



Facultad de Ciencias Económicas y Empresariales
ICADE

Predicción de la Demanda Energética en España mediante Inteligencia Artificial: Retos, Oportunidades y Visión hacia la Sostenibilidad

Autor: Karla Guerrero Landabaso
Director: David Hernández García

Resumen

En un contexto de transición energética y necesidad de optimización de recursos, la inteligencia artificial (IA) se presenta como una herramienta clave para mejorar la predicción de la demanda energética. Este trabajo tiene como objetivo analizar el uso de la IA en la gestión del consumo eléctrico en España, explorando sus beneficios, retos y oportunidades.

Para ello, se ha desarrollado un caso práctico utilizando la herramienta Data Analyst, basada en modelos de aprendizaje automático, con datos históricos de demanda energética entre 2018 y 2022. Se realizó una estimación de la demanda diaria de 2023 y se compararon los valores obtenidos con los reales. La evaluación de precisión mediante métricas como el MAPE y el WMAPE evidenció que el modelo es capaz de capturar patrones generales, aunque presenta ciertas desviaciones debido a la falta de variables externas en el análisis.

Los resultados obtenidos subrayan el potencial de la IA para mejorar la planificación energética, facilitar la integración de energías renovables y contribuir a la sostenibilidad del sector. No obstante, se identificaron barreras como la necesidad de datos de alta calidad y modelos más avanzados para reducir los márgenes de error. Finalmente, se destaca la importancia de continuar investigando en este campo para optimizar la eficiencia energética y reducir la huella de carbono.

Palabras Clave

Inteligencia Artificial, Demanda Energética, Aprendizaje Automático, Sostenibilidad, Energía Renovable.

Abstract

In the context of the energy transition and the need for resource optimization, artificial intelligence (AI) emerges as a key tool to improve energy demand forecasting. This study aims to analyze the use of AI in managing electricity consumption in Spain, exploring its benefits, challenges, and opportunities.

For this purpose, a case study was developed using the Data Analyst tool, based on machine learning models, with historical energy demand data from 2018 to 2022. The daily demand for 2023 was estimated and compared with real values. Accuracy evaluation using metrics such as MAPE and WMAPE demonstrated that the model effectively captures general trends, although some deviations were observed due to the absence of external variables in the analysis.

The findings highlight AI's potential to enhance energy planning, facilitate the integration of renewable energies, and contribute to sector sustainability. However, challenges such as the need for high-quality data and more advanced models to reduce error margins were identified. Finally, the importance of further research in this field is emphasized to optimize energy efficiency and reduce carbon footprint.

Keywords

Artificial Intelligence, Energy Demand, Machine Learning, Sustainability, Renewable Energy.

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

ADVERTENCIA: Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, [Nombre completo del estudiante], estudiante de [nombre del título] de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "[Título del trabajo]", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación [el alumno debe mantener solo aquellas en las que se ha usado ChatGPT o similares y borrar el resto. Si no se ha usado ninguna, borrar todas y escribir "no he usado ninguna"]:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Crítico:** Para encontrar contra-argumentos a una tesis específica que pretendo defender.
3. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
4. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
5. **Interpretador de código:** Para realizar análisis de datos preliminares.
6. **Estudios multidisciplinarios:** Para comprender perspectivas de otras comunidades sobre temas de naturaleza multidisciplinar.
7. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
8. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
9. **Generador previo de diagramas de flujo y contenido:** Para esbozar diagramas iniciales.
10. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
11. **Generador de datos sintéticos de prueba:** Para la creación de conjuntos de datos ficticios.
12. **Generador de problemas de ejemplo:** Para ilustrar conceptos y técnicas.
13. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
14. **Generador de encuestas:** Para diseñar cuestionarios preliminares.
15. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 17 de marzo del 2025

Firma:



Índice

Índice de Ilustraciones.....	6
Índice de Tablas	7
1. Introducción	8
2. Objetivos	9
2.1. Objetivo general	9
2.2. Objetivos específicos.....	9
3. Marco Teórico.....	11
3.1. Definición e historia de la Inteligencia Artificial (IA).....	11
3.2. Tipos de Inteligencia Artificial	13
3.3. Machine Learning y Deep Learning.....	17
3.4. Energías renovables y sostenibilidad	18
3.4.1. Energías renovables y su impacto en la sostenibilidad	19
3.4.2. Sostenibilidad en el sector energético	20
3.5. Casos de uso de la IA en la gestión de la demanda energética	20
3.5.1. Proyecto del Departamento de Energía de EE.UU. (DOE).....	20
3.5.2. Laboratorio Nacional de Argonne.....	20
3.5.3. Google DeepMind.....	20
3.5.4. Redes Inteligentes en Europa	21
3.6. Ventajas de la IA en la predicción energética y su relación con los ODS	21
4. Metodología	22
4.1. Enfoque metodológico	22
4.2. Herramienta de IA utilizada en la predicción de la demanda energética.	22
4.2.1. Data Analyst.....	22
4.3. Procedimiento para la implementación del estudio del caso.....	23
4.3.1. Recopilación y preparación de datos.....	23
4.3.2. Aplicación de la herramienta Data Analyst.....	24
5. Resultados	26

5.1.	Patrones identificados	26
5.2.	Comparación entre la demanda estimada y la real	27
5.3.	Evaluación de los resultados	28
5.3.1.	Error absoluto medio porcentual (MAPE)	28
5.3.2.	Media de la desviación porcentual absoluta ponderada (WMAPE)	29
5.3.3.	Conclusión sobre la precisión del modelo.....	29
5.4.	Análisis del impacto del COVID-19 en la demanda energética en 2020.....	29
5.4.1.	Resultados del análisis de la demanda en 2020.....	30
6.	Discusión y Conclusiones	33
6.1.	Interpretación de los resultados obtenidos	33
6.1.1.	Conclusiones del análisis de la demanda en 2020.....	33
6.2.	Beneficios observados en la aplicación de la IA para predecir la demanda energética	34
6.3.	Retos, barreras y mejoras	34
6.3.1.	Riesgos asociados al uso de IA para la predicción energética	34
6.3.2.	Riesgos financieros y éticos en el uso de la IA: Caso de fraude empresarial	35
7.	Visión a Futuro: IA, Sostenibilidad y Transición Energética	37
7.1.	Recomendaciones para la implementación futura de la IA en el mercado energético	37
7.2.	Impacto potencial de la IA en la sostenibilidad y la reducción de la huella de carbono	37
8.	Bibliografía.....	39
9.	Anexo	44
9.1.	Anexo 1. Datos de partida	44
9.2.	Anexo 2. Resultados.....	51

Índice de Ilustraciones

Ilustración 1: Áreas y aplicaciones de la Inteligencia Artificial. Fuente: Santander, 2020	11
Ilustración 2: Cronología de los primeros desarrollos de la IA (de los años 1950 al 2000). Fuente: OECD, 2019.....	13
Ilustración 3: Tipos de inteligencia artificial según Russell y Norving. Fuente: elaboración propia.....	14
Ilustración 4: Tipos de inteligencia artificial según Arend Hintze. Fuente: elaboración propia	16
Ilustración 5: Relación entre Inteligencia Artificial, Machine Learning y Deep Learning. Fuente: Santander, 2020.....	18
Ilustración 6: Objetivos de Desarrollo Sostenibles (ODS). Fuente: Naciones Unidas, s.f.	21
Ilustración 7: Logo de Data Analyst. Fuente: ChatGPT	22
Ilustración 8: Interfaz inicial Data Analyst. Fuente: elaboración propia.	23
Ilustración 9: Inicio conversación con Data Analyst. Fuente: elaboración propia.....	24
Ilustración 10: Introducción de datos en Data Analyst. Fuente: elaboración propia.	25
Ilustración 11: Generación de resultados por Data Analyst. Fuente: elaboración propia.	25
Ilustración 12: Demanda energética diaria real y estimada en España en 2023. Fuente: Data Analyst (2025) & Redei (2024).....	26
Ilustración 13: Demanda energética diaria real y estimada en España en abril de 2023. Fuente: Data Analyst (2025.) & Redei (2024)	28
Ilustración 14: Evolución de la demanda energética diaria en España (2018 - 2022). Fuente: Redei (2024).....	31
Ilustración 15: Comparación de la demanda energética en España (marzo – mayo). Fuente: Redei (2024).....	31

Índice de Tablas

Tabla 1: Diferencias entre Machine Learning y Deep Learning. Fuente: elaboración propia. .. 18

Tabla 2: Demanda energética media anual en España 2018-2021 (GWh). Fuente: Data Analyst, 2025..... 30

Tabla 3: Resultados análisis estadístico de la demanda energética en España para marzo, abril y mayo (2018-2020). Fuente: Data Analyst 32

Tabla 4: Demanda diaria 2018-2022 (GWh) Fuente: Redeia, (2024)..... 44

Tabla 5: Resultados. Fuente: Redeia (2024) & Data Analyst (2025)..... 51

1. Introducción

El crecimiento de la demanda energética, la necesidad de eficiencia en el uso de los recursos y la integración de energías renovables han generado un desafío para la planificación y gestión del sector eléctrico. En este contexto, la inteligencia artificial (IA) se ha convertido en una herramienta clave para optimizar el sistema eléctrico y mejorar la precisión de las predicciones de consumo.

La predicción precisa de la demanda energética es fundamental para garantizar la estabilidad de la red eléctrica, reducir costes y optimizar la generación y distribución de energía. Sin embargo, los métodos tradicionales de estimación, basados en modelos estadísticos y series temporales, presentan limitaciones ante la creciente complejidad del mercado energético. La IA, mediante algoritmos avanzados de aprendizaje automático, permite identificar patrones ocultos en los datos históricos y realizar predicciones más precisas y adaptativas.

Este trabajo tiene como objetivo analizar el uso de la IA en la predicción de la demanda energética en España. Para ello, se ha llevado a cabo un caso práctico en el que se han utilizado datos históricos de la Red Eléctrica de España (REE) entre 2018 y 2022 para realizar una estimación de la demanda en 2023. Se ha empleado la herramienta Data Analyst, basada en algoritmos de machine learning, para evaluar su capacidad predictiva y comparar los resultados obtenidos con los valores reales de demanda del año 2023.

La metodología adoptada combina un enfoque teórico-práctico. En primer lugar, se revisan los conceptos clave relacionados con la IA y su aplicación en la gestión energética. Posteriormente, se desarrolla un estudio de caso para evaluar la precisión de la IA en la predicción de la demanda, analizando sus fortalezas y limitaciones.

Finalmente, se presentan las conclusiones del trabajo, discutiendo los beneficios, barreras y desafíos de la implementación de IA en el sector energético. Además, se plantea una visión de futuro en la que se exploran las oportunidades que ofrece esta tecnología para mejorar la sostenibilidad y la eficiencia del sistema eléctrico.

2. Objetivos

2.1. Objetivo general

Analizar el impacto del uso de la inteligencia artificial en la predicción y gestión de la demanda energética en España, evaluando su efectividad y aplicabilidad en la optimización del sistema eléctrico.

2.2. Objetivos específicos

- Examinar los principales tipos de inteligencia artificial aplicables a la predicción de la demanda energética. Antes de implementar modelos predictivos basados en inteligencia artificial, es crucial comprender qué tipo de IA es más adecuada para el sector energético. La IA puede abarcar distintos enfoques, desde sistemas de memoria limitada hasta redes neuronales avanzadas, cada uno con sus ventajas y limitaciones específicas.
- Determinar la precisión de una herramienta de IA accesible en la estimación de la demanda eléctrica en España. En este trabajo, se ha optado por utilizar una herramienta que no requiera conocimientos avanzados de programación, lo que facilita su uso tanto en pequeñas como en grandes empresas.
- Comparar los valores obtenidos mediante IA con los datos reales de demanda energética en 2023. Un aspecto fundamental de este estudio es la validación del modelo predictivo mediante la comparación de los valores estimados con los datos reales de demanda en España. Para ello, se analizarán los errores absolutos y relativos en las predicciones (MAPE y WMAPE), identificando periodos donde la IA ha tenido mayor acierto y aquellos donde ha presentado desviaciones. Esto permitirá evaluar en qué condiciones la IA funciona mejor y qué factores pueden haber influido en los errores observados.
- Identificar los beneficios, limitaciones y desafíos de la implementación de IA en el sector energético. La adopción de inteligencia artificial en el sector eléctrico no está exenta de dificultades. Factores como la calidad y disponibilidad de los datos, la necesidad de infraestructuras tecnológicas avanzadas y los costes asociados a la implementación de modelos de IA pueden representar barreras para muchas empresas. Sin embargo, sus beneficios en términos de eficiencia operativa y optimización del uso de energías renovables justifican el estudio de su aplicación a gran escala.
- Explorar el papel de la IA en la transición hacia un sistema energético más sostenible y eficiente. En el contexto del cambio climático y los Objetivos de Desarrollo Sostenible (ODS), la inteligencia artificial se perfila como una herramienta clave para mejorar la integración de energías renovables en el mix energético. La IA puede ayudar a predecir


la generación de energía eólica y solar con mayor precisión, facilitando una mejor planificación y reduciendo la dependencia de fuentes fósiles. Además, su aplicación en redes inteligentes puede mejorar la estabilidad del sistema eléctrico y reducir las pérdidas de energía en la distribución.

3. Marco Teórico

3.1. Definición e historia de la Inteligencia Artificial (IA)

La inteligencia artificial es un término que está cada vez más incluido en nuestro vocabulario y para poder desarrollar este trabajo es primordial entender qué es. Grosso modo, la IA hace referencia a la tecnología y combinación de algoritmos que pretende imitar la inteligencia humana y su capacidad de razonar, aprender y planificar. El Parlamento Europeo (2021) lo define como “*la habilidad de una máquina de presentar las mismas capacidades que los seres humanos, como el razonamiento, el aprendizaje, la creatividad y la capacidad de planear*”. Es decir, es una herramienta multifuncional que permite que las máquinas ejecuten tareas que normalmente requerirían intervención humana. (International Business Machines Corporation [IBM], 2024) (Iberdrola, 2024).

Ilustración 1: Áreas y aplicaciones de la Inteligencia Artificial. Fuente: Santander, 2020



Hablando en términos más prácticos, es aquello que permite a los sistemas tecnológicos percibir el entorno, tomar decisiones y actuar de manera autónoma para lograr un objetivo en concreto. No obstante, la IA va más allá. No sólo imita las acciones y habilidades humanas, sino que las mejora, haciendo que los procesos sean más rápidos y eficientes. Puede aprender de datos previos, adaptarse y mejorar su rendimiento con el tiempo. Esto supone una gran ventaja con respecto a las capacidades humanas, limitadas por factores como el cansancio. (Amazon Web Services, 2023)

Por ejemplo, un experto radiólogo puede tardar varios minutos en analizar de forma completa una tomografía para detectar algún signo de cáncer. Sin embargo, un sistema con IA puede realizar la misma operación en pocos segundos, así como identificar aquellos pequeños signos que a un ojo humano pueden pasar fácilmente desapercibidos, mejorando el tiempo y la precisión del estudio médico. (Bejnordi, y otros, 2017).


Pero al igual que la IA es empleada en ámbitos tan importantes como la medicina, también se encuentra integrada en muchos aspectos de nuestra vida cotidiana. Desde asistentes virtuales como Alexa o Siri, hasta sistemas de navegación por GPS. Todas estas aplicaciones facilitan las actividades diarias y mejoran la calidad de vida. (Parlamento Europeo, 2021) (Iberdrola, 2024).

Esta tecnología ha experimentado una gran evolución, larga y dinámica, desde sus primeras concepciones hasta ser una de las más importantes de la actualidad. John McCarthy fue la primera persona en emplear el término “inteligencia artificial” en el año 1956. Este hecho tuvo lugar en la conferencia de Dartmouth, celebrada ese mismo año. Se trataba de un campus universitario, organizado por el propio John McCarthy junto con Marvin Minsky, Nathaniel Rochester y Claude Shannon, en el que se reunieron grandes expertos en informática, matemáticas y psicología cognitiva. Estos “genios” comenzaron a acuñar el concepto de “inteligencia simbólica”, una visión de futuro en el que las máquinas eran capaces de seguir reglas y ejecutar operaciones lógicas como si fuera un cerebro humano (Peter, 2024).

Desde entonces, la IA ha ido evolucionando hasta convertirse en lo que conocemos hoy en día. Sin embargo, dicho avance no ha sido progresivo. Encontramos etapas de mucha gloria y progreso, pero también encontramos los denominados “inviernos de la IA”, periodos de estancamiento causados porque los desarrolladores marcaran objetivos demasiado excesivos que espantaban a los inversores (Palau, 2023). En la Ilustración 2 se puede observar en eje cronológico en el que se destacan los hitos más importantes durante los primeros años de la IA.

Fue a partir del siglo XXI, con el auge del Big Data y la potencia computacional, cuando la IA experimentó un gran despegue. La clave fue desarrollar algoritmos que no solo se basaran en reglas predefinidas, sino que pudieran aprender y adaptarse a sí mismos a partir de datos.

Ilustración 2: Cronología de los primeros desarrollos de la IA (de los años 1950 al 2000). Fuente: OECD, 2019.



A pesar de los increíbles avances de los últimos tiempos, la IA moderna sigue teniendo que hacer frente a numerosos desafíos. El principal inconveniente reside en el volumen de datos que necesitan ser procesados para un correcto funcionamiento del sistema, generando problemas de privacidad y seguridad. Por otro lado, aunque la IA es capaz de realizar ciertas tareas específicas (como aparcar un coche de forma autónoma), sigue siendo un reto imitar completamente la flexibilidad y adaptabilidad que caracterizan a la inteligencia humana (Norving & Russell, 2020).


A todo esto, se suman todos los debates éticos que nacen del uso y utilización de esta potente herramienta. Han surgido preocupaciones crecientes sobre el impacto que tendrá en el mercado laboral y en la sustitución de los trabajadores por máquinas. Hay quienes se muestran contrarios ante el desarrollo de la nueva inteligencia; pero, también, existen defensores que argumentan que, en vez de eliminar empleos, los transformará y creará nuevos, mejorando, adicionalmente, la eficiencia (OECD, 2019).

3.2. Tipos de Inteligencia Artificial

Aunque existen diversos tipos de inteligencia artificial, no hay una forma única y concreta de dividirlos. Distintos autores plantean distintas formas de organización.

Russell y Norving (2020) proponen cuatro enfoques diferentes partiendo de dos ejes principales: humano/racional y pensamiento/comportamiento, tal y como se muestra en la Ilustración 3.

Ilustración 3: Tipos de inteligencia artificial según Russell y Norving. Fuente: elaboración propia.



- **Actuar humanamente: enfoque del Test Turing.** Aquellas máquinas que son capaces de engañar a un humano en una conversación por escrito. Deben ser capaces de procesar el lenguaje natural, representar el conocimiento y razonar a la vez que aprender de forma automática. Dentro de esta categoría entran las tecnologías que realizan tareas imitando a los humanos, como los robots (Valverde, 2019).
- **Pensar humanamente: enfoque del Modelado Cognitivo.** Este enfoque busca replicar el procesamiento humano. Es decir, imitar la forma de pensar y resolver problemas que tienen las personas. Para ello, hace uso de técnicas como la introspección, experimentos psicológicos e imagenología cerebral. Un ejemplo de este tipo de IA son las redes neuronales artificiales (Valverde, 2019).
- **Actuar racionalmente: enfoque del Agente Racional.** Si se define un agente como algo que actúa en su entorno, un agente racional actúa para maximizar y obtener los mejores resultados posibles. Las características que define a este tipo son la autonomía, la capacidad de percibir el entorno y adaptarse a él y la de perseguir objetivos y de hacer inferencias correctas (Valverde, 2019). Un ejemplo son los coches autónomos. Una serie de sensores avanzados (cámaras, radares...) les permiten captar el entorno a tiempo real para procesar toda esa información y decidir cuál es la mejor acción en cada momento. Por ejemplo, si está circulando por la ciudad y detecta un peatón cruzando la calle, el sistema decidirá frenar para evitar un accidente.
- **Pensar racionalmente: enfoque de las Leyes del Pensamiento.** La inteligencia empleada en las máquinas debe ser no sólo racional, sino racionalmente correcta. Basado en los silogismos de Aristóteles y empleando la teoría de la probabilidad, el objetivo es desarrollar sistemas que puedan razonar para tomar la decisión correcta, aun cuando la información de la que se disponga no sea completa o sea incierta (Valverde,

2019). Dentro de esta categoría se encuentran los sistemas de diagnóstico médico. Por ejemplo, un paciente indica que tiene los siguientes síntomas: fiebre, tos y dolor de pecho. Con esta información, el sistema puede deducir que lo más probable es que el paciente padezca una infección respiratoria.

Esta no es la única clasificación que existe sobre la inteligencia artificial. Arend Hintze, un profesor e investigador de la Universidad de Michigan, establece otra división, mostrada en la Ilustración 4, que separa los sistemas desde los más simples hasta los más avanzados.



- **Máquinas reactivas (Tipo I):** son las más simples porque sólo tienen en cuenta los datos presentes. No aprenden de datos pasados ni hacen previsiones sobre el futuro. Es decir, no saben adaptarse a cambios o nuevas situaciones y, por ello, se emplean para llevar a cabo acciones concretas. Un claro ejemplo es el sistema Deep Blue desarrollado por IBM para jugar al ajedrez. Analiza únicamente el estado del tablero en cada jugada para determinar el próximo movimiento (Google, s.f.a).
- **Máquinas de memoria limitada (Tipo II):** poseen una mayor capacidad para poder almacenar y procesar una cantidad limitada de información, con la que mejoran su rendimiento. La mayor parte de la IA que conocemos corresponde a esta categoría. Muchas empresas financieras lo emplean para hacer previsiones de mercado y analizar inversiones (Valencia, 2021).
- **Teoría de la mente (Tipo III):** se trata de un tipo de IA todavía teórico que es capaz de simular el funcionamiento de la mente humana: reconocer y recordar intenciones, emociones y pensamientos y actuar en función de ello. Su desarrollo supondría una gran revolución para el mundo tal y como lo conocemos ahora, en todos los ámbitos (Valencia, 2021).
- **Autoconciencia (Tipo IV):** como en el caso anterior, este tipo de IA aún no existe. Sin embargo, su desarrollo implicaría ir un paso más allá. No sólo sería capaz de entender y comprender de forma completa su entorno, sino que también sería consciente de su propia existencia. Es decir, podría analizar su propio estado y entender cómo afecta a los demás, como lo haría un ser humano. Su desarrollo plantea importantes avances, pero también, un gran debate ético (Google, s.f.a).

Las clasificaciones realizadas por Russell y Norving y por Arend Hintze muestran distintas perspectivas y enfoques para entender la inteligencia artificial. No sólo identifican la diversidad actual existente, si no que van más allá y nombran, incluso, los tipos de IA que aún no existen. Esto demuestra el gran potencial y las numerosas oportunidades que quedan pendientes por descubrir. Sin embargo, esta innovación va, así mismo, de la mano de grandes desafíos éticos y exhaustivos análisis.

3.3. Machine Learning y Deep Learning

Al hablar de inteligencia artificial, es imprescindible mencionar los conceptos de Machine Learning (ML) y Deep Learning (DL), dos disciplinas que han revolucionado el campo de la investigación y de la industria.


El Machine Learning es una de las principales ramas de la IA y se dedica a desarrollar algoritmos que sean capaces de aprender patrones a partir de unos datos. Con ello, el objetivo es poder llevar a cabo predicciones o tomar decisiones sin una intervención humana directa (Zhang, y otros). Existen tres categorías de ML:

- **Aprendizaje supervisado:** se entrena con datos etiquetados o categorizados. Basados en ellos, se llevarán a cabo las predicciones. Por ejemplo, si queremos que el sistema sea capaz de reconocer lo que es una bicicleta, es necesario transmitirle una base de datos con fotos de bicicletas. Los algoritmos más empleados para trabajar son: regresión lineal, regresión polinómica, kNN, Naive Bayes y árboles de decisión (Google, s.f.b).
- **Aprendizaje no supervisado:** en este caso, el modelo usa datos sin etiquetar. Es decir, el resultado no se conoce a priori. En cambio, categoriza en función de unos determinados atributos. El algoritmo más empleado en este caso es el *clustering* (Google, s.f.b).
- **Aprendizaje por refuerzo:** funciona a través del prueba y error. El sistema intenta conseguir un determinado resultado, empleando un ciclo de retroalimentación, hasta que quede dentro de un rango admisible. Resulta muy útil en entornos dinámicos. Es el tipo de método que se emplea para enseñar a los ordenadores a jugar a juegos (Google, s.f.b).

Un ejemplo real de ML es el sistema de recomendaciones que hace la página web o la aplicación de Amazon. Analiza el historial de compras de un usuario para sugerirle productos personalizados que le pueden llegar a resultar interesantes para que acabe, finalmente, comprándolo (Zhang, y otros).

Por su lado, el Deep Learning resulta ser un subconjunto del ML. Utiliza redes neuronales profundas con el fin de aprender de forma automática y directa las características de una base de datos (Google, s.f.b). El sistema ordena la información en distintas capas interconectadas, lo que le permite extraer las características de forma jerárquica. Por ello, el DL es muy eficaz para llevar a cabo tareas de reconocimiento facial, traducción y generación de texto (Zhang, y otros).

Uno de los ejemplos más famosos de este tipo de tecnología es ChatGPT. Esta herramienta utiliza DL para analizar la información recibida y generar respuestas adecuadas y coherentes (Holdsworth & Scapicchio, 2024).



Aunque el DL se encuentra dentro del ML, ambos poseen diferencias importantes, resumidas en la Tabla 1 (IBM, s.f.) (Holdsworth & Scapicchio, 2024) (Google, s.f.b).

Tabla 1: Diferencias entre Machine Learning y Deep Learning. Fuente: elaboración propia.

ASPECTO	MACHINE LEARNING (DL)	DEEP LEARNING
ESTRUCTURA	Algoritmos simples (regresión, árboles de decisión...)	Redes neuronales
DATOS NECESARIOS	Funciona con conjuntos de datos más pequeños	Se entrena con grandes volúmenes de datos
AUTOMATIZACIÓN	Requiere preprocesamiento manual de las características	Aprende automáticamente las características más importantes
REQUERIMIENTOS COMPUTACIONALES	Puede ejecutarse en hardware estándar	Requiere GPUs O TPUs
APLICACIONES	Modelos predictivos, sistemas de recomendación...	Reconocimiento de voz, visión artificial, generación de texto...

Es decir, mientras que el ML proporciona soluciones más prácticas, el DL aborda problemas mucho más complejos, ofreciendo una mayor autonomía. Actualmente, ambas tecnologías siguen siendo estudiadas para conseguir una mayor evolución (Holdsworth & Scapicchio, 2024).

3.4. Energías renovables y sostenibilidad

La optimización de la generación de la energía es clave en la transición a un mundo más sostenible. En este sentido, las energías renovables y la eficiencia energética constituyen un papel fundamental en la lucha contra el cambio climático.

3.4.1. Energías renovables y su impacto en la sostenibilidad

Las energías renovables son aquellas que proceden de fuentes que se regeneran de forma natural (la luz solar, el viento, el agua, la biomasa...) y se caracterizan por no producir gases de efecto invernadero durante su generación (Guillén García, 2002).

Los principales tipos son (Guillén García, 2002):

- **Energía solar:** la radiación solar es captada a través de los paneleros fotovoltaicos o sistemas de concentración solar (CSP) para producir electricidad o calor.
- **Energía eólica:** generada a través de aerogeneradores que se encargan de transformar el movimiento del viento en electricidad.
- **Energía hidroeléctrica:** las turbinas hidráulicas aprovechan el flujo de agua de los ríos y embalses para producir electricidad. Es una de las fuentes más utilizadas mundialmente.
- **Energía geotérmica:** en este caso, la electricidad se genera a través de la extracción del calor del subsuelo. Ofrece un suministro estable de energía, puesto que es una fuente que siempre está disponible.
- **Biomasa:** la biomasa está constituida por todos los materiales orgánicos de origen biológico, como las plantas, los residuos orgánicos sólidos urbanos, la madera, etc. La biomasa se puede transformar en diversos tipos de energía (eléctrica o calor) a través de su combustión. Aunque, a priori, parezca que este tipo de energía no es sostenible con el medio ambiente, la biomasa se considera neutra en carbono. Esto se debe a que, por ejemplo, las plantas, de donde procede gran parte de la biomasa, capturan CO₂ durante su crecimiento, compensado el que se produce en el proceso de combustión (Novaluz Energía, 2024). Así mismo, esta fuente de energía también ofrece más alternativas. Por un lado, la gasificación, que produce un gas de síntesis que funciona como sustituto de otros combustibles gaseosos (como el propano o el gas natural). Por otro lado, también destaca la pirólisis, un proceso que genera un biogás que puede ser empleado para producir hidrógeno (Guillén García, 2002).
- **Energía oceánica:** a diferencia de la energía hidráulica, la energía oceánica utiliza el movimiento de las mareas y las olas para generar electricidad.

A pesar de todo esto, las energías renovables presentan un problema; y es que dependen casi por completo de las condiciones ambientales que se den, las cuales no pueden estar condicionadas por la acción humana. Es por ello por lo que su integración en la red eléctrica supone un gran reto, ya que resultan, en cierta medida, incontrolables.

3.4.2. Sostenibilidad en el sector energético

La sostenibilidad busca la transición hacia el uso de fuentes limpias y renovables, con la que se pueda garantizar un acceso mundial a la energía y se equilibren los objetivos económicos y sociales. Según UNEP (2022), un sistema energético sostenible es crucial para mitigar el cambio climático, garantizar la seguridad energética y fomentar el desarrollo económico equitativo.

3.5. Casos de uso de la IA en la gestión de la demanda energética

La IA se ha convertido en una herramienta esencial para optimizar la gestión de numerosos sectores industriales; entre ellos, el sector energético. Puede resultar clave para optimizar la generación, distribución y consumo de energía (McKinsey & Company, 2023).

Gracias al desarrollo de tecnologías como el ML, la IA permite anticipar con mayor precisión la generación de energía. Analizando los datos históricos y en tiempo real, puede prever las fluctuaciones del consumo energético y buscar una forma óptima de integrar las energías en la red eléctrica (Boswell, Buckley, Elliot, Melero, & Smith, 2022).

Así mismo, la implementación de la IA contribuye a la reducción de emisiones de carbono. McKinsey & Company (2022) afirma que los modelos de IA aplicados en redes eléctricas pueden disminuir las emisiones globales en un 10%, lo que supone un gran avance para lograr el objetivo de emisiones netas en el año 2050 propuesto por la ONU (ONU, s.f.).

3.5.1. Proyecto del Departamento de Energía de EE.UU. (DOE)

El DOE está empleando modelos de IA para mejorar la predicción de la demanda de las redes eléctricas en Estados Unidos. A través de una serie de algoritmos de aprendizaje automático, procesan datos climáticos y patrones históricos de consumo para anticipar variaciones en la demanda energética. Esto ha favorecido la gestión y el equilibrio entre oferta y demanda (U.S. Department of Energy, 2024) (Daniel, y otros, 2024).

3.5.2. Laboratorio Nacional de Argonne

Esta empresa ha desarrollado un programa de investigación sobre la IA con el objetivo de utilizarla para predecir la demanda energética en tiempo real. Trabajan con sistemas que procesan datos muy complejos sobre consumo, fuentes de generación y condiciones climáticas, mejorando la estabilidad de la red y evitando interrupciones innecesarias (Daniel, y otros, 2024).

3.5.3. Google DeepMind

Google DeepMind, la empresa de Inteligencia artificial de Google (Ghosh, 2023), ha

desarrollado un modelo de aprendizaje automático que es capaz de anticipar la producción de energía eólica 36 horas antes, lo que permite ajustar con mayor precisión la oferta y la demanda de las redes eléctricas (Lagarrigue, 2021).

3.5.4. Redes Inteligentes en Europa

En Europa, se han impulsado varias iniciativas para emplear la IA en los picos de consumo energético generados por olas de calor o inviernos fuertes. Combinando esta herramienta con sensores IoT, capaces de registrar datos físicos o químicos en datos electrónicos (Fernández, 2022), el objetivo es distribuir la demanda para cubrir las necesidades cuando se producen estos acontecimientos críticos sin causar una gran pérdida de energía (Masterson, 2024).

3.6. Ventajas de la IA en la predicción energética y su relación con los ODS

La implementación de algoritmos de IA en el sector energético puede ofrecer numerosas ventajas operativas y estratégicas, muchas de ellas alineadas con varios Objetivos de Desarrollo Sostenible (ODS) (Naciones Unidas, s.f.):



Ilustración 6: Objetivos de Desarrollo Sostenibles (ODS). Fuente: Naciones Unidas, s.f.

- **Mejoras en la precisión de las predicciones:** la IA puede analizar tanto datos históricos como datos en tiempo real, generando pronósticos más precisos. Hablando en términos energéticos, permite optimizar la planificación de los recursos y minimizar los desajustes entre oferta y demanda.
- **Optimización del consumo energético:** al ajustar la generación y la distribución energética, se reducen las pérdidas y aumenta la eficiencia.
- **Facilitación de la integración de energías renovables:** con la IA se puede abordar el desafío de la variabilidad que presentan las fuentes renovables, puesto que permite anticipar la generación y hacer frente a las fluctuaciones.
- **Reducción de emisiones de carbono:** relacionado con el punto anterior, al optimizar el uso de energías renovables se disminuyen las emisiones de gases de efecto invernadero.

4. Metodología

4.1. Enfoque metodológico

Este trabajo presenta un enfoque teórico-práctico, con el que se pretende analizar el uso de la inteligencia artificial (IA) en la predicción y gestión de la demanda energética en España.

Desde una perspectiva teórica, resulta interesante analizar los conceptos relacionados con la IA, la sostenibilidad y el sector energético. Constituyen las bases para comprender cuestiones como:

- La importancia de la predicción de la demanda y su relación con la sostenibilidad.
- La integración de energías renovables en el mix energético.
- La contribución de la IA a la reducción de emisiones de carbono y el cumplimiento de los objetivos de desarrollo sostenible.

En cuanto al punto de vista práctico, se busca ilustrar cómo una herramienta de IA accesible puede utilizarse para analizar y predecir tendencias en la demanda energética. Para ello, se emplearán datos reales proporcionados por operadores del mercado eléctrico como REE (Red Eléctrica de España). Para ello:

- Se recopilarán los datos históricos de demanda energética mensual entre los años 2018 y 2022.
- Estos datos serán procesados y analizados utilizando la herramienta Data Analyst, un sistema desarrollado por GPT y que permite llevar a cabo análisis predictivos sin necesidad de programación. La plataforma emplea sus propios algoritmos de aprendizaje automático para identificar patrones y generar predicciones.

Con este enfoque metodológico, se consigue no sólo evaluar, de forma simplificada, el potencial de la IA como herramienta en el sector energético, sino que también permite reflexionar sobre sus limitaciones e implicaciones que tendrá en el futuro.

4.2. Herramienta de IA utilizada en la predicción de la demanda energética.

4.2.1. Data Analyst



Ilustración 7: Logo de Data Analyst. Fuente: ChatGPT

Data Analyst es una plataforma que permite procesar y analizar información sin necesidad de tener un avanzado conocimiento en programación, lo que lo ha convertido en una herramienta muy útil para el presente trabajo. Presenta un interfaz muy fácil e intuitivo de utilizar, basado en un sistema conversacional.

A través de algoritmos automatizados, la plataforma es capaz de identificar patrones complejos en datos históricos y generar predicciones. Entre dichos algoritmos destacan:

- **Regresión lineal:** establece una relación entre una variable dependiente y una o más independientes. Se emplea, sobre todo, para predecir series temporales, como podría ser la demanda energética (Guillard, 2024).
- **Redes neuronales artificiales (ANN):** basadas principalmente en el funcionamiento del cerebro humano. Reconoce patrones complejos y genera predicciones no lineales. (Smarkia, 2023).
- **Máquinas de soporte vectorial (SVM):** analizan los datos para generar regresiones. Este tipo de algoritmo resulta muy útil para identificar patrones en datos complejos. (IBM, 2023).

Data Analyst ▾




Ilustración 8: Interfaz inicial Data Analyst. Fuente: elaboración propia.

4.3. Procedimiento para la implementación del estudio del caso

Para evaluar el potencial que puede tener la IA en la predicción de la demanda energética en España, se ha desarrollado un caso práctico basado en datos reales del mercado eléctrico.

4.3.1. Recopilación y preparación de datos.

En primer lugar, se recopilaron los datos de demanda energética diaria (GWh) en España entre

el año 2018 y 2022. Dichos datos se recogieron de la página oficial de Red Eléctrica de España (REE) (Redeia, 2024), organismo encargado de la operación y el transporte de la electricidad en el país.

Con el fin de facilitar el procesamiento de la información, los datos se organizaron en formato tabla, pero separando cada columna a través de una barra vertical, como se puede observar en la Ilustración 10. Este formato permitió introducir los datos en Data Analyst de forma estructurada, asegurando que la plataforma pudiera interpretar la información correctamente. Todos los datos se encuentran en el Anexo 1. Datos de partida.

4.3.2. Aplicación de la herramienta Data Analyst

Una vez los datos estaban preparados, se inició una conversación con la plataforma y se introdujeron todos los datos con el objetivo de que generara una predicción de la demanda energética diaria en España para el año 2023 (Ilustración 9).

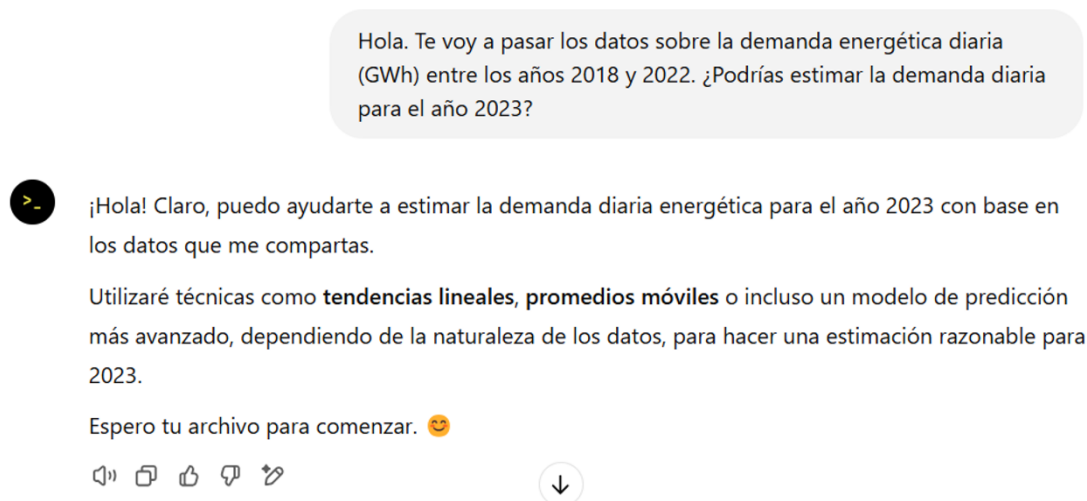


Ilustración 9: Inicio conversación con Data Analyst. Fuente: elaboración propia.

En un principio, se intentó proporcionar todos los datos de una sola vez. Sin embargo, la herramienta generaba resultados confusos, posiblemente a causa del volumen de información procesada simultáneamente. Para solucionar este inconveniente, se decidió introducir la información mensualmente. Es decir, se proporcionaron los datos correspondientes a un solo mes o a dos meses y se solicitó a la plataforma que realizara la predicción para esos mismos meses en 2023.

De esta forma se consiguieron resultados más coherentes y ajustados a las tendencias observadas en los datos históricos. El proceso se repitió mes a mes hasta obtener la predicción completa para el año 2023, analizada en el apartado 5.Resultados.

En la Ilustración 10 e Ilustración 11 se presentan unas capturas de pantalla de una parte de la interacción mantenida con Data Analyst, donde se muestra el formato de datos utilizados y la generación de predicciones.

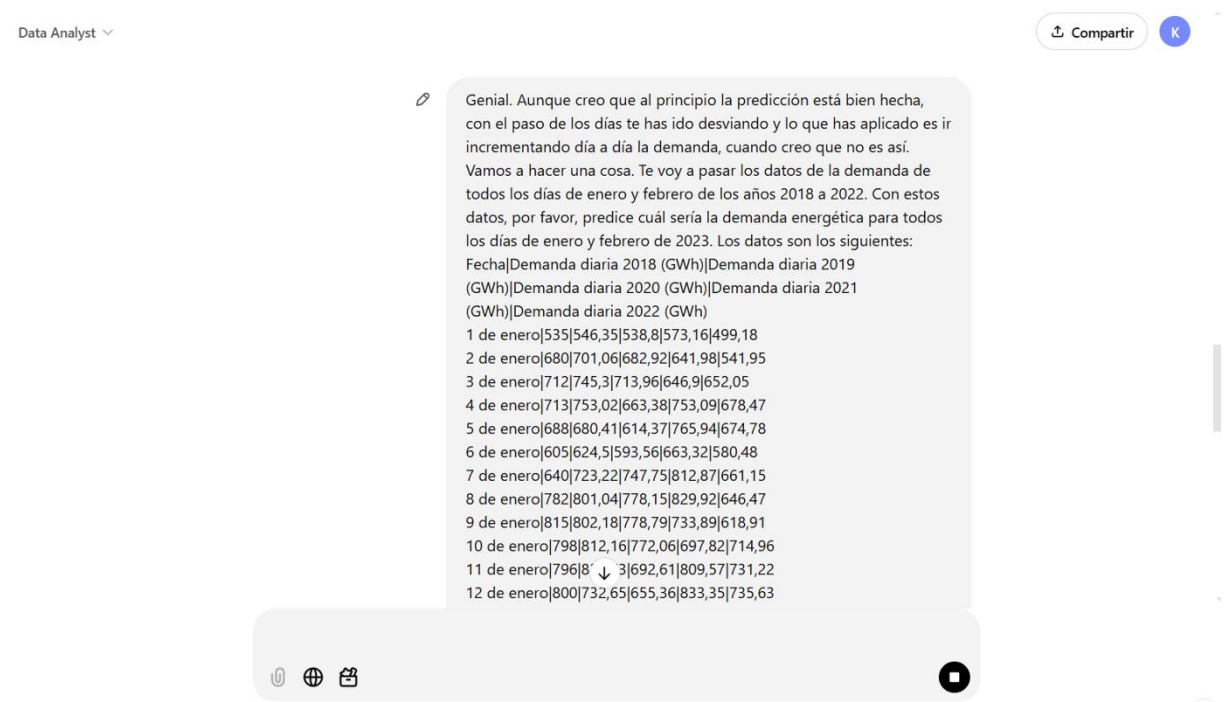


Ilustración 10: Introducción de datos en Data Analyst. Fuente: elaboración propia.




Ilustración 11: Generación de resultados por Data Analyst. Fuente: elaboración propia.

El propio programa informa, cuando aporta los resultados, que ha llevado a cabo algunos ajustes adicionales en los datos para aportar valores más exactos.

5. Resultados

En la Ilustración 12 se muestra un gráfico comparativo de la demanda diaria de energía en España durante 2023 en gigavatios-hora (GWh).

Contiene dos series de datos:

- Demanda diaria estimada 2023 (GWh) (línea azul): Es la estimación realizada por Data Analyst.
- Demanda diaria 2023 (GWh) (línea naranja): Es la demanda real observada a lo largo del año.

El eje horizontal representa los días del año, mientras que el eje vertical muestra la cantidad de energía demandada en GWh.




Ilustración 12: Demanda energética diaria real y estimada en España en 2023. Fuente: Data Analyst (2025) & Redei (2024)

5.1. Patrones identificados

A partir del análisis de los datos, se identifican las siguientes tendencias y comportamientos en la evolución de la demanda energética:

- Enero y febrero: se observan valores elevados y relativamente estables, con algunas fluctuaciones. Esto es coherente con el invierno, donde la demanda energética tiende a ser alta debido al uso de calefacción y mayor consumo eléctrico en los hogares. Se identifican picos durante los días laborables y descensos en los fines de semana.
- Marzo: a medida que avanza el mes, la demanda comienza a disminuir de manera progresiva, reflejando la transición hacia temperaturas más templadas con la llegada de la primavera. Sin embargo, se observan repuntes en ciertos días, posiblemente debido a cambios climáticos puntuales o a aumentos en la actividad industrial y comercial.
- Abril: se mantiene una tendencia descendente en la demanda, en línea con la mejora de

las condiciones climáticas y el menor uso de la calefacción.

- Mayo en adelante: a partir de mediados de mayo, la demanda se estabiliza antes de experimentar un aumento gradual con la llegada del verano.
- Verano (junio, julio y agosto): se observa un incremento progresivo en la demanda debido a temperaturas más altas y un mayor uso de sistemas de refrigeración. En algunos días, la demanda estimada y la real presentan ligeras discrepancias, posiblemente debido a olas de calor no previstas en la estimación.
- Septiembre: se identifica un descenso progresivo en la demanda a medida que bajan las temperaturas y se inicia la transición hacia el otoño.
- Octubre y noviembre: la demanda se mantiene relativamente estable en octubre y empieza a aumentar en noviembre, con picos significativos en la segunda quincena del mes, en concordancia con la llegada del frío.
- Diciembre: se detectan variaciones significativas en la demanda debido a las festividades. A pesar del aumento general por la llegada del invierno, los días festivos presentan caídas marcadas, siendo el 25 de diciembre el día con menor consumo del año, reflejando la menor actividad industrial y comercial.

Cabe mencionar que, de manera constante a lo largo del año, los fines de semana presentan menor demanda que los días laborables, reflejando una menor actividad en sectores industriales y comerciales. Los días laborales en los que más consumo suele haber son los martes y los jueves.

5.2. Comparación entre la demanda estimada y la real

En la Ilustración 12 se observa una tendencia similar entre la demanda real y la estimada, lo que indica que el modelo de predicción ha sabido capturar correctamente el comportamiento general de la demanda a lo largo del año. Se han identificado y reflejado correctamente:

- Patrones estacionales: se observan picos y valles recurrentes que reflejan la variabilidad de la demanda en diferentes épocas del año.
- Fluctuaciones diarias: el modelo ha logrado replicar las variaciones dentro de cada mes, siguiendo la tendencia de consumo energético diario.

A pesar del buen ajuste general, se observan algunas desviaciones en ciertos periodos, especialmente durante los meses de verano e invierno, donde la predicción parece subestimar o sobreestimar la demanda real.

Para una mejor visualización y análisis de los resultados, en la Ilustración 13 se presenta el

gráfico correspondiente al mes de abril de 2023.




Ilustración 13: Demanda energética diaria real y estimada en España en abril de 2023. Fuente: Data Analyst (2025.) & Redei (2024)

Con mayor detalle, se observa cómo las desviaciones diarias son más evidentes. La IA ha sobreestimado la demanda en algunos días, mientras que en otros la ha subestimado. Esto puede deberse a que no se han tenido en cuenta para la predicción ciertos factores externos que pueden influir en la demandan energética, como pueden ser:

- Datos meteorológicos (temperatura, precipitaciones, velocidad del viento, etc.) para mejorar la precisión en periodos de clima extremo.
- Indicadores económicos (PIB, tasas de empleo, precios de la energía, etc.) que pueden influir en el consumo industrial y residencial.
- Eventos específicos (festivos nacionales, huelgas, cambios regulatorios, etc.) que impactan el comportamiento de la demanda.

5.3. Evaluación de los resultados

Para evaluar la precisión de los resultados, se han calculado dos métricas de error ampliamente utilizadas en la validación de modelos de predicción.

5.3.1. Error absoluto medio porcentual (MAPE)

El MAPE (Mean Absolute Percentage Error) mide el error absoluto medio de la predicción en términos porcentuales con respecto a los valores reales. Se calcula siguiendo la siguiente fórmula (SAP, s.f.):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Donde:

- y_i es el valor real de la demanda en el día i .
- $\hat{y}_i$ es el valor estimado de la demanda en el día i .
- n es el número total de días analizados. En este caso 365 días (1 año, sin contar el 29 de febrero en los años bisiestos).

El valor de MAPE obtenido es de 8,64%. Es decir, la predicción se desvía un 8,64% de los valores reales. Aunque este margen de error es relativamente bajo, sigue reflejando ciertas imprecisiones que podrían evitarse con modelos más sofisticados.

5.3.2. Media de la desviación porcentual absoluta ponderada (WMAPE)

El WMAPE (Weighted Mean Absolute Percentage Error) es una variante del MAPE que pondera el error en función del valor real, evitando problemas en datos con valores cercanos a cero. Su fórmula es (SAP, s.f.):

$$WMAPE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{\sum_{i=1}^n y_i} \times 100$$

A diferencia del MAPE, que puede verse afectado por valores atípicos, el WMAPE ajusta la ponderación de los errores para que no tengan el mismo impacto en la métrica (SAP, s.f.).

El valor obtenido del WMAPE es 8,16%, lo que confirma que el modelo presenta una desviación moderada respecto a la demanda real, pero aún dentro de un rango aceptable para una predicción que no ha considerado factores adicionales.

5.3.3. Conclusión sobre la precisión del modelo

Los valores de MAPE (8,64%) y WMAPE (8,16%) sugieren que la predicción realizada tiene una precisión considerable, aunque todavía con mucho margen de mejora. A pesar de ello, se ha logrado capturar la tendencia general de la demanda energética.

Estos resultados refuerzan las ideas presentadas sobre el impacto que tiene la IA en la sostenibilidad y la optimización del sector energético. Si bien la predicción realizada en este estudio ha sido de carácter exploratorio, demuestra el potencial que tiene esta herramienta para mejorar la planificación energética, facilitando una mejor integración de fuentes renovables y contribuyendo a la reducción de emisiones, en línea con los Objetivos de Desarrollo Sostenible (ODS).

5.4. Análisis del impacto del COVID-19 en la demanda energética en 2020

Para evaluar la capacidad del modelo de IA para reconocer patrones atípicos, se le pidió que

realizara un análisis específico para el año 2020, un año de gran interés de estudio al estar marcado como el año de la pandemia de COVID-19.

Durante ese periodo, España experimentó grandes restricciones de movilidad, confinamientos estrictos y una ralentización generalizada de la actividad económica, sobre todo entre los meses de marzo y junio. Todos estos factores, causaron un impacto directo en la demanda energética.

5.4.1. Resultados del análisis de la demanda en 2020

Inicialmente, la herramienta de Data Analyst, calculó y comparó los valores medios anuales, la desviación típica y el máximo y mínimo de los años 2018, 2019, 2020 y 2021, obteniendo las siguientes conclusiones:

- Media: la demanda promedio en 2020 fue de 688,37 GWh, menor que en 2018, 2019 y 2021. Esto indica una caída en la demanda durante el año de la pandemia.

Tabla 2: Demanda energética media anual en España 2018-2021 (GWh). Fuente: Data Analyst, 2025

	2018	2019	2020	2021
Demanda energética media anual (GWh)	696,8 GWh	718,92 GWh	688,37 GWh	711,89 GWh

- Desviación estándar: similar a otros años ($\sim 84 - 88$ GWh), lo que sugiere que la variabilidad de la demanda no cambió mucho.
- Mínimo y máximo: el valor máximo de 2020 (778,79 GWh) es menor que el de 2018, 2019 y 2021, lo que sugiere que no hubo picos de consumo tan altos como en otros años.

Para entender mejor los cambios, en la Ilustración 14 se muestra la evolución de la demanda a lo largo del tiempo.




Ilustración 14: Evolución de la demanda energética diaria en España (2018 - 2022). Fuente: Redei (2024)

Como se puede observar, la demanda en 2020 tuvo una caída significativa en ciertos periodos en comparación con otros años, especialmente entre marzo y mayo, coincidiendo con los meses de confinamiento más estricto en España. En la Ilustración 15, se muestra en más detalle la evolución en dichos meses.




Ilustración 15: Comparación de la demanda energética en España (marzo – mayo). Fuent: Redei (2024)

El análisis estadístico llevado a cabo por Data Analyst, en el que estudia la demanda energética diaria en España para marzo, abril y mayo de 2020 en comparación con los años anteriores, establece los siguientes resultados, recogidos en la Tabla 3.

Tabla 3: Resultados análisis estadístico de la demanda energética en España para marzo, abril y mayo (2018-2020). Fuente: Data Analyst

	2018	2019	2020
Promedio de demanda (GWh)	674,80	652,42	477,67
Mediana de demanda (GWh)	679,50	671,28	571,12
Variabilidad (desviación estándar)	62,99	53°,33	62,87

En 2020, la demanda energética fue menor, tanto en promedio como en mediana, en comparación con 2018 y 2019. Esto confirma una reducción general en la demanda energética durante el año de la pandemia. Sin embargo, la variabilidad fue más parecida a la de 2018, lo que indica fluctuaciones similares a las de un año normal.

Por otro lado, durante esos meses, la máxima demanda en 2020 fue de 727,51 GWh, muy similar al máximo en 2019. La diferencia se aprecia en el mínimo registrado. En el año 2020 fue de 471,46 GWh, muy por debajo de los mínimos de 2018 y 2019. Todo ello, sugiere que hubo una caída muy fuerte en el consumo, posiblemente por las restricciones establecidas por la pandemia.

6. Discusión y Conclusiones

6.1. Interpretación de los resultados obtenidos

El análisis realizado ha permitido observar que la predicción de la demanda energética realizada por la IA sigue de manera general la tendencia de los valores reales. Se han identificado correctamente los patrones estacionales y las fluctuaciones diarias, lo que indica que, incluso con un modelo básico basado exclusivamente en datos históricos, es posible obtener una estimación razonablemente precisa.

Sin embargo, también se han observado desviaciones significativas en ciertos periodos, sobre todo en los meses de verano e invierno. Estas diferencias en los resultados podrían deberse a la ausencia de factores externos en la predicción. Componentes como las condiciones meteorológicas, las variaciones económicas o eventos específicos, pueden afectar a la demanda y, sin embargo, no se han tenido en cuenta en este proyecto.

Además, la metodología utilizada se basa en un modelo de IA accesible a todo el mundo con internet y que no requiere programación, lo que, si bien facilita su implementación, también puede limitar su capacidad de ajuste y refinamiento. Modelos más avanzados, como las redes neuronales convolucionales (CNN) o los modelos híbridos que combinan aprendizaje automático con técnicas estadísticas tradicionales, han demostrado ofrecer predicciones más precisas en contextos similares (Borunda-Pacheco & Ibargüengoytia-González, 2018).

6.1.1. Conclusiones del análisis de la demanda en 2020

El análisis llevado a cabo confirma que la pandemia tuvo un impacto significativo en la demanda energética en España, especialmente durante los meses de marzo, abril y mayo. Los puntos clave a destacar, son los siguientes:

- Caída generalizada del consumo. La demanda promedio fue, aproximadamente, de un 12% a un 15% menor que en años anteriores, lo que refleja la reducción en la actividad económico-social.
- Valores mínimos extremos. En abril de 2020, se registraron los niveles de demanda más bajos de los datos analizados, lo que coincide con la época de las medidas de confinamiento más estrictas.
- Recuperación progresiva en mayo: a medida que las restricciones fueron flexibilizándose, la demanda comenzó a aumentar lentamente, aunque sin alcanzar los niveles de años previos.

Estos resultados demuestran cómo la pandemia alteró los patrones de consumo energético en

España y resaltan la relación entre actividad económica y demanda de energía. Además, el análisis podría servir como referencia para futuras situaciones de crisis que impliquen restricciones a la movilidad y la actividad industrial.

6.2. Beneficios observados en la aplicación de la IA para predecir la demanda energética

A pesar de las limitaciones mencionadas, este estudio ha demostrado que, con un enfoque relativamente simple y sin necesidad de conocimientos avanzados en modelado predictivo, es posible obtener una estimación general de la demanda energética. Esto resalta el enorme potencial de la inteligencia artificial en el sector energético, ya que permite generar predicciones de forma rápida y accesible.

El uso de IA en la predicción de la demanda energética puede proporcionar numerosos beneficios, como la optimización del suministro, la mejora en la gestión de la red eléctrica y la reducción de costes operativos. Además, si estos modelos se complementan con un mayor volumen de datos y técnicas más avanzadas, es posible mejorar significativamente la precisión de las estimaciones.

6.3. Retos, barreras y mejoras

El uso de inteligencia artificial en la predicción y gestión de la demanda energética representa un gran avance en la optimización del sector. Sin embargo, su implementación también conlleva una serie de desafíos y riesgos que deben ser considerados para garantizar su seguridad.

6.3.1. Riesgos asociados al uso de IA para la predicción energética

Uno de los principales retos es la necesidad de contar con datos de alta calidad y en cantidad suficiente para obtener resultados más precisos. Si bien los modelos predictivos pueden detectar patrones basados en el comportamiento previo del consumo energético, estos no siempre son representativos de las condiciones futuras. En este estudio, solo se han empleado datos históricos de los últimos cinco años (2018-2022), lo que limita la capacidad del modelo para capturar patrones a largo plazo y evaluar fenómenos más complejos.

Un ejemplo claro de esta dependencia de datos históricos fue la crisis del COVID-19 en el año 2020. Un modelo de IA basado únicamente en datos previos no habría sido capaz de anticipar correctamente un evento de tal magnitud, resaltando la importancia de integrar más factores.

Siguiendo este ejemplo, otra mejora clave para la metodología utilizada en este trabajo sería la incorporación de variables externas. Factores como la temperatura, la actividad económica o

eventos puntuales (festividades, días de alta actividad comercial, etc.) pueden influir significativamente en la demanda energética y deberían ser considerados para mejorar la precisión de las predicciones.

Además, aunque herramientas de IA más avanzadas pueden ofrecer predicciones más precisas, su implementación requiere mayores conocimientos computacionales y una inversión significativa en infraestructura tecnológica. En este estudio se ha empleado una herramienta de predicción accesible y sencilla, pero para que la IA sea una solución viable en el sector energético, es fundamental desarrollar estrategias más complejas y adaptadas a cada contexto.

Resumiendo, las principales barreras que deben ser consideradas, son:

- Cambios abruptos en los patrones de consumo. Eventos imprevistos, como pandemias o desastres naturales, pueden alterar significativamente los patrones de consumo energético de los datos históricos, limitando la capacidad de la IA para poder llevar a cabo predicciones tan precisas.
- Dependencia de modelos históricos. La mayoría de los modelos de IA se entrenan con datos históricos, lo que puede no ser representativo en el futuro. Estamos en un mundo muy cambiante y que evoluciona muy rápido gracias a los potentes desarrollos de la tecnología. Por ello, ante tantos grandes cambios, se hace más difícil poder predecir nuestro comportamiento como consumidores de energía en el futuro.
- Problemas de interpretabilidad. Algunos modelos de IA ofrecen poca transparencia en su proceso de toma de decisiones. Esto hace más difícil que se puedan detectar errores o sesgos en las predicciones.

6.3.2. Riesgos financieros y éticos en el uso de la IA: Caso de fraude empresarial

Aunque, como hemos visto, la IA ofrece una gran serie de beneficios aplicables en el ámbito energético, también plantea ciertos riesgos, sobre todo cuando se habla de seguridad y ética.

Un caso reciente refleja el peligro que puede suponer esta tecnología si no se gestiona adecuadamente. Según una noticia publicada por el periódico ABC (2024), una empresa fue víctima de un fraude millonario debido al uso de la IA para suplantar la identidad de un alto ejecutivo mediante una videollamada falsa. A través de técnicas avanzadas de clonación de voz e imagen, los delincuentes consiguieron engañar a las personas encargadas de la administración financiera de la empresa y hacerles transferir una gran cantidad de dinero (en torno a 24 millones de euros) a los delincuentes.

Este caso pone de manifiesto los riesgos que surgen con el uso de la IA, sobre todo, en entornos

empresariales:

- Suplantación de identidad: la clonación de voz o deepfakes, vídeos creados con IA que imitan la apariencia y voz de una cierta persona (BlackBerry, 2024), pueden emplearse para engañar a individuos o sistemas automatizados.
- Vulnerabilidad de los sistemas automatizados: algunas plataformas que dependen de la IA pueden tomar decisiones, financieras, por ejemplo, y pueden ser manipuladas si no cuentan con buenos mecanismos de autenticación y seguridad.
- Reputación corporativa: los incidentes relacionados con fraudes tecnológicos pueden llegar a dañar la imagen pública de las empresas y perjudicar en sus resultados económicos.

Este caso refleja la necesidad de que las organizaciones adopten no solo tecnologías de IA, sino también medidas complementarias que refuercen la seguridad, la transparencia y la ética en su implementación.

7. Visión a Futuro: IA, Sostenibilidad y Transición Energética

7.1. Recomendaciones para la implementación futura de la IA en el mercado energético

Los resultados obtenidos en este trabajo proporcionan una aproximación útil para estimar la demanda energética en España. No obstante, los avances en inteligencia artificial permiten el desarrollo de modelos más sofisticados que podrían mejorar significativamente la precisión de estas predicciones.

En el apartado 3.2. Tipos de Inteligencia Artificial, se explicaron las diferentes categorías de IA existentes. A partir del análisis del caso práctico, se puede concluir que ciertos tipos de IA serían más adecuados para mejorar la estimación de la demanda energética. Las máquinas de memoria limitada (Tipo II) y las redes neuronales artificiales destacan como dos opciones prometedoras en este campo.

Estos sistemas son capaces de almacenar y procesar grandes volúmenes de datos históricos, lo que es fundamental para tareas de predicción basadas en series temporales. Además, las redes neuronales artificiales tienen la capacidad de identificar patrones complejos en los datos, permitiéndoles realizar estimaciones más ajustadas a la realidad. Empresas como Google DeepMind, por ejemplo, han aplicado IA para optimizar el consumo energético en centros de datos, logrando reducir significativamente su gasto energético.

En conclusión, para mejorar la precisión de las predicciones en el sector energético, sería recomendable avanzar hacia el uso de un tipo de IA más avanzada, como las redes neuronales artificiales. Estos modelos pueden identificar relaciones más complejas entre los diferentes factores que afectan la demanda energética, lo que permitiría desarrollar predicciones más eficaces y precisas.

7.2. Impacto potencial de la IA en la sostenibilidad y la reducción de la huella de carbono

La inteligencia artificial tiene el potencial de convertirse en un aliado clave en la lucha contra el cambio climático. Su capacidad para analizar grandes volúmenes de información y optimizar procesos abre nuevas oportunidades para mejorar la eficiencia en la generación, distribución y consumo de energía. Algunas aplicaciones clave incluyen:

- Optimización del consumo energético y automatización de redes. La IA puede identificar patrones de consumo y ajustar la demanda energética en tiempo real, reduciendo desperdicios y aumentando la eficiencia operativa. Esto no solo beneficia a

las empresas, sino que también impacta en el ámbito doméstico. La integración de sistemas inteligentes en los hogares permite a los consumidores gestionar su consumo eléctrico de manera más eficiente, reduciendo costes y contribuyendo a la sostenibilidad.

Por otro lado, el desarrollo de redes eléctricas inteligentes (smart grids) representa un gran avance. Estas redes permiten una distribución más eficiente de la energía, ajustando la oferta y la demanda en tiempo real. Con la incorporación de IA, estos sistemas pueden operar de manera autónoma y optimizada.

- Integración de energías renovables y planificación energética. Uno de los mayores desafíos de las fuentes renovables es su intermitencia. La IA ayuda a mitigar este problema mediante modelos predictivos que anticipan la producción energética y ajustan la distribución en consecuencia. Esto facilita la toma de decisiones estratégicas tanto para gobiernos como para empresas, promoviendo un mejor uso de los recursos y reduciendo la dependencia de los combustibles fósiles.
- Reducción de emisiones de carbono y economía circular. Como se ha mencionado, al reducir la generación de energía basada en combustibles fósiles, se logra una disminución de las emisiones de gases de efecto invernadero.

Además, la IA puede desempeñar un papel clave en la transición hacia una economía circular, al identificar oportunidades para la reutilización de materiales, optimizar el reciclaje y minimizar los residuos generados en los procesos industriales.

En conclusión, la inteligencia artificial está transformando el sector energético al mejorar la eficiencia, facilitar la integración de energías renovables y reducir las emisiones de carbono. Su impacto no se limita únicamente al ámbito industrial, sino que también tiene el potencial de transformar la manera en que los consumidores individuales gestionan su demanda energética.

A medida que la IA siga avanzando y volviéndose más accesible, su papel en la transición energética será cada vez más relevante, consolidándose como una herramienta fundamental para alcanzar un sistema energético más sostenible y eficiente. En definitiva, la inteligencia artificial no solo representa una tecnología innovadora, sino que se presenta como un pilar clave en la construcción de un futuro energético más inteligente, sostenible y resiliente.

8. Bibliografía

- ABC. (06 de febrero de 2024). Ojo con la IA: así la han utilizado para robarle 24 millones de euros a una empresa. ABC. Obtenido de <https://www.abc.es/tecnologia/ojo-ia-utilizado-robarle-millones-euros-empresa-20240206122750-nt.html>
- Amazon Web Services. (2023). *¿Qué es la inteligencia Artificial?* Obtenido de AWS: <https://aws.amazon.com/es/what-is/artificial-intelligence/>
- Amini, M., & Sharifani, K. (2023). Machine Learning and Deep Learning: A Review of Methods and Applications. *World Information Technology and Engineering Journal*, 10(7), 3897-3904. Obtenido de https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4458723#paper-citations-widget
- Bejnordi, B. E., Ciompi, F., Ghafoorian, M., Kooi, T., Litjens, G., Sánchez, C., . . . van Ginneken, B. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*(42), 60-88. Obtenido de <https://doi.org/10.1016/j.media.2017.07.005>
- BlackBerry. (2024). *Deepfakes unmasked: the technology and techniques behind this growing threat*. Obtenido de BlackBerry: <https://www.blackberry.com/us/en/pdfviewer?file=/content/dam/bbcomv4/blackberry-com/en/solutions/threat-intelligence/deepfakes-blackberry-wp.pdf>
- Borunda-Pacheco, M., & Ibargüengoytia-González, P. H. (2018). Predicción de potencia eólica utilizando técnicas modernas de Inteligencia Artificial Wind power forecasting using Artificial Intelligence tools. *Ingeniería Investigación y tecnología*, 19(4), 1-11. doi:<http://dx.doi.org/10.22201/fi.25940732e.2018.19n4.033>
- Boswell, B., Buckley, S., Elliot, B., Melero, M., & Smith, M. (mayo de 2022). *An AI power play: Fueling the next wave of innovation in the energy sector*. Obtenido de McKinsey & Company: <https://www.mckinsey.com/~media/mckinsey/business%20functions/mckinsey%20digital/how%20we%20help%20clients/inside%20an%20ai%20power%20play/an-ai-power-play-fueling-the-next-wave-of-innovation-in-the-energy-sector-may-2022.pdf>
- Canales Luna, J. (11 de Septiembre de 2024). *Las 10 mejores herramientas de análisis de datos para analistas de datos en 2024*. Obtenido de DataCamp: <https://www.datacamp.com/es/blog/the-9-best-data-analytics-tools-for-data-analysts-in-2023>

- Daniel, C., Gehin, J. C., Laurin-Kovitz, K., Morreale, B., Stevens, R., & Tumas, W. (abril de 2024). *AI for Energy*. Obtenido de Argone National Laboratory: https://www.anl.gov/sites/www/files/2024-04/AI-for-Energy-Report_APRIL%202024.pdf
- Fernández, E. C. (8 de septiembre de 2022). *Sensores IoT: qué son, para qué sirven, tipos, características y más*. Obtenido de Tokio School: <https://www.tokioschool.com/noticias/sensores-iot/>
- Ghosh, P. (25 de octubre de 2023). *Cómo DeepMind, la inteligencia artificial de Google, está acelerando la identificación de genes que causan enfermedades*. Obtenido de BBC News: <https://www.bbc.com/mundo/articles/crglgeqgpl4o>
- Google. (s.f.a). *¿Qué es la inteligencia artificial o IA?* Obtenido de Google Cloud: <https://cloud.google.com/learn/what-is-artificial-intelligence?hl=es-419>
- Google. (s.f.b). *¿Cuál es la diferencia entre el aprendizaje profundo, el aprendizaje automático y la inteligencia artificial?* Obtenido de Google Cloud: <https://cloud.google.com/discover/deep-learning-vs-machine-learning?hl=es-419>
- Guillard, E. (19 de diciembre de 2024). *Predicción del Consumo de Energía mediante el Machine Learning y la IA*. Obtenido de Energy Spacewell: <https://www.dexma.com/es/blog-es/prediccion-del-consumo-de-energia-mediante-el-machine-learning-y-la-ia/>
- Guillén García, J. (2002). Las energías renovables. *Revista de la universidad del Azuay*(29), 269-294. Obtenido de https://www.researchgate.net/profile/Walter-Larriva/publication/316345582_NEMATODOS_QUE_SE_ALIMENTAN_DE_INSECTOS_Una_opcion_para_el_Manejo_Integrado_de_Plagas/links/58fab875a6fdccde9892bf5e/NEMATODOS-QUE-SE-ALIMENTAN-DE-INSECTOS-Una-opcion-para-el-Manejo-
- Holdsworth, J., & Scapicchio, M. (17 de junio de 2024). *¿Qué es el deep learning?* Obtenido de IBM: <https://www.ibm.com/es-es/topics/deep-learning>
- Iberdrola. (2024). *¿Qué es la Inteligencia Artificial?* Obtenido de Iberdrola: <https://www.iberdrola.com/innovacion/que-es-inteligencia-artificial>
- IBM. (27 de diciembre de 2023). *¿Qué son las SVM?* Obtenido de IBM: <https://www.ibm.com/es-es/topics/support-vector-machine>

- IBM. (s.f.). *¿Qué es el machine learning (ML)?* Obtenido de IBM: <https://www.ibm.com/es-es/topics/machine-learning>
- International Business Machines Corporation [IBM]. (2024). *¿Qué es la inteligencia artificial (IA)?* Obtenido de IBM: <https://www.ibm.com/es-es/topics/artificial-intelligence>
- Lagarrigue, E. (30 de marzo de 2021). *Why artificial intelligence is key to renewable energy grid resilience.* Obtenido de World Economic Forum: <https://www.weforum.org/stories/2021/03/artificial-intelligence-is-key-to-grid-resilience/>
- Masterson, V. (12 de febrero de 2024). *9 ways AI is helping tackle climate change.* Obtenido de World Economic Forum: <https://www.weforum.org/stories/2024/02/ai-combat-climate-change/>
- McKinsey & Company. (agosto de 2023). *The AI-enabled utility.* Obtenido de McKinsey & Company: https://www.mckinsey.com/~media/mckinsey/industries/electric%20power%20and%20natural%20gas/our%20insights/the%20ai%20enabled%20utility%20rewiring%20to%20win%20in%20the%20energy%20transition/mck_utility_compendium.pdf
- Mendelsohn, S. (7 de octubre de 2024). *La IA es un acelerador para la sostenibilidad, pero no es una bala de plata.* Obtenido de World Economic Forum: <https://es.weforum.org/stories/2024/10/la-inteligencia-artificial-acelera-la-sostenibilidad-pero-no-es-la-panacea/>
- Naciones Unidas. (s.f.). *Objetivos de Desarrollo Sostenible.* Obtenido de Naciones Unidas.
- Norving, P., & Russell, S. (2020). *Artificial Intelligence: A Modern Approach (4th ed.).* Pearson. Obtenido de <https://dl.ebooksworld.ir/books/Artificial.Intelligence.A.Modern.Approach.4th.Edition.Peter.Norvig.%20Stuart.Russell.Pearson.9780134610993.EBooksWorld.ir.pdf>
- Novaluz Energía. (9 de enero de 2024). *¿La energía de biomasa es limpia o contaminante?* Obtenido de Novaluz.: <https://novaluz.es/blog/energia-verde/la-energia-de-biomasa-es-limpia-o-contaminante/>
- OECD. (2019). *Artificial Intelligence in Society.* Paris: OECD Publishing. Obtenido de <https://doi.org/10.1787/eedfee77-en>

- ONU. (s.f.). *Llegar a las emisiones netas 0: el mundo se compromete a tomar medidas*. Obtenido de Naciones Unidas: <https://www.un.org/es/climatechange/net-zero-coalition>
- Palau, N. (6 de junio de 2023). *Qué es un invierno-IA y cómo evitarlo*. Obtenido de Telefónica Tech: <https://telefonicatech.com/blog/que-es-el-invierno-ia-y-como-evitarlo>
- Parlamento Europeo. (26 de marzo de 2021). *¿Qué es la inteligencia artificial y cómo se usa?* Obtenido de <https://www.europarl.europa.eu/topics/es/article/20200827STO85804/que-es-la-inteligencia-artificial-y-como-se-usa>
- Peter, S. (5 de septiembre de 2024). *La IA nació en un campamento de verano en Estados Unidos hace 68 años. Por eso, ese acontecimiento sigue siendo importante hoy en día*. Obtenido de International Science Council: <https://es.council.science/blog/ai-was-born-at-a-us-summer-camp-68-years-ago-heres-why-that-event-still-matters-today/>
- Redeia. (2024). *Boletines mensuales*. Obtenido de Red Eléctrica de España: <https://www.ree.es/es/datos/publicaciones/boletines-mensuales>
- Santander, C. (13 de marzo de 2020). *Machine Learning vs. Deep Learning*. Obtenido de Cognitive. Business Insights Thru Data.: <https://cognitive.la/blog/machine-learning-vs-deep-learning>
- SAP. (s.f.). *Medidas de error*. Obtenido de SAP. Help Portal: https://help.sap.com/docs/SAP_INTEGRATED_BUSINESS_PLANNING/feae3cea3cc549aaa9d9de7d363a83e6/32cc1c552770a20ce10000000a44176d.html
- Smarkia. (7 de septiembre de 2023). *5 aplicaciones de la IA en la gestión energética*. Obtenido de Smarkia: <https://www.smarkia.com/blog/5-aplicaciones-de-la-ia-en-la-gestion-energetica>
- The Nature Conservancy. (18 de febrero de 2022). *Tres cosas que hay que saber sobre inteligencia artificial y la planeación de energía verde*. Obtenido de The Nature Conservancy: <https://www.nature.org/es-us/que-hacemos/nuestra-vision/perspectivas/tres-cosas-sobre-inteligencia-artificial-y-planeacion-energia-verde/>
- U.S. Department of Energy. (16 de agosto de 2024). *How AI Can Help Clean Energy Meet Growing Electricity Demand*. Obtenido de U.S. Department of Energy: <https://www.energy.gov/policy/articles/how-ai-can-help-clean-energy-meet-growing-electricity-demand>

- UNEP. (7 de noviembre de 2022). *How artificial intelligence is helping tackle environmental challenges*. Obtenido de UN environmental programme: <https://www.unep.org/news-and-stories/story/how-artificial-intelligence-helping-tackle-environmental-challenges>
- Valencia, A. (2021). *La Inteligencia Artificial y la empresa: dilemas éticos generados por su aplicación en un futuro automatizado*. [Trabajo Fin de Grado, Universidad Pontificia Comillas]: Repositorio de la Universidad Pontificia Comillas. Obtenido de <http://hdl.handle.net/11531/46576>
- Valverde, S. (2019). *Aplicaciones de la Inteligencia Artificial en la empresa*. [Trabajo de Fin de Grado, Unviersidad de Cantabria] Repositorio Abierto de la Universidad de Cantabria. Obtenido de <https://repositorio.unican.es/xmlui/handle/10902/17521>
- Zhang, X., Guo, F., Chen, T., Pan, L., Beliakov, G., & Wu, J. (s.f.). A Brief Survey of Machine Learning and Deep Learning Techniques for E-Commerce Research. *Journal of Theoretical and Applied Electronic Commerce Research*, 18(4). Obtenido de 2188-2216. <https://doi.org/10.3390/jtaer18040110>

9. Anexo

9.1. Anexo 1. Datos de partida

Tabla 4: Demanda diaria 2018-2022 (GWh) Fuente: Redeia, (2024)

Fecha	Demanda diaria 2018 (GWh)	Demanda diaria 2019 (GWh)	Demanda diaria 2020 (GWh)	Demanda diaria 2021 (GWh)	Demanda diaria 2022 (GWh)
1 de enero	535	546,35	538,8	573,16	499,18
2 de enero	680	701,06	682,92	641,98	541,95
3 de enero	712	745,3	713,96	646,9	652,05
4 de enero	713	753,02	663,38	753,09	678,47
5 de enero	688	680,41	614,37	765,94	674,78
6 de enero	605	624,5	593,56	663,32	580,48
7 de enero	640	723,22	747,75	812,87	661,15
8 de enero	782	801,04	778,15	829,92	646,47
9 de enero	815	802,18	778,79	733,89	618,91
10 de enero	798	812,16	772,06	697,82	714,96
11 de enero	796	821,73	692,61	809,57	731,22
12 de enero	800	732,65	655,36	833,35	735,63
13 de enero	725	682,69	786,76	833,15	747,19
14 de enero	674	791,84	802,03	831,9	759,06
15 de enero	795	801,9	790,81	818,88	677,86
16 de enero	794	804,49	780,94	727,32	634,8
17 de enero	783	807,54	766,37	673,65	749,41
18 de enero	780	805,89	690,22	788,17	767,21
19 de enero	771	725,75	651,15	806,28	772,33
20 de enero	682	666,62	803,69	810,4	773,24
21 de enero	624	785,83	819,23	778,29	770,63
22 de enero	737	821	798,76	755,61	690,85
23 de enero	753	810,85	787,14	682,9	643,75
24 de enero	758	793,13	779,21	620,67	758,34
25 de enero	771	771,04	694,45	737,38	762,4
26 de enero	779	682,78	638,33	733,24	758,05
27 de enero	701	640,44	765,22	715,06	752,87
28 de enero	651	764,19	764,83	706,05	745,43
29 de enero	757	787,91	750,76	694,55	659,01
30 de enero	772	784,82	736,47	634,84	610,81
31 de enero	770	779,83	724,29	595,63	720,81
1 de febrero	788	768,4	643,16	690,43	733,02
2 de febrero	799	697,99	589,02	707,87	723,15
3 de febrero	717	656,69	689,47	708,67	719,83
4 de febrero	684	784,55	707,28	706,45	716,73
5 de febrero	813	782,52	718,14	706,54	644,2
6 de febrero	824	769,9	728,67	639,68	598,6
7 de febrero	831	762,32	731,46	602,72	706,57
8 de febrero	838	756,64	659,23	721,44	715,85
9 de febrero	829	678,83	609,96	753,02	714,79
10 de febrero	734	634,86	708,73	731,59	721,06
11 de febrero	668	739,45	720,08	721,83	713,6

12 de febrero	791	756,62	725,18	708,66	641,36
13 de febrero	810	754,93	718,72	629,79	598,58
14 de febrero	801	751,24	713,15	594,3	700,64
15 de febrero	779	747,74	637,48	706,69	717,99
16 de febrero	762	665,83	588,96	715,33	717,6
17 de febrero	678	619,42	698,96	715,95	703,82
18 de febrero	634	737,38	725,08	718,85	695,32
19 de febrero	750	747,29	723,23	713,54	639,4
20 de febrero	760	742,57	722,12	634,77	591,6
21 de febrero	764	738,51	712,55	605,51	687,96
22 de febrero	777	728,5	632,83	707,05	693,74
23 de febrero	788	649,12	583,88	714,39	691,68
24 de febrero	702	599,47	689,82	710,88	696,57
25 de febrero	649	708,48	703,61	708,47	701,02
26 de febrero	770	717,27	711,54	703,38	631,97
27 de febrero	811	713,85	709,52	626,72	581,13
28 de febrero	797	699,92	686,86	587,88	655,41
1 de marzo	790	707,37	591,16	696,08	684,9
2 de marzo	785	631	700,45	713,55	695,94
3 de marzo	681	585,11	727,51	708,22	702,98
4 de marzo	628	689,6	717,42	704,05	702,64
5 de marzo	756	706,05	712,99	699,87	621,89
6 de marzo	771	727,25	716,4	624,45	582,71
7 de marzo	763	717,29	643,92	589,76	692,35
8 de marzo	757	706,73	593,08	705,78	694,87
9 de marzo	745	631,44	698,6	721,39	686,16
10 de marzo	659	580,25	705,57	713,09	681,54
11 de marzo	617	684,4	700,68	702,52	691,13
12 de marzo	731	701,18	696,65	692,62	603,35
13 de marzo	748	711,21	688,66	612,48	556,15
14 de marzo	755	711,41	607,45	574,18	686,42
15 de marzo	748	697,01	563,98	682,98	686,56
16 de marzo	739	621,29	665,5	695,59	688,43
17 de marzo	676	574,58	667,26	693,09	685,18
18 de marzo	624	666,43	647,24	704,51	663,46
19 de marzo	740	664,5	604,98	667,74	584,55
20 de marzo	790	712,41	610,8	633,48	554,28
21 de marzo	788	716,02	578	594,48	657,98
22 de marzo	774	706,84	550,34	695,54	676,36
23 de marzo	772	630,12	618,41	700	678,08
24 de marzo	697	574,62	628,84	691,83	684,05
25 de marzo	613	675,53	628,92	686,3	666,14
26 de marzo	738	691,31	624,37	679,85	591,77
27 de marzo	727	693,52	631,2	611,5	517,71
28 de marzo	699	693,86	570,85	538,26	636,49
29 de marzo	618	691,48	508,14	653,37	651,86
30 de marzo	581	621,61	573,03	657,09	664,63
31 de marzo	602	558,73	573,18	640,9	662,98

1 de abril	569	687,49	566,76	568,86	670,56
2 de abril	626	699,31	565,87	524,7	607,46
3 de abril	702	702,5	551,85	543,58	575,35
4 de abril	713	705,16	511,31	518,35	701,52
5 de abril	700	717,16	488,51	568,43	720,92
6 de abril	705	643,56	536,47	642,68	702,68
7 de abril	641	597,98	535,61	668,74	681,61
8 de abril	589	704,22	523,44	673,51	666,53
9 de abril	702	720,17	499,67	675,16	583,25
10 de abril	746	716,96	480,97	605,08	538,51
11 de abril	751	711,95	488,05	560,44	627,95
12 de abril	745	694,82	471,46	655,45	647,2
13 de abril	736	618,29	506,71	679,86	644,41
14 de abril	641	568,52	551,83	678,84	546,95
15 de abril	591	663,54	571,08	683,85	500,21
16 de abril	697	670,19	571,16	675,64	513,78
17 de abril	700	665,72	565,55	606,2	491,51
18 de abril	690	595,41	520,88	559,26	541,98
19 de abril	681	547,93	488,94	660,68	618,71
20 de abril	674	559,89	552,29	672,56	659,27
21 de abril	606	538,8	576,97	673,89	657,7
22 de abril	559	582,58	575,73	674,72	656,01
23 de abril	651	650,32	566,89	647,97	589,83
24 de abril	678	696,94	562,05	585,44	535,62
25 de abril	685	698,5	524,39	551,64	615,5
26 de abril	680	680,99	492	652,51	637,95
27 de abril	674	602,33	558,34	665,91	647,69
28 de abril	603	543,2	569,42	661,34	649,49
29 de abril	554	640,77	567,73	660,84	629,8
30 de abril	618	651,87	560,6	651,94	554,94
1 de mayo	556	551,91	495,05	543,96	493,76
2 de mayo	655	633,92	498,33	526,4	576,02
3 de mayo	687	656,17	479,52	631,36	639,11
4 de mayo	685	596,42	552,98	653,38	648,19
5 de mayo	610	550,39	574,76	653,93	641,8
6 de mayo	556	651,18	577,84	651,99	629,6
7 de mayo	668	672,36	573,41	644,32	559,05
8 de mayo	683	679,55	566,52	577,85	515,31
9 de mayo	680	678,82	517,7	541,15	611,83
10 de mayo	678	673,16	485,17	635,77	631,49
11 de mayo	678	603,73	560,33	653,17	638,58
12 de mayo	606	552,38	585,49	659,21	643,88
13 de mayo	559	652,19	584,21	655,87	638,76
14 de mayo	661	675,2	587,39	651,7	575,01
15 de mayo	671	673,15	575,92	589,7	529,04
16 de mayo	684	682,26	524,44	549,63	618,59
17 de mayo	681	665,98	489,14	631,36	648,63
18 de mayo	677	593,08	563,5	657,74	660,66

19 de mayo	606	550,48	581,45	659,97	675,12
20 de mayo	556	650,85	588,69	658,97	673,03
21 de mayo	653	669,69	596,17	652,95	605,79
22 de mayo	679	677,22	598,99	585,51	553,11
23 de mayo	687	677,82	549,14	540,22	650,37
24 de mayo	687	674,48	509,58	621,47	657,78
25 de mayo	682	601,42	592,81	649,47	641,89
26 de mayo	605	547,46	607,72	654	714,84
27 de mayo	553	660,21	610,69	656,39	651,79
28 de mayo	659	680,1	606,96	648,22	587,47
29 de mayo	679	678,86	606,09	588,88	540
30 de mayo	675	678,2	549,63	544,54	630,24
31 de mayo	667	677,07	507,53	644,03	653,94
1 de junio	667	615,87	591,93	657,39	666,53
2 de junio	599	570,73	618,21	661,27	670,33
3 de junio	544	682,94	627	659,21	667,36
4 de junio	658	699,13	615,57	653,34	590,63
5 de junio	677	683,68	605,5	585,42	543,57
6 de junio	676	675,25	549,19	541,37	627,23
7 de junio	672	672,17	508,27	648,69	673,05
8 de junio	673	607,12	590,77	679,53	686,7
9 de junio	603	559,17	608,59	687,64	694,26
10 de junio	554	650,19	618,66	697,85	695,44
11 de junio	665	674,81	617,92	691,19	634,87
12 de junio	686	679,3	609,96	623,31	590,13
13 de junio	694	682,64	547,15	578,51	711,76
14 de junio	694	677,82	510,74	696	751,68
15 de junio	694	608,78	607,25	716,52	768,91
16 de junio	630	562,37	619,25	711,71	762,66
17 de junio	582	671,34	623,61	689,79	759,15
18 de junio	700	692,56	624,51	677,87	674,92
19 de junio	725	697,56	620,36	606,45	594,81
20 de junio	739	690,27	572,68	556,46	697,39
21 de junio	747	687,91	539,31	652,73	705,12
22 de junio	748	630,62	644,45	667,67	686,72
23 de junio	672	583,2	668,47	658,9	665,17
24 de junio	621	643,84	631,44	626,64	612,39
25 de junio	743	718,09	673,08	652,55	589,49
26 de junio	762	744,56	662,91	610,68	552,92
27 de junio	759	759,12	599,59	568,73	649,46
28 de junio	750	772,34	568,33	662,74	669,98
29 de junio	738	704,59	680,73	682,62	678,77
30 de junio	663	651,77	707,84	698,73	675,34
1 de julio	607	755,37	722,49	700,25	666,97
2 de julio	718	767,81	724,4	705,25	619,25
3 de julio	753	764,69	694,98	642,05	584,92
4 de julio	746	763,29	623,24	601,85	685,66
5 de julio	740	765,01	590,66	708,75	716,37

6 de julio	735	689,02	715,88	717,6	714,54
7 de julio	667	639,12	738,18	701,16	706,79
8 de julio	617	731,64	743,1	695,67	710,26
9 de julio	758	730,77	728,63	688,1	644,76
10 de julio	771	742,08	716,56	634,99	606,44
11 de julio	771	770,28	650,6	619,53	730,37
12 de julio	761	777,73	595,65	713,11	760,3
13 de julio	757	690,09	710,04	691,77	777,04
14 de julio	674	621,41	718,1	694,96	783,51
15 de julio	612	745,68	716,46	701,53	780,11
16 de julio	726	760	720,97	702,4	699,01
17 de julio	755	755,19	718	656,7	650,91
18 de julio	764	757,49	648,91	611,65	769,33
19 de julio	769	767,52	606,49	719,79	769,58
20 de julio	755	695,14	726,22	735,76	769,06
21 de julio	663	645,38	742,1	745,83	781,21
22 de julio	599	784,22	732,72	756,3	776,53
23 de julio	737	805,29	745,05	749,65	681,59
24 de julio	763	807,18	743,56	657,59	636,06
25 de julio	752	781,85	660,75	599,78	730,29
26 de julio	762	756,29	623,71	690,92	766
27 de julio	760	655,84	747,84	713,84	748,93
28 de julio	680	593,01	766,95	726,42	745,39
29 de julio	618	708,7	769,84	734,47	738,36
30 de julio	738	721,8	776,96	728,01	665,27
31 de julio	757	714,39	761,17	637,63	624,86
1 de agosto	778,42	738,09	692,34	568,29	729,89
2 de agosto	801,97	732,89	630,84	646,65	746,28
3 de agosto	811,27	657,26	701,52	670,33	741,78
4 de agosto	720,25	613,06	706,18	680,27	735,59
5 de agosto	666,32	720,23	719,27	689,25	719,27
6 de agosto	783,38	739,69	731,18	684,96	647,49
7 de agosto	788,11	734	730,2	629,89	599,13
8 de agosto	768,97	741,64	657,88	572,4	674,66
9 de agosto	741,49	741,76	616,61	641,07	692,27
10 de agosto	715,92	664,78	692,14	665,41	701,15
11 de agosto	666,41	603,25	687,85	687,14	697,42
12 de agosto	624,77	660,59	665,76	705,84	697,28
13 de agosto	706,18	663,7	669,26	712,52	645,53
14 de agosto	698,75	672,82	663,85	685,48	579,63
15 de agosto	625,04	615,02	588,1	646,72	571,56
16 de agosto	688,02	665,26	550,1	686,02	627,72
17 de agosto	673,1	642,84	638	684,45	625,08
18 de agosto	612,74	604,32	662,61	680,24	609,98
19 de agosto	582,41	696,77	678,72	673,54	613,28
20 de agosto	695,91	697,75	682,61	673,9	586,72
21 de agosto	724,74	693	691,09	633,33	557,35
22 de agosto	735,96	696,29	630,85	598,34	652,43

23 de agosto	734,31	695,5	582,87	692,4	679,6
24 de agosto	726,25	635,86	687,31	704,13	687,57
25 de agosto	649,09	593,24	725,46	691,65	683,43
26 de agosto	599,98	700,99	743,41	699,25	671,91
27 de agosto	737,14	697,7	749,16	703,98	608,68
28 de agosto	763,71	708,7	726,44	633,66	567,04
29 de agosto	757,74	726,89	594,26	583,28	674,24
30 de agosto	756,84	731,15	535,41	676,28	698,16
31 de agosto	748,02	654,18	638,56	700,85	687,16
1 de septiembre	667,19	612,87	660,77	699,87	681,68
2 de septiembre	625,81	722,64	671,85	686,52	681,67
3 de septiembre	738,37	746,85	679,53	683,93	594,39
4 de septiembre	748,38	753,01	685,24	616,13	551,13
5 de septiembre	741,33	735,72	616,4	583,23	660,97
6 de septiembre	727,02	712,57	569,31	703,6	677,76
7 de septiembre	714,12	633,35	658,55	728,74	682,62
8 de septiembre	623,92	584,25	660,38	710,93	667,63
9 de septiembre	575,73	680,39	678,48	711,61	672,21
10 de septiembre	676,78	684,74	682,26	694,87	606,82
11 de septiembre	685,23	654,2	659,46	618,53	574,89
12 de septiembre	727,81	674,58	612,51	581,38	693,08
13 de septiembre	733,23	665,36	571,2	684,11	695,59
14 de septiembre	727,37	596,04	680,15	697,9	671,74
15 de septiembre	635,21	558,44	700,4	693,66	664,13
16 de septiembre	592,64	674,1	711,92	684,38	660,62
17 de septiembre	707,4	695,95	700,71	670,62	574,68
18 de septiembre	725,96	700,11	674,45	599,62	533,02
19 de septiembre	731,82	701,16	590,52	552,03	640,66
20 de septiembre	738,9	693,54	539,81	652,21	659,34
21 de septiembre	733,15	614,85	644,35	651,35	654,91
22 de septiembre	656,88	562,01	664,55	657,57	650,8
23 de septiembre	607,85	659,62	673,81	658,4	645,18
24 de septiembre	723,97	679,78	673,44	652,72	559,17
25 de septiembre	731,37	690,31	653,14	590,9	507,86
26 de septiembre	731,73	691,95	579,08	546,25	596,69
27 de septiembre	715,08	687,42	535,62	644,47	616,55
28 de septiembre	712,17	609,11	629,39	662,93	620,42
29 de septiembre	624,82	558,24	649,86	666,43	621,42
30 de septiembre	572,1	667,99	653,2	660,2	606,34
1 de octubre	688,44	694,64	663,92	651,42	537,74
2 de octubre	692,24	687,48	661,37	593,13	498,97
3 de octubre	695,44	676,77	577,17	547,67	603,87
4 de octubre	697,16	672,53	542,75	627,52	625,88
5 de octubre	686,45	602,4	634,64	644,97	627,17
6 de octubre	613,71	555,6	653,98	657,65	633,39
7 de octubre	564,87	662,7	662,85	648,25	625,02
8 de octubre	657,36	685,57	662,47	643,47	549,95
9 de octubre	663,11	674,05	643,28	573,33	503,37

10 de octubre	677	681,44	580	531,1	604,25
11 de octubre	676,33	673,3	531,69	575,42	613,96
12 de octubre	580,13	583,61	537,54	540,29	520,68
13 de octubre	582,68	552,21	637,13	628,23	601,05
14 de octubre	557,13	665,17	665,82	641,24	613,51
15 de octubre	654,65	664,86	672,95	641,07	540,41
16 de octubre	673,88	668,48	667,33	576,75	503,48
17 de octubre	681,15	669,88	597,58	536,46	604,83
18 de octubre	682,02	658,97	551,01	635,54	625,87
19 de octubre	673,83	597,52	650,47	651,16	637,35
20 de octubre	600,26	551,4	675,2	652,43	642,85
21 de octubre	555,42	656,01	670,33	647,48	630,97
22 de octubre	659,99	686,55	674,23	641,88	547,17
23 de octubre	676,76	689,57	661,18	573,76	513,37
24 de octubre	675,26	687,72	591,67	534,73	604,95
25 de octubre	673,86	679,04	568,39	631,56	622,66
26 de octubre	675,42	599,41	653,38	652,34	628,22
27 de octubre	607,43	576,59	678,35	650,38	622,49
28 de octubre	594,3	663,36	679,69	650,1	611,7
29 de octubre	703,92	678,06	678,74	651,74	534
30 de octubre	734,89	673,79	667,95	588,95	510,33
31 de octubre	730,35	664,02	593,29	553,6	549,12
1 de noviembre	618,36	574,44	544,52	545,91	502,81
2 de noviembre	662,89	572,69	614,71	639,35	595,47
3 de noviembre	623,8	549,19	666,28	665,29	618
4 de noviembre	592,36	662,63	694,01	674,84	615,03
5 de noviembre	715,95	683,21	693,72	677,41	536,17
6 de noviembre	734,78	689,15	673,08	617,8	498,45
7 de noviembre	736,87	699,98	601,96	583,12	601,03
8 de noviembre	737,75	710,59	552,79	678,54	629,2
9 de noviembre	724,85	638,2	656,49	692,15	623,71
10 de noviembre	648,35	592,53	680,83	704,57	626,37
11 de noviembre	596,1	721,48	688,66	707,06	627,24
12 de noviembre	710,53	733,95	687,24	697	552,42
13 de noviembre	718,45	733,34	681,32	620,92	509,04
14 de noviembre	718,14	750,3	610,43	579,76	615,5
15 de noviembre	716,88	751,67	554,07	686,31	637,95
16 de noviembre	710,76	673,48	660,37	713,34	643,68
17 de noviembre	630,2	635,76	680,27	711,07	642
18 de noviembre	598,27	745,02	687,18	716,69	638,09
19 de noviembre	715,42	769,7	680,96	716,66	568,27
20 de noviembre	740,01	777,91	676,13	644,8	526,71
21 de noviembre	743,01	776,4	613,52	595,39	649,45
22 de noviembre	748,78	769,64	578,05	708,97	677,77
23 de noviembre	742,26	665,39	696,19	732,63	664,04
24 de noviembre	663,42	616,8	724,08	748,57	660,68
25 de noviembre	624,28	732,97	732,85	748,02	640,46
26 de noviembre	739,68	740,85	729,78	742,05	578,29

27 de noviembre	756,85	728,54	722,52	674,97	547,37
28 de noviembre	758,93	731,36	643,81	644,09	645,94
29 de noviembre	762,33	719,56	602,14	741,79	671,51
30 de noviembre	748,47	638,7	710,31	755,14	685,3
1 de diciembre	672,19	607,05	716,38	757,5	691,25
2 de diciembre	623,12	734,32	729,06	759,09	692,28
3 de diciembre	728,69	751,46	745,37	750,28	622,78
4 de diciembre	735,12	760,3	750,96	673,31	580,81
5 de diciembre	731,57	754,7	686,17	624,69	669,55
6 de diciembre	640,17	648,46	638,22	630,07	609,25
7 de diciembre	669,76	639,11	672,96	671,14	655,34
8 de diciembre	624,4	615,66	655,67	646,01	596,35
9 de diciembre	606,95	690,62	761,28	741,36	633,42
10 de diciembre	728,09	753,01	767,96	735,56	586,33
11 de diciembre	752,93	768,05	745,41	651,73	570,7
12 de diciembre	761,21	783,14	644,2	606,31	689,29
13 de diciembre	770,69	752,35	608,25	717,29	694,62
14 de diciembre	760,04	665,16	717,93	741,65	678,89
15 de diciembre	682,05	623,07	726,8	744,95	673,63
16 de diciembre	640,25	739,98	738,67	750,46	675,23
17 de diciembre	759,11	746,18	737,52	741,85	592,54
18 de diciembre	781,4	751,1	734,95	665,75	554,73
19 de diciembre	765,4	752,13	661,18	623,54	670,27
20 de diciembre	755,32	715,99	606,74	729,55	684,73
21 de diciembre	731,44	628,28	710,21	731,09	672,06
22 de diciembre	650,12	584,9	708,51	714,9	655,77
23 de diciembre	610,88	636,78	688,33	686,85	618,8
24 de diciembre	608,11	580,92	602,56	596,44	523,89
25 de diciembre	532,21	506,38	531,79	511,19	455,33
26 de diciembre	633,88	593,53	595,44	545,74	496,58
27 de diciembre	680,78	633,75	603,02	618,07	572,83
28 de diciembre	681,79	606,84	683,77	624,25	589,28
29 de diciembre	634,9	578,42	690,78	617,06	596,77
30 de diciembre	600,05	648,05	694,09	612,84	583,28
31 de diciembre	614,4	614,99	646,1	570,09	520,3

9.2. Anexo 2. Resultados

Tabla 5: Resultados. Fuente: Redeia (2024) & Data Analyst (2025)

Fecha	Demanda diaria estimada 2023 (GWh)	Demanda diaria 2023 (GWh)
1 de enero	514,87	466,41
2 de enero	587,00	580,92
3 de enero	674,46	636,49
4 de enero	712,39	644,03
5 de enero	683,60	625,17
6 de enero	620,57	537,83
7 de enero	699,72	583,28

8 de enero	722,56	572,93
9 de enero	703,76	658,21
10 de enero	740,40	687,13
11 de enero	750,87	695,42
12 de enero	752,05	700,40
13 de enero	747,00	693,62
14 de enero	766,77	620,98
15 de enero	717,41	575,23
16 de enero	701,53	711,34
17 de enero	764,15	714,71
18 de enero	770,23	734,48
19 de enero	759,25	743,25
20 de enero	770,18	712,34
21 de enero	783,01	632,57
22 de enero	734,85	605,08
23 de enero	687,64	738,77
24 de enero	702,10	777,18
25 de enero	722,37	767,90
26 de enero	708,68	768,98
27 de enero	696,57	756,24
28 de enero	691,48	670,22
29 de enero	655,62	629,29
30 de enero	612,18	744,28
31 de enero	686,42	740,99
1 de febrero	708,02	742,51
2 de febrero	710,33	732,36
3 de febrero	689,22	718,59
4 de febrero	702,44	630,79
5 de febrero	701,72	582,17
6 de febrero	671,79	717,02
7 de febrero	676,91	754,57
8 de febrero	692,91	751,31
9 de febrero	706,55	738,20
10 de febrero	715,83	733,71
11 de febrero	712,00	640,99
12 de febrero	682,22	595,78
13 de febrero	645,19	707,43
14 de febrero	663,47	736,71
15 de febrero	701,34	717,59
16 de febrero	706,49	708,77
17 de febrero	700,20	698,20
18 de febrero	697,71	612,24
19 de febrero	683,73	561,43
20 de febrero	662,92	658,31
21 de febrero	670,29	674,29
22 de febrero	680,73	677,28
23 de febrero	695,24	697,51
24 de febrero	689,52	693,21

25 de febrero	692,80	624,66
26 de febrero	682,15	586,96
27 de febrero	621,56	715,89
28 de febrero	644,73	720,87
1 de marzo	693,69	762,42
2 de marzo	705,28	745,63
3 de marzo	683,89	723,34
4 de marzo	688,86	637,74
5 de marzo	679,85	592,25
6 de marzo	684,4	692,72
7 de marzo	681,3	688,57
8 de marzo	689,82	684,29
9 de marzo	696,52	669,73
10 de marzo	688,87	643,74
11 de marzo	679,99	565,18
12 de marzo	664,36	517,70
13 de marzo	643,1	615,00
14 de marzo	666,38	626,06
15 de marzo	668,08	626,12
16 de marzo	669,14	627,27
17 de marzo	663,22	624,82
18 de marzo	661,57	560,43
19 de marzo	653,94	513,71
20 de marzo	645,58	599,57
21 de marzo	651,02	622,44
22 de marzo	664,98	622,88
23 de marzo	671,89	619,43
24 de marzo	670,16	619,08
25 de marzo	666,17	552,01
26 de marzo	658,52	489,67
27 de marzo	629,63	597,27
28 de marzo	647,48	609,06
29 de marzo	651,88	609,48
30 de marzo	658,47	611,45
31 de marzo	655,53	609,35
1 de abril	608,49	549,16
2 de abril	611,92	508,80
3 de abril	615,37	595,03
4 de abril	626,19	606,83
5 de abril	636,73	595,47
6 de abril	638,44	522,86
7 de abril	639,89	477,72
8 de abril	642,41	489,69
9 de abril	641,09	467,98
10 de abril	625,73	520,20
11 de abril	615,28	587,44
12 de abril	622,18	615,34
13 de abril	628,67	613,24

14 de abril	618,73	618,60
15 de abril	605,14	550,20
16 de abril	608,76	506,73
17 de abril	594,33	589,97
18 de abril	586,91	610,60
19 de abril	595,92	611,80
20 de abril	606,12	613,09
21 de abril	610,56	607,18
22 de abril	609,28	547,07
23 de abril	601,41	502,88
24 de abril	588,7	588,90
25 de abril	592,93	613,97
26 de abril	601,24	617,38
27 de abril	608,52	621,91
28 de abril	613,84	615,79
29 de abril	612,12	547,33
30 de abril	604,96	499,37
1 de mayo	507,89	482,99
2 de mayo	578,46	578,11
3 de mayo	618,21	615,79
4 de mayo	646,88	620,26
5 de mayo	650,72	614,86
6 de mayo	639,04	547,35
7 de mayo	610,37	507,61
8 de mayo	588,92	598,04
9 de mayo	583,17	622,62
10 de mayo	594,51	618,09
11 de mayo	616,84	611,94
12 de mayo	623,42	611,44
13 de mayo	619,87	537,74
14 de mayo	614,92	501,84
15 de mayo	586,45	587,00
16 de mayo	575,88	605,30
17 de mayo	600,23	597,70
18 de mayo	627,48	605,21
19 de mayo	641,21	601,63
20 de mayo	645,83	533,04
21 de mayo	620,46	494,43
22 de mayo	582,94	594,59
23 de mayo	612,33	608,65
24 de mayo	630,77	603,93
25 de mayo	638,92	605,87
26 de mayo	662,84	591,95
27 de mayo	645,29	522,86
28 de mayo	608,51	479,14
29 de mayo	582,14	576,14
30 de mayo	605,78	595,67
31 de mayo	621,49	593,82

1 de junio	659,18	603,80
2 de junio	664,72	595,72
3 de junio	660,98	526,13
4 de junio	643,15	486,19
5 de junio	621,62	584,59
6 de junio	614,41	612,25
7 de junio	634,71	626,33
8 de junio	657,42	617,51
9 de junio	672,13	606,27
10 de junio	676,95	536,60
11 de junio	664,48	500,41
12 de junio	641,27	603,91
13 de junio	646,35	621,05
14 de junio	684,92	624,80
15 de junio	704,38	634,96
16 de junio	720,81	645,50
17 de junio	717,14	578,99
18 de junio	692,57	531,17
19 de junio	648,35	632,69
20 de junio	658,74	651,12
21 de junio	676,25	660,19
22 de junio	680,39	654,06
23 de junio	664,78	652,12
24 de junio	630,62	578,11
25 de junio	614,23	567,63
26 de junio	597,94	699,71
27 de junio	611,85	718,08
28 de junio	639,74	722,61
29 de junio	668,52	716,10
30 de junio	678,03	674,89
1 de julio	698,74	597,50
2 de julio	702,19	568,76
3 de julio	687,78	689,17
4 de julio	683,92	700,30
5 de julio	713,45	701,83
6 de julio	722,18	705,74
7 de julio	714,62	697,15
8 de julio	712,44	611,98
9 de julio	689,06	577,52
10 de julio	678,98	721,82
11 de julio	706,52	761,30
12 de julio	731,45	750,98
13 de julio	740,83	738,53
14 de julio	750,92	739,12
15 de julio	752,74	642,15
16 de julio	720,84	586,23
17 de julio	695,47	721,06
18 de julio	722,93	764,90

19 de julio	726,82	777,42
20 de julio	732,74	758,17
21 de julio	748,21	718,08
22 de julio	761,84	626,05
23 de julio	729,48	593,02
24 de julio	698,62	691,56
25 de julio	711,79	662,52
26 de julio	730,11	675,67
27 de julio	722,39	690,75
28 de julio	721,06	681,59
29 de julio	715,42	624,61
30 de julio	688,71	591,11
31 de julio	671,59	676,87
1 de agosto	702,38	694,69
2 de agosto	711,12	706,58
3 de agosto	718,25	683,76
4 de agosto	710,56	634,76
5 de agosto	700,39	565,81
6 de agosto	696,81	545,13
7 de agosto	682,74	624,04
8 de agosto	671,29	656,15
9 de agosto	693,14	675,68
10 de agosto	705,87	689,32
11 de agosto	702,43	679,97
12 de agosto	701,92	622,88
13 de agosto	687,51	578,74
14 de agosto	659,84	620,41
15 de agosto	625,16	577,35
16 de agosto	640,89	638,82
17 de agosto	653,32	646,46
18 de agosto	648,79	648,54
19 de agosto	646,28	612,69
20 de agosto	638,51	595,46
21 de agosto	622,19	708,98
22 de agosto	659,47	730,12
23 de agosto	676,03	741,81
24 de agosto	687,92	743,72
25 de agosto	678,84	733,90
26 de agosto	671,38	644,58
27 de agosto	664,92	537,29
28 de agosto	648,57	613,28
29 de agosto	672,43	630,93
30 de agosto	690,38	638,87
31 de agosto	689,56	642,39
1 de septiembre	664,3	655,38
2 de septiembre	677,9	566,52
3 de septiembre	688,72	518,80
4 de septiembre	670,48	626,85

5 de septiembre	666,73	647,92
6 de septiembre	678,48	659,49
7 de septiembre	683,35	664,50
8 de septiembre	661,84	643,70
9 de septiembre	663,42	572,05
10 de septiembre	668,98	532,81
11 de septiembre	638,86	617,34
12 de septiembre	655,48	651,27
13 de septiembre	668,92	650,71
14 de septiembre	674,75	656,59
15 de septiembre	668,91	648,67
16 de septiembre	664,28	555,75
17 de septiembre	648,52	521,65
18 de septiembre	622,79	611,26
19 de septiembre	635,84	627,95
20 de septiembre	654,21	625,81
21 de septiembre	661,73	625,00
22 de septiembre	659,84	602,77
23 de septiembre	655,17	524,81
24 de septiembre	648,92	491,44
25 de septiembre	615,83	592,04
26 de septiembre	598,74	619,55
27 de septiembre	623,68	630,61
28 de septiembre	633,21	631,71
29 de septiembre	628,42	627,05
30 de septiembre	620,35	555,75
1 de octubre	647,42	521,75
2 de octubre	626,64	625,57
3 de octubre	624,4	641,47
4 de octubre	632,52	644,64
5 de octubre	639,42	645,09
6 de octubre	622,47	646,59
7 de octubre	612,12	568,47
8 de octubre	583,87	524,72
9 de octubre	562,58	609,33
10 de octubre	598,35	629,78
11 de octubre	600,42	624,57
12 de octubre	552,85	527,44
13 de octubre	588,66	564,19
14 de octubre	613,71	530,04
15 de octubre	622,68	496,14
16 de octubre	595,48	606,79
17 de octubre	589,72	634,02
18 de octubre	623,33	638,52
19 de octubre	634,72	643,96
20 de octubre	641,58	618,74
21 de octubre	629,11	532,18
22 de octubre	602,42	503,74

23 de octubre	578,84	603,92
24 de octubre	599,41	619,65
25 de octubre	619,75	629,98
26 de octubre	625,83	643,36
27 de octubre	620,38	630,49
28 de octubre	612,74	553,37
29 de octubre	590,81	539,49
30 de octubre	568,22	621,88
31 de octubre	579,64	611,88
1 de noviembre	519,8	548,96
2 de noviembre	622,01	632,88
3 de noviembre	644,86	640,53
4 de noviembre	648,19	575,56
5 de noviembre	561,28	524,52
6 de noviembre	516,73	628,20
7 de noviembre	609,56	651,76
8 de noviembre	639,93	666,07
9 de noviembre	647,28	655,51
10 de noviembre	649,76	650,34
11 de noviembre	662,12	578,29
12 de noviembre	578,91	526,59
13 de noviembre	548,92	628,50
14 de noviembre	621,68	639,26
15 de noviembre	640,75	646,68
16 de noviembre	648,23	650,90
17 de noviembre	660,84	639,82
18 de noviembre	655,32	563,14
19 de noviembre	591,82	520,75
20 de noviembre	559,94	628,89
21 de noviembre	658,73	648,97
22 de noviembre	687,85	659,01
23 de noviembre	675,19	667,96
24 de noviembre	669,74	668,29
25 de noviembre	656,48	593,78
26 de noviembre	610,52	561,19
27 de noviembre	581,94	676,38
28 de noviembre	645,62	694,76
29 de noviembre	672,83	690,73
30 de noviembre	689,34	681,49
1 de diciembre	699,32	679,71
2 de diciembre	700,85	606,57
3 de diciembre	666,74	585,38
4 de diciembre	621,52	699,49
5 de diciembre	682,31	707,08
6 de diciembre	612,74	632,71
7 de diciembre	654,25	656,12
8 de diciembre	618,32	594,40
9 de diciembre	639,71	590,38

10 de diciembre	627,14	563,84
11 de diciembre	603,89	668,35
12 de diciembre	682,58	689,47
13 de diciembre	688,93	694,83
14 de diciembre	675,61	698,97
15 de diciembre	670,48	693,42
16 de diciembre	673,85	619,99
17 de diciembre	631,24	595,20
18 de diciembre	599,87	713,37
19 de diciembre	678,34	728,64
20 de diciembre	692,21	734,00
21 de diciembre	679,48	710,89
22 de diciembre	665,15	673,85
23 de diciembre	631,72	595,39
24 de diciembre	535,62	552,92
25 de diciembre	463,78	513,01
26 de diciembre	506,34	608,92
27 de diciembre	579,28	654,36
28 de diciembre	596,43	662,44
29 de diciembre	603,85	652,00
30 de diciembre	591,27	582,80
31 de diciembre	537,61	559,21