmd.copernicus.org/articles/15/5481/2022/gmd-15-5481-2022.pdf> (visitado 02-06-2024).
- [51] R. Rocca. «Interpreting R²: a Narrative Guide for the Perplexed». (2024), dirección: <https://towardsdatascience.com/interpreting-r%C2%B2-a-narrative-guide-for-the-perplexed-086a9a69c1ec> (visitado 01-06-2023).
- [52] E. Sánchez-López, A. Barreras-Serrano, C. Pérez-Linares, F. Figueroa-Saavedra y J. A. Olivas-Valdez. «APLICACIÓN DE UN MODELO ARIMA PARA PREDICIR LA PRODUCCIÓN DE LECHE DE BOVINO EN BAJA CALIFORNIA, MÉXICO». (2013), dirección: <https://www.redalyc.org/pdf/939/93929595004.pdf> (visitado 02-06-2024).
- [53] D. L. A.M., H. R.J. y R. D. Snyder. «tbats 1.1.3». (2023), dirección: <https://pypi.org/project/tbats/> (visitado 01-06-2023).

Este documento esta firmado por



Firmante	CN=tfgm.fi.upm.es, OU=CCFI, O=ETS Ingenieros Informaticos - UPM, C=ES
Fecha/Hora	Mon Jun 03 21:13:23 CEST 2024
Emisor del Certificado	EMAILADDRESS=camanager@etsiinf.upm.es, CN=CA ETS Ingenieros Informaticos, O=ETS Ingenieros Informaticos - UPM, C=ES
Numero de Serie	561
Metodo	urn:adobe.com:Adobe.PPKLite:adbe.pkcs7.sha1 (Adobe Signature)