

Universidad de Alcalá
Escuela Politécnica Superior

Grado en Ingeniería en Electrónica y Automática Industrial



Trabajo Fin de Grado

Predicador de generación fotovoltaica y de precios del mercado minorista de la electricidad para la gestión óptima de baterías

ESCUELA POLITECNICA
SUPERIOR

Autor: Alejandro García Sánchez

Tutor: Carlos Santos Pérez

Cotutor: Pablo José Hueros Barrios

2023

UNIVERSIDAD DE ALCALÁ
Escuela Politécnica Superior

Grado en ingeniería electrónica y automática Industrial

Trabajo Fin de Grado

Predictor de generación fotovoltaica y de precios del mercado minorista de la electricidad para la gestión óptima de baterías

Autor: Alejandro García Sánchez

Tutor: Carlos Santos Pérez

Cotutor: Pablo José Hueros Barrios

TRIBUNAL:

Presidente: Ricardo Mallol Poyato

Vocal 1º: Enrique Alexandre Cortizo

Vocal 2º: Carlos Santos Pérez

FECHA depósito: 19/09/2023



Universidad
de Alcalá

Agradecimientos

Para iniciar mis agradecimientos, quiero destacar la confianza y oportunidad que me brindó Carlos Santos Pérez y el grupo de investigación GEISER de la Universidad de Alcalá, permitiéndome colaborar con ellos a través de una beca de investigación. También deseo agradecer a los compañeros de cátedra por toda la ayuda proporcionada y por los gratos momentos compartidos durante la ejecución de este proyecto.

Por otra parte, alcanzar la conclusión de este proyecto representa el cierre de una etapa significativa y prolongada de mi vida. Ha sido un período lleno de experiencias enriquecedoras, acompañado de personas maravillosas y momentos inolvidables. A pesar de haber enfrentado momentos duros, estos fueron menores gracias al apoyo de mi familia, los amigos que gané durante el grado y, por supuesto, mi pareja, quien ha sido mi pilar en los momentos más desafiantes, donde la rendición parecía ser la única salida. A todos vosotros, mi más sincero agradecimiento.

Como nota final y profundamente personal, quiero dedicar unas palabras a mis abuelos. Me habría encantado que pudieran estar aquí para cerrar este capítulo conmigo y ser testigos de cómo el nieto que tanto amaron y cuidaron ha logrado convertirse en ingeniero. Estéis donde estéis os quiero mucho y sé que estáis orgullosos de vuestro nieto.

Este trabajo ha sido posible gracias al proyecto "RuralVPP" ref. SBPLY/21/180501/000223 financiado por la Junta de Comunidades de Castilla-La Mancha (JCCM) y la Unión Europea a través del Fondo Europeo de Desarrollo Regional y al al proyecto "iPVBEMS" ref. PIUAH22/IA-060 financiado por la Universidad de Alcalá.

Índice general

Agradecimientos.....	3
Resumen	10
Abstract.....	11
Palabras clave	12
Resumen Extendido.....	13
Glosario de Acrónimos y Abreviaturas.....	15
1 Introducción.....	16
1.1 Motivación del trabajo	16
1.2 Objetivos y campo de aplicación	17
1.2.1 Objetivos.....	17
1.2.2 Campo de Aplicación	18
1.3 Estructura del documento	18
2 Estado del arte de predictores	21
2.1 Generación de energía renovable mediante VPPs	21
2.2 Estudio de las técnicas de predicción fotovoltaica	22
2.2.1 Horas similares	23
2.2.2 Redes neuronales	25
2.2.3 Conversión a potencia	26
2.2 Conclusiones.....	27
3 Análisis y Predicción con LSTM	28
3.1 Introducción a la red neuronal	28
3.2 Las redes LSTM.....	28
3.2.1 Arquitectura	29
3.2.2 Entrenamiento.....	30
3.2.3 Aplicaciones	32
3.2.4 Ventajas.....	33
3.2.5 Desventajas.....	33
4 Implementación y Configuración de la Red.....	34
4.1 Redes LSTM para la predicción de irradiancia.....	34
4.1.1 Recopilación y elección de datos.....	34
4.1.2 Entrenamiento y resultados de las predicciones	45
4.2 Redes LSTM para la predicción de precios de la energía.....	52
4.2.1 Recopilación y elección de datos.....	52
4.2.2 Entrenamiento y resultados de las predicciones	59

5	Transformación de Irradiancia a potencia	64
5.1	Lectura de mapas de AEMET	65
5.1.1	Procesamiento del CCF	65
5.1.2	Procesamiento de la temperatura.....	69
5.2	Cálculo de potencia.....	70
5.2.1	Cálculo de la componente horizontal de la irradiancia.....	71
5.2.2	Estimación de las pérdidas por suciedad y espectrales.....	73
5.2.3	Determinación de la temperatura de los paneles	74
5.2.4	Cálculo de la potencia generada mediante el modelo de Osterwald	74
6	Estrategia de almacenamiento de energía en baterías. BEMS.....	75
6.1	Ubicación y Configuración de la Instalación.....	75
6.2	Introducción a las BEMS	78
6.3	Análisis de las variables de la gestión de las baterías.....	78
6.4	Comparación con valores reales	81
7	Conclusiones.....	82
8	Bibliografía.....	83

Índice Figuras

FIGURA 1: ESTRUCTURA VISUAL DEL TRABAJO	20
FIGURA 2: ESQUEMA DE CONEXIÓN DE UNA VPP. FUENTE [51]	22
FIGURA 3: CLASIFICADOR DE REDES NEURONALES. FUENTE [1].....	23
FIGURA 4: ARQUITECTURA RED NEURONAL LSTM DE MATLAB. FUENTE [41]	28
FIGURA 5: MODELO CELDA LSTM.....	29
FIGURA 6: ERROR ENTRE GHI REAL Y PREDICCIÓN.....	30
FIGURA 7: ENTRENAMIENTO REAL LSTM.....	32
FIGURA 8: SERIE TEMPORAL DE GHI	32
FIGURA 9: "MATRIZ DE PCC ENTRE TODAS LAS VARIABLES CONSIDERADAS EN EL ESTUDIO, PARA LA ESTACIÓN METEOROLÓGICA DE JUAN CARLOS I." FUENTE [1]	35
FIGURA 10: MAPA DE NUBOSIDAD DE LA COMUNIDAD DE ESPAÑA OBTENIDO DE LA AEMET. FUENTE [29]	36
FIGURA 11: MAPA DE COBERTURA DE NUBES DEL 10 DE SEPTIEMBRE DE 2023. IMAGEN DESCARGADA DE ECMWF. FUENTE [69].....	36
FIGURA 12: LEYENDA DE NUBES ALTAS, BAJAS Y MEDIAS DE ECMWF. FUENTE [69]	37
FIGURA 13: HISTÓRICO DEL MES DE ENERO DE 2015 DE LA VARIABLE TCC	37
FIGURA 14: CORRELACIÓN TCC Y GHI/GHICLEARSKY 2/6/2022-9/6/2022	39
FIGURA 15: GHI/GHICLEARSKY VS CCF 2/6/2022-9/6/2022	39
FIGURA 16: GHI Y GHI CLEAR SKY 2/6/2022-9/6/2022	39
FIGURA 17: CORRELACIÓN CCF Y GHI/GHICLEARSKY 2/6/2022-9/6/2022	39
FIGURA 18: CORRELACIÓN CCF Y GHI/GHICLEARSKY 14/5/2022-25/5/2022	40
FIGURA 19: CORRELACIÓN TCC Y GHI/GHICLEARSKY 14/5/2022-25/5/2022	40
FIGURA 20: GHI/GHICLEARSKY VS CCF 14/5/2022-25/5/2022	40
FIGURA 21: GHI Y GHI CLEAR SKY 14/5/2022-25/5/2022	40
FIGURA 22: CORRELACIÓN CCF Y GHI/GHICLEARSKY 20/9/2022-27/9/2022.....	41
FIGURA 23: CORRELACIÓN TCC Y GHI/GHICLEARSKY 20/9/2022-27/9/2022.....	41
FIGURA 24: GHI/GHICLEARSKY VS CCF 20/9/2022-27/9/2022	41
FIGURA 25: GHI Y GHI CLEAR SKY 20/9/2022-27/9/2022	41
FIGURA 26: CORRELACIÓN TCC Y GHI/GHICLEARSKY 2/7/2022-9/7/2022	42
FIGURA 27: GHI/GHICLEARSKY VS CCF 2/7/2022-9/7/2022	42
FIGURA 28: GHI Y GHI CLEAR SKY 2/7/2022-9/7/2022	42
FIGURA 29: CORRELACIÓN CCF Y GHI/GHICLEARSKY 2/7/2022-9/7/2022	42
FIGURA 30: HISTÓRICO DEL MES DE ENERO DE 2015 DE LA VARIABLE GHI EXTRATERRESTRE.....	44
FIGURA 31: HISTÓRICO DEL MES DE ENERO DE 2015 DE LA VARIABLE GHI	44
FIGURA 32: VALORES DEL ENTRENAMIENTO DE LA RED LSTM PARA LA PREDICCIÓN DE GHI.....	47
FIGURA 34: PREDICCIÓN INTRADIARIA O EN LAZO ABIERTO	48
FIGURA 33: ESQUEMA DE ENTRADAS Y SALIDAS DE LA RED LSTM EN LOS INSTANTES "X" Y "X+1" EN LAZO ABIERTO	48
FIGURA 35: HISTOGRAMA DE LOS VALORES DE RMSE DE LA PREDICCIÓN INTRADAY.....	49
FIGURA 36: PREDICCIÓN EN LAZO CERRADO.	50
FIGURA 37: ESQUEMA DE ENTRADAS Y SALIDAS DE LA RED LSTM EN LOS INSTANTES "X" Y "X+1" EN LAZO CERRADO.....	50
FIGURA 38: VALORES PREDICHOS DE GHI Y PREDICHOS Y REALES.....	51
FIGURA 39: GENERACIÓN ELÉCTRICA ESPAÑOLA DESGLOSADO POR TECNOLOGÍAS. FUENTE [33]	53
FIGURA 40: HISTÓRICO DEL MES DE ENERO DE 2016 DE LA VARIABLE POTENCIA EÓLICA NACIONAL	54
FIGURA 41: HISTÓRICO DEL MES DE ENERO DE 2016 DE LA VARIABLE POTENCIA FOTOVOLTAICA NACIONAL	55
FIGURA 42: HISTÓRICO DEL MES DE ENERO DE 2016 DE LA VARIABLE PRECIO DEL GAS.....	56
FIGURA 43: HISTÓRICO DEL MES DE ENERO DE 2016 DE LA VARIABLE FESTIVOS.....	57
FIGURA 44: HISTÓRICO DEL MES DE ENERO DE 2016 DE LA VARIABLE PRECIO DEL MERCADO SPOT	58
FIGURA 45: ESQUEMA DE ENTRADAS Y SALIDAS DE LA RED LSTM EN LOS INSTANTES "X" Y "X+1" EN LAZO CERRADO.....	60
FIGURA 46: VISUALIZACIÓN DE LOS VALORES DE ENTRADA NORMALIZADOS PARA LA PREDICCIÓN DE UN DÍA EN LAZO ABIERTO	60

FIGURA 47: RESULTADO DE LA PREDICCIÓN EN LAZO CERRADO DEL PRECIO DE LA ELECTRICIDAD EL MERCADO SPOT	61
FIGURA 48: HISTOGRAMA DE LOS VALORES DE RMSE DEL DÍA 29 DE LA PREDICCIÓN.....	62
FIGURA 49: PERFIL DE IMPUESTOS PARA FINES DE SEMANA	63
FIGURA 50: PERFIL DE IMPUESTOS PARA DÍAS LABORABLES	63
FIGURA 51: PRECIO DE LA ENERGÍA CON Y SIN IMPUESTOS.....	63
FIGURA 52: POSICIÓN DEL SOL SEGÚN LA HORA Y DEFINICIÓN DE LAS VARIABLES MÁS IMPORTANTES PARA LA ADQUISICIÓN DEL CCF. FUENTE [1]	66
FIGURA 53: " DIAGRAMA DE BLOQUES DEL PROCEDIMIENTO PARA OBTENER EL CCF DE LOS NWP." FUENTE [1].....	68
FIGURA 54: CCF CALCULADO DEL 29 DE AGOSTO DE 2023	68
FIGURA 55: MAPA DE NUBOSIDAD DEL 29 DE AGOSTO DE 2023 A LAS 19H. IMAGEN DESCARGADA DE AEMET. FUENTE [29]	68
FIGURA 56: MAPA DE TEMPERATURAS DEL MES DE AGOSTO DE 2023. IMAGEN DESCARGADA DE AEMET. FUENTE [29].....	69
FIGURA 57: LEYENDA DE TEMPERATURAS.....	69
FIGURA 58: MAPA DE TEMPERATURAS DEL MES DE MAYO DE 2023. IMAGEN DESCARGADA DE AEMET. FUENTE [29].....	69
FIGURA 59: MAPA DE TEMPERATURA DEL 29 DE AGOSTO DE 2023 A LAS 19H. IMAGEN DESCARGADA DE AEMET. FUENTE [29]	70
FIGURA 60: TEMPERATURA CALCULADA DEL 29 DE AGOSTO DE 2023.....	70
FIGURA 61: ECUACIÓN PARA EL CÁLCULO DE LA RADIACIÓN EXTRATERRESTRE. OBTENIDA DE LA TESIS DOCTORAL [1].....	71
FIGURA 62: VALORES PROMEDIOS DE LOS COEFICIENTES PARA PANELES DE DIFERENTES TECNOLOGÍAS. FUENTE [40].....	73
FIGURA 63: POTENCIA PREDICHA FRENTE A LA REAL PRODUCIDA POR LA INSTALACIÓN FOTOVOLTAICA EL DÍA 30 DE AGOSTO DE 2023	74
FIGURA 64: "DISPOSICIÓN DE LOS PANELES SOLARES FOTOVOLTAICOS INSTALADOS EN LA UNIVERSIDAD DE ALCALÁ, JUNTO A SU NUMERACIÓN Y CONEXIONADO." FUENTE [1]	75
FIGURA 65: PT100 FIJADO AL MÓDULO. FUENTE [1].....	76
FIGURA 68: PIRANÓMETRO. FUENTE [1]	76
FIGURA 66: ELECTRÓNICA DE ADQUISICIÓN. FUENTE [1]	76
FIGURA 67: ANEMÓMETRO. FUENTE [1]	76
FIGURA 69: PYLONTECH FORCE-L2-48-148. FUENTE [42].....	77
FIGURA 70: ESTRATEGIA EJEMPLO DEL BEMS PARA MOSTRAR LAS DISTINTAS VARIABLES A ANALIZAR.	79
FIGURA 71: PERDIDA DE LA VIDA ÚTIL POR LA GESTIÓN DE LAS BATERÍAS EN REFERENCIA A LA FIGURA 70	80
FIGURA 72: AHORRO ACUMULADO POR LA GESTIÓN DE LAS BATERÍAS EN REFERENCIA A LA FIGURA 70	80
FIGURA 73: BEMS CON VALORES PREDICHOS	81
FIGURA 74: BEMS CON VALORES REALES.....	81

Índice Tablas

TABLA 1: CORRELACIÓN R 2/6/2022-9/6/2022	TABLA 2: CORRELACIÓN P 2/6/2022-9/6/2022	39
TABLA 3: CORRELACIÓN R Y P 14/5/2022-25/5/2022		40
TABLA 4: CORRELACIÓN R Y P 20/9/2022-27/9/2022		41
TABLA 5: CORRELACIÓN R Y P 2/7/2022-9/7/2022		42

Índice Códigos

CÓDIGO 1: CAPAS RED LSTM	30
CÓDIGO 2: OPCIONES OPTIMIZACIÓN LSTM EN MATLAB.....	31
CÓDIGO 3: VALORES DE ENTRENAMIENTO	46

Resumen

Este trabajo se centra en el uso de las redes neuronales Long Short Term Memory (LSTM) para predecir irradiancia y precio PVPC. En el primer bloque, se aborda la técnica LSTM, y su aplicación en la predicción meteorológica y energética. La segunda parte está dedicada a la interpretación y utilización de las previsiones de irradiancia, junto con los mapas de nubosidad y temperatura proporcionados por AEMET, para calcular la energía que producida por paneles fotovoltaicos. Finalmente, se analiza cómo gestionar el almacenamiento eficiente de la energía en baterías de una planta real con la ayuda de los predictores diseñados. Este trabajo se realiza dentro del proyecto "iPVBEMS" ref. PIUAH22/IA-060

Abstract

This work focuses on the use of Long Short Term Memory (LSTM) neural networks to predict irradiance and PVPC price. The first section addresses the LSTM technique and its application in weather and energy prediction. The second part is dedicated to the interpretation and utilization of irradiance forecasts, along with cloudiness and temperature maps provided by AEMET, to calculate the energy produced by photovoltaic panels. Finally, it analyzes how to efficiently manage energy storage in batteries of a real plant with the assistance of the designed predictors. This work is carried out within the "iPVBEMS" project, reference PIUAH22/IA-060.

Palabras clave

LSTM, predicción de potencia fotovoltaica, irradiancia, precio de la energía, gestión de baterías

Resumen Extendido

Introducción

El presente proyecto tiene como objetivo principal desarrollar un sistema predictivo y de gestión energética basado en técnicas de Machine Learning, específicamente mediante el uso de Redes LSTM. Se busca optimizar la producción y el almacenamiento de energía solar en las instalaciones de la Universidad de Alcalá. El proyecto se divide en tres bloques principales.

Parte 1: Técnica LSTM y su aplicación en la predicción meteorológica y de precios de la energía.

En el primer capítulo, se profundiza en la técnica LSTM, explicando su origen, características y ventajas frente a otras técnicas de Machine Learning. Se describen los principios subyacentes de las redes LSTM y cómo pueden ser aplicadas para predecir patrones temporales complejos con una alta precisión.

Se destaca la importancia de predecir variables meteorológicas, como la irradiancia, para optimizar la producción de energía fotovoltaica. Se ve cómo estas predicciones pueden ayudar a anticipar los niveles de producción de energía, sabiendo que tiene un RMSE de 374,26 kW/m² en un fondo de escala de 2.4 MW/m², permitiendo una gestión más eficiente de los recursos energéticos disponibles.

También se estudia el funcionamiento en la predicción de precios del sector energético español. En la predicción de precios se calcula que tiene un RMSE de 17€/MW, consiguiendo unas predicciones ajustadas al precio real.

Parte 2: Interpretación de mapas de nubes y utilización de las previsiones de irradiancia

En el segundo capítulo, se aborda la interpretación y utilización de las previsiones de irradiancia. Se analiza cómo los datos proporcionados por AEMET, incluyendo mapas de nubosidad y temperatura, pueden ser utilizados para calcular la energía que será producida por los paneles fotovoltaicos.

Se exploran diferentes métodos para establecer patrones que permitan realizar predicciones precisas sobre la potencia que será generada por los paneles fotovoltaicos instalados en la Universidad de Alcalá. Además, se discutirá cómo estos patrones pueden ser utilizados para optimizar el rendimiento de los paneles fotovoltaicos, mejorando así la eficiencia del sistema energético.

Parte 3: Gestión Óptima del Almacenamiento de Energía

El tercer capítulo se centra en la gestión óptima del almacenamiento de energía. Se analiza cómo se puede implementar un sistema inteligente que permita optimizar el uso de las baterías de almacenamiento de energía, garantizando un suministro ininterrumpido de energía y maximizando la eficiencia del sistema energético, observando cómo en 3 días consecutivos genera un beneficio de 0.15€.

Se discuten diferentes estrategias para la gestión óptima del almacenamiento de energía, incluyendo el uso de algoritmos avanzados que permitan una respuesta rápida a las fluctuaciones en la producción de energía, asegurando así una gestión energética más sostenible y consciente del medio ambiente.

En conclusión, el enfoque del proyecto destaca en el uso de Redes LSTM para optimizar la producción y el almacenamiento de energía solar en la Universidad de Alcalá. Se enfatiza que, además de beneficiar a la Universidad, el proyecto tiene el potencial de sentar las bases para futuras implementaciones en otros entornos, promoviendo una gestión energética más sostenible y consciente del medio ambiente.

Se destaca que el proyecto no solo tiene aplicaciones prácticas significativas, sino que también puede contribuir a la investigación y desarrollo en el campo de la gestión energética sostenible, abriendo nuevas vías para la exploración y la innovación.

Glosario de Acrónimos y Abreviaturas.

LSTM	Long Short-Term Memory	Redes Neuronales Recurrentes de Memoria a Largo y Corto Plazo
RNN	Recurrent Neural Networks	Red Neuronal Recurrente
ANN	Artificial Neural Networks	Red Neuronal Artificial
GHI	Global Horizontal Irradiance	Irradiancia Horizontal Global
DG	Distributed Generation	Generación Distribuida
DER	Distributed Energy Resource	Recurso Energético Distribuido
EMS	Energy Management System	Sistema de Gestión Energético
ESS	Energy Storage System	Sistema de Almacenamiento de Energía
RMSE	Root-mean-square error	Raíz del error cuadrático medio
SOC	State of Charge	Estado de carga
BEMS	Building Energy Management System	Sistema de Gestión de Energía de Edificios

1 Introducción

1.1 Motivación del trabajo

La transformación energética global, en una crítica coyuntura impulsada por la imperiosa necesidad de realizar la transición hacia fuentes de energía más sostenibles y ecológicas, está marcando el surgimiento renovado de la energía solar como una solución viable y cada vez más accesible. Este escenario resalta la vitalidad de la energía fotovoltaica, una vía poderosa y sostenible respaldada por la innovación tecnológica. Los sistemas eléctricos actuales son entidades complejas donde la generación y la demanda deben mantener un equilibrio constante para evitar desequilibrios que podrían disparar protecciones en algunos elementos conectados, provocando cortes y sobrecargas.

Ante la creciente penetración de las fuentes de generación fotovoltaica, los retos se magnifican, requiriendo estrategias sofisticadas de predicción que tomen en cuenta variables meteorológicas como la velocidad y dirección del viento, la temperatura, la humedad y la nubosidad, entre otros. Este panorama abre la puerta al empleo de métodos avanzados como las redes LSTM que están demostrando su valía en predecir patrones temporales complejos con precisión elevada.

En este entorno dinámico, el presente proyecto, articulado alrededor del empleo de las redes LSTM para predecir la irradiancia y el precio fluctuante de la energía, emerge como un pilar fundamental en el camino hacia una gestión energética más sostenible y consciente del medio ambiente. La iniciativa se divide en tres segmentos críticos: la comprensión teórica y aplicación de las técnicas LSTM en la predicción de variables meteorológicas y energéticas; un análisis profundo de las predicciones de irradiancia basado en datos proporcionados por AEMET para optimizar la producción energética; y, finalmente, una estrategia perspicaz para la gestión eficaz del almacenamiento de energía, abordando así los desafíos de intermitencia comúnmente asociados con las fuentes renovables.

Los métodos de predicción que se exploran pueden ser segmentados según diversos criterios, incluyendo el horizonte temporal y las características del modelo, abarcando desde predicciones a muy corto plazo (nowcasting) hasta predicciones a largo plazo que pueden extenderse por años. Estos métodos se basan en una amplia variedad de estrategias, incluyendo análisis estadístico de series temporales, aprendizaje automático, estrategias de predicción física y modelos híbridos que combinan diferentes enfoques para mejorar la precisión y optimizar los recursos. En este contexto, los modelos LSTM se destacan como una herramienta crítica en la gestión eficiente de los recursos energéticos renovables.

El análisis profundiza en cómo, mediante el análisis de predicciones de irradiancia y la interpretación de datos climáticos, es posible optimizar la generación de energía fotovoltaica en las instalaciones de la Universidad de Alcalá, adaptándose a las variaciones meteorológicas y ajustando operaciones en consecuencia. Además, se considera la incertidumbre inherente a las predicciones, diferenciando entre predicciones

deterministas y probabilísticas que brindan diferentes niveles de confianza en la predicción.

Mirando hacia el futuro, se destaca la importancia de la predicción de precios en el contexto de los mercados eléctricos europeos, donde los precios están sujetos a una volatilidad significativa debido a factores como las fluctuaciones en la demanda y oferta energética, y las variaciones en el precio del gas y los derechos de emisión de CO₂. Al integrar estas avanzadas técnicas de predicción, el proyecto aspira no solo a fortalecer la infraestructura existente sino también a pavimentar el camino hacia una sociedad baja en carbono, abriendo nuevas vías para una gestión energética más consciente y sostenible.

El proyecto culmina con una reflexión crítica sobre los resultados alcanzados, destacando la promesa y el potencial de los métodos de predicción basados en LSTM en el ecosistema energético contemporáneo. Este estudio, comprometido con la innovación tecnológica y sostenible, resalta la importancia de explorar las fronteras aún no descubiertas de la energía solar, y enfatiza el rol esencial que juegan estos métodos avanzados en la transición hacia un futuro más verde y sostenible.

1.2 Objetivos y campo de aplicación

1.2.1 Objetivos

El objetivo principal de este proyecto es desarrollar un sistema predictivo y de gestión energética basado en técnicas de Machine Learning, específicamente mediante la utilización de Redes LSTM, para optimizar la producción y el almacenamiento de energía solar en las instalaciones de la Universidad de Alcalá.

Para alcanzar este objetivo, se establecen los siguientes subobjetivos:

Desarrollar modelos de predicción LSTM para estimar los niveles de irradiancia solar y los precios fluctuantes de la energía en el contexto nacional, haciendo uso de datos históricos y variables meteorológicas proporcionadas por la AEMET.

Analizar mapas de nubosidad y temperatura con el fin de establecer patrones que permitan realizar predicciones precisas sobre la potencia que sería generada por los paneles fotovoltaicos instalados en la Universidad de Alcalá.

Implementar un sistema inteligente de gestión de almacenamiento de energía, que permita optimizar el uso de las baterías de almacenamiento, garantizando no solo el suministro ininterrumpido de energía, sino también maximizando la eficiencia del sistema energético a través del uso óptimo de la energía renovable generada.

Evaluar críticamente los resultados obtenidos a partir del sistema desarrollado, contemplando tanto el desempeño de los modelos predictivos como la efectividad del sistema de gestión de energía.

1.2.2 Campo de Aplicación

El campo de aplicación de este proyecto se centra en la optimización de sistemas de energía renovable, abarcando tanto la producción como el almacenamiento de energía solar fotovoltaica en el marco del proyecto "iPVBEMS" ref. PIUAH22/IA-060 financiado por la Universidad de Alcalá. El escenario específico de aplicación es la Universidad de Alcalá, donde se buscará realizar una implantación real del sistema, monitoreando y ajustando las instalaciones fotovoltaicas existentes basándose en las predicciones realizadas.

Además, el proyecto tiene un alcance más amplio, al considerar las fluctuaciones en los precios de la energía a nivel nacional. Esto implica que, aunque focalizado inicialmente en la Universidad de Alcalá, el proyecto puede ser la base para futuras implementaciones en otros entornos educativos o incluso industriales, promoviendo una gestión energética más sostenible y consciente del medio ambiente, alineada con los objetivos de transición hacia fuentes de energía más limpias y sostenibles.

En el ámbito académico, el proyecto servirá como un recurso educativo significativo, facilitando una comprensión más profunda de los sistemas de energías renovables y fomentando la investigación centrada en la integración eficiente de las energías renovables en la red eléctrica.

1.3 Estructura del documento

Este trabajo de fin de grado está organizado en los siguientes 6 capítulos:

Capítulo 1: INTRODUCCIÓN

En este capítulo, se presenta el contexto y los objetivos que motivan el desarrollo del presente trabajo de fin de grado. Se brindará una visión general de la problemática que se aborda y se definirá el alcance del proyecto.

Capítulo 2: ESTADO DEL ARTE

Se realizará una revisión bibliográfica exhaustiva que permitirá situar el trabajo dentro del estado actual de la investigación en el campo del aprendizaje profundo aplicado a la predicción de la generación de energía fotovoltaica. Se analizarán estudios recientes, tecnologías emergentes y las principales tendencias del sector.

CAPÍTULO 3: ANÁLISIS Y PREDICCIÓN CON LSTM

Se detallará el uso de redes LSTM para el análisis y predicción de series temporales de datos relacionados con la generación de energía fotovoltaica. Se explicarán los fundamentos teóricos de estas redes y se describirá el proceso seguido para el diseño, entrenamiento y evaluación de los modelos de predicción implementados.

CAPÍTULO 4: IMPLEMENTACIÓN Y CONFIGURACIÓN DE LA RED

En este capítulo, se expone la metodología seguida para implementar y configurar la red neuronal que servirá como herramienta central en el proceso de predicción. Se abordará la selección de hiperparámetros, así como los criterios adoptados para la configuración de las distintas capas y elementos de la red.

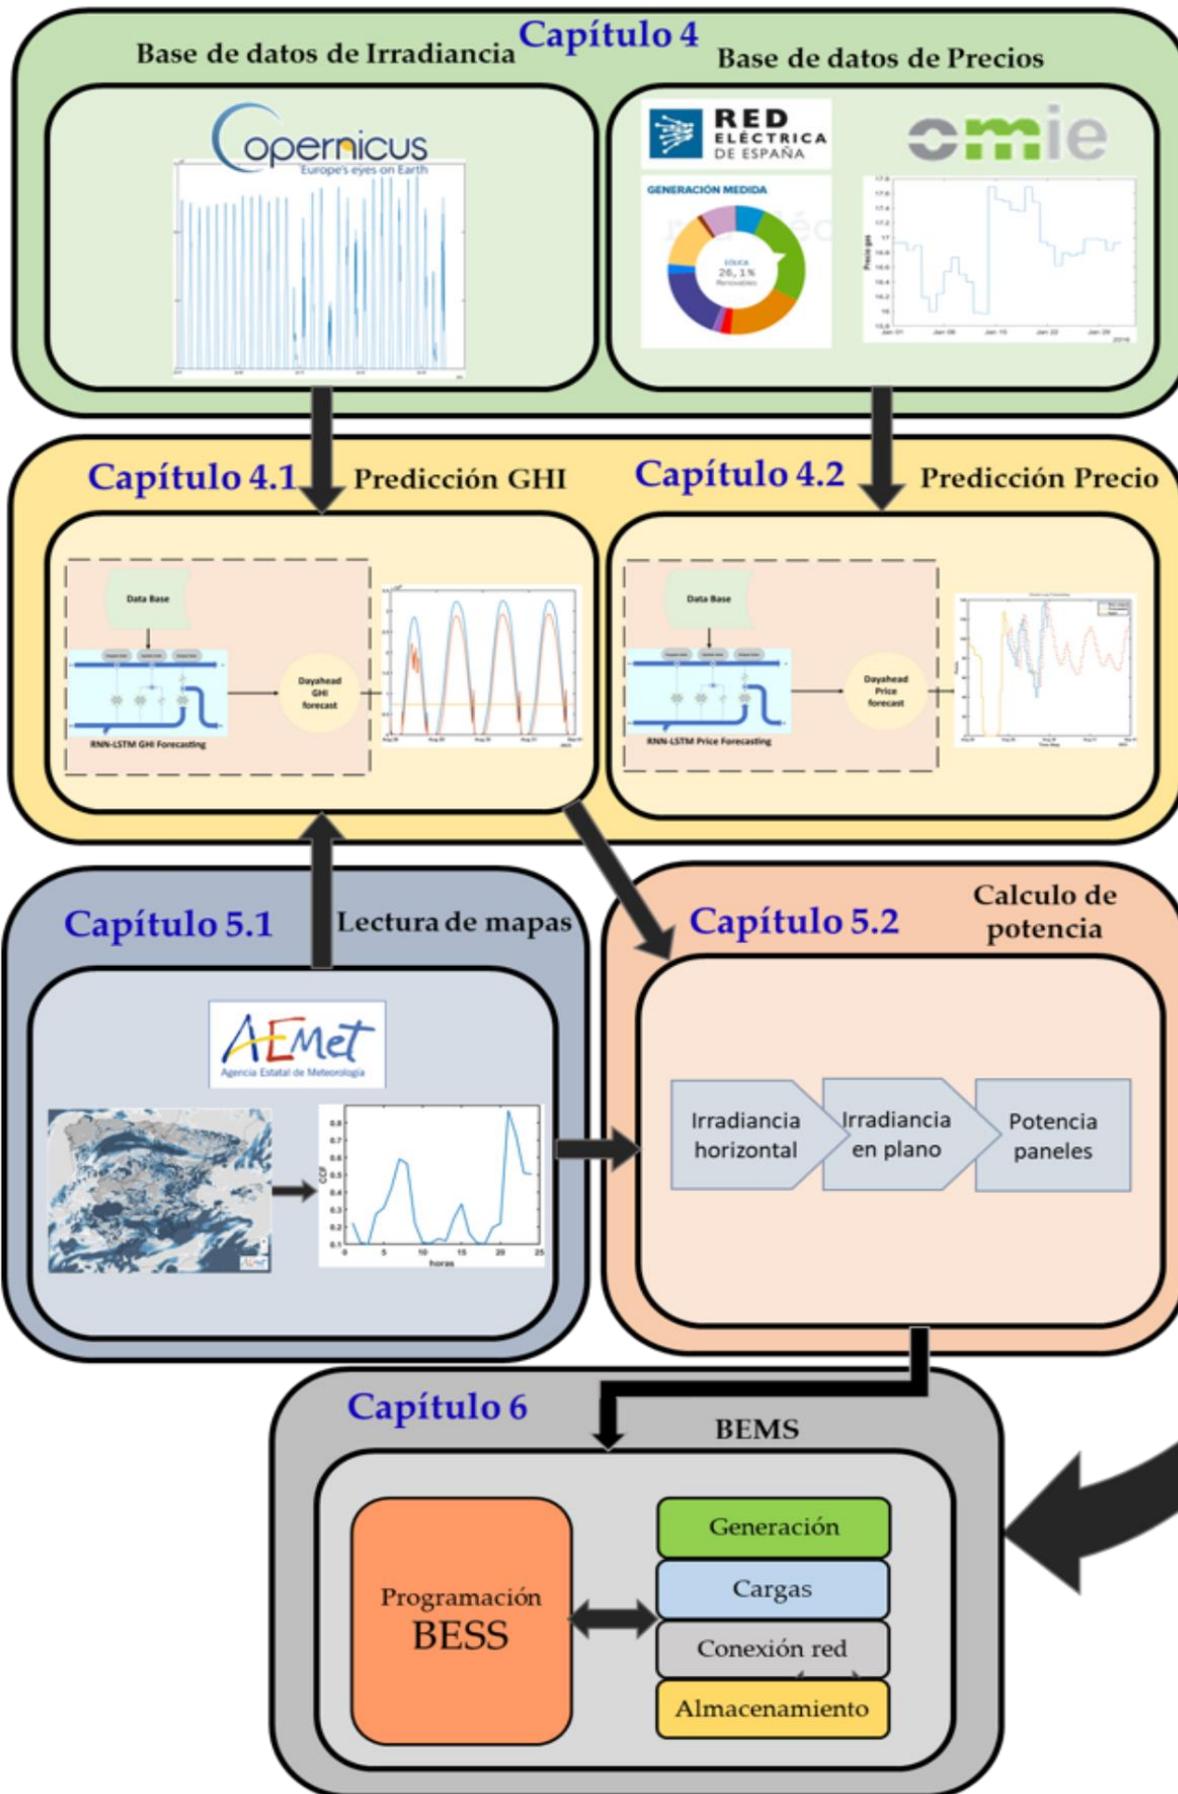
CAPÍTULO 5: TRANSFORMACIÓN DE IRRADIANCIA A POTENCIA

Se describirá el proceso de transformación de los datos de irradiancia solar en datos de potencia fotovoltaica. Se expondrán los modelos de conversión empleados y se discutirá su capacidad para representar de forma fidedigna el comportamiento de una instalación fotovoltaica real, así como las posibles mejoras y optimizaciones aplicadas.

CAPÍTULO 6: Estrategia de almacenamiento de energía en baterías. BEMS

En este último capítulo, se desarrollará una estrategia para la gestión del almacenamiento de energía generada en baterías, integrándola dentro de un sistema de gestión de energía en edificios (BEMS). Se explorará el diseño y la implementación de estrategias para una operación eficiente del sistema de almacenamiento, garantizando una adecuada satisfacción de la demanda energética y promoviendo el uso de energías renovables.

A continuación, en la Figura 1 se describe la estructura de trabajo desarrollada.



2 Estado del arte de predictores

En este capítulo se revisa el estado del arte de los temas relacionados con el trabajo. En concreto, las temáticas clave pueden ser diferenciadas en dos ramas: generación renovable en VPPs, que se analizan en el apartado 2.1, y técnicas de predicción fotovoltaica, que son tratadas en el apartado 2.2. Finalmente, el apartado 2.3 destaca las conclusiones más relevantes y especifica las contribuciones aportadas en este proyecto.

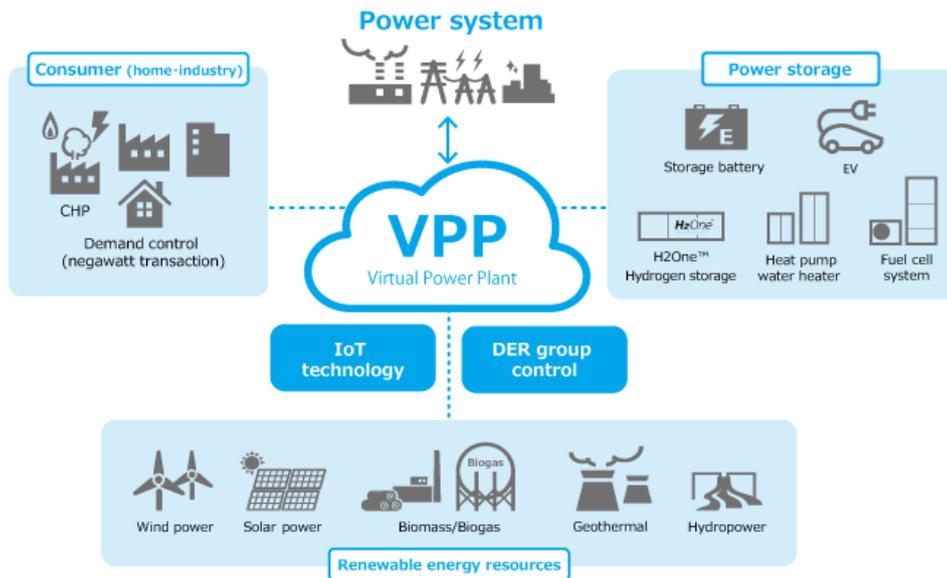
2.1 Generación de energía renovable mediante VPPs

La adopción creciente de energías renovables, especialmente la fotovoltaica, están en auge a nivel internacional [2]. Este crecimiento está impulsado por diversos factores como la disminución de costes de las células fotovoltaicas [13], el impulso político hacia fuentes renovables debido al cambio climático [4], y el avance en las técnicas de predicción de potencia fotovoltaica.

A pesar de los desafíos de predictibilidad y fluctuaciones significativas en la generación de energía fotovoltaica debido a factores meteorológicos estocásticos como: las nubes, la temperatura ambiental, la humedad relativa o la velocidad del viento y su dirección, se están explorando soluciones a gran escala, como los sistemas de almacenamiento energético, aunque suponen un alto coste [5-7] y la implementación de Plantas Virtuales de Energía (VPP) [8-10]. El concepto de VPP, surgió a principios de siglo, implica la agregación de varias unidades de Generación Distribuida (DG), cargas controlables y sistemas de almacenamiento en una entidad virtual coordinada por un Sistema de Gestión de Energía (EMS) para funcionar como una sola planta eléctrica, integrando una amplia gama de Recursos Energéticos Distribuidos (DER) y tecnologías de almacenamiento [11-15].

En este proyecto, se define la VPP como una entidad virtual que agrupa elementos de DG, almacenamiento y cargas, apoyándose en tecnologías de información y comunicación para operar como una central eléctrica unificada, optimizando costes y beneficios, y reduciendo la emisión de contaminantes. Estas VPP incluyen tres componentes esenciales: DER, que pueden variar en términos de fuente de energía primaria, capacidad, propiedad y naturaleza operativa [8,16]; Sistemas de Almacenamiento de Energía (ESS), que ayudan a equilibrar la oferta y la demanda, especialmente en fuentes estocásticas [17]; y el EMS, que supervisa, coordina y controla los flujos de energía para optimizar la operación de la VPP [18].

Este proyecto se centra particularmente en la predicción fotovoltaica, esencial para manejar recursos DER de pequeña capacidad y naturaleza estocástica, y busca profundizar en el conocimiento de estos recursos naturales para mitigar los problemas derivados de su variabilidad. A su vez, se aborda la optimización de una VPP, que puede centrarse tanto en la estructuración de sus componentes [19] como en su operación [20], siendo crucial para reducir los costes de producción y mejorar su funcionamiento.



2.2 Estudio de las técnicas de predicción fotovoltaica

La predicción de potencia fotovoltaica es un elemento crucial para el sector energético junto con el precio de la electricidad predicha, especialmente cuando se están gestionando grandes volúmenes de energía. Dicha predicción puede segmentarse y analizarse desde diversas perspectivas y utilizando distintas métricas temporales y espaciales, siempre en función del contexto específico, como puede ser un entorno de VPP.

Con respecto a las características que permiten clasificar los modelos de predicción fotovoltaica, podemos señalar las siguientes:

Según el parámetro a predecir:

- Estrategia directa [21]: predice la potencia fotovoltaica a partir de registros históricos y/o condiciones climáticas.
- Estrategia indirecta [22]: inicialmente estima la irradiancia para luego calcular la potencia fotovoltaica utilizando un modelo específico de la instalación.

Basándose en el horizonte temporal diferenciando en 4 plazos temporales [23,24]:

- Nowcasting: predicciones para un horizonte de minutos.
- Corto plazo: predicciones de horas.
- Medio plazo: predicciones de días a meses.
- Largo plazo: predicciones de años.

Considerando la resolución temporal:

Establecida según el horizonte temporal y el objetivo específico que se quiere alcanzar, y puede variar desde un minuto hasta una base semanal para identificar tendencias a largo plazo [25].

Atendiendo al modelo de predicción:

Cinco categorías principales de modelos [26], incluyendo desde modelos estadísticos lineales hasta híbridos que combinan diversas estrategias y técnicas.

De acuerdo con la incertidumbre asociada:

- Predicciones deterministas: ofrecen un único valor por instante temporal.
- Predicciones probabilísticas: proporcionan un rango de valores posibles para cada instante, dando una medida de la confianza de la predicción [27].

Para desarrollar este este, hemos adoptado una estrategia indirecta, estimando primero la irradiancia global horizontal (GHI) para luego calcular la potencia fotovoltaica. Utilizamos datos meteorológicos proporcionados por la Agencia Estatal de Meteorología (AEMET) [29], el CAMS [28] y datos sacados del ERA5 de Copernicus [30].

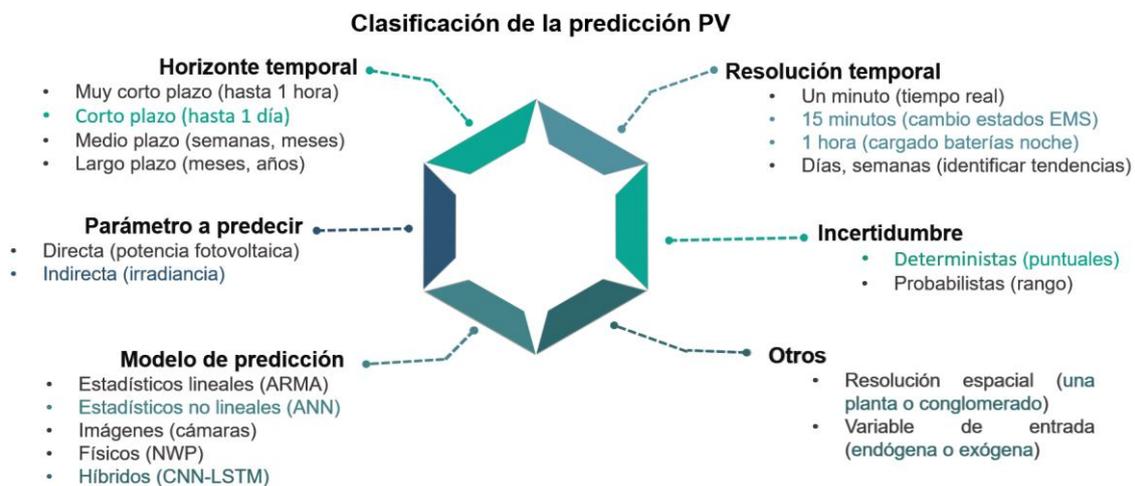


Figura 3: Clasificador de redes neuronales. Fuente [1].

2.2.1 Horas similares

Esta estrategia pronostica la GHI en una base diaria, empleando un análisis comparativo entre las predicciones meteorológicas actuales relacionadas con la GHI y los datos históricos correspondientes. Se emplea una selección meticulosa de medidas GHI para configurar la predicción final.

Numerosos estudios [43-48] han respaldado este modelo de predicción.

La predicción se puede categorizar de dos maneras: (1) enfocada directamente en la predicción de potencia fotovoltaica y (2) enfocada indirectamente en la irradiancia. La predicción directa es preferida y ampliamente aplicada debido a la fuerte correlación entre la potencia, la irradiancia y la temperatura, formulada como $P = f(I, T)$. Utilizando registros históricos de estas variables, se puede desarrollar un modelo bastante preciso [43-45, 49-50].

2.1.1.1 Predicción directa.

En la referencia [43], los investigadores utilizaron datos de pronóstico disponibles públicamente y registros históricos de temperatura para predecir la generación de energía fotovoltaica con un horizonte de predicción máximo de 1 día.

Posteriormente, se utilizan las estimaciones preliminares de producción de energía, así como datos de temperatura para el día del pronóstico y fechas similares seleccionadas, para refinar el pronóstico utilizando una red neuronal artificial (ANN).

El conjunto de datos históricos se desglosa por tipo de día (por ejemplo, soleado o nublado) para facilitar predicciones más precisas. Como resultado, el error absoluto medio relativo (rMAE) varía del 10% en días despejados al 19% en días nublados, superando así la precisión de otros modelos registrados en estudios anteriores.

La estrategia de utilizar días similares puede extenderse para evaluar la relación entre la variable que se desea predecir y las variables que se van a emplear como inputs en el modelo predictivo. Un caso de este tipo de evaluación se detalla en el estudio [44], donde se utiliza con el propósito de calcular la producción potencial de energía fotovoltaica mediante varias técnicas.

En este modelo específico, se cuantifica y se destaca cuál es la variable más significativa y cuál es la segunda más relevante, basándose en el análisis de las distancias euclídeas entre la variable objetivo y las posibles variables predictoras.

Aunque en el artículo sólo se escogen dos variables para llevar a cabo el análisis, la metodología podría ampliarse para incorporar un mayor número de variables, facilitando así la identificación de correlaciones a través de medios que difieren de los abordajes tradicionales, como sería el uso del coeficiente de correlación de Pearson (PCC). Este enfoque brinda una alternativa viable y potencialmente más precisa para discernir las relaciones intrínsecas entre diversas variables.

En la referencia [50], el modelo de horas similares emplea la estadística para realizar las predicciones, presupone que las variables tienen una distribución gaussiana y realiza la predicción basándose en la teoría de Bayes. Los resultados del estudio son relativamente buenos con un RMSE de 284kW.

2.1.1.2 Predicción indirecta

En la referencia [53], se implementa una estrategia para prever la GHI usando series temporales basadas en datos históricos recopilados a lo largo de un período de 12 años. Los datos reunidos se categorizan en tres conjuntos diferenciados: registros históricos de irradiación que abarcan aspectos globales, directos y difusos; variables climáticas como la temperatura, humedad, precipitación, turbulencia, cobertura nubosa y velocidad del viento; y un tercer grupo conformado por imágenes de la cobertura nubosa.

El procedimiento seguido por los investigadores involucra un preprocesamiento en el que se seleccionan los tres días que presentan mayor similitud con el período que se desea predecir. Los datos correspondientes a estos días se introducen posteriormente en una red neuronal profunda para crear una simulación de GHI, la cual se emplea dentro de un modelo de regresión para conseguir la predicción final. Este resultado final puede ser tanto determinista como probabilístico, dependiendo del alcance temporal establecido, el cual es configurable.

Para una proyección configurada con un horizonte de 24 horas, el modelo óptimo alcanzado muestra un error absoluto medio (MAE) por hora de 89,81 w/m², una métrica que resulta comparable a la obtenida a través del modelo basado en horas similares que fue desarrollado en la tesis en cuestión.

En la referencia [46], las predicciones se calculan mediante la diferencia del histórico de GHI y se le añade a la medida anterior la diferencia esperada. Este modelo presenta un rMAE del 14% hasta el 24%.

Por último, en la referencia [47] se calcula el PCC entre el GHI y las variables meteorológicas que se relacionan con la irradiancia, en este estudio se presenta una correlación relevante entre el viento y la GHI, al contrario que en la referencia usada en este trabajo [1] que en viento representa una correlación baja.

2.2.2 Redes neuronales

El panorama de los modelos de predicción está marcado por un debate continuo sobre cuál estrategia brinda la mayor precisión, especialmente en el contexto de los modelos estadísticos. Aunque hay estudios que sostienen que los modelos estadísticos tradicionales superan a los modelos de aprendizaje automático (Machine Learning, ML) [53], hay otros que defienden lo opuesto [54] [55]. Esta discrepancia, no obstante, debería analizarse teniendo en cuenta varios factores incluyendo el tamaño del conjunto de datos históricos [56], la variable que se quiere predecir [57], el horizonte temporal de las predicciones [58] y la carga computacional [59]. Pese a que los modelos estadísticos tradicionales han prevalecido en la última década, recientemente se está notando una tendencia creciente hacia el uso de estrategias de ML [27].

En este proyecto se utiliza una RNN-LSTM. La selección de esta herramienta dependió de diversos factores, incluyendo la complejidad del modelo y la carga computacional.

Es fundamental destacar que las redes neuronales se han establecido como las herramientas predominantes en la predicción fotovoltaica [60],[61]. Dentro de estas, las redes neuronales profundas están adquiriendo una mayor relevancia gracias a la disponibilidad de hardware más avanzado, demostrando ser extremadamente útiles en el manejo de series temporales y datos secuenciales, donde se requieren técnicas altamente potentes. En este escenario, las unidades recurrentes cerradas (Gated Reunited Units, GRUs), las RNN-LSTMs [62] y las CNN-LSTM se han vuelto las más utilizadas, superando a otras técnicas en precisión para predicciones de GHI a corto plazo [66].

Las RNN-LSTMs se destacan como las técnicas recurrentes más popularmente adoptadas para predecir la GHI, respaldadas por una amplia literatura [61],[59]. A lo largo de varias

investigaciones se ha demostrado que una mayor cantidad de datos históricos puede incrementar significativamente la precisión del modelo, razón por la cual en la tesis se optó por emplear un histórico de 5 años para predicciones intradía [63].

2.2.3 Conversión a potencia

La estrategia de convertir la irradiancia predicha a potencia fotovoltaica es una etapa crucial en cualquier modelo de predicción indirecta para instalaciones fotovoltaicas. Esto se da porque es esencial para estimar la potencia que generará una instalación fotovoltaica basada en las predicciones de irradiancia.

En este proyecto, se ha optado por utilizar el modelo Osterwald [64], que destaca por su simplicidad y su amplia utilización. Sin embargo, es importante señalar que este modelo puede presentar ciertas limitaciones, especialmente en condiciones de baja irradiancia, un escenario donde su precisión puede verse comprometida.

A pesar de estos desafíos, hay investigaciones que han intentado abordar esta problemática ofreciendo mejoras significativas en condiciones de baja irradiancia [65,66]. Estos trabajos pueden proveer técnicas valiosas que podrías considerar para mejorar el rendimiento del modelo en estas condiciones específicas.

Adicionalmente, se debe tener en cuenta que cuando se tiene un conocimiento preciso del punto de trabajo de la instalación, hay modelos disponibles que pueden ofrecer una mayor precisión en la predicción de la potencia generada [67,68].

Los modelos de conversión utilizan la irradiación medida en el plano del panel. Sin embargo, en algunas ocasiones, la medición se realiza en el plano horizontal, proporcionando datos de GHI. Estas mediciones se obtienen principalmente por medio de satélites, pero también pueden ser empleadas en instalaciones que cuentan con múltiples sistemas de rastreo del punto de máxima potencia o en paneles que tienen seguidores solares.

Para abordar este obstáculo, es necesario implementar un procedimiento que permita determinar la irradiancia directamente en el plano del panel. Utilizando fórmulas analíticas que descompongan la irradiancia en sus componentes fundamentales, para luego ajustar su ángulo de acuerdo con las especificaciones del panel solar, obteniendo una representación más precisa de la irradiancia que incide sobre el panel.

2.2 Conclusiones

En el capítulo actual, se llevó a cabo una revisión meticulosa del estado actual del arte con relación a los temas discutidos a lo largo del proyecto, enfocándose principalmente en la implementación de tecnologías renovables en el contexto de VPP y las estrategias destacadas para la predicción fotovoltaica. A través de este análisis, se han articulado y fundamentado las elecciones tomadas para el estudio del caso presentado, garantizando así un desarrollo optimizado y bien fundamentado del proyecto.

Es indispensable mencionar el papel crucial que desempeña el concepto novedoso de VPP, aunque no sea el núcleo central de la investigación, dada su interrelación íntima con la generación fotovoltaica, que es central en este contexto. Esto establece una premisa para la necesidad de predicciones fotovoltaicas eficaces que se pueden adaptar a diferentes resoluciones y horizontes temporales.

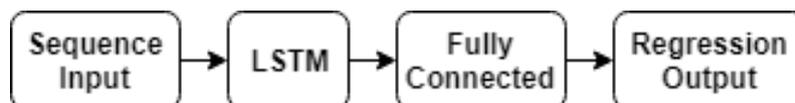
3 Análisis y Predicción con LSTM

3.1 Introducción a la red neuronal

Las redes neuronales artificiales o ANN están inspiradas en las redes neuronales biológicas que se encuentran en los cerebros biológicos. Están compuestas por unidades básicas llamadas celdas o mejor conocido como "neuronas" que colaboran para aprender patrones complejos y realizar clasificaciones, regresiones, etc. Estas redes se componen de múltiples capas, incluida una capa de entrada, una o más capas ocultas y una capa de salida, lo que crea una arquitectura profunda que puede aprender de grandes cantidades de datos a través de un proceso de entrenamiento iterativo.

3.2 Las redes LSTM

Las redes neuronales LSTM (memoria larga a corto plazo) representan una categoría especializada de redes neuronales recurrentes (RNN). Cuentan con la incorporación de un componente adicional llamado Cell State, que está diseñado para facilitar el procesamiento de series temporales y datos secuenciales, superando las barreras tradicionales asociadas con el aprendizaje de dependencias a largo plazo. A continuación, estaré encantado de describir en detalle su estructura y funcionamiento.



3.2.1 Arquitectura

La arquitectura LSTM se compone principalmente de unidades llamadas "celdas LSTM", que están diseñadas para recordar información durante largos períodos de tiempo. Cada celda LSTM está compuesta por varias "puertas" que modulan el flujo de información a ser recordada u olvidada en cada paso de tiempo:

Forget Gate: Decide qué información debería ser eliminada del estado de la celda.

Update Gate: Decide qué nueva información se va a almacenar en el estado de la celda.

Output Gate: Decide qué parte del estado de la celda actual vamos a enviar a la salida esta la entrada a la siguiente celda LSTM

Cell State: Representa la "memoria" de la red, que se actualiza combinando la información de las puertas de olvido y entrada.

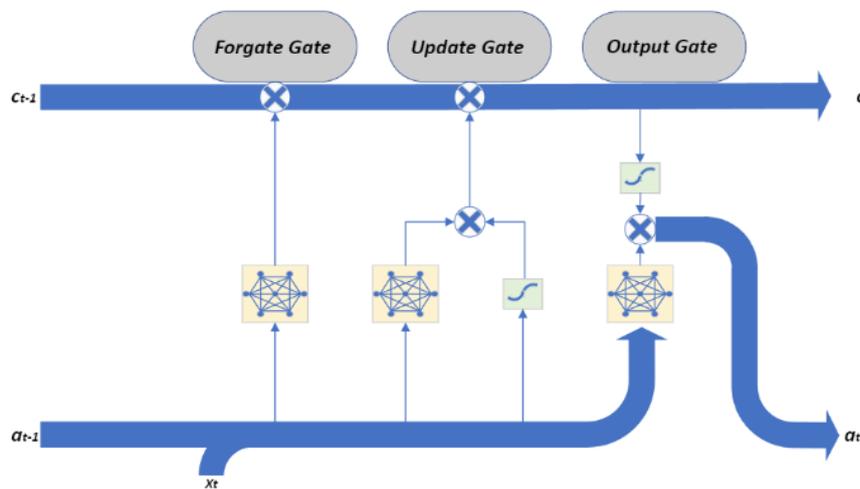


Figura 5. Modelo celda LSTM

3.2.2 Entrenamiento

El entrenamiento de una red neuronal LSTM se fundamenta en una serie de procesos secuenciales meticulosamente diseñados para facilitar el aprendizaje eficiente de series temporales complejas. Este proceso inicia con la definición de los sesgos y pesos de las variables a predecir; estos valores se establecen inicialmente a través de una distribución de valores pequeños y aleatorios.

```
numFeatures =6;
numResponses = 2;
numHiddenUnits = 200;

layers = [ ...
    sequenceInputLayer(numFeatures)
    lstmLayer(numHiddenUnits, 'OutputMode', 'sequence')
    fullyConnectedLayer(numResponses)
    regressionLayer];
```

Código 1: Capas red LSTM

Posteriormente, se procede a la fase de "feedforward", en la que los datos se introducen en la red y se procesan avanzando secuencialmente a través de las capas. A lo largo de esta fase, cada celda de la LSTM lleva a cabo una serie de operaciones reguladas por sus respectivas puertas y su estado actual, generando una salida y un nuevo estado oculto que, a su vez, alimenta la siguiente celda en la secuencia.

A continuación, se lleva a cabo el cálculo del error o "pérdida" generado a partir de las predicciones de la red, empleando para ello una función de pérdida adecuada que permite cuantificar la discrepancia entre las predicciones y los valores reales proporcionados durante la fase de entrenamiento.

Open Loop Forecasting

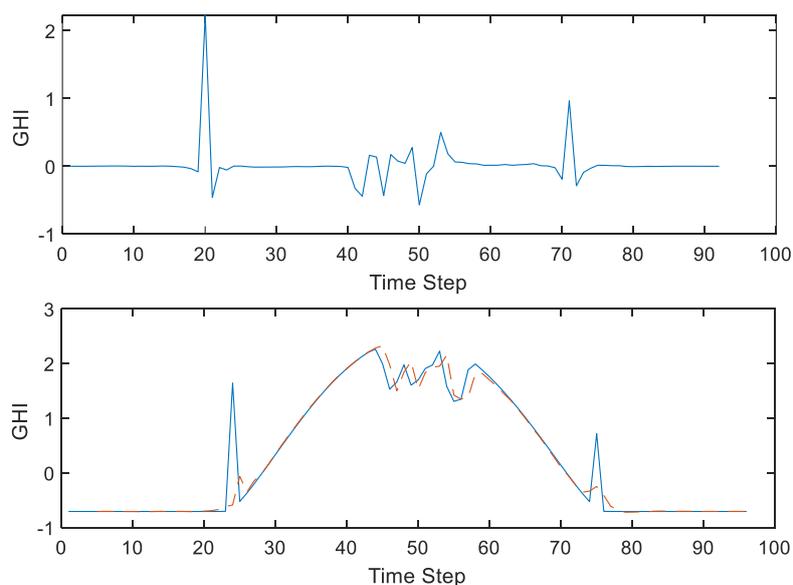


Figura 6: Error entre GHI real y predicción

El paso siguiente involucra la implementación del algoritmo de "Backpropagation Through Time" (BPTT), una variante de la retropropagación convencional utilizada en el entrenamiento de redes neuronales profundas. En esta etapa, se calculan los gradientes de la función de pérdida y se propagan retrospectivamente desde el final hasta el principio de la secuencia de datos, facilitando así la identificación de la influencia específica de cada parámetro en el error acumulado.

Con el apoyo de algoritmos de optimización avanzados, tales como Adam o SGD, se procede a la actualización de los parámetros de la red con el objetivo central de minimizar la función de pérdida. Este procedimiento se repite a lo largo de un número predeterminado de ciclos, conocidos como "épocas", buscando alcanzar una convergencia hacia una solución satisfactoria, donde el error alcanza un valor mínimo aceptable.

```
options = trainingOptions('adam', ...
    'ExecutionEnvironment','gpu', ...
    'MaxEpochs',200, ...
    'SequencePaddingDirection','right', ...
    'Shuffle','every-epoch', ...
    'Plots','training-progress', ...
    'GradientThreshold',1, ...
    'MiniBatchSize',2^8, ...
    'InitialLearnRate',0.01, ...
    'LearnRateSchedule','piecewise', ...
    'LearnRateDropPeriod',20, ...
    'LearnRateDropFactor',0.5, ...
    'Verbose',0, ...
    'L2Regularization',0.0005);
```

Código 2: Opciones optimización LSTM en Matlab

A través de la iteración continua de estos pasos durante un número delimitado de veces o epochs, el modelo LSTM está diseñado para afinar progresivamente su capacidad predictiva, representando una herramienta robusta y altamente eficaz en el manejo de datos secuenciales y series temporales complejas.

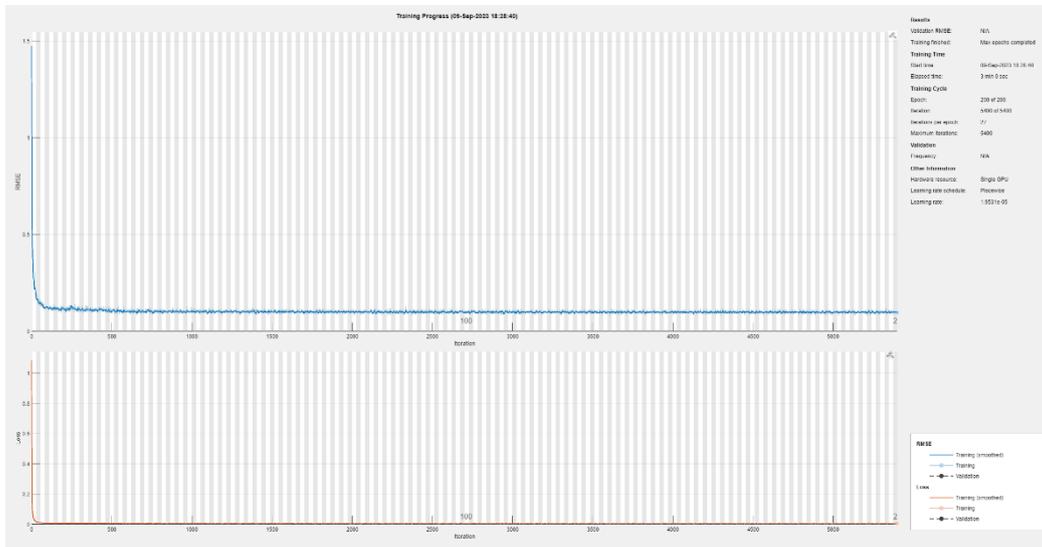
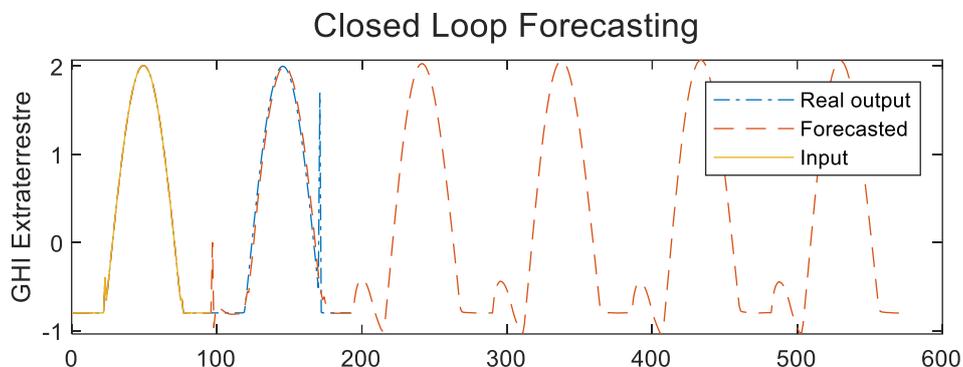


Figura 7. Entrenamiento real LSTM

3.2.3 Aplicaciones

Las redes neuronales Long Short-Term Memory (LSTM) se distinguen por su especial eficacia en el manejo de tareas que requieren el análisis de datos secuenciales o temporales. Entre las aplicaciones más destacadas de estas redes se encuentran la traducción automática, el reconocimiento de voz y la generación automática de texto, así como la interpretación y análisis de series temporales.

Esta habilidad para analizar series temporales las convierte en una gran herramienta en la predicción meteorológica. Su aplicación en este campo permite no solo anticipar con precisión condiciones climáticas futuras, sino también entender patrones y tendencias a largo plazo, gracias a su capacidad para aprender de las dependencias temporales de los datos con los que son alimentadas.



3.2.4 Ventajas

Reconocimiento de Dependencias a Largo Plazo: Las redes LSTM son realmente buenas en la identificación y en el aprendizaje de dependencias temporales de largo alcance en los datos. Esto se traduce en una mayor precisión en tareas como la predicción de series temporales, donde los eventos futuros pueden estar fuertemente caracterizado por una periodicidad en el tiempo.

Manejo Versátil de Secuencias de Diversa Longitud: Otro de los puntos fuertes de las LSTM es su flexibilidad para trabajar con secuencias de datos de longitud variable. Esta característica es especialmente valiosa cuando la información de la que se dispone puede variar en el tiempo posibilitando el uso de conjuntos de datos muy heterogéneos.

3.2.5 Desventajas

Alta Complejidad Computacional: Una de las limitaciones significativas de las redes LSTM es su mayor complejidad computacional comparada con otros tipos de redes neuronales. Esto implica un incremento en los recursos computacionales necesarios, así como tiempos más prolongados para el entrenamiento y la predicción, lo que puede representar un desafío en entornos con limitaciones de hardware o tiempo.

Necesidad de Amplios Conjuntos de Datos para el Entrenamiento: Las redes LSTM, para alcanzar un nivel óptimo de eficiencia y precisión, a menudo requieren grandes volúmenes de datos durante la fase de entrenamiento. La necesidad de conjuntos de datos extensos puede resultar en dificultades adicionales, tanto desde la perspectiva de la adquisición de datos como desde el punto de vista computacional, lo que se traduce en mayores demandas en términos de almacenamiento y procesamiento.

4 Implementación y Configuración de la Red

Después de brindar una descripción detallada de las capacidades intrínsecas de las redes neuronales LSTM y resaltar sus principales ventajas, se procede a presentar en detalle el proceso específico de implementación de la tecnología LSTM en la predicción de la irradiancia solar. Esta sección se centrará en los métodos utilizados para entrenar redes neuronales y describirá cada paso, desde la recopilación y el procesamiento de datos hasta el ajuste de la arquitectura de la red para obtener resultados precisos y confiables.

A continuación de este apartado, se esboza la metodología utilizada para pronosticar las fluctuaciones del precio de la electricidad a nivel nacional en España. Este análisis proporcionará una revisión detallada de las estrategias de modelado adoptadas, los desafíos encontrados durante la implementación y cómo las capacidades inherentes de las redes LSTM facilitan soluciones efectivas y eficientes.

El análisis tendrá en cuenta la naturaleza fluctuante y temporal de las variables relevantes, así como la capacidad superior de las redes LSTM para procesar datos de series de tiempo con dependencias a largo plazo, lo que concuerda con las características de los conjuntos de datos de irradiancia y energía.

4.1 Redes LSTM para la predicción de irradiancia

4.1.1 Recopilación y elección de datos

En el contexto del objetivo central de este proyecto, se realizó un análisis para identificar los factores más relevantes que influyen en la irradiancia derivada de la irradiación global extraterrestre. Este análisis destacó varias variables cruciales para considerar, incluyendo:

- Temperatura ambiente
- Humedad relativa
- Presión atmosférica
- Velocidad y dirección del viento
- Precipitaciones (lluvia y nieve)
- Profundidad de la nieve

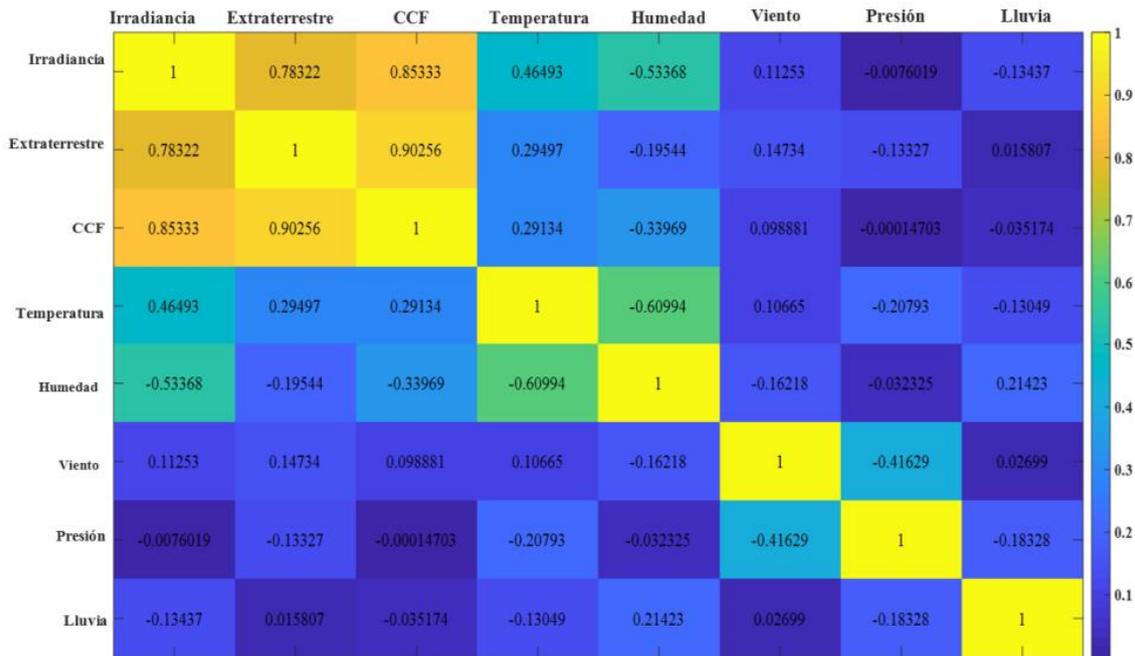


Figura 9: “Matriz de PCC entre todas las variables consideradas en el estudio, para la estación meteorológica de Juan Carlos I.” Fuente [1]

La adquisición de datos necesarios para alimentar del modelo de red LSTM derivó en una serie de desafíos dado que este proyecto se inscribe dentro de la iniciativa más amplia del grupo GEISER, desarrollar un gemelo digital, un escenario que obligaba a que la recolección de datos se realizara sin incurrir en costos.

Lamentablemente, esta restricción presupuestaria condujo a una limitación considerable: la incapacidad de desarrollar una base de datos lo suficientemente amplia para garantizar predicciones con un alto grado de confiabilidad. Esto resalta una de las desventajas notables de las redes LSTM, que es su dependencia crítica de grandes conjuntos de datos para el entrenamiento efectivo y la optimización del modelo.

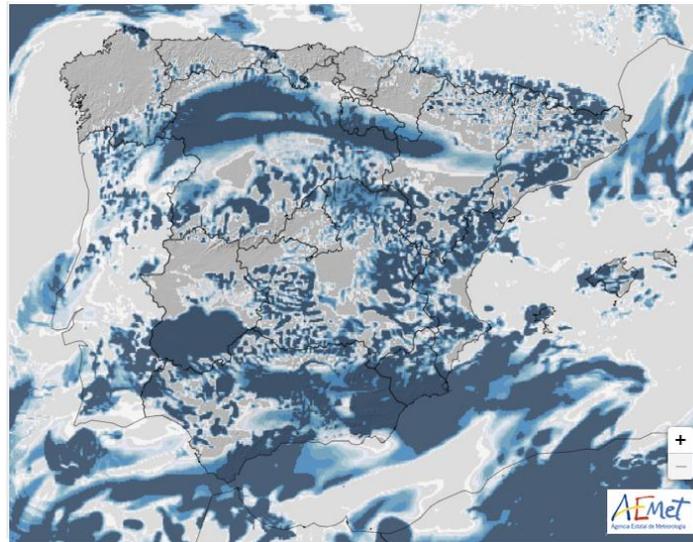
Debido a esta restricción, se buscó una solución alternativa basada en el “Cloud Cover Factor” (CCF) [1] y el “Total Cloud Cover” (TCC).

4.1.1.1 Cloud Cover Factor

La GHI (Irradiación Global Horizontal) mantiene una correlación considerable con los niveles de nubosidad, facilitando así la determinación de las pérdidas de irradiación ocasionadas en la superficie terrestre por la opacidad de las nubes que eclipsan el sol. En este contexto, se decidió utilizar la variable CCF [1], que tiene por objetivo señalar el grado de sombreado que las nubes imponen sobre la instalación. Es relevante destacar que el CCF es una variable adimensional que, dentro del mapa aplicado, denota la proporción de sombreado terrestre proyectado por cada píxel de nube para cada pronóstico de nubosidad NWP (Predicción Numérica del Tiempo).

Esta métrica presenta una correlación inversa con la GHI; registra un valor de cero cuando las condiciones atmosféricas permiten una exposición solar directa, y alcanza el máximo (uno) en circunstancias de cobertura nubosa total.

Es imperativo subrayar que los mapas de nubosidad, accesibles a través del sitio web de AEMET, se presentan en un rango porcentual que fluctúa desde un 0% (que indica un cielo despejado) hasta un 100% (representando un cielo totalmente cubierto).



4.1.1.2 Total Cloud Cover

La variable TCC es un indicador de la cobertura de nubes, derivado de los datos proporcionados por ERA5 [30]. Es importante destacar que el TCC engloba la cobertura nubosa a diferentes altitudes: baja, media y alta.

Mientras que los mapas de nubosidad de la AEMET no permiten distinguir con precisión entre estos diferentes niveles de nubosidad, el TCC de ERA5 se presenta como una herramienta que ofrece datos que pueden ser extraídos para cualquier ubicación específica del globo, desde el año 1940.

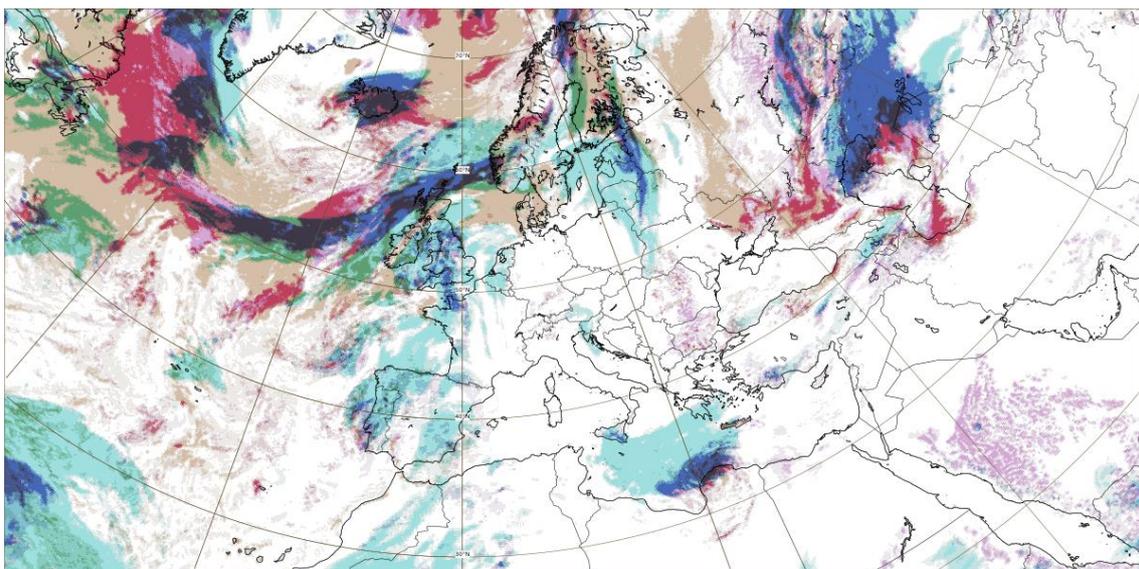


Figura 11: Mapa de cobertura de nubes del 10 de septiembre de 2023. Imagen descargada de ECMWF. Fuente [69]

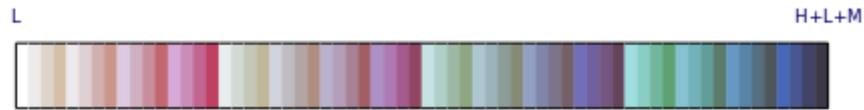
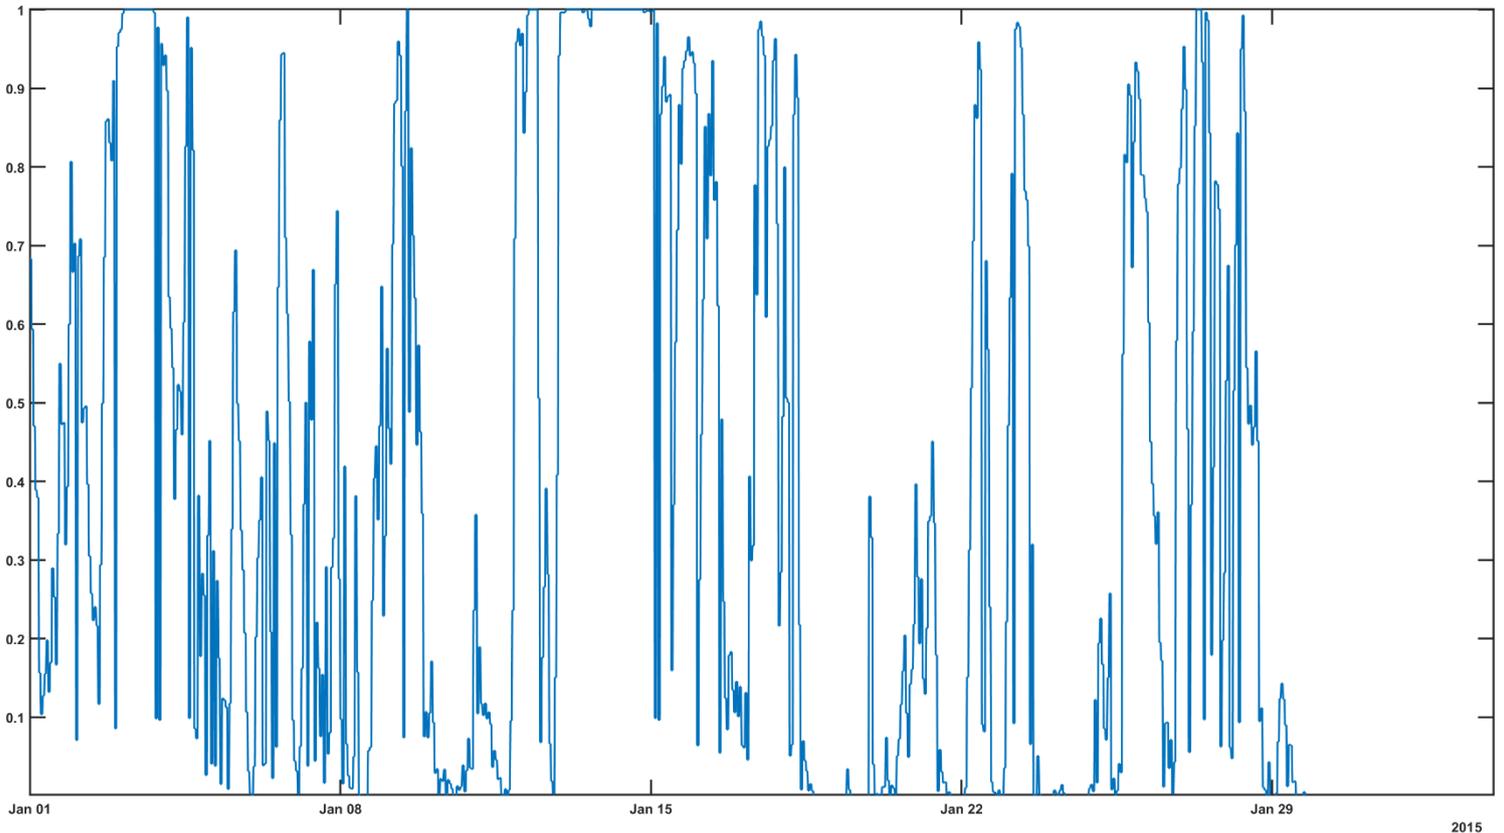


Figura 12: Leyenda de nubes altas, bajas y medias de ECMWF. Fuente [69]



4.1.1.3 Correlación entre TCC y CCF

La elección de incorporar tanto las variables TCC como CCF en nuestro modelo responde a la necesidad de equilibrar la riqueza histórica de los datos con la precisión en la predicción a corto plazo. Es preciso señalar que, aunque el TCC proporcionado por ERA5 brinda datos hasta la fecha de ejecución de la predicción, su ventaja radica en la disponibilidad de datos históricos extensos.

Por otro lado, la variable CCF surge como una respuesta complementaria, derivada del análisis de los mapas de nubes facilitados por la AEMET. La particularidad de esta variable es su capacidad para ofrecer estimaciones más inmediatas, abarcando un horizonte de predicción que se extiende desde el momento de la emisión de la predicción hasta dos días posteriores. Específicamente, se generan predicciones para las 7:00 a.m. del día en curso y los dos días consecutivos.

Así, la integración de estas dos variables no solo favorece un entrenamiento más efectivo de la red LSTM aprovechando una base de datos histórica rica, sino que también facilita predicciones más precisas en el corto plazo, garantizando una aproximación robusta a la predicción de irradiación solar.

En el proceso de implementar ambas variables CCF y TCC en el modelo, es imperativo asegurar que mantengan una correlación consistente con la GHI. Es decir que la discrepancia observada entre la GHI extraterrestre y la GHI efectivamente recibida por las placas solares, sostenga una correlación sólida tanto con el CCF como con el TCC.

Establecer esta relación correlativa no es simplemente una cuestión de coherencia metodológica; se trata de un requisito fundamental para garantizar que el modelo pueda generar predicciones precisas.

En el marco de este estudio, se ha establecido un procedimiento sistemático que se lleva a cabo en intervalos de 8 días. Durante cada uno de estos periodos, se procede a realizar una inspección detallada de varias métricas clave: la GHI, la GHI extraterrestre, junto con los valores de TCC y CCF.

Esencialmente, este análisis se centra en discernir las correlaciones existentes entre dos pares de variables: por un lado, la correlación entre CCF y el cociente GHI/GHI extraterrestre, y por otro, la correlación entre TCC y el mismo cociente. Para llevar a cabo esta evaluación de manera rigurosa, se calculan y se analizan las matrices de correlación, identificadas como R y P, que proporcionan una visión más profunda de las relaciones entre estas variables.

4.1.1.4 Cálculos del 2 de junio al 9 de junio de 2022

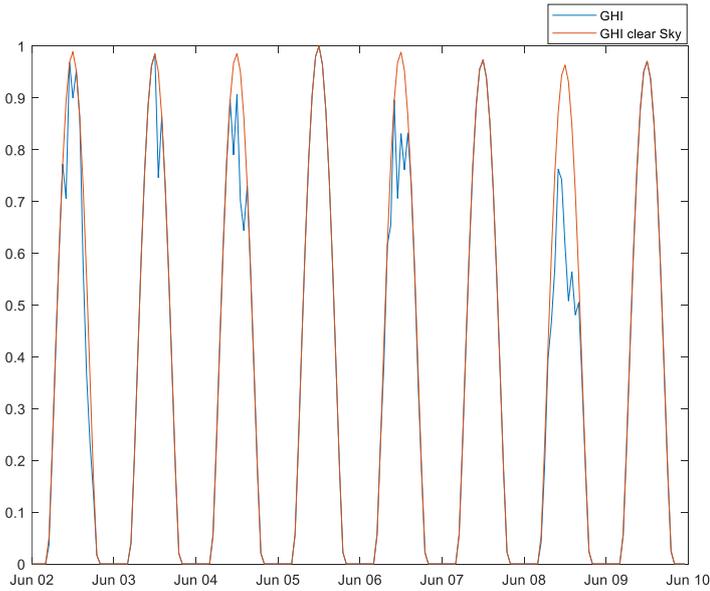


Figura 16: GHI y GHI clear Sky 2/6/2022-9/6/2022

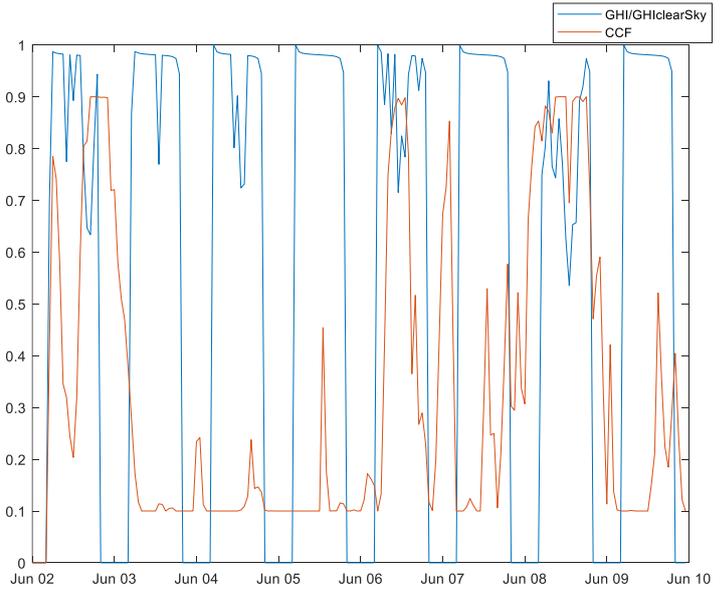


Figura 15: GHI/GHIclearSky vs CCF 2/6/2022-9/6/2022

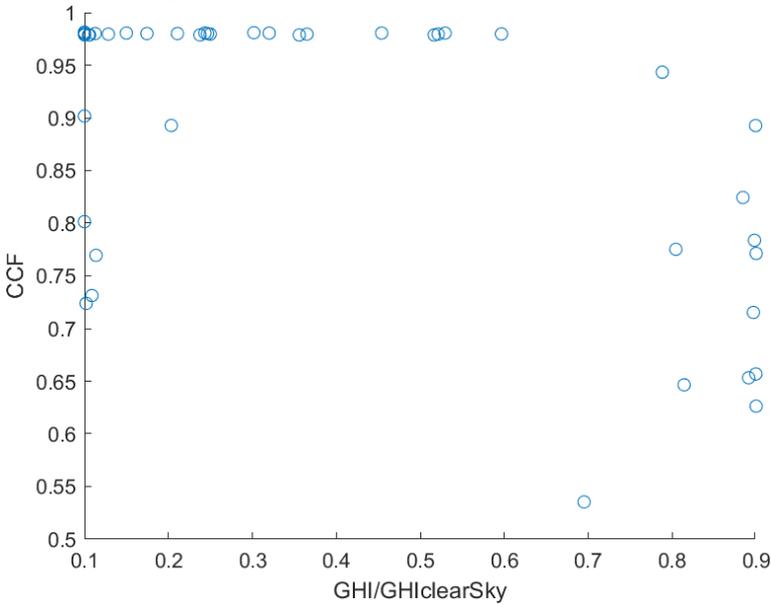


Figura 17: Correlación CCF y GHI/GHIclearSky 2/6/2022-9/6/2022

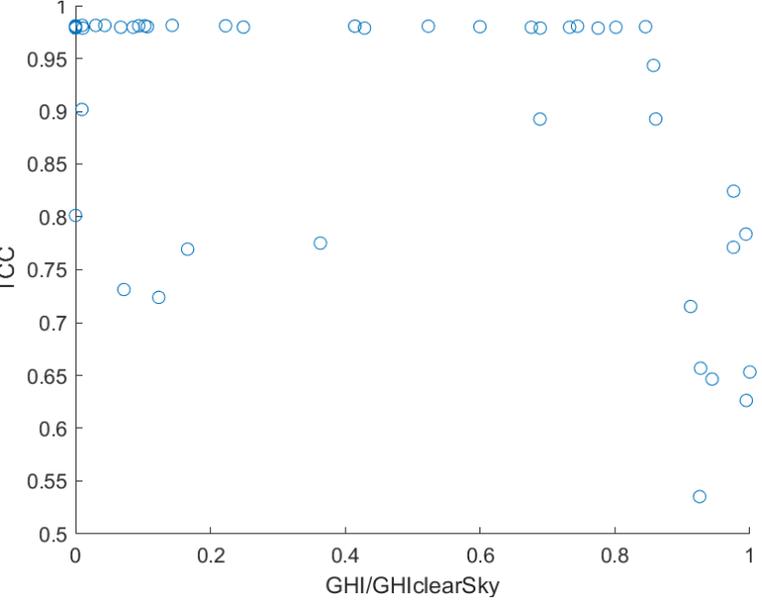


Figura 14: Correlación TCC y GHI/GHIclearSky 2/6/2022-9/6/2022

Correlación R	CCF	GHI/GHIclearSky	TCC
CCF	1.000	-0.6033	0.722
GHI/GHIclearSky	-0.6033	1.000	-0.4847
TCC	0.722	-0.4847	1.000

Tabla 1: Correlación R 2/6/2022-9/6/2022

Correlación P	CCF	GHI/GHIclearSky	TCC
CCF	1.000	0.000	0.000
GHI/GHIclearSky	0.000	1.000	0.005
TCC	0.000	0.005	1.000

Tabla 2: Correlación P 2/6/2022-9/6/2022

4.1.1.5 Cálculos del 14 de mayo al 25 de mayo de 2022

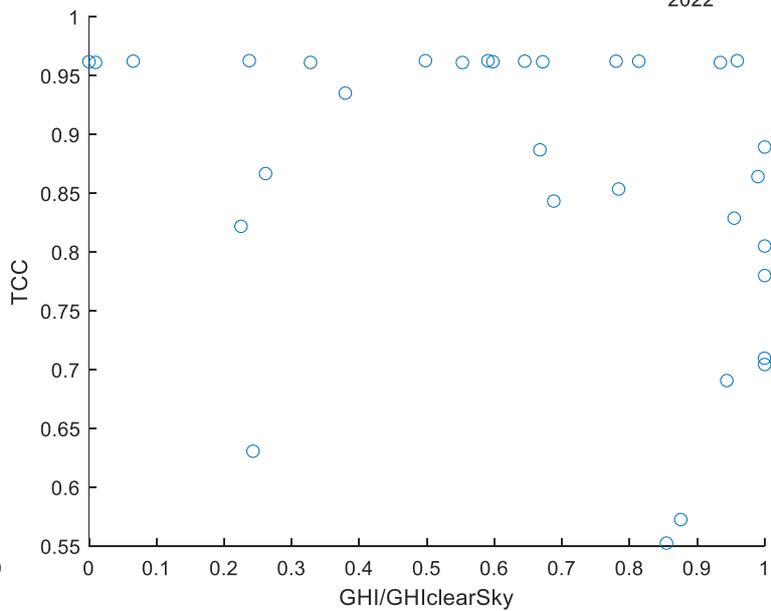
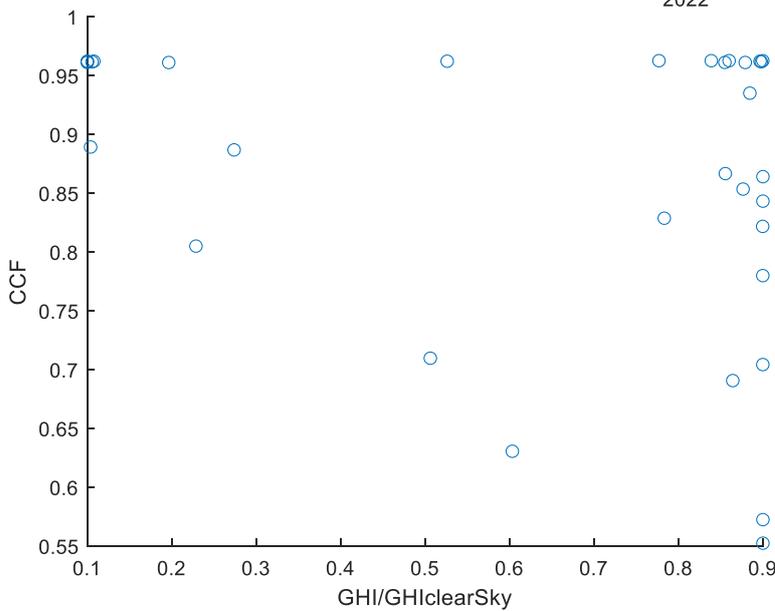
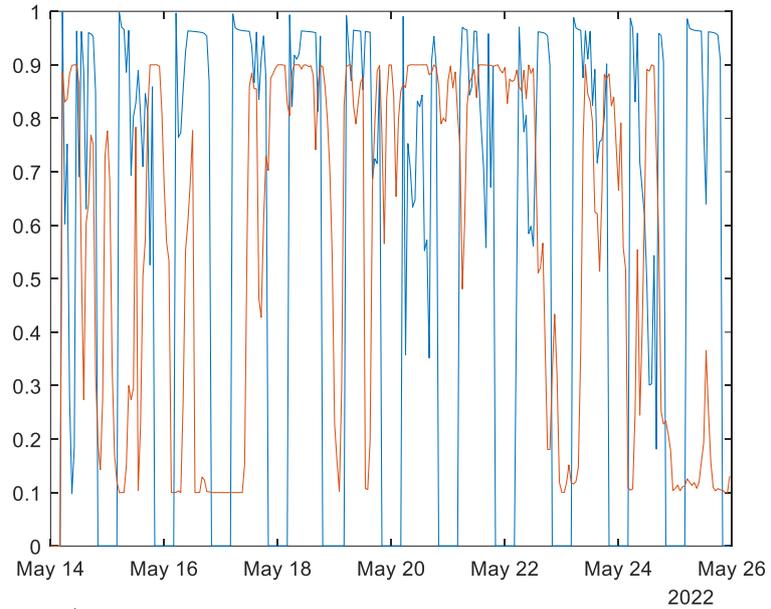
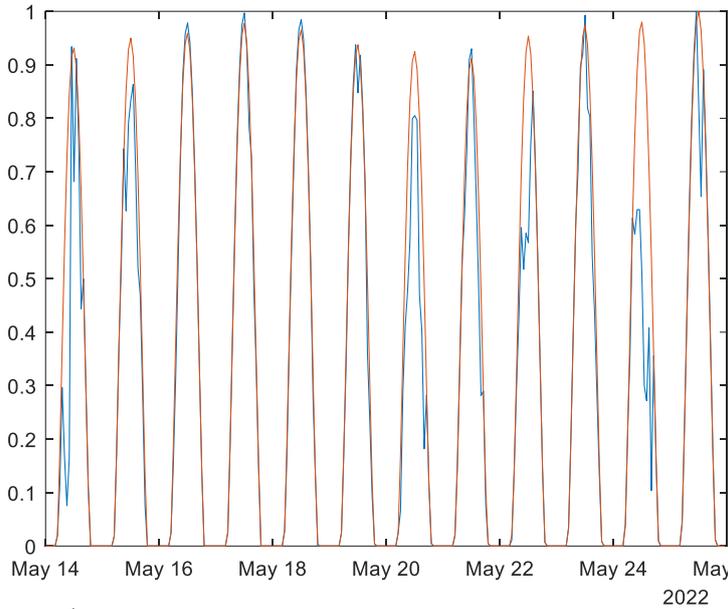


Figura 18: Correlación CCF y GHI/GHIclearSky 14/5/2022-25/5/2022

Figura 19: Correlación TCC y GHI/GHIclearSky 14/5/2022-25/5/2022

Correlación R	CCF	GHI/GHIclearSky	TCC
CCF	1.000	-0.2947	0.2295
GHI/GHIclearSky	-0.2947	1.000	-0.3604
TCC	0.2295	-0.3604	1.000

Correlación P	CCF	GHI/GHIclearSky	TCC
CCF	1.000	0.1016	0.2064
GHI/GHIclearSky	0.1016	1.000	0.0428
TCC	0.2064	0.0428	1.000

Tabla 3: Correlación R y P 14/5/2022-25/5/2022

4.1.1.6 Cálculos del 20 de septiembre al 28 de septiembre de 2022

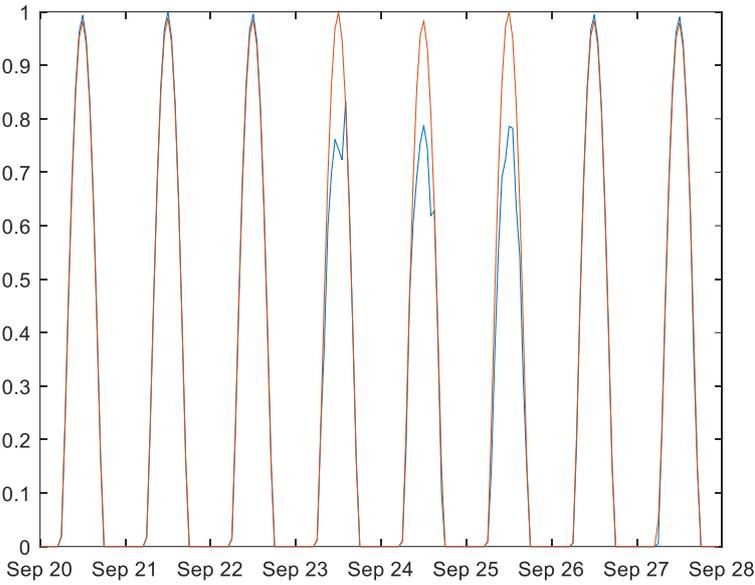


Figura 25: GHI y GHI clear Sky 20/9/2022-27/9/2022

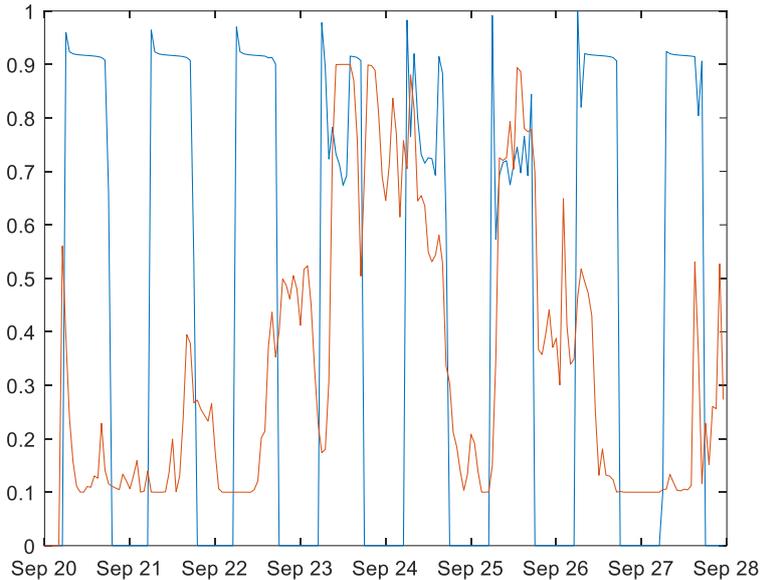


Figura 24: GHI/GHIclearSky vs CCF 20/9/2022-27/9/2022

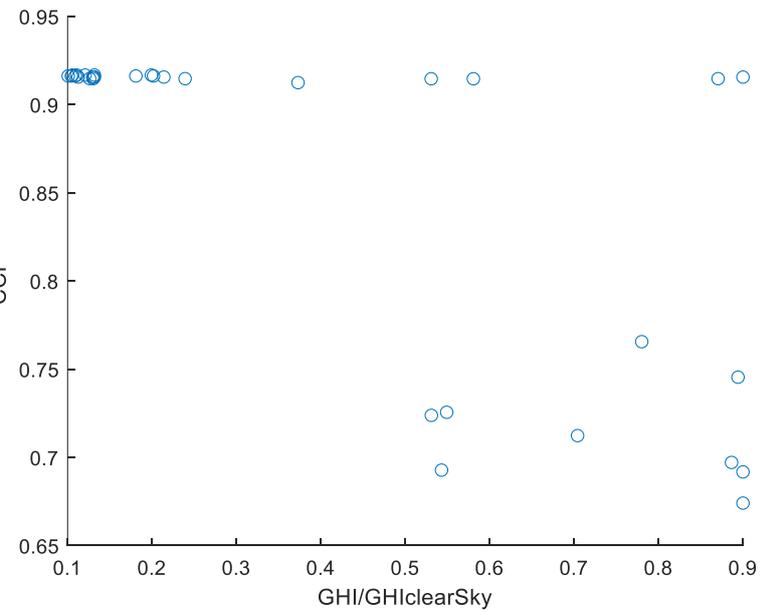
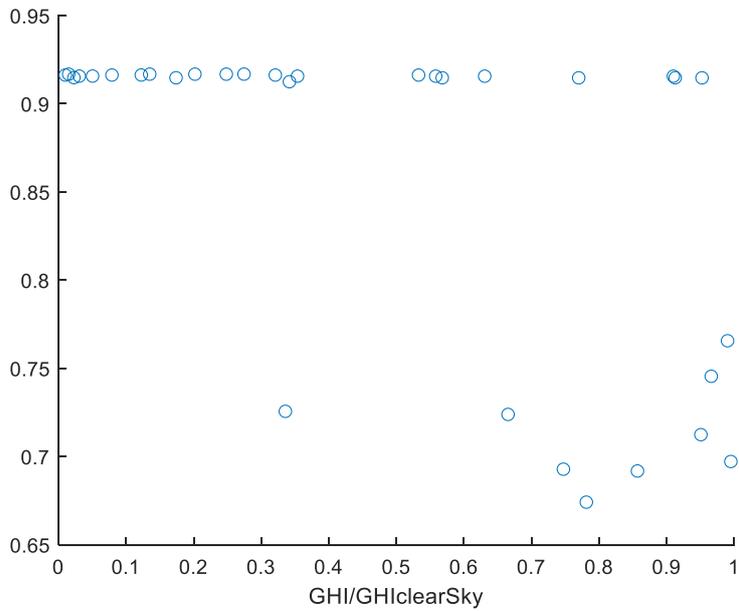


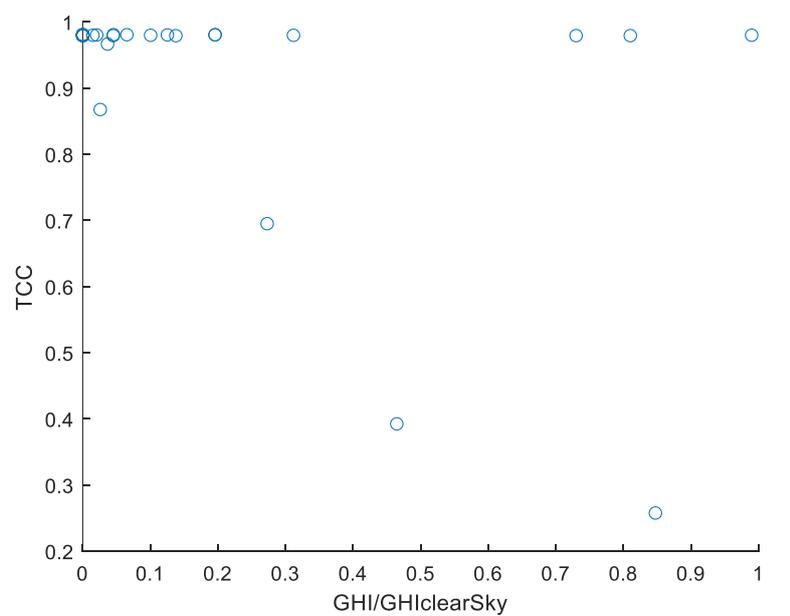
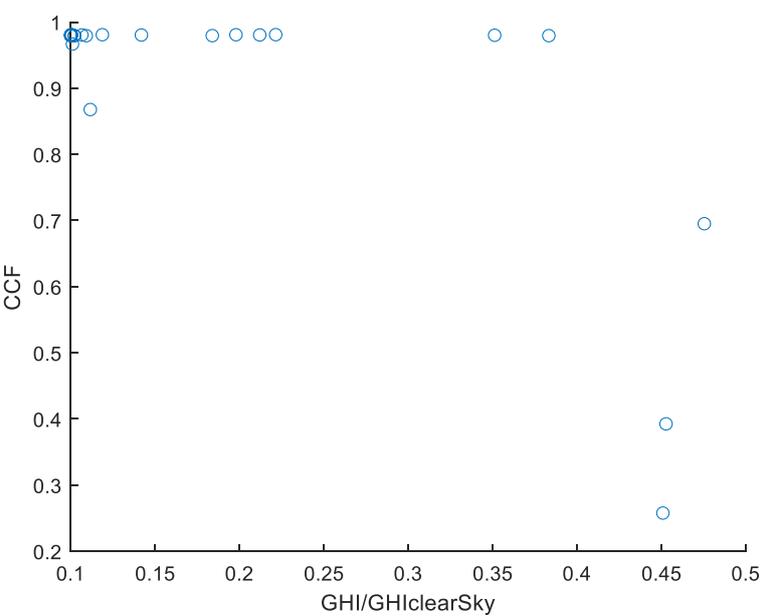
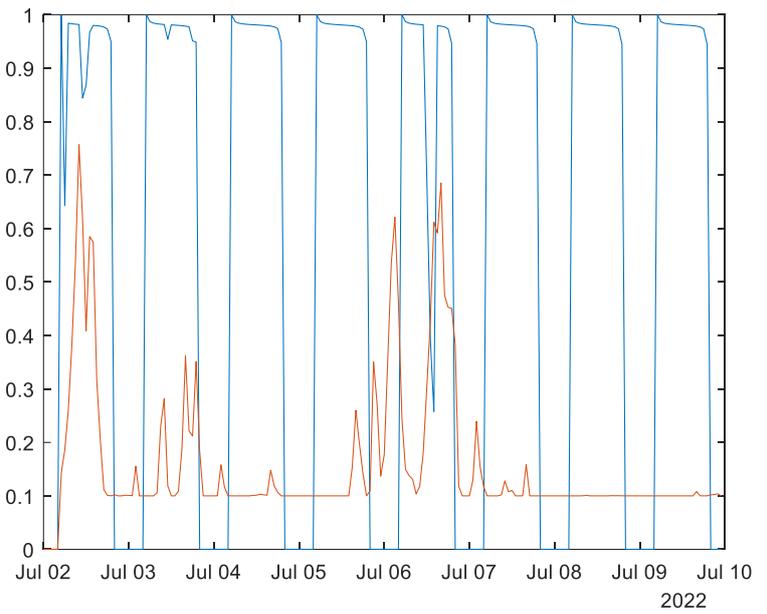
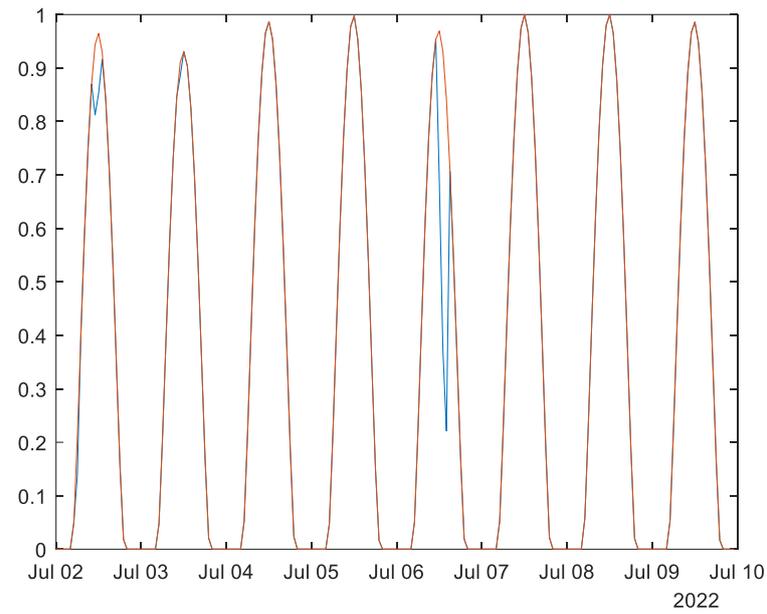
Figura 22: correlación CCF y GHI/GHIclearSky 20/9/2022-27/9/2022

Correlación R	CCF	GHI/GHIclearSky	TCC
CCF	1.000	-0.7166	0.8479
GHI/GHIclearSky	-0.7166	1.000	-0.5783
TCC	0.8479	-0.5783	1.000

Correlación P	CCF	GHI/GHIclearSky	TCC
CCF	1.000	0.000	0.000
GHI/GHIclearSky	0.000	1.000	0.005
TCC	0.000	0.005	1.000

Tabla 4: Correlación R y P 20/9/2022-27/9/2022

4.1.1.7 Cálculos del 2 de julio al 10 de julio de 2022



Correlación R	CCF	GHI/GHIclearSky	TCC
CCF	1.000	-0.7382	0.7362
GHI/GHIclearSky	-0.7382	1.000	-0.4596
TCC	0.7362	-0.4596	1.000

Correlación P	CCF	GHI/GHIclearSky	TCC
CCF	1.000	0.000	0.000
GHI/GHIclearSky	0.000	1.000	0.0081
TCC	0.000	0.0081	1.000

Tabla 5: Correlación R y P 2/7/2022-9/7/2022

4.1.1.8 GHI y GHI extraterrestre

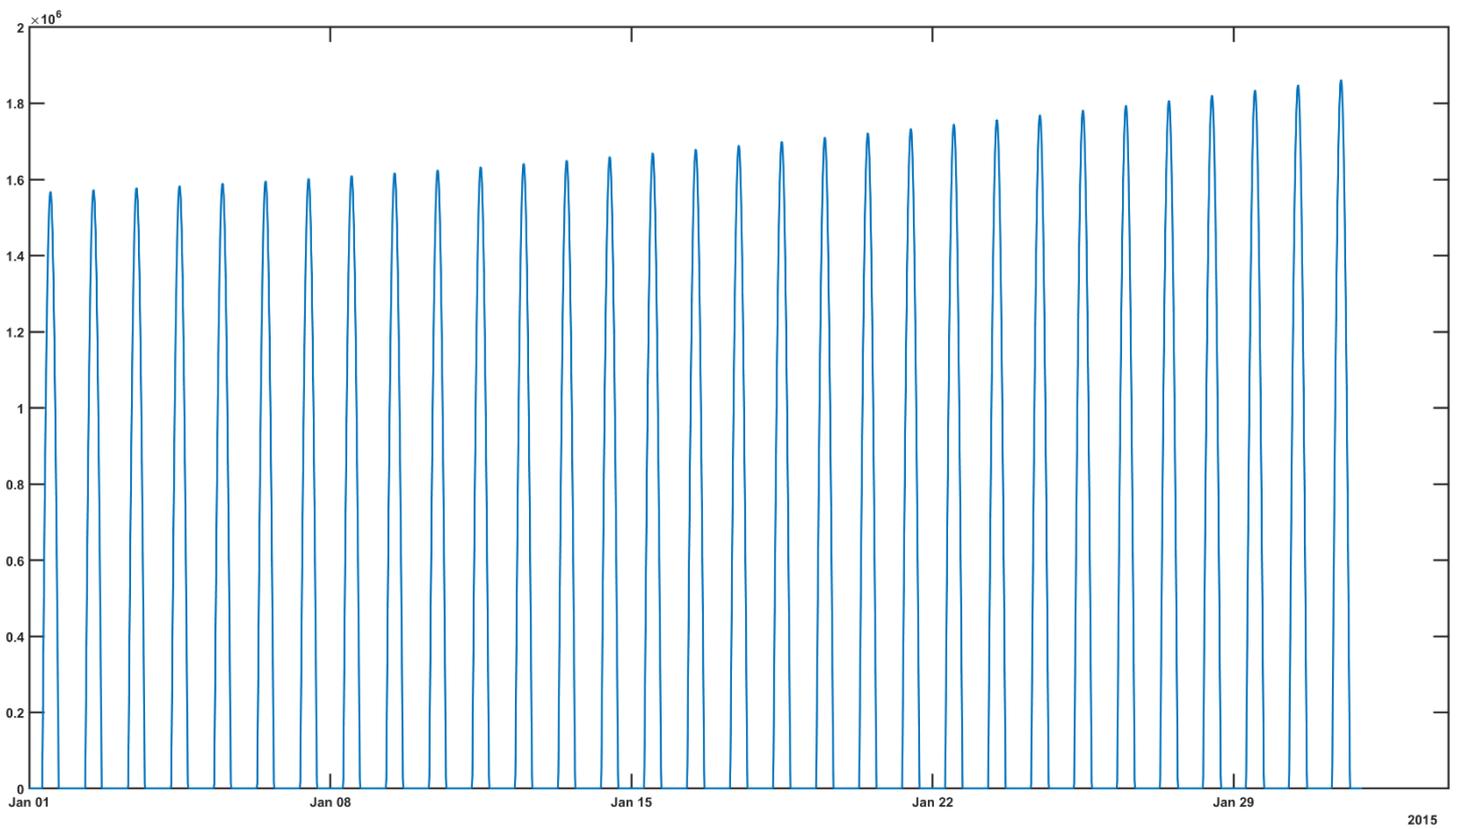
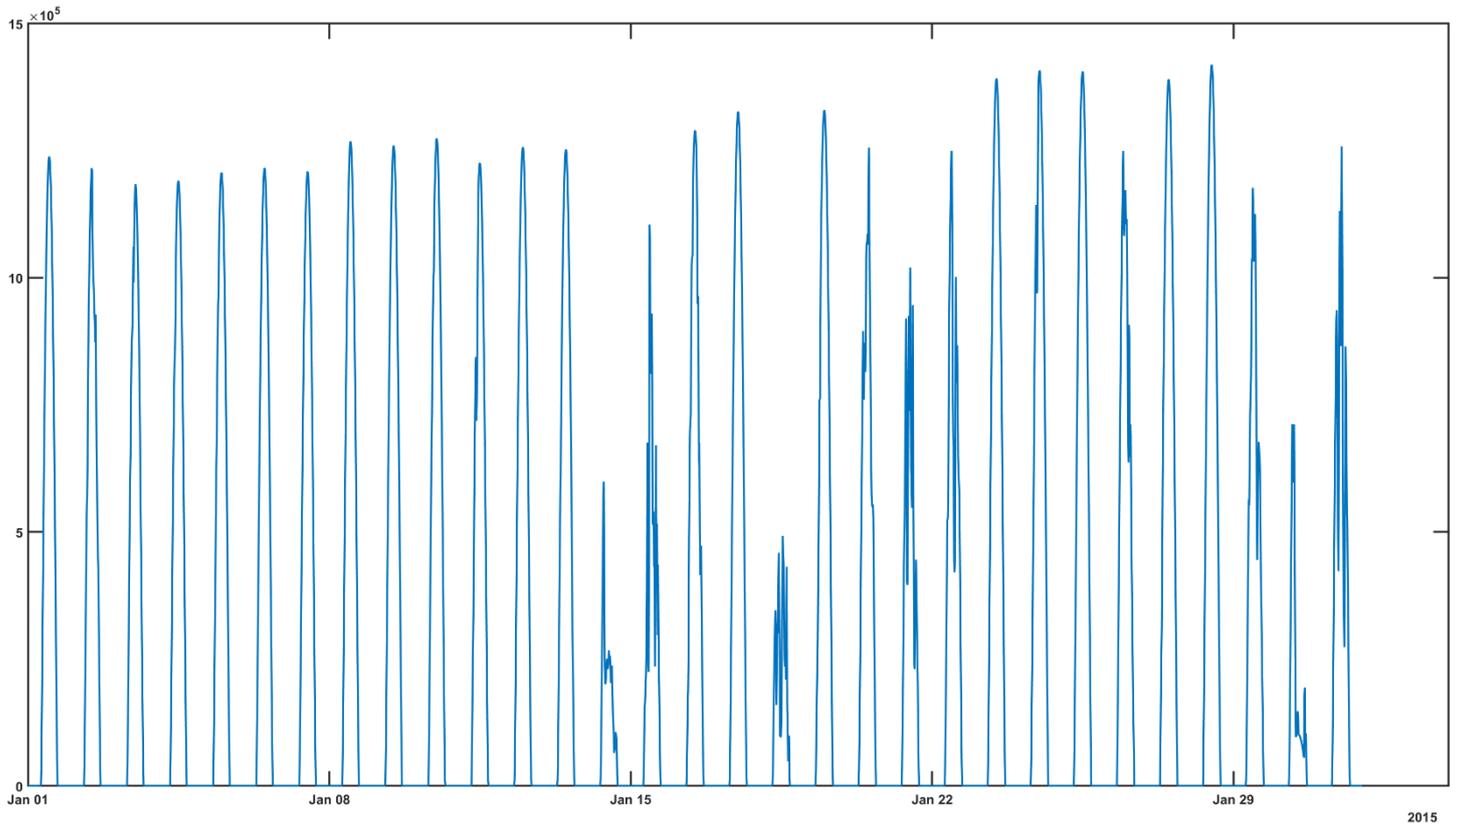
En la siguiente sección, se abordarán dos variables cruciales en nuestro estudio: el GHI y el GHI extraterrestre. Es fundamental destacar que estos elementos funcionan tanto como variables de entrada como de salida o, en otras palabras, como valores predichos en nuestro modelo.

Al emplear estos índices como variables de entrada, se ha notado una significativa mejora en la precisión de las predicciones. Este enfoque, sin embargo, plantea un dilema: las variables de entrada están intrínsecamente ligadas con los valores de GHI y GHI extraterrestre de la misma franja horaria, interrumpiendo el proceso de predicción una vez que se agotan los datos de entrada disponibles.

Para superar este obstáculo, se ha implementado una estrategia que implica crear un desfase temporal en los datos. En este método, los datos de entrada en un tiempo determinado "x" están sincronizados con los datos de salida de un momento posterior, específicamente "x+1". De esta manera, es posible prever los valores de GHI y GHI extraterrestre para el instante "x+1" teniendo a disposición los datos de entrada correspondientes al momento "x" y los valores de GHI y GHI extraterrestre del instante "x-1".

Esta estrategia facilita la continuación del proceso de predicción, permitiendo una mejor anticipación de los valores GHI y GHI extraterrestre, aún en ausencia de datos de entrada contemporáneos. Este desarrollo asegura que el modelo no solo mantenga una alta precisión, sino que también pueda operar de manera ininterrumpida mejorando considerablemente su funcionalidad y eficiencia.

Estas variables han sido descargados del CAMS [28].



4.1.1.9 Variables temporales.

Una propiedad destacable del GHI es su carácter estacionario, que se refleja de forma diferente en cada mes del año debido a factores como la inclinación del eje terrestre.

En este sentido, es importante subrayar que la irradiancia experimenta variaciones en los valores máximos entre los meses de invierno, como diciembre y enero, y los meses de verano, específicamente julio y agosto, donde la irradiación solar tiende a ser más prominente. Esta estacionalidad ha hecho que se tome la decisión de incorporar la variable "mes" como valor de entrada, permitiendo así que la red neuronal LSTM asocie las fluctuaciones medias de la irradiancia con el mes correspondiente durante el cual se efectúa la predicción.

Otro aspecto temporal para considerar es la "hora del día", ya que la irradiancia presenta una marcada variación a lo largo de las horas de sol, alcanzando su punto álgido durante las horas centrales del día. Por lo tanto, se ha incluido la hora como una variable de entrada, facilitando que la predicción se ajuste más fielmente a las distintas fases del día.

Al combinar estas dos variables temporales (mes y hora), el modelo es capaz de adelantarse a los cambios en los patrones de irradiancia solar que se adaptan a los ciclos naturales de salida y puesta del sol a lo largo del año. Esta integración tiene como objetivo mejorar la precisión de nuestras previsiones, ajustando estrechamente la dinámica diaria y estacional que afecta a la radiación solar.

4.1.2 Entrenamiento y resultados de las predicciones

Durante la fase de entrenamiento del modelo, se optó por utilizar, como se han desarrollado en el punto anterior, un total de cinco variables de entrada: GHI extraterrestre, GHI, mes, TCC y hora; así como dos variables de salida, que son GHI extraterrestre y GHI. Además, se implementaron 200 neuronas ocultas para optimizar el funcionamiento de la red.

A fin de potenciar el rendimiento de la red LSTM durante el entrenamiento, los datos fueron normalizados haciendo uso de una fórmula específica que se detallará posteriormente. Esto facilita el procesamiento y la interpretación de los datos por parte de la red neuronal.

$$Mu = \frac{1}{N} \sum_{i=1}^N A_i$$

$$Sig = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |A_i - Mu|^2}$$

$$A_{norm} = \frac{A_i - Mu}{Sig}$$

Posteriormente, estos datos normalizados se almacenan en contenedores de una longitud temporal correspondiente a un día, denominados “Cells”, para simplificar y agilizar el uso de los datos durante las etapas siguientes.

La configuración específica seleccionada para la red LSTM es la siguiente, resaltando cada elemento y justificando las decisiones tomadas para asegurar un entrenamiento óptimo y resultados precisos en nuestras predicciones.

```
options = trainingOptions('adam', ...  
    'ExecutionEnvironment','gpu', ...  
    'MaxEpochs',200, ...  
    'SequencePaddingDirection','right', ...  
    'Shuffle','every-epoch', ...  
    'Plots','training-progress', ...  
    'GradientThreshold',1, ...  
    'MiniBatchSize',2^8, ...  
    'InitialLearnRate',0.01, ...  
    'LearnRateSchedule','piecewise', ...  
    'LearnRateDropPeriod',20, ...  
    'LearnRateDropFactor',0.5, ...  
    'Verbose',0, ...  
    'L2Regularization',0.0005);
```

Se optó por utilizar el optimizador Adam, conocido por su eficacia en este tipo de tareas. Para aprovechar al máximo las capacidades de procesamiento y facilitar una ejecución más eficiente, se habilitó el uso de la GPU, utilizando para ello el parámetro 'ExecutionEnvironment', dada su arquitectura optimizada para el manejo de redes neuronales.

Se estableció un número de 200 iteraciones para el entrenamiento del modelo, buscando un equilibrio prudente entre el tiempo invertido en esta fase y la confiabilidad de los resultados obtenidos a partir de las predicciones.

La configuración detallada de los parámetros involucrados en la optimización es la siguiente:

'GradientThreshold': Se fijó un umbral unitario para el gradiente, controlando así la magnitud máxima de los gradientes durante el entrenamiento para prevenir divergencias.

'MiniBatchSize': Este valor indica que el aprendizaje se segmentará en varios grupos, facilitando un procesamiento más eficiente de los datos.

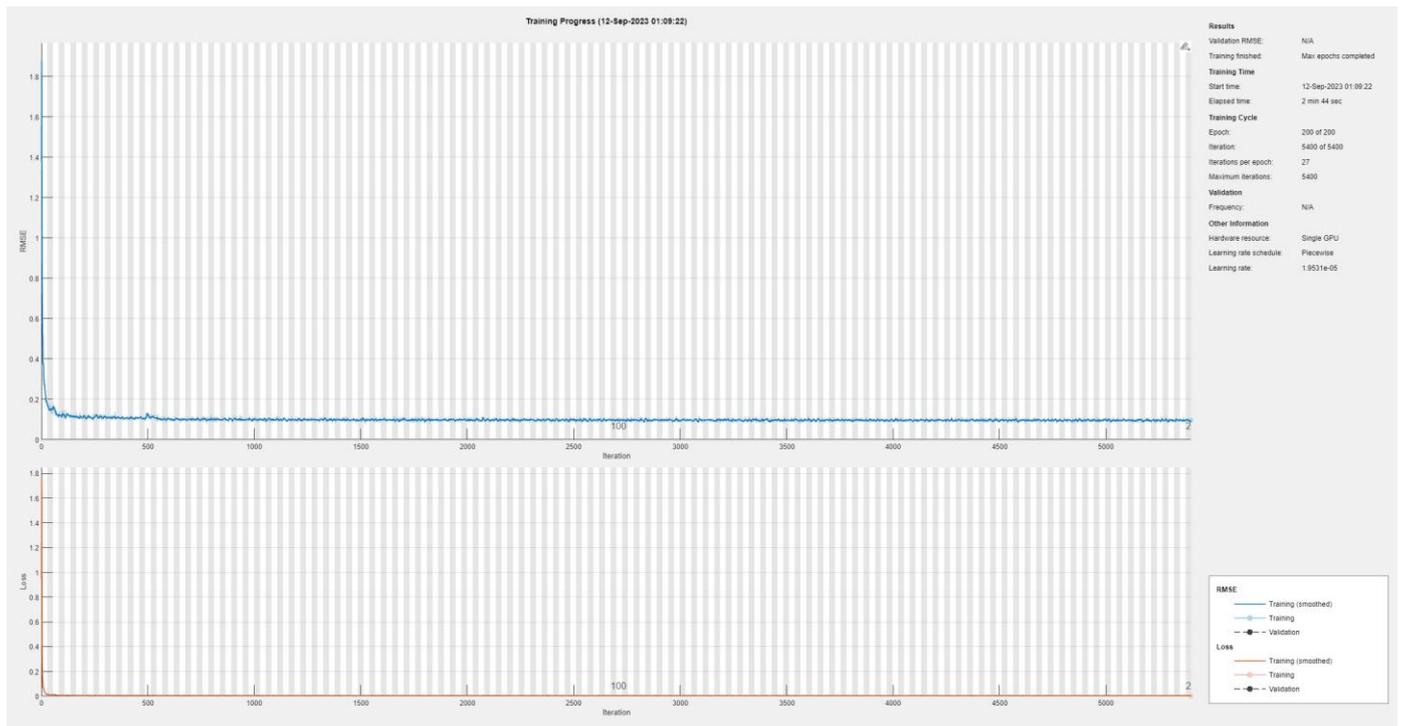
'InitialLearnRate': Se estableció una tasa de aprendizaje inicial de 0.01 para regular la rapidez con la que la red se ajusta durante el entrenamiento.

'LearnRateSchedule': Se optó por un esquema de aprendizaje por tramos, permitiendo ajustes variables en la tasa de aprendizaje a lo largo del entrenamiento.

'**LearnRateDropPeriod**': Se definió un periodo de reducción de la tasa de aprendizaje cada 20 iteraciones.

'**LearnRateDropFactor**': Durante cada periodo de reducción, la tasa de aprendizaje se disminuye en un factor de 0.5, buscando refinar progresivamente los ajustes del modelo a medida que avanza el entrenamiento.

'**L2Regularization**': Se implementó una regularización L2 con el objetivo de mejorar la generalización del modelo, prevenir el sobreajuste y promover soluciones más estables y robustas.



Tras completar la etapa de entrenamiento, el siguiente paso en la metodología es poner a prueba la red neuronal recién entrenada a través de la realización de predicciones. En el inicio de esta fase, se ejecutaron predicciones intradiarias, las cuales buscan evaluar el comportamiento del modelo dentro de un mismo día. El objetivo principal de este ejercicio inicial era obtener una primera impresión de la fiabilidad del modelo en un horizonte de tiempo más corto y controlado.

Para mantener la coherencia con el proceso de entrenamiento, se aplicaron las mismas técnicas de normalización con los valores de μ y σ obtenidos en el entrenamiento para cada variable y manteniendo el mismo almacenamiento de datos en la fase de predicción.

Las predicciones intradiarias, también conocidas como predicciones en lazo abierto, se derivan utilizando los valores reales del GHI y el GHI extraterrestre registrados en la hora previa a la que se está haciendo la predicción. Este enfoque asegura que se esté utilizando

la información más actual y precisa disponible al momento de generar cada pronóstico, pero impide hacer predicciones con horizontes mayores de 1h en el caso de estudio.

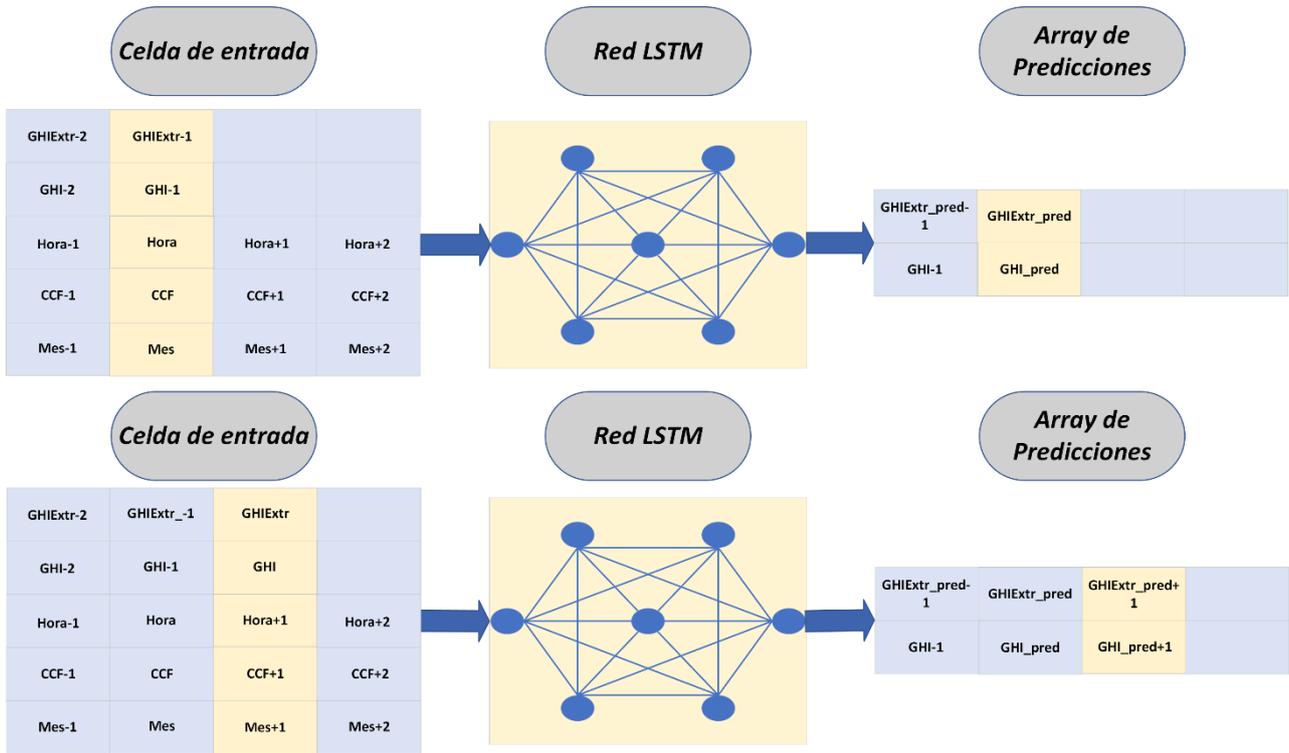
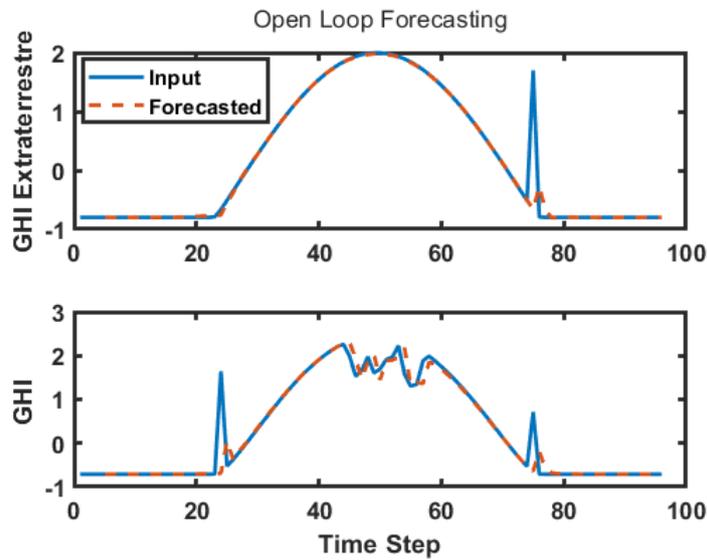


Figura 34: Predicción intradiaria o en lazo abierto



Para evaluar el error en la predicción intradiaria, donde contamos con los valores reales de la hora anterior, se utiliza el error cuadrático medio (RMSE). Al tratarse de un conjunto de datos se obtiene el RMSE para cada par de datos (real y predicho) y luego hallando la media de estos valores. Esta métrica ofrece una cuantificación precisa del error, permitiendo así determinar el nivel de exactitud de las predicciones generadas [31].

$$RMSE_i = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{pred\ i} - A_i)^2}$$

$$RMSE\ medio = 14.07\ kW/m^2$$

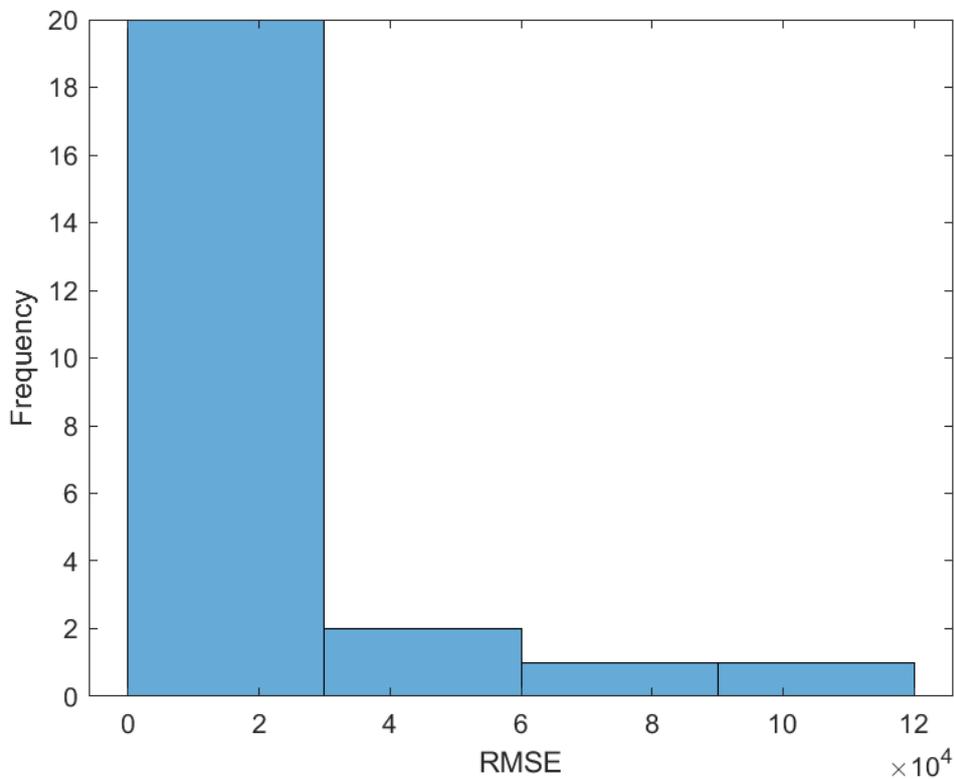


Figura 35: Histograma de los valores de RMSE de la predicción intraday

Después de evaluar la predicción intradía, se procede a formular una predicción con un horizonte temporal de tres días, que incluye el día en el que se realiza la predicción, conforme se discutió en la sección 4.1.1.3. Estas predicciones de múltiples días se conocen como predicciones en bucle cerrado. En este tipo de predicciones, los valores que desempeñan roles tanto de entrada como de salida no se derivan de datos reales en cambio, los valores predichos anteriormente se reincorporan como entradas para las predicciones siguientes. Este procedimiento se repite hasta alcanzar el horizonte de predicción deseado.

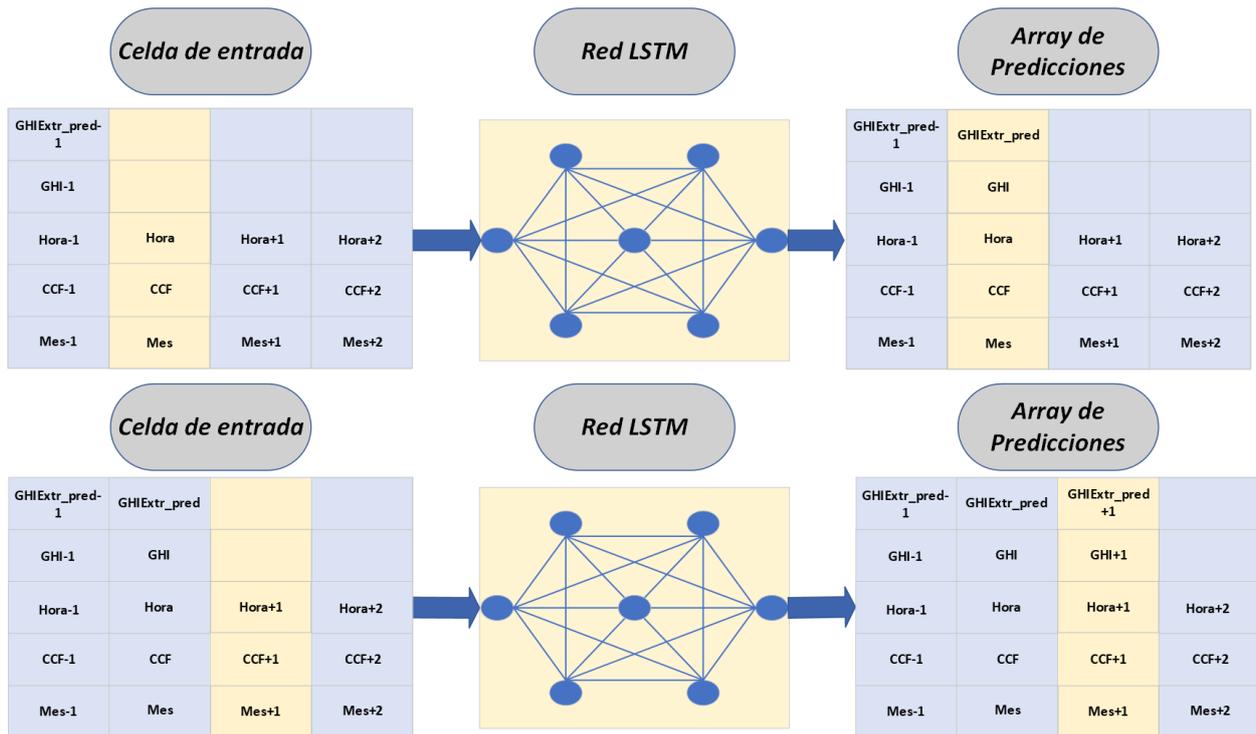
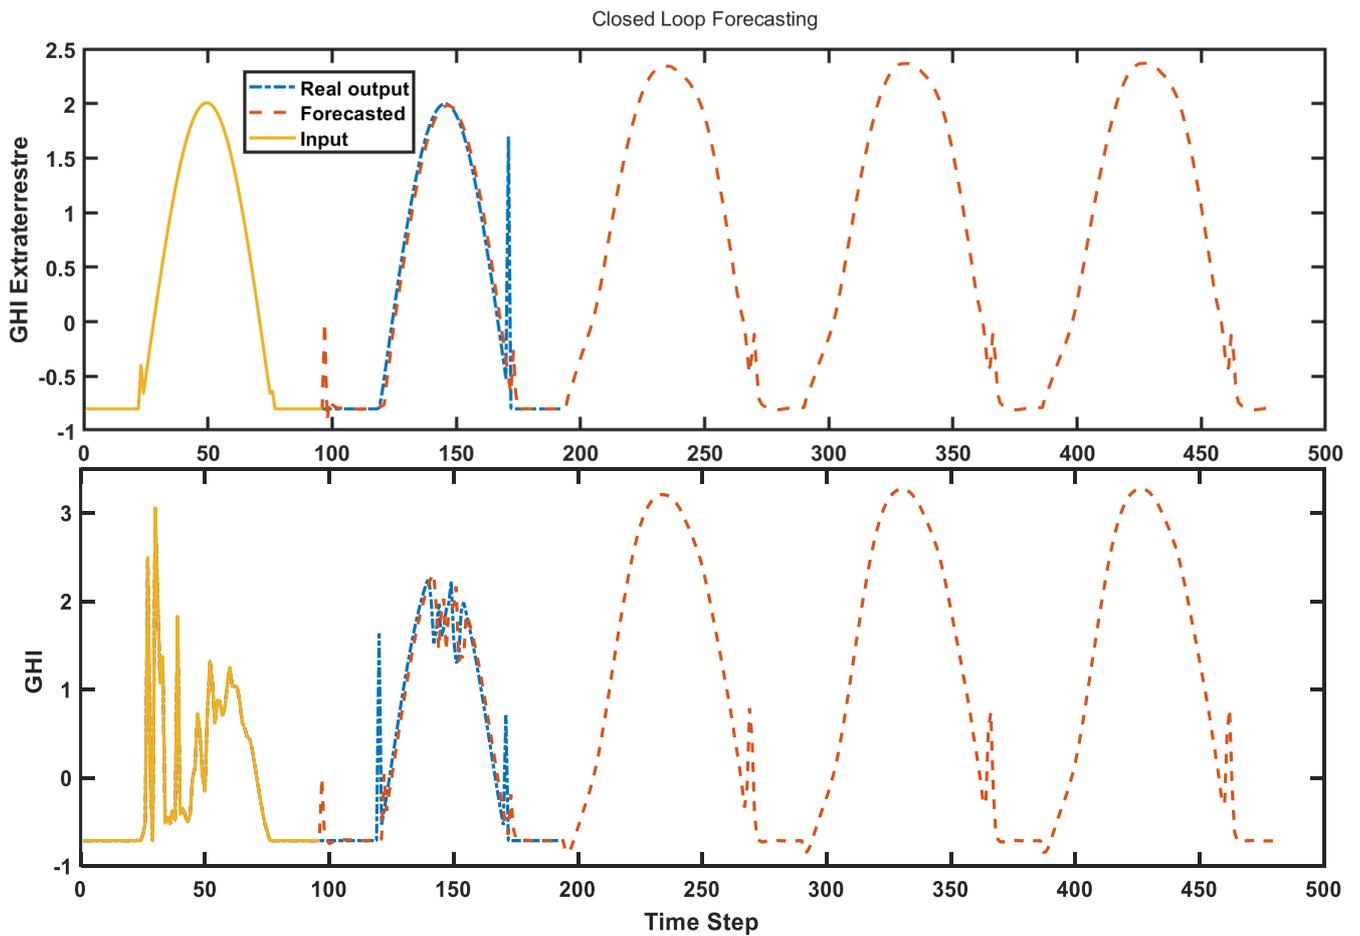
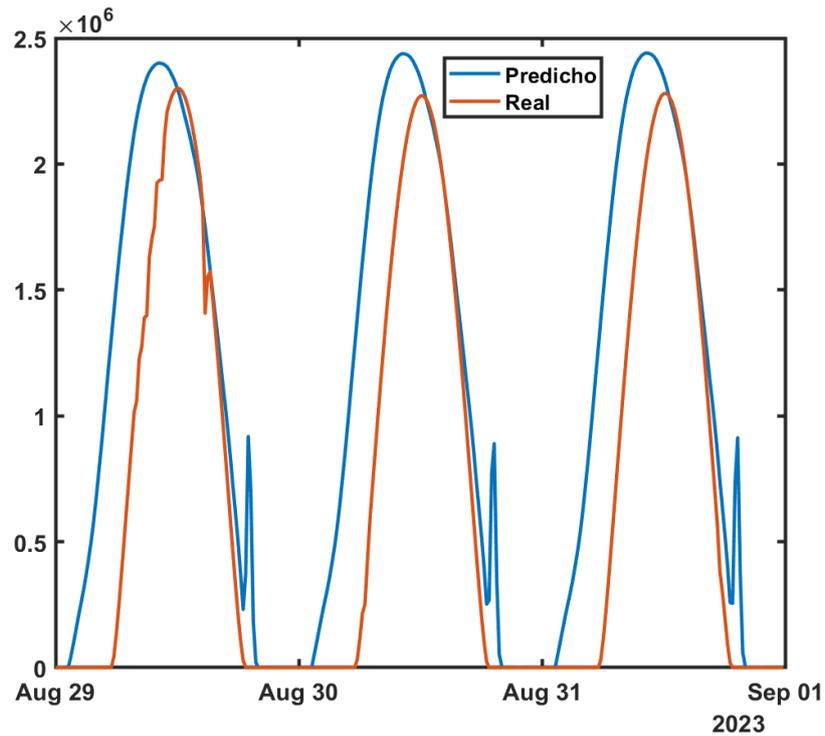


Figura 37: Esquema de entradas y salidas de la Red LSTM en los instantes "X" y "X+1" en lazo cerrado



En este caso, el RMSE no se puede calcular debido a la naturaleza de la predicción en bucle cerrado, en este tipo de predicciones no tenemos acceso a los valores reales que corresponden a los puntos futuros en los que nos encontramos. Sin embargo, una vez que alcanzamos el momento previsto, podemos obtener los datos reales y proceder a calcular el RMSE para evaluar la precisión de nuestras predicciones, en este caso se obtiene un RMSE medio = 374,26 kW/m² .



4.2 Redes LSTM para la predicción de precios de la energía

Tras un estudio en profundidad de las peculiaridades y principales ventajas de las redes neuronales LSTM en la predicción de irradiancia, en este apartado se describirá el procedimiento exacto de aplicación de técnicas LSTM para predecir las fluctuaciones del precio de la electricidad en el contexto español. En esta sección, la atención se centrará en las técnicas utilizadas para entrenar estas redes neuronales, detallando cada etapa desde la recopilación y el procesamiento de datos hasta la configuración óptima de la estructura de la red para lograr predicciones precisas y confiables.

A esta presentación le seguirá una visión general de los métodos utilizados para predecir los cambios en los precios de la electricidad en España. Este apartado discutirá en detalle la estrategia de modelado empleada, los obstáculos encontrados durante la implementación y cómo las cualidades inherentes de las redes LSTM permiten respuestas ágiles y efectivas.

4.2.1 Recopilación y elección de datos

La actual dinámica del mercado energético español se caracteriza por una marcada volatilidad en los precios, circunstancia que hace necesaria una predicción de los futuros valores del coste de la electricidad. Esto es crucial para adaptar y optimizar estrategias relacionadas con el almacenamiento energético.

Para lograr predicciones precisas, es fundamental llevar a cabo un análisis de los elementos que más importantes en la determinación del precio de la electricidad. Además, es vital seleccionar adecuadamente estos factores, una tarea que requiere considerar no solo su relevancia y peso en las fluctuaciones de precios, sino también la facilidad de obtener estos datos.

Los elementos que inciden significativamente en el precio de la electricidad incluyen:

Precios de las Materias Primas:

- Fuelóleo
- Gas
- Carbón
- Uranio

Factores Climatológicos y Meteorológicos:

Condiciones meteorológicas que pueden afectar la producción energética, como la velocidad del viento, la irradiación solar, las precipitaciones, etc.

GENERACIÓN MEDIDA

05 / 2023

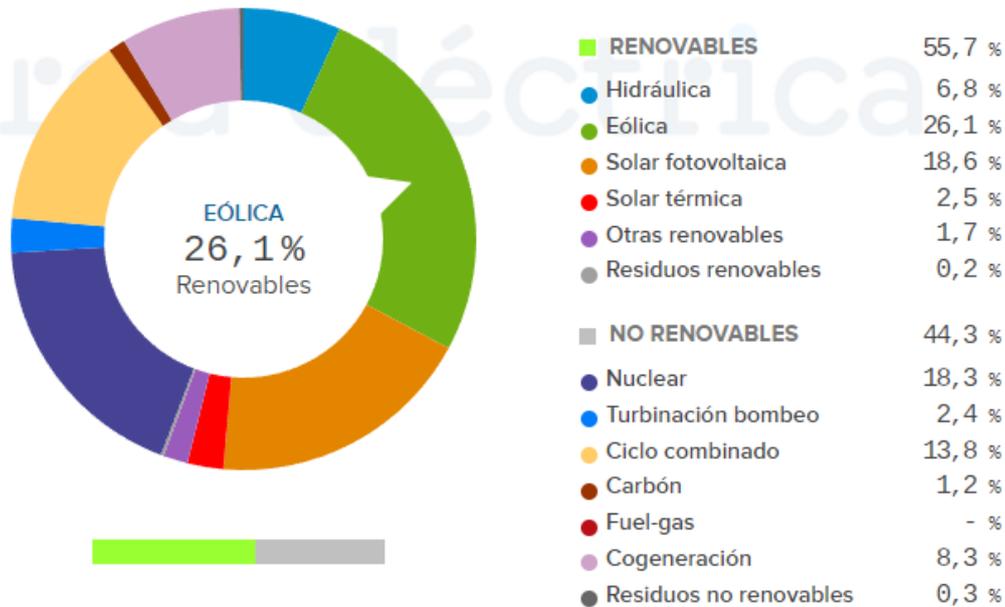


Figura 39: Generación eléctrica española desglosado por tecnologías. Fuente [33]

Contexto Económico y Derechos de Emisión:

La salud económica del país influye significativamente en el consumo eléctrico, históricamente, una mejor economía implica un aumento en la demanda y, por ende, un incremento en los precios de la electricidad. Esta relación se ha evidenciado tanto en periodos de crecimiento como en momentos de crisis económica.

Normativas y tarifas relacionadas con la emisión de gases de efecto invernadero y otros contaminantes.

Otros Factores:

Aspectos Económicos: como la inflación, las tasas de interés, y otros indicadores macroeconómicos.

Regulaciones y Política Energética: cambios legislativos, normativas sectoriales, y políticas energéticas tanto a nivel nacional como internacional.

Dinámicas Geopolíticas: situaciones geopolíticas que puedan afectar la disponibilidad y el precio de los recursos energéticos, como conflictos políticos, sanciones, etc.

Cada uno de estos elementos contribuye a crear un entorno altamente complejo y dinámico en el que se determina el precio de la electricidad. [32]

Tras evaluar los factores determinantes en resultado del precio de la energía, se concluyó que solo los relacionados con los precios de las materias primas, así como los factores climatológicos y meteorológicos, podrían incorporarse en el proyecto. Esto se debe a la complejidad y dificultad de cuantificar y prever con precisión los otros parámetros, como los económicos y geopolíticos.

Tras evaluar los distintos factores, se estableció que las variables a emplear para el modelo de predicción incluirían: la energía generada a través de la fotovoltaica, el indicador booleano que diferencia entre días festivos y laborables, la hora del día y el mes (por razones semejantes a las explicadas en el apartado de predicción de la irradiancia), la energía generada mediante tecnología eólica, el precio del gas y finalmente, el histórico de precios de la electricidad.

4.2.1.1 Producción fotovoltaica y eólica

La selección de estas variables no es aleatoria, sino que se basa en su representación significativa en la matriz energética española. Juntas representan casi el 45% de la generación eléctrica total del país, como se puede observar en la **Figura 39**. Este porcentaje se acerca a la mitad de la producción total y refleja una parte importante del panorama energético español, lo que implica un importante factor dentro de la determinación del precio de la electricidad.

Es importante resaltar que, la energía renovable contribuye aún más, alcanzando un impresionante 55% de la producción total de energía. Esta cifra no sólo subraya la relevancia de estas fuentes de energía en el contexto nacional, sino que también demuestra el compromiso de España con la transición hacia fuentes de energía más sostenibles y respetuosas con el medio ambiente.

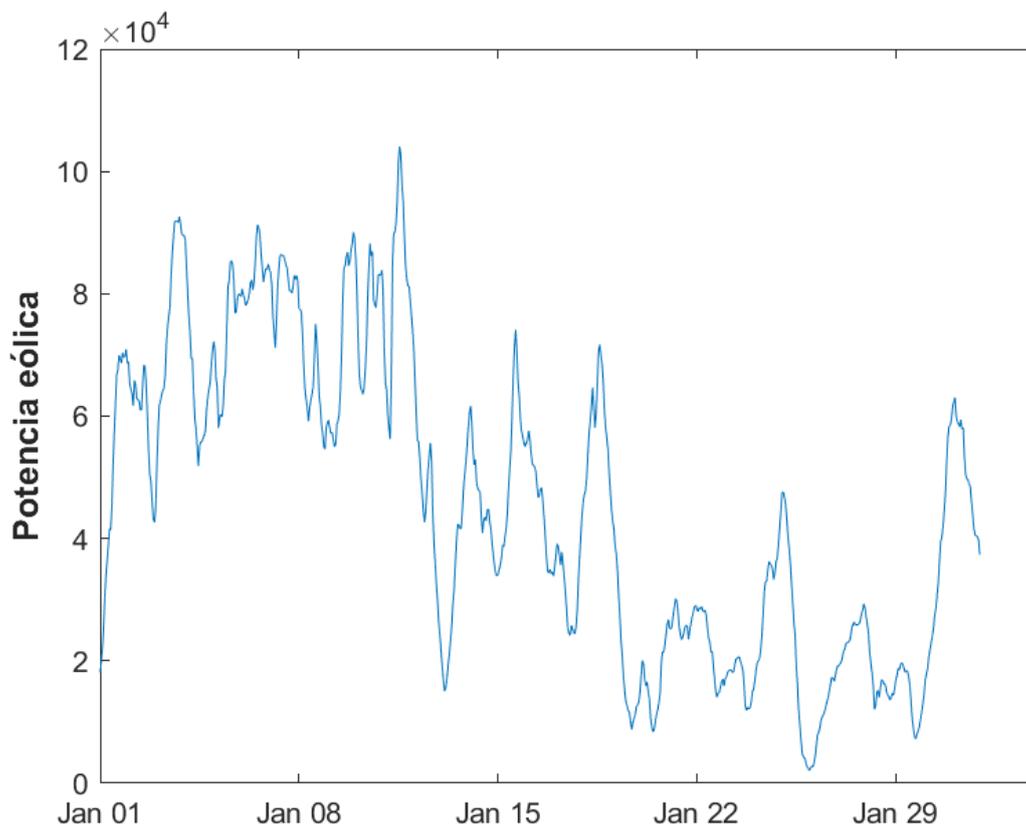


Figura 40: Histórico del mes de enero de 2016 de la variable Potencia eólica nacional 2016

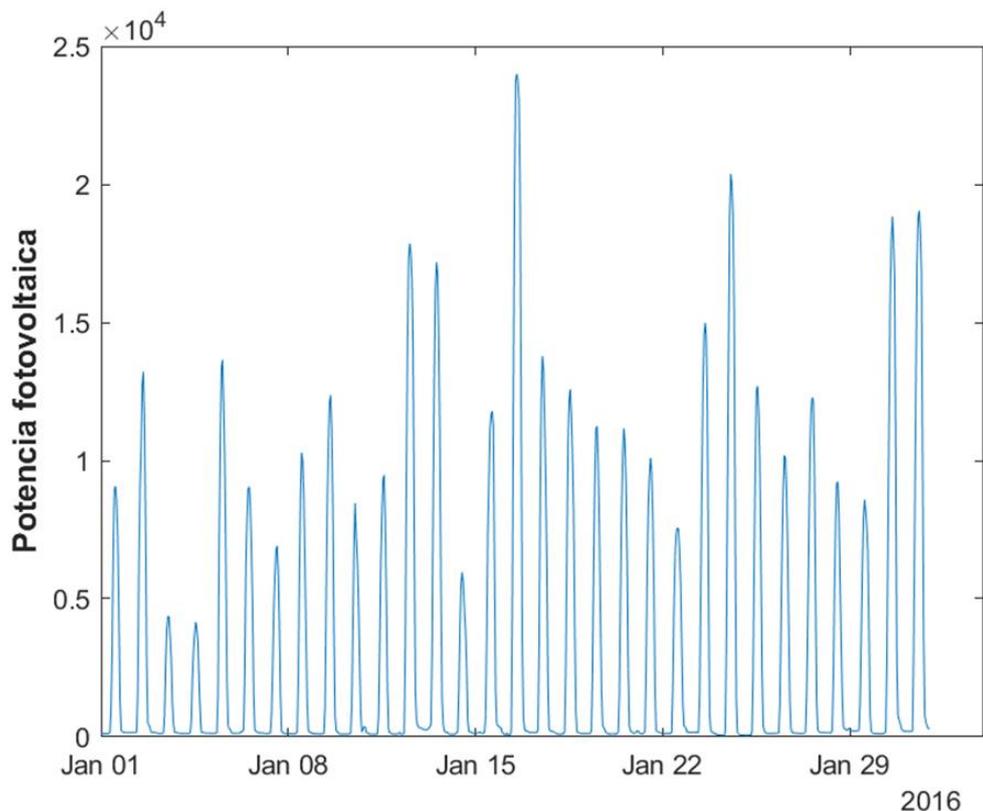


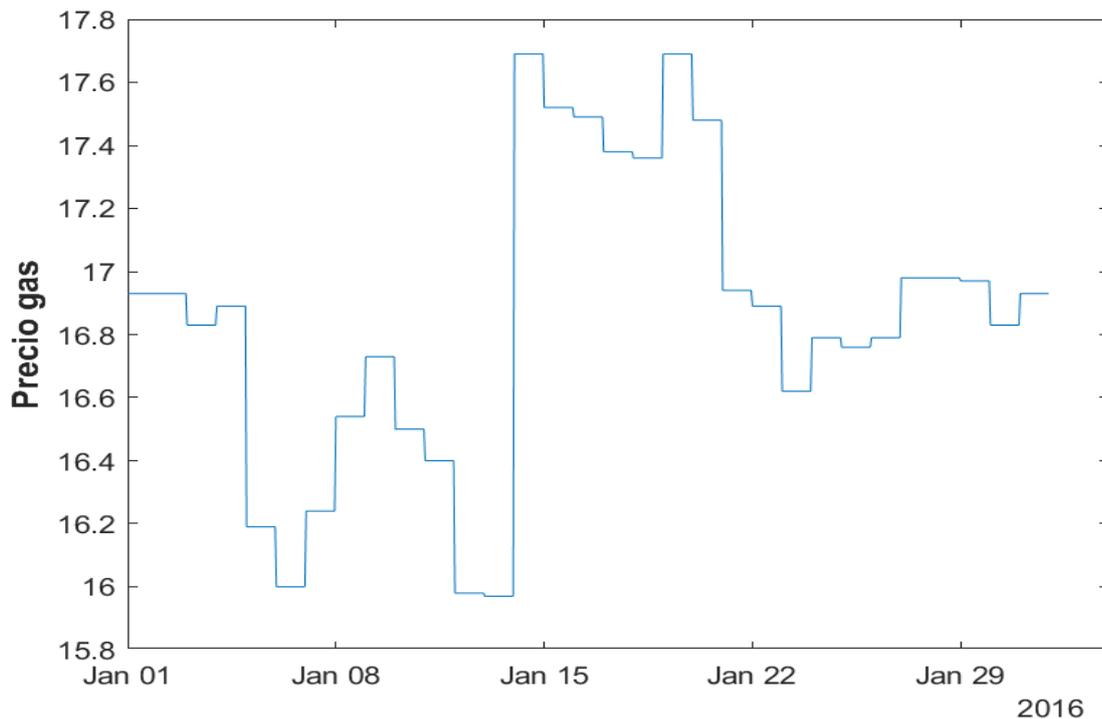
Figura 41: Histórico del mes de enero de 2016 de la variable Potencia fotovoltaica nacional

4.2.1.2 Precio del gas

La relación entre el precio del gas y el precio final de la electricidad es directa y muy significativa, como ha quedado patente en casos recientes en Europa. Un claro ejemplo de esta conexión surgió a raíz del conflicto en Ucrania y la posterior imposición de sanciones al gas ruso. Estos acontecimientos geopolíticos han tenido un impacto directo en las economías energéticas del continente, demostrando cuán interdependientes y sensibles son los mercados energéticos a las fluctuaciones de suministro y precios de materias primas como el gas natural.

Por lo tanto, incorporar variables del precio del gas natural en los modelos de predicción es fundamental para garantizar pronósticos precisos. Esta decisión está respaldada no sólo por los acontecimientos geopolíticos sino también por la composición de la matriz energética de España. Como se muestra en la **Figura 39**, el gas natural juega un papel vital en la generación eléctrica de España. Las centrales eléctricas de ciclo combinado, que utilizan gas natural para producir energía, representan alrededor del 15% de la generación eléctrica total del país.

Por lo tanto, cualquier cambio en los precios del gas natural o en los volúmenes de suministro tendrá inevitablemente un impacto significativo en los precios finales de la electricidad. Es por ello por lo que se debe tener en cuenta el impacto de los precios del gas natural a la hora de desarrollar modelos de previsión del precio de la electricidad, dada su relevancia en el panorama energético nacional.



4.2.1.3 Energía nuclear

Un factor inicialmente considerado para su inclusión en el análisis fue la producción de energía nuclear. Pero después de una su evaluación, se decidió excluir esta variable. La razón principal detrás de esta decisión es la estabilidad y previsibilidad de la producción de energía nuclear, siendo raras las grandes fluctuaciones en la producción y generalmente limitadas a períodos de mantenimiento programados en las centrales nucleares.

Es importante señalar que estas intervenciones de mantenimiento son eventos infrecuentes a lo largo de la vida operativa de una central nuclear, lo que se traduce en un patrón de generación muy constante y predecible. Esta regularidad en la producción minimiza su impacto en las fluctuaciones del precio de la electricidad, haciendo que su inclusión como variable en el modelo de predicción agregue poco valor al análisis y potencialmente desvíe el foco de factores más volátiles y determinantes.

Por lo tanto, aunque la energía nuclear forma una parte significativa la matriz energética española, su contribución a las variaciones en el precio de la electricidad es limitada. En este sentido, se optó por concentrar los esfuerzos analíticos y de modelado en variables que presentan una mayor variabilidad y, por ende, tienen un impacto más directo y significativo en la determinación del precio de la electricidad en el mercado español.

4.2.1.4 Días Festivos y domingos

Otro factor incorporado en el análisis es la distinción entre días festivos y días laborables. Esto se debe a que, tanto los días festivos nacionales como los domingos, experimentan una reducción en la demanda de energía, lo que a su vez genera una disminución en el precio de la electricidad. Para modelar esta variable se ha empleado un valor booleano: asignando el número 1 a los días festivos y domingos, y el número 0 a los días laborables.

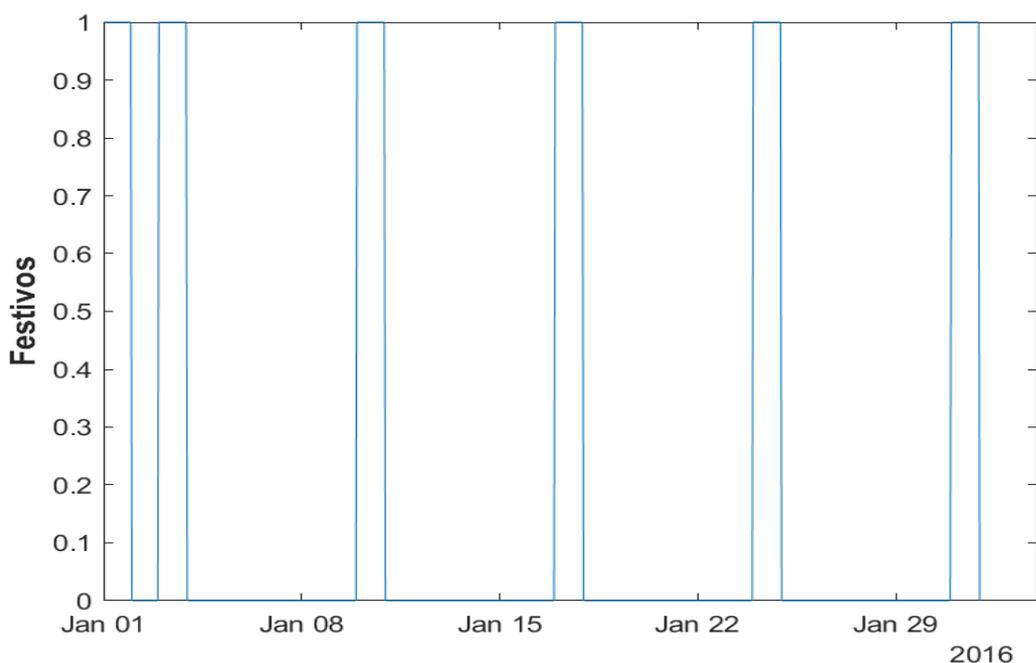


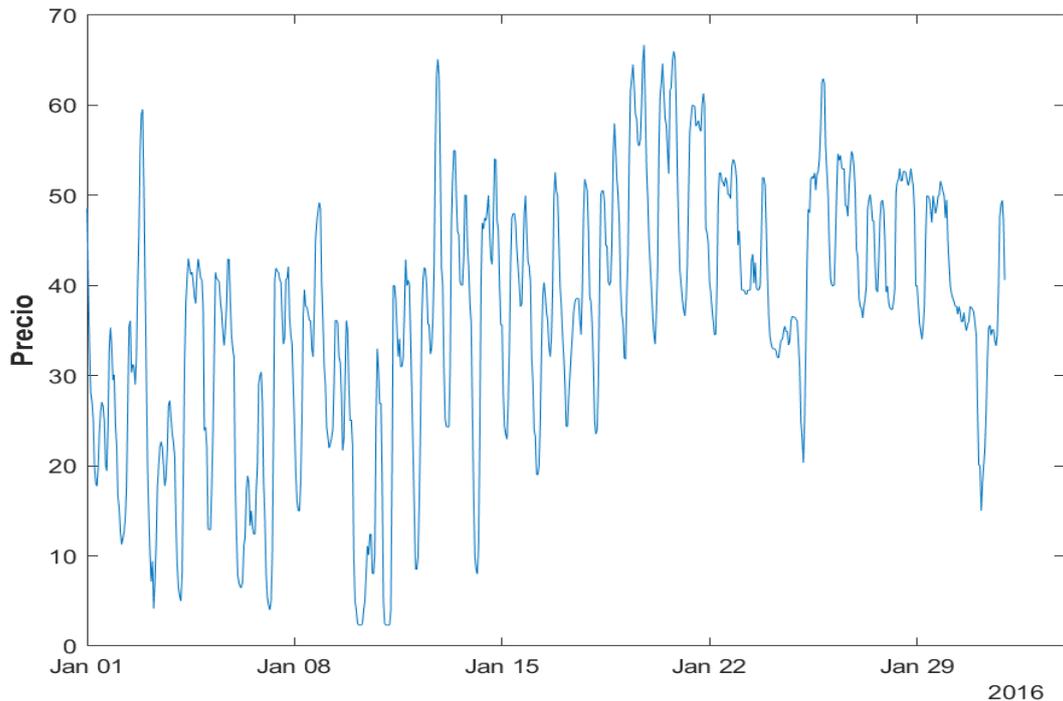
Figura 43: Histórico del mes de enero de 2016 de la variable Festivos

4.2.1.5 Precio del mercado SPOT de la electricidad

El precio de la electricidad, al igual que las variables GHI y GHI extraterrestre discutidas en el apartado 4.1, opera tanto como variable de entrada como de salida en el modelo desarrollado. Esto se debe a la existencia de una fuerte dependencia temporal entre los precios consecutivos en una serie temporal, donde el precio en un instante concreto "X" está significativamente influenciado por el precio en el instante previo "X-1".

Este fenómeno puede entenderse mejor a través de la inercia del mercado, donde los precios tienden a seguir una trayectoria influenciada por los valores más recientes debido a una variedad de factores, incluyendo, pero no limitado a, la respuesta de la oferta y la demanda a los precios previos, las expectativas de los agentes del mercado, entre otros aspectos económicos y financieros que rigen el comportamiento del mercado eléctrico.

Por lo tanto, incorporar el precio anterior como una variable de entrada en el modelo ayuda a entender esta dependencia temporal y facilita la creación de pronósticos más acertados y fundamentados en la historia reciente del comportamiento de los precios. Este enfoque permite al modelo aprender y entender las tendencias y patrones en la evolución de los precios.



4.2.1.6 Variables temporales.

Una propiedad destacable de los precios en el mercado spot de electricidad es su carácter estacionario, que se manifiesta de manera diferenciada cada mes del año debido a factores como las fluctuaciones estacionales en la demanda y oferta de electricidad.

En este contexto, es vital destacar que los precios experimentan variaciones significativas entre los meses de invierno y verano, períodos donde se registran diferencias notables en el consumo energético debido a las condiciones climáticas y hábitos de consumo. Por tanto, se ha tomado la decisión de incorporar la variable "mes" como un valor de entrada, permitiendo a la red neuronal LSTM correlacionar las fluctuaciones promedio de los precios con el mes específico en que se está efectuando la predicción.

Otro aspecto relevante es la "hora del día", dado que los precios del mercado eléctrico pueden variar considerablemente a lo largo del día, influenciados por los picos de demanda que usualmente se registran en las horas centrales del día. Por lo tanto, la "hora" se ha introducido como una variable adicional de entrada, facilitando que la predicción se alinee más estrechamente con las distintas fases del día y los patrones de consumo asociados.

4.2.2 Entrenamiento y resultados de las predicciones

En este capítulo no se abordará en detalle el entrenamiento de la red LSTM, ya que se emplea una configuración idéntica a la utilizada en el entrenamiento de la red para la predicción del GHI, con la única distinción radicando en los datos de entrenamiento, que en este caso son los que se han expuesto en el apartado anterior.

Esto implica que la metodología, las estrategias de optimización, y demás parámetros asociados al entrenamiento de la red se mantienen constantes.

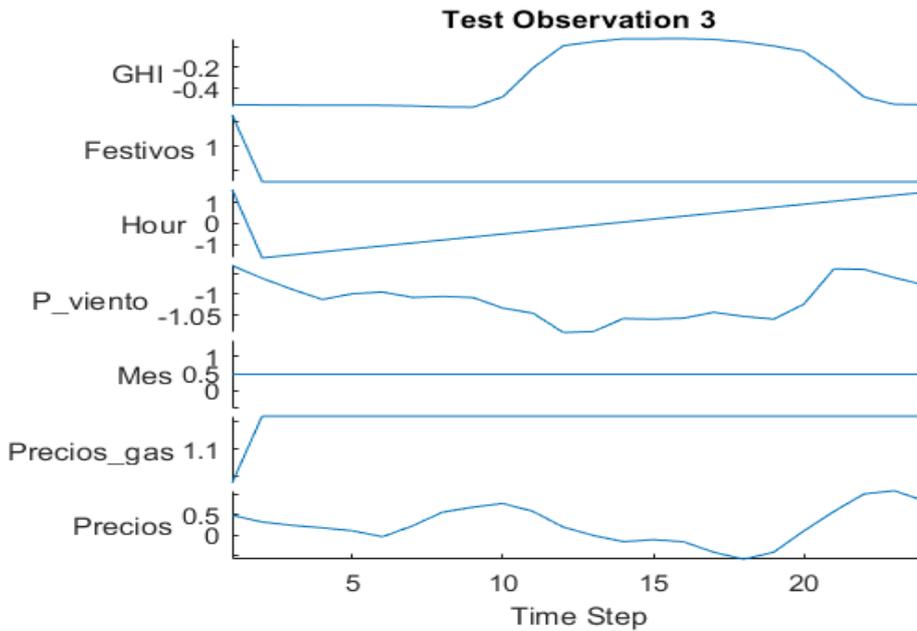
Así, se presume que el lector está familiarizado con los detalles técnicos del proceso de entrenamiento de una red LSTM, según se describió en el [capítulo 4.1.2](#), y que puede referirse a esas secciones para una comprensión profunda de los procedimientos y técnicas aplicadas en esta fase del proyecto.

Durante la fase de predicción, se han configurado dos "arrays" o conjuntos de vectores. Uno de ellos incorpora los valores históricos de las variables antes citadas, destinados a las predicciones intradiarias o en lazo abierto. Sin embargo, este enfoque es relativamente innecesario para la predicción de precios, considerando que los precios de la energía se determinan a las 20:15h del día anterior [34], mientras que las estrategias intradiarias se implementan a lo largo del día en curso en el cual ya sabemos los precios del día entero.

El segundo "array" se compone de valores predichos que se adquirieron de la página web de ESIOS [35-36], que proporciona predicciones sobre los futuros datos de generación fotovoltaica y potencia eólica generada. Las demás variables pueden preverse con relativa facilidad, dado que se relacionan con aspectos fácilmente identificables, como la distinción entre días festivos y laborables, el mes en el que se está llevando a cabo la predicción y la hora específica de cada predicción individual.

Una notable excepción es la variable del precio del gas para los días futuros pronosticados, cuya predicción exacta es más compleja. Dada esta limitación, se ha decidido emplear una estrategia que involucra el uso de los valores de los días anteriores para facilitar una estimación más precisa.

Esta estrategia, aunque no es perfecta, permite aprovechar la información disponible para formar una predicción razonable, ayudando a mantener una cierta coherencia y permitiendo la realización de predicciones a pesar de la falta de datos exactos para el futuro inmediato. Esta es una técnica comúnmente usada cuando se trata de elementos que tienen una cierta estabilidad o que no presentan fluctuaciones drásticas en cortos periodos de tiempo.



En el contexto del análisis presentado, la estrategia adoptada para prever el precio diario del mercado SPOT es la de implementar una predicción en lazo cerrado. Esta estrategia implica que las predicciones generadas en un paso dado se retroalimentan en el sistema como datos de entrada para las predicciones subsiguientes. Es decir, la predicción del precio para una hora determinada será utilizada como una de las variables de entrada para la predicción de la hora siguiente.

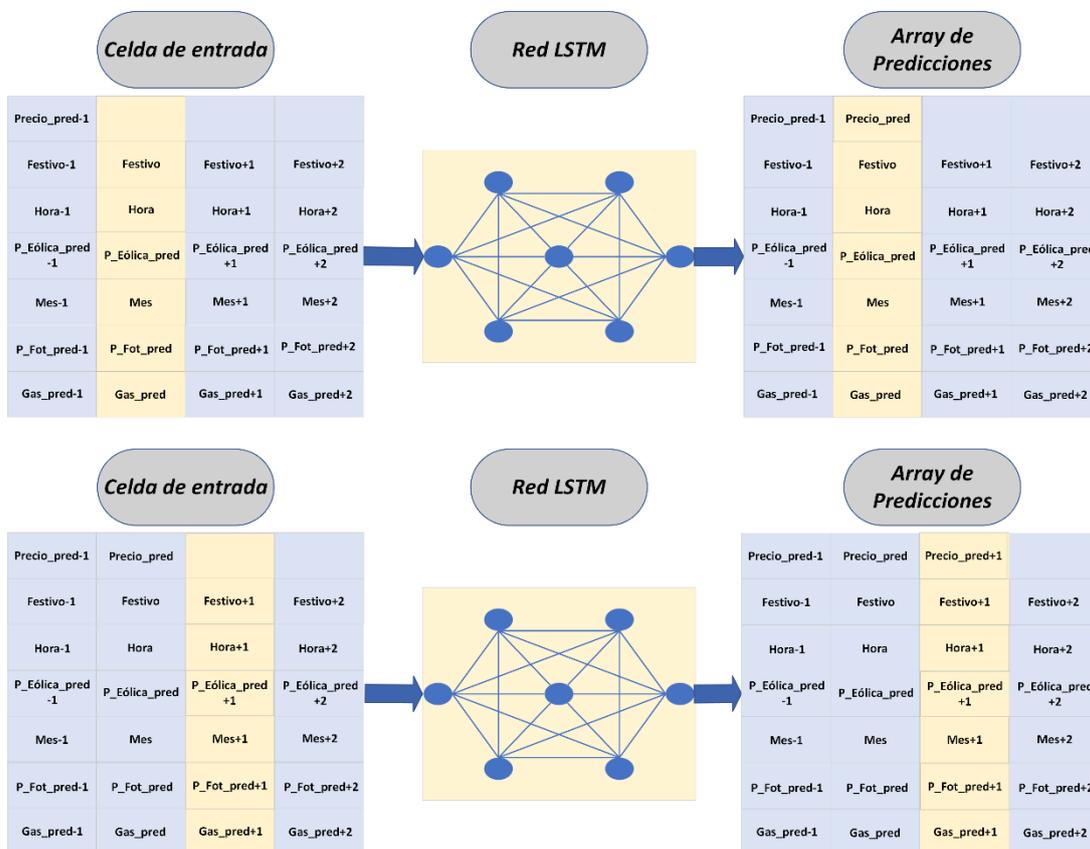
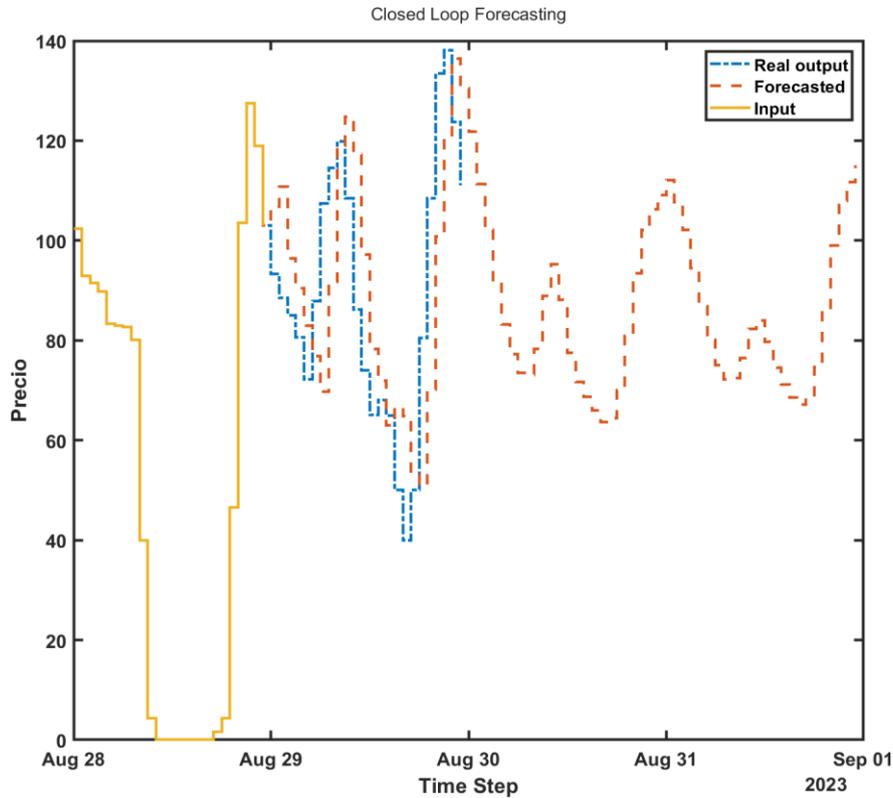


Figura 45: Esquema de entradas y salidas de la Red LSTM en los instantes "X" y "X+1" en lazo cerrado

Una vez establecida la estrategia implementada para efectuar la predicción, es imperativo valorar los resultados derivados de esta. La evaluación se enfoca específicamente en las predicciones generadas para los días 29, 30 y 31 de agosto de 2023, período que coincide exactamente con los días seleccionados para la predicción de GHI.



Como se puede observar en la gráfica, se presentan los valores reales correspondientes al día 29, delineados mediante una línea que combina puntos y rayas en tonalidad azul. Aunque estos valores pertenecen al rango de fechas destinado para la predicción, es pertinente señalar que estuvieron disponibles desde las 20:15h del día anterior, lo cual facilitó su inclusión en este análisis.

La decisión de predecir estos valores, aun teniendo la disponibilidad de los datos reales, fue tomada con el propósito expreso de emplear los resultados reales en el cálculo del RMSE.

$$RMSE_{i\ medio} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{pred\ i} - A_i)^2} = 17.6950 \text{ €}$$

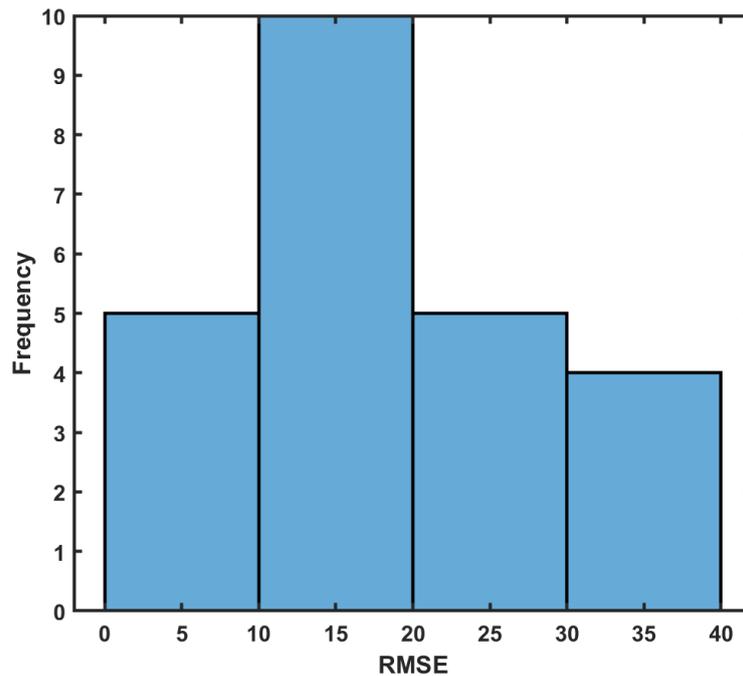
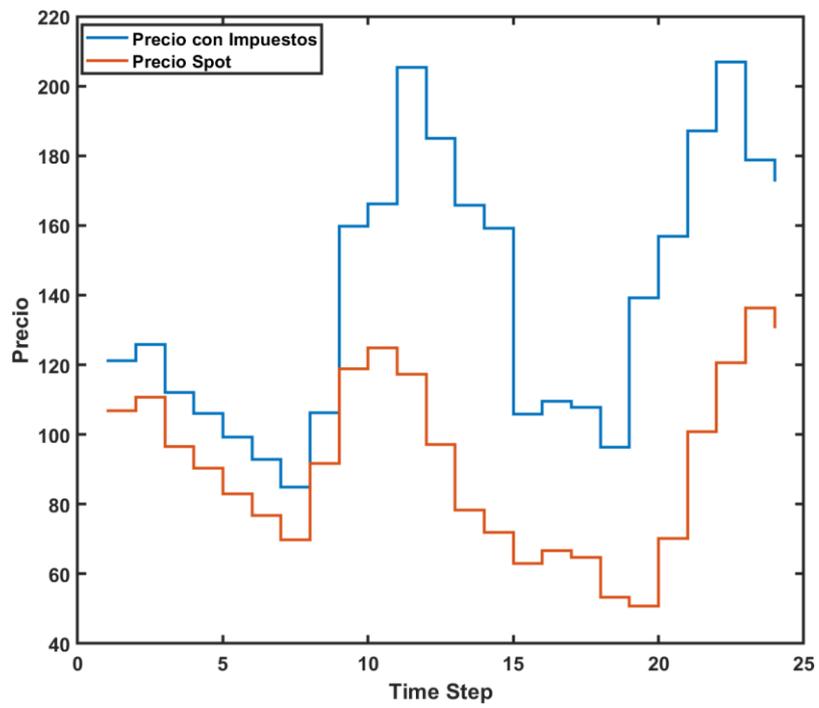
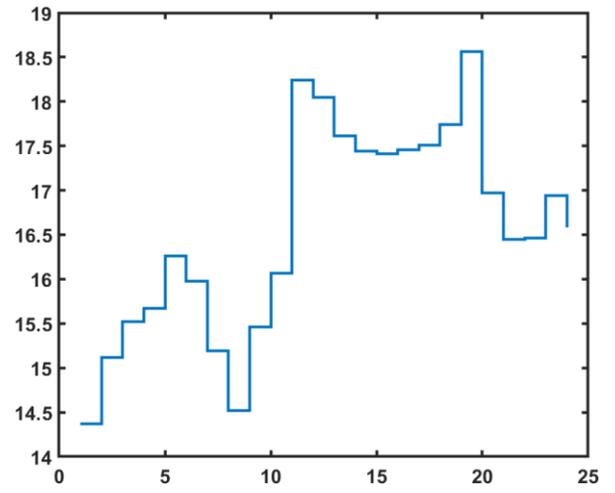
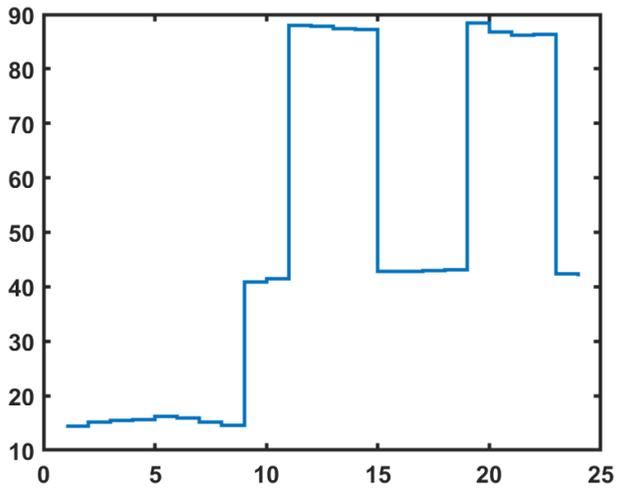


Figura 48: Histograma de los valores de RMSE del día 29 de la predicción

Este procedimiento, entonces, facilita no solo una evaluación objetiva de la eficacia del modelo sino también confirma que las predicciones armonizan considerablemente bien con los datos reales. Al ejecutar este análisis, se ha obtenido un RMSE medio de 17.6950 €. Es significativo destacar que el 63% de los valores RMSE calculados se encuentran bajo la marca de 20€, señalando una concordancia robusta entre las predicciones y los eventos verdaderos. Este dato refleja un grado satisfactorio de precisión, corroborando la fiabilidad de nuestro modelo en la predicción del mercado SPOT diario de electricidad.

El paso final para completar la predicción de precios de la energía implica incorporar los perfiles de impuestos según los tramos horarios, dado que el mercado spot refleja el costo en el mercado mayorista, mientras que para la gestión de baterías es imperativo considerar el PVPC. Optamos por enfocarnos en pronosticar el mercado SPOT, no solo por la accesibilidad a un registro más extenso de datos históricos, sino también porque la gestión de baterías requiere el precio de venta de energía, que es el precio del mercado SPOT. Esta estrategia ofrece una ruta eficiente para manejar tanto la predicción como la implementación práctica en la administración de baterías.



5 Transformación de Irradiancia a potencia

En este capítulo, nos enfocamos en transformar los valores de irradiancia previamente pronosticados en la potencia que generarían los paneles fotovoltaicos bajo las condiciones estimadas. Este proceso requiere dos etapas.

La primera se centra en el análisis de los mapas de nubosidad y temperatura suministrados por la AEMET. Este análisis permitirá tener una comprensión detallada de las condiciones meteorológicas que se involucran en la generación de energía solar mediante paneles fotovoltaicos.

La segunda etapa requiere la implementación de un modelo matemático que emula el comportamiento operacional de los paneles solares. Mediante la utilización de los datos recabados de los mapas, se busca determinar los valores precisos de potencia que se podrían obtener. Este modelo se fundamenta en la relación intrínseca entre las condiciones climáticas y la eficacia de los paneles solares, lo que a su vez permite una estimación más exacta del rendimiento energético potencial.

En resumen, este capítulo busca establecer un puente entre las predicciones de irradiancia y el cálculo de la energía que puede ser generada, uniendo el análisis meteorológico con las especificidades técnicas de los sistemas fotovoltaicos. Con esto, se busca tener una herramienta confiable para prever la potencia generada y así facilitar una gestión más efectiva y anticipada en el ámbito de la energía solar.

5.1 Lectura de mapas de AEMET

En este segmento dedicado a la interpretación de mapas, es fundamental mencionar que estamos fundamentando nuestro enfoque en la revisión de la tesis [1]. El amplio y meticuloso proceso de investigación que fue llevado a cabo en dicho trabajo nos ha brindado el marco ideal para adoptar una la misma estrategia en este proyecto.

5.1.1 Procesamiento del CCF

La variable más importante que se obtiene de la lectura de los mapas es el CCF, variable explicada en el apartado 4.1.1.3, para ello hay que determinar una representación precisa de las nubes que interfieren entre el sol y la planta fotovoltaica. Es fundamental ubicar con precisión la planta fotovoltaica dentro del mapa. Para poder lograr esto hay que tener en cuenta que cada píxel del mapa representa un área considerablemente grande, con dimensiones de aproximadamente 2.5 km por lado. Dada esta gran superficie, un único píxel puede encapsular la posición de la estación.

El desafío principal es identificar específicamente aquellas nubes que obstruyen la luz solar directamente, dado que estas son las que tienen un impacto significativo en el GHI, principalmente al absorber la componente directa de la irradiancia. Mientras que otras nubes y partículas dispersas en la atmósfera pueden, de hecho, incrementar la GHI al aportar radiación difusa adicional, este estudio se concentra primordialmente en el efecto de las nubes obstructoras, ya que los efectos secundarios de las otras partículas atmosféricas son considerablemente más desafiantes de estimar con la información disponible.

Para identificar las nubes relevantes, es indispensable referirse a la **Figura 52**, que ilustra la posición solar horaria durante un día específico desde un punto de vista del hemisferio norte. La figura también resalta las variables cruciales para calcular el CCF. Dicha ilustración pone de manifiesto que, si se conocen tanto la altura de la nube como la elevación solar, es posible determinar la distancia entre la nube y, en el caso de la **Figura 52**, el piranómetro mediante trigonometría básica. Posteriormente, utilizando datos de azimut, se puede identificar su ubicación exacta en la superficie terrestre.

En este contexto, los NWP de nubosidad de AEMET se convierten en una herramienta vital, permitiendo la creación de una representación en píxeles idéntica a la de la **Figura 52**. Conociendo la ubicación exacta del píxel que alberga la estación meteorológica, se puede discernir qué píxeles del mapa señalan la presencia de nubes que efectivamente bloquean la irradiación solar hacia la estación fotovoltaica, teniendo en cuenta una altura específica.

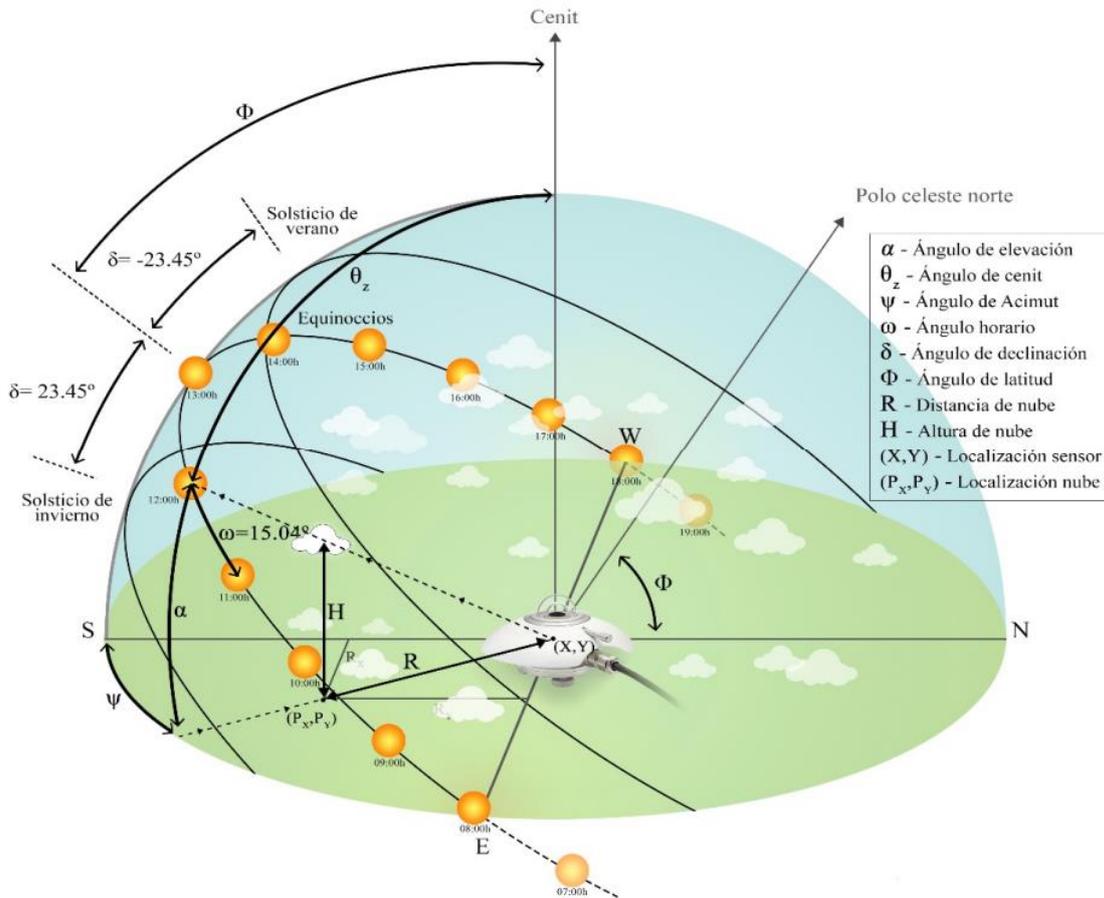


Figura 52: Posición del sol según la hora y definición de las variables más importantes para la adquisición del CCF. Fuente [1]

Para determinar si una nube obstruye o no la incidencia solar, como indica la **Figura 52**, es fundamental considerar dos parámetros clave:

Altura de la Nube (H): La altitud a la que se encuentra la nube puede influir en su capacidad para obstruir el sol. Una nube más cercana al suelo tendrá un impacto diferente en la irradiación solar que una nube que esté a gran altitud. Las nubes más bajas, como los estratos, tienden a bloquear más directamente la luz solar, mientras que las nubes altas, como los cirros, pueden tener un efecto de dispersión, incluso si están en el camino directo del sol.

Posición Relativa de la Nube (R): Esta posición se define en un plano bidimensional y se relaciona con la distancia horizontal de la nube respecto a la estación fotovoltaica. En este contexto, no es solo la presencia de la nube lo que importa, sino su ubicación específica en relación con la estación y el sol. Si, por ejemplo, la nube se encuentra directamente entre el sol y la estación fotovoltaica, su impacto en la irradiación solar será mayor que si estuviera situada a un lado, fuera del camino directo de la luz solar.

La combinación de estos dos parámetros permite obtener una representación más precisa de cómo las nubes afectan la irradiación solar en un punto específico. Es necesario considerar ambos factores en conjunto y aplicar modelos o algoritmos adecuados que integren esta información.

Con esto existe un problema el cual consiste en que los mapas de nubosidad, **Figura 10**, muestran únicamente la densidad de la nube (CCF) y su posición en el plano horizontal (P) **Figura 52**, pero no proporciona ninguna información sobre la altura a la que se encuentran las nubes, esto supone un problema por lo que se opta por seleccionar todas las nubes que puedan generar sombra sobre la estación fotovoltaica, independientemente de la altura.

El problema que surge es que los mapas de nubosidad, reflejados en la **Figura 10**, solo ofrecen detalles sobre la densidad de la nube (CCF) y su ubicación en el plano horizontal, según se puede ver en la **Figura 52**, omitiendo la altura de las nubes.

Al desconocer la altura a la que se encuentran las nubes, es no es posible determinar si efectivamente la nube bajo análisis obstruirá la luz solar en la estación fotovoltaica en un momento dado.

Para sortear este obstáculo, se ha tomado la decisión de adoptar un enfoque conservador: se seleccionan todas las nubes que, basándose en su posición horizontal, tienen el potencial de crear sombra sobre la estación fotovoltaica, sin importar la altura a la que se encuentren. Esta estrategia, aunque pueda resultar en la inclusión de nubes que no afectan realmente la irradiación solar, asegura que no se omiten nubes que sí tienen un impacto significativo.

Es importante tener en cuenta que este método, aunque práctico, puede llevar a una sobreestimación de los periodos de obstrucción solar, ya que todas las nubes detectadas en el plano horizontal serán consideradas como obstrucciones potenciales, independientemente de su altura.

Si bien los mapas de nubosidad de la AEMET es una buena fuente para analizar las condiciones atmosféricas, es importante tener en cuenta que la posición de las nubes posee una incertidumbre debido a la resolución de las imágenes satelitales [37], las imágenes pueden no capturar con precisión los detalles más finos de la distribución y el tipo de nubosidad, lo que resulta en una cierta cantidad de error.

Para abordar este problema y mejorar la confiabilidad de las predicciones, se opta por introducir un parámetro de incertidumbre, denotado como μ [1]. La incorporación de este parámetro permite una consideración más matizada de los datos de los mapas, ofreciendo una forma de contabilizar los posibles errores y variabilidades que no están claramente representados en los datos originales.

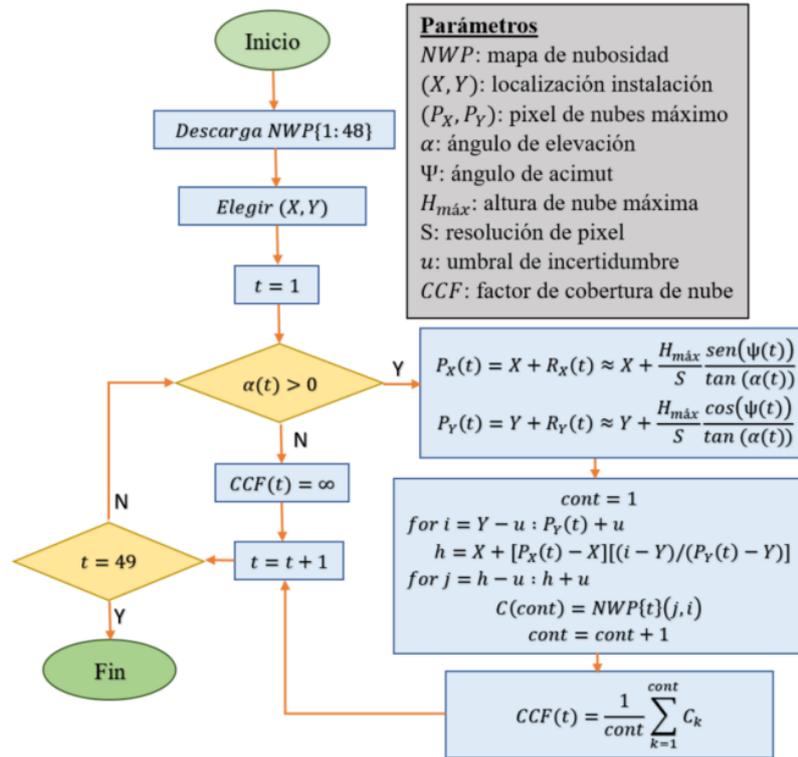
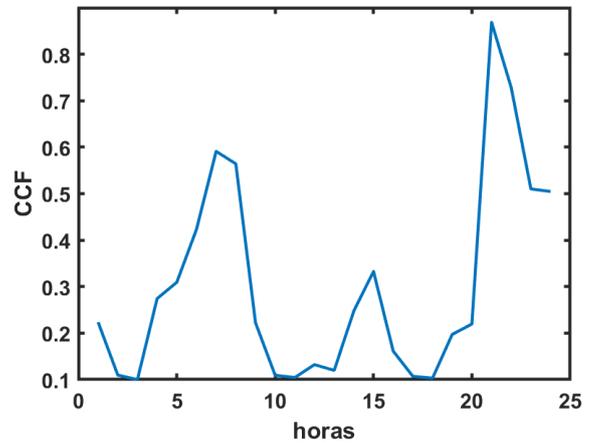
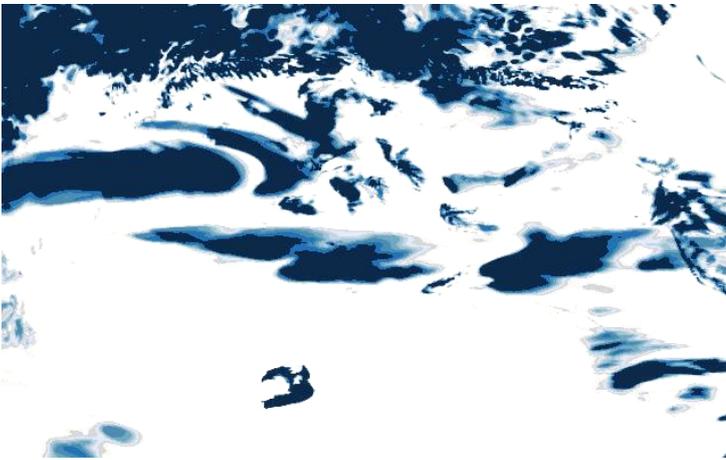


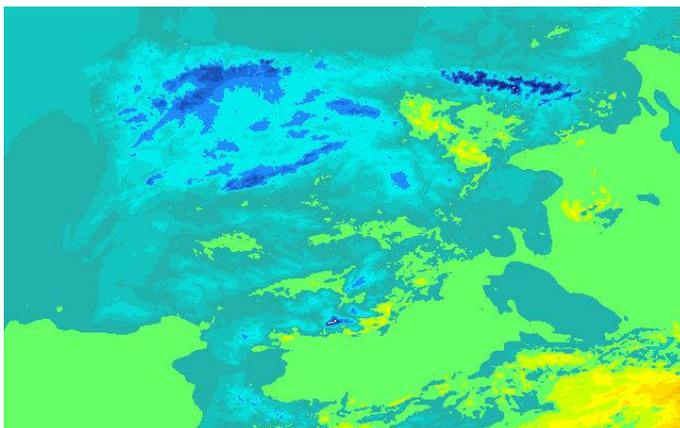
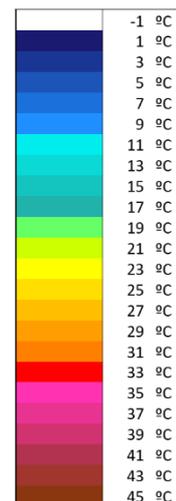
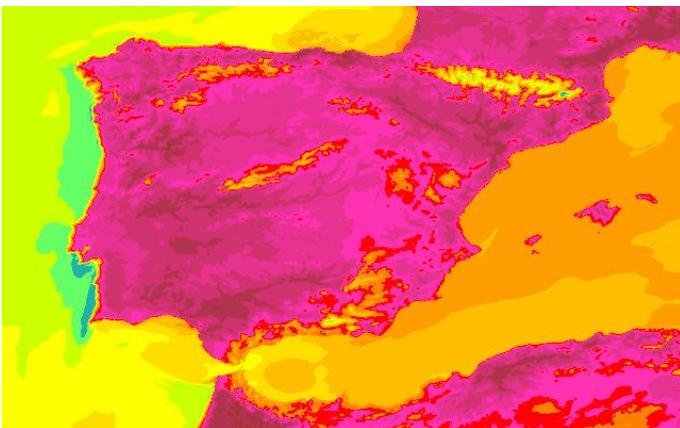
Figura 53: " Diagrama de bloques del procedimiento para obtener el CCF de los NWP."
Fuente [1]

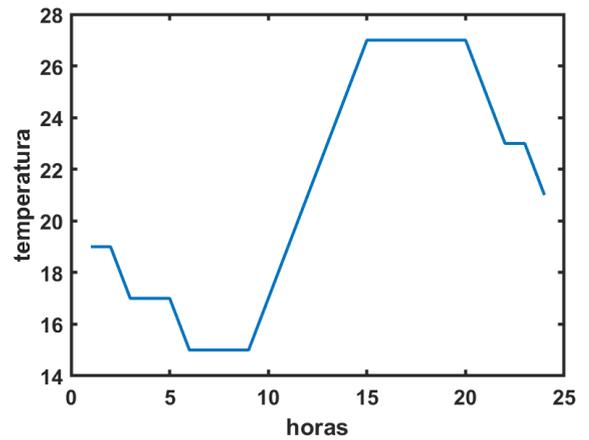
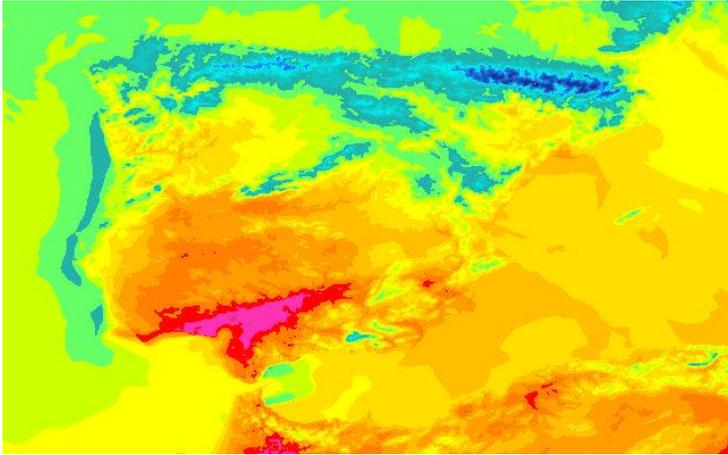


5.1.2 Procesamiento de la temperatura.

Otra variable crucial que puede obtenerse mediante el análisis de los mapas proporcionados por la AEMET es la temperatura ambiental, un factor que, según se destaca en el análisis de la **Figura 9**, debe tenerse muy en cuenta. En contraste con el análisis del CCF, el estudio de la temperatura ambiental presenta la ventaja de no requerir procesamientos adicionales, dado que el dato necesario se encuentra directamente en el plano horizontal.

Por lo tanto, la estrategia que se adoptará consistirá en diseñar una leyenda de colores, **Figura 57**, que esté directamente relacionada con distintos rangos de temperatura y a continuación leer el color correspondiente al píxel situados en la ubicación exacta de la estación fotovoltaica en el mapa, para así obtener una medición precisa y directa de la temperatura ambiental en ese punto específico.





5.2 Cálculo de potencia

Una vez completada la fase de predicción de la GHI conforme al horizonte temporal previamente definido, y posteriormente haber llevado a cabo la recopilación de las variables necesarias a través del análisis de los mapas proporcionados por la AEMET, se procede a la siguiente etapa del proyecto. Esta fase no es otra que la estimación precisa de la potencia que será generada por las placas solares instaladas.

Este apartado se estructura en cuatro fases críticas, cada una centrada en una etapa esencial en la determinación de la potencia generada por una instalación de paneles fotovoltaicos.

Cálculo de la componente horizontal de la irradiancia: Este primer paso está enfocado en determinar la cantidad de irradiación solar que llega horizontalmente a la superficie terrestre, un parámetro fundamental que influirá directamente en el rendimiento energético potencial de las placas.

Estimación de las pérdidas por suciedad y espectrales: En esta fase, se calcula la reducción de la irradiación efectiva debido a factores como la acumulación de suciedad en las placas y las pérdidas inherentes al espectro de luz que estas pueden absorber. Esto nos proporciona una visión realista de la irradiancia que efectivamente puede ser aprovechada por los paneles.

Determinación de la temperatura de los paneles: La temperatura operativa de los paneles fotovoltaicos es un factor significativo en su rendimiento. En esta etapa, se busca determinar la temperatura exacta a la que estarán operando los paneles, teniendo en cuenta las condiciones ambientales y otros factores externos.

Cálculo de la potencia generada mediante el modelo de Osterwald: En la fase final, se aplica el modelo de Osterwald, que será detallado más adelante, para calcular con precisión la potencia que los paneles pueden generar. Este modelo toma en cuenta todas

las variables y los factores determinados en las etapas anteriores, integrándolos en una fórmula que permite estimar la potencia de salida.

A través de este enfoque por etapas, nos aseguramos de considerar todos los elementos críticos que afectan el rendimiento de los paneles fotovoltaicos, permitiendo así una estimación más precisa y fundamentada de su potencia.

5.2.1 Cálculo de la componente horizontal de la irradiancia

Para calcular la irradiancia en el plano horizontal de los paneles se siguen tres pasos: primero, se determina la irradiancia difusa y directa horizontal usando la GHI predicha luego, se obtienen tres componentes de irradiancia en el plano de los paneles la irradiancia difusa, la directa y el albedo. Aunque generalmente se sumarían estas componentes para obtener la irradiancia global, en este caso, se necesita conocer las componentes individuales sin pérdidas asociadas para calcular la irradiancia efectiva.

5.2.1.1 Irradiancia directa y difusa

En el marco de la tesis doctoral presentada en [1] de la cual se ha basado esta parte del desarrollo del proyecto, para determinar la irradiancia horizontal difusa d_{hmo} es esencial conocer la fracción de difusa horizontal k_{dh} , la cual se obtiene a partir de la GHI mediante la fórmula:

$$d_{hmo} = k_{dh} * GHI$$

Esta fracción se puede calcular utilizando el índice de claridad horizontal k_{th} , que a su vez se determina por correlaciones empíricas descritas en [38]. El índice se calcula con el siguiente cociente:

$$k_{th} = GHI * b_{00}$$

Siendo b_{00} la radiación extraterrestre la cual se calcula con la excentricidad de la órbita ($\epsilon(n)$) y el ángulo cenital del sol (θ_s):

$$b_{00} = b_0 \cdot \epsilon(n) \cdot \cos(\theta_s(n))$$

$$\epsilon(n) = 1.00011 + 0.034221 * \cos(I(n)) + 0.00128 * \sin(I(n)) + 0.000719 * \cos(2I(n)) + 0.000077 * \sin(2I(n))$$

$$\theta_s(n) = \arccos(\sin(\delta(n)) * \sin(\Phi) + \cos(\delta(n)) * \cos(\Phi) * \cos(\omega))$$

Figura 61: Ecuación para el cálculo de la radiación extraterrestre. Obtenida de la tesis doctoral [1].

Para hallar la fracción de difusa horizontal a partir del índice de claridad se aplica la correlación proporcionada por [38], dando lugar a las siguientes expresiones condicionales:

$$\begin{aligned}
 k_{dh} &= 0.995 - 0.081 * k_{th} && \text{si } k_{th} \leq 0.21 \\
 k_{dh} &= 0.724 + 2.738 * k_{th} + 8.32 * k_{th}^2 + 4.967 * k_{th}^3 && \text{si } k_{th} \leq 0.76 \\
 k_{dh} &= 0.18 && \text{si } k_{th} > 0.76
 \end{aligned}$$

Para el cálculo final de la irradiancia directa horizontal (b_{hmo}):

$$b_{hmo} = GHI - d_{hmo} = GHI * (1 - k_{dh})$$

Cálculo de la irradiancia directa en el plano de los paneles (b_{hmi}):

$$b_{hmi} = \frac{b_{hmo}}{\theta_s}$$

5.2.1.2 Albedo

Para el albedo (a) se considera que $r_o = 0.2$ es el coeficiente de albedo [1] y β la inclinación de los paneles:

$$a = r_o * GHI * \frac{1 - \cos(\beta)}{2}$$

La determinación de la irradiancia difusa en el plano de los paneles (d_{hi}) se lleva a cabo a través del modelo establecido en [38]. Este procedimiento se desglosa en una componente isotrópica (d_{ii}) y una asociada con la radiación circunsolar (d_{ci}).

$$\begin{aligned}
 d_{hi} &= d_{ii} + d_{ci} \\
 d_{ii} &= d_{hmo} * (1 - k_1) * \frac{1 - \cos(\beta)}{2} \\
 d_{ci} &= \frac{d_{hmo} * k_1}{\cos(\beta)} \\
 k_1 &= \frac{b_{hmo}}{b_{00}}
 \end{aligned}$$

5.2.2 Estimación de las pérdidas por suciedad y espectrales

Para determinar la potencia entregada por el panel se debe calcular la irradiancia efectiva (G_{panel}). Este cálculo implica: el factor de ajuste del ángulo, que tiene en cuenta el aumento de la reflexión debido al ángulo de incidencia de la luz en el panel, y el factor de correlación espectral, que tiene en cuenta los cambios en la intensidad de la luz.

La irradiancia que llega a los paneles teniendo en cuenta las pérdidas angulares se modela como:

$$G_{ang} = a_{effect} + b_{effect} + d_{effect}$$

Todo el análisis previo para llegar a obtener la fórmula anterior se ha obtenido de [1].

Para calcular las pérdidas espectrales, se ha utilizado el procedimiento que se encuentra en [39]. Este punto de vista ajusta la dirección de la irradiancia al introducir un instrumento que se llama modificador de errores de espectro (f_{Ama}).

$$G_{panel} = f_{Ama} * (a_{effect} + b_{effect} + d_{effect})$$

$$f_{Ama} = (a_0 + a_1 * Ama + a_2 * Ama^2 + a_3 * Ama^3 + a_4 * Ama^4)$$

$$Ama = AM * e^{-0.0001184 * z}$$

$$AM = \frac{1}{(\cos(\theta_s) + 0.50572(96.07995 - 180 * \frac{\theta_s}{\pi}))^{-1.6364}}$$

Los valores de a_0, a_1, a_2, a_3 y a_4 se obtienen de la **Figura 62** siendo las placas solares de la instalación de la universidad de Alcalá de mc-Si

Coeficientes del método de Sandía						
Tecnología		a_0	a_1	a_2	a_3	a_4
2-a-Si	Media	8.8832e-01	1.5329e-01	-6.2913e-02	7.3055e-03	-2.9175e-04
	Moda	8.2392e-01	2.2748e-01	-8.8651e-02	1.1387e-02	-5.1542e-04
3-a-Si	Media	1.0470e+00	8.2115e-04	-2.5900e-02	3.1736e-03	-1.1026e-04
	Moda	1.0470e+00	8.2115e-04	-2.5900e-02	3.1736e-03	-1.1026e-04
CdTe	Media	9.4679e-01	5.8883e-02	-1.7872e-02	1.7536e-03	-6.7603e-05
	Moda	9.4170e-01	6.5160e-02	-2.0220e-02	2.1900e-03	-9.0700e-05
Si-Film	Media	9.2847e-01	7.2365e-02	-1.9025e-02	1.7040e-03	-4.9674e-05
	Moda	9.2800e-01	7.3144e-02	-1.9427e-02	1.7513e-03	-5.1288e-05
HIT-Si	Media	9.2715e-01	6.1518e-02	-9.8363e-03	6.1917e-04	-1.2734e-05
	Moda	9.2619e-01	6.2356e-02	-1.0119e-02	6.7031e-04	-1.6221e-05
EFG-mc-Si	Media	9.3600e-01	5.3645e-02	-7.9402e-03	5.2228e-04	-1.3142e-05
	Moda	9.3600e-01	5.3645e-02	-7.9402e-03	5.2228e-04	-1.3142e-05
CIS	Media	9.2100e-01	7.1817e-02	-1.4619e-02	1.2500e-03	-3.7403e-05
	Moda	9.2100e-01	7.1817e-02	-1.4619e-02	1.2500e-03	-3.7403e-05
mc-Si	Media	9.3017e-01	6.2992e-02	-1.2156e-02	9.4519e-04	-2.6000e-05
	Moda	9.2108e-01	7.5403e-02	-1.8481e-02	2.1538e-03	-1.0662e-04
c-Si	Media	9.3309e-01	5.9175e-02	-1.1066e-02	8.9574e-04	-2.8517e-05
	Moda	9.3800e-01	5.4230e-02	-9.9000e-03	7.3000e-04	-1.9100e-05

Figura 62: Valores promedios de los coeficientes para paneles de diferentes tecnologías. Fuente [40]

5.2.3 Determinación de la temperatura de los paneles

La temperatura de los paneles se ha determinado mediante [1] como:

$$T_{panel} = \frac{NOCT - 20^{\circ}C}{800} * G_{panel} + T_{amb}$$

La temperatura de funcionamiento nominal de la célula NOCT (Nominal Operating Cell Temperature) es de 45 grados Celsius para los componentes utilizados en la instalación.

5.2.4 Cálculo de la potencia generada mediante el modelo de Osterwald

La instalación opera en régimen de corriente continua, evitando de esta manera las pérdidas ordinarias asociadas a la transformación a energía alterna. Para calcular la potencia generada por los paneles (Ppv), se explorado el modelo clásico propuesto por Osterwald [41] dando la formula:

$$P_{DC} = P_{Som} * n_{dc} * P_{pico} * \frac{G_{panel}}{G_{std}} * (1 + \delta * Pm(T_{cell} - T_{cell std}))$$

Los valores P_{pico} , G_{std} , $\delta * Pm$ y n_{dc} son valores contantes los cuales tienen un valor de $P_{pico} = 2.97kW$ y $G_{std} = 1 \frac{kw}{m^2}$ en condiciones estándar. $\delta * Pm = -0.4 \frac{\%}{^{\circ}C}$ coeficiente temperatura a potencia máxima y $n_{dc} = 0.927$ que son las pérdidas por cableado.

A través del análisis desarrollado en esta sección, se ha alcanzado una estimación confiable de la potencia que las placas fotovoltaicas estarían en capacidad de generar.

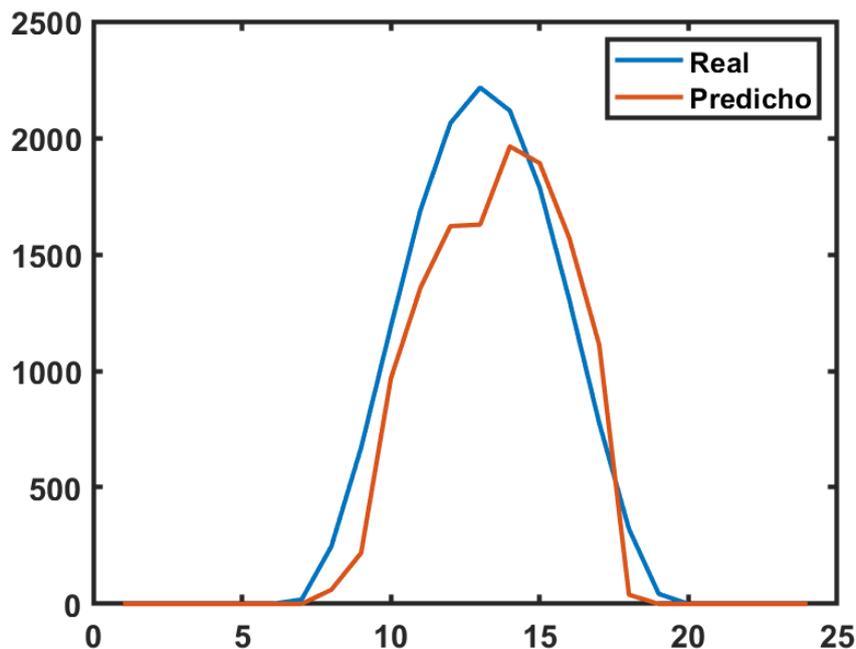


Figura 63: Potencia predicha frente a la real producida por la instalación fotovoltaica el día 30 de agosto de 2023

6 Estrategia de almacenamiento de energía en baterías. BEMS

6.1 Ubicación y Configuración de la Instalación

En la **Figura 64**, se ilustra la posición exacta de la instalación fotovoltaica que se encuentra emplazada en la Escuela Politécnica Superior de la Universidad de Alcalá. Específicamente, se destaca la disposición cenital de la instalación, brindando una visión clara del agrupamiento de los paneles solares.

La infraestructura está compuesta por un total de 9 módulos solares de tipo policristalino, cada uno con una potencia nominal de 330 W y compuestos por 72 células dispuestas en serie. Esta configuración resulta en una potencia pico agregada de 2.97 kW, que se logra mediante la disposición de los paneles en tres paralelos de tres unidades en serie cada uno.

El sistema alimenta un regulador MPPT que opera de manera continua y está ajustado a una tensión nominal de 48 V. Este aspecto garantiza una gestión óptima de la energía, maximizando la eficiencia en la conversión de energía solar a eléctrica.

A continuación, se llevará a cabo un análisis más profundo de los distintos elementos y variables que intervienen en el proceso de generación de energía.

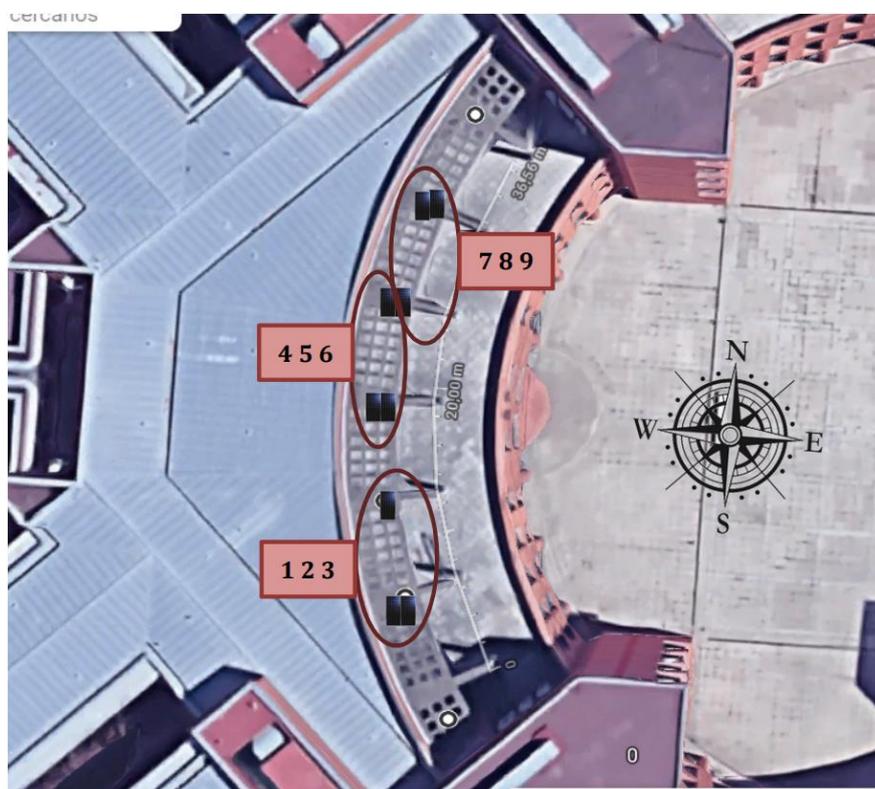


Figura 64: “Disposición de los paneles solares fotovoltaicos instalados en la Universidad de Alcalá, junto a su numeración y conexionado.” Fuente [1]

Adicionalmente a la instalación de paneles fotovoltaicos, la instalación está equipada con una estación meteorológica. La función principal de esta instalación es recolectar datos precisos del ambiente local que, a largo plazo, permitirán una mayor precisión en las predicciones de la potencia que será generada.

La estación meteorológica está compuesta por un conjunto de instrumentos sensoriales, los cuales consisten en un anemómetro, un PT100 y un piranómetro, diseñados para medir una serie de variables ambientales clave. En paralelo, se ha instalado una electrónica de adquisición especializada en la captación de datos meteorológicos directamente de los paneles solares.



Figura 68: Piranómetro. Fuente [1]

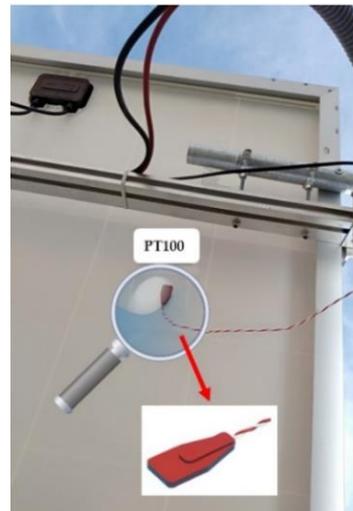
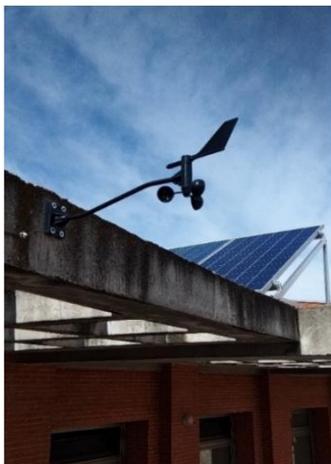


Figura 65: PT100 fijado al módulo. Fuente [1]



Esta configuración no solo permite monitorizar las condiciones meteorológicas predominantes, sino también llevar un control detallado del estado y desempeño de los paneles en tiempo real.

Con el tiempo, la estrategia se basará en la unión de los datos recopilados por la instalación meteorológica propia con los datos analizados en este trabajo, para así lograr una mejora significativa en las predicciones de potencia y una optimización en la gestión y mantenimiento de la instalación.

El corazón del sistema de almacenamiento de la instalación es un conjunto de baterías de ion de litio, una tecnología que se destaca por su alta densidad de energía y su larga vida útil. A continuación, se desglosan las características técnicas principales proporcionadas por el fabricante:

Voltaje nominal: 48V. Este es el voltaje estándar de operación del banco de baterías, el nivel al que se busca mantener durante su funcionamiento normal para garantizar una eficiencia óptima.

Voltaje de carga: Entre 52.5V y 53.5V. Este rango establece los límites dentro de los cuales se realiza la carga de las baterías, asegurando un llenado óptimo de la capacidad de almacenamiento disponible sin comprometer su integridad y durabilidad.

Corriente máxima: 100A. Esta es la corriente máxima que pueden manejar las baterías, estableciendo el límite superior para el flujo de corriente en cualquier operación de carga o descarga.

Capacidad: 148Ah. Representa la cantidad de carga eléctrica que puede almacenar el banco de baterías, un indicador crucial de la autonomía energética que puede ofrecer el sistema.

Energía almacenada: 7.10 kWh. Este valor señala la cantidad total de energía que el sistema de baterías puede almacenar, lo que determina la cantidad de energía que puede suministrar a la red o utilizar para alimentar cargas durante un período determinado.



6.2 Introducción a las BEMS

Este capítulo, que representa la finalización del proyecto, se desarrolló en el contexto del trabajo de investigación llevado a cabo en la tesis doctoral [1]. En él, se adopta y adapta la estrategia de gestión de baterías o BEMS, previamente delineada en dicha tesis, para satisfacer los objetivos de este proyecto. Mi aportación es caracterizar el modelo para las nuevas baterías de la instalación **Figura 69**.

La implementación de la estrategia BEMS permite una gestión óptima del almacenamiento de las energías renovables disponibles.

El BEMS [1] se encarga de utilizar las predicciones de potencia, obtenidas en el apartado [4.1](#) en la administración del uso de las baterías, estableciendo como criterio un único ciclo de carga y descarga diario. Esta estrategia, junto con el mantenimiento de los niveles de carga (State of Charge, SoC) en un rango entre 0.2 y 0.7, tiene el objetivo de extender la vida útil de las baterías.

La planta fotovoltaica permite la inyección de energía a la red eléctrica, además debido a esta capacidad, se ajusta una carga fija de 2 kW, incentivando que existan momentos donde la producción fotovoltaica supere la carga demandada. Esto da lugar a la implementación de un escenario optimizado, donde se generan excedentes de energía fotovoltaica que pueden destinarse tanto a la carga de baterías como a la inyección directa a la red eléctrica.

Para garantizar un funcionamiento segura y eficiente, se establece una corriente máxima de 80 A para el banco de baterías, operando a una tensión de 48 V. La determinación de los precios de compra y venta de energía se regirá según las previsiones y estrategias descritas en el apartado [4.2](#), permitiendo una gestión energética óptima para horizontes temporales futuros.

6.3 Análisis de las variables de la gestión de las baterías

A continuación, se detallan los diferentes elementos que se pueden observar en dentro de la **Figura 70** que representa la gestión de las baterías lograda con las predicciones de potencia y precios:

Líneas de precio de compra y venta de energía a la red: Diferenciadas mediante una línea roja continua (para el precio de compra) y una línea roja discontinua (para el precio de venta). Estas líneas han sido escaladas para facilitar su análisis en comparación con otros parámetros presentados.

Predicción de potencia fotovoltaica: Representada en verde, esta línea indica las predicciones de energía solar que se utilizarán como referencia para tomar decisiones estratégicas.

Potencia planificada para inyección a la red: Demarcada con un área rosa, muestra los períodos durante los cuales se planea inyectar energía en la red.

Demanda de potencia de las cargas fijas: Ilustrada en negro, esta línea refleja la energía requerida para satisfacer las cargas fijas de la instalación.

Planificación de carga y descarga de baterías: Indicada con áreas azules, delimitan los momentos designados para las fases de carga y descarga de las baterías.

Se establece que la ejecución de la predicción se realiza a las 3:00 a.m., sin embargo, dada la manera en que AEMET distribuye los mapas meteorológicos, sería óptimo realizar actualizaciones cada 6 horas. Esta estrategia no solo permite aprovechar la información más reciente, sino que también amplía el horizonte de la predicción, favoreciendo una planificación más precisa y adaptativa frente a posibles variaciones meteorológicas que puedan influir en la generación de energía fotovoltaica.

Es importante señalar que este caso de estudio se ha estructurado con una resolución temporal de una hora, debido a la limitación de que la predicción de precios es horaria, pero considerando esta franja es lo suficientemente precisa para llevar a cabo una optimización las.

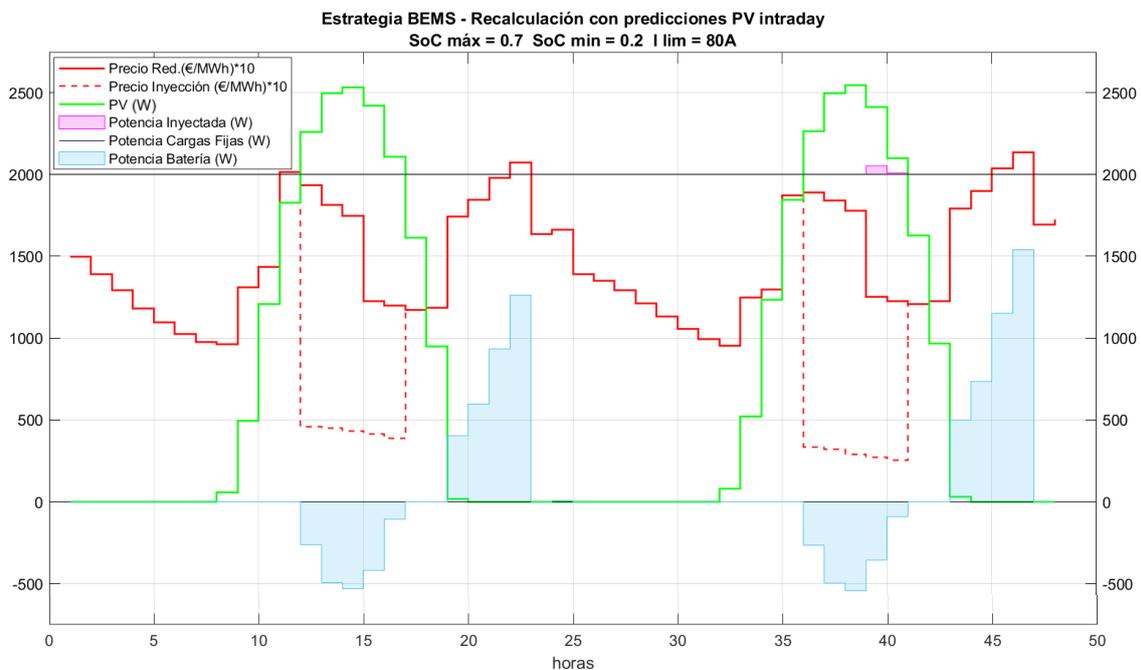
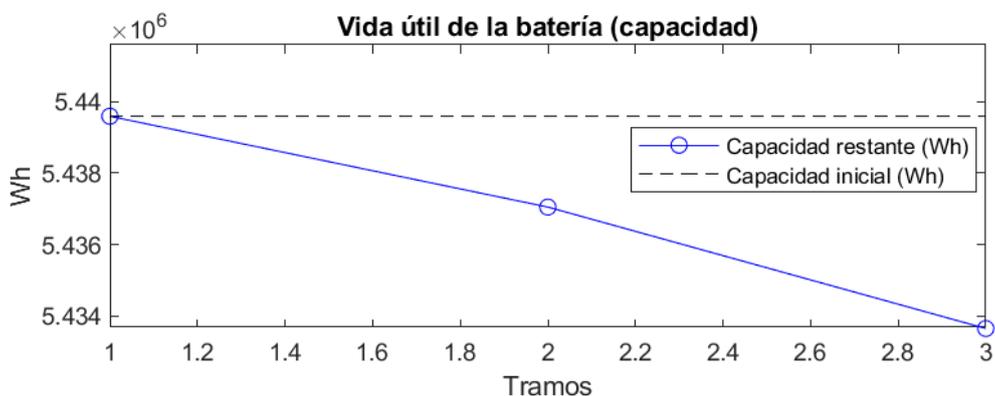
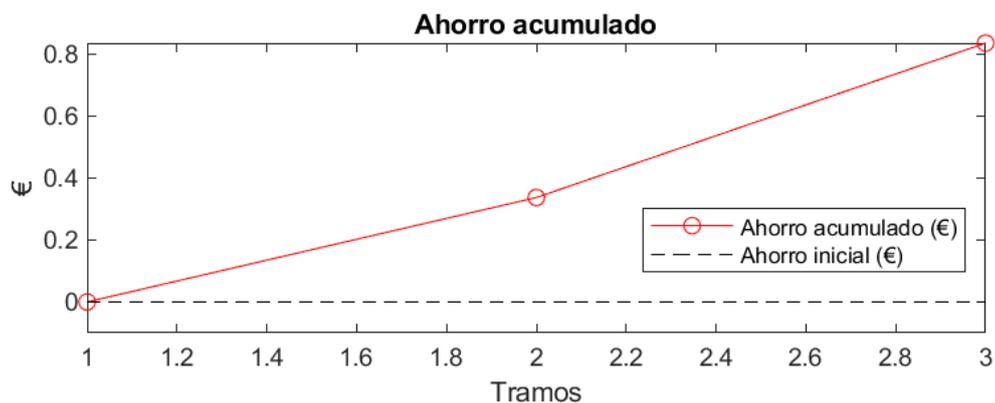


Figura 70: Estrategia ejemplo del BEMS para mostrar las distintas variables a analizar.

Como se observa en la **Figura 70** durante los dos días en cuestión, se establece un único ciclo de carga y descarga para optimizar la vida útil de las baterías, teniendo en cuenta la degradación que experimentan con cada ciclo de uso. La carga de las baterías se lleva a cabo utilizando el excedente de energía generado una vez que se ha satisfecho la demanda de las cargas fijas y asignado una cuota de energía para ser inyectada en la red eléctrica, seleccionando el momento óptimo (si lo hay) dentro del período de superávit energético.



Las **Figuras 71y 72** destaca dos aspectos cruciales del sistema de gestión de baterías: la durabilidad de la batería y el ahorro acumulativo alcanzado a través de la estrategia descrita en el apartado [6.3](#).

En lo que respecta a la vida útil de la batería, se identifica una tendencia de reducción gradual y estable durante los tres ciclos de carga y descarga, culminando en una degradación minúscula cercana al 0.1092%. Esto traduce a un desgaste anual del 19.93%, proyectando una vida útil de aproximadamente 3 años y medio antes de alcanzar una degradación del 70%. Estos resultados nos indican una estimación real de la vida útil de la batería, debido a que la muestra de los ciclos de carga y descarga obtenidos para los días bajo estudio.

En cuanto al ahorro económico acumulado en el periodo de tres días, se calcula en 0.80€. Aunque este dato, por sí solo, no permite proyectar con certeza el ahorro anual total, sí evidencia que la estrategia de almacenar y vender energía es efectiva para generar ahorros. A pesar de que la muestra es limitada y no permite llegar a conclusiones, se demuestra que la estrategia diseñada ofrece una ruta viable para optimizar el rendimiento económico del sistema.

6.4 Comparación con valores reales

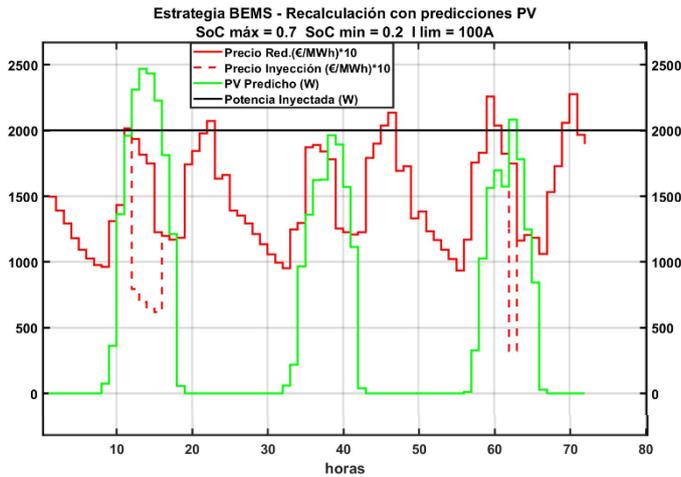


Figura 73: BEMS con valores predichos

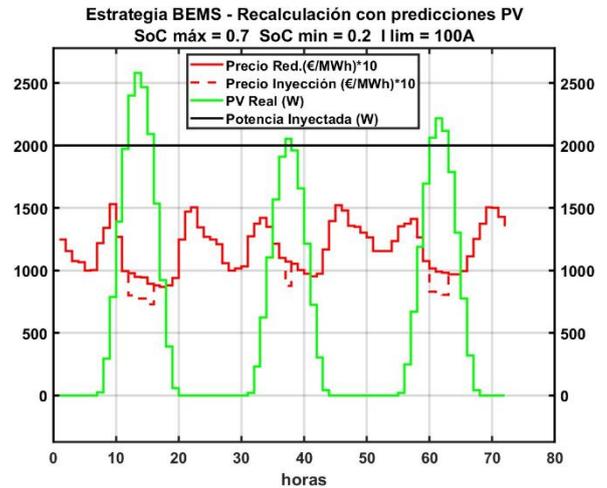


Figura 74: BEMS con valores reales

Al examinar los datos correspondientes a los días 29, 30 y 31 de agosto de 2023, es destacable que los valores predichos y reales, aunque no son idénticos, exhiben una notable similitud, siguiendo un patrón de comportamiento congruente en lo que respecta a los perfiles de generación de energía fotovoltaica.

En el primer día del periodo evaluado, la generación energética alcanzó su pico máximo. Con una disminución en la generación de energía en los dos días siguientes, mantiene una correlación positiva con las predicciones, superando, incluso, las estimaciones iniciales en términos de la cantidad de energía generada, aunque las proyecciones anticipaban una contribución menor.

7 Conclusiones

Como conclusiones de este Trabajo de Fin de Grado, se puede afirmar que las redes LSTM se perfilan como una de las herramientas más prometedoras para el pronóstico de series temporales asociadas a variables meteorológicas y la fluctuación en los precios de la electricidad. Durante el desarrollo de este proyecto, se evidenció que las predicciones tanto del GHI como de los precios eléctricos alcanzan un grado satisfactorio de precisión, considerando el horizonte de predicción establecido de tres días y la metodología de lazo cerrado implementada, que prescinde de la inserción de datos reales futuros para ajustar las predicciones en curso. Esta afirmación encuentra respaldo en el valor obtenido de RMSE medio de 17,6€/MW, en una escala de 140€/MW, para las predicciones de precios y un RMSE medio de 374.26 kW/m² para las de irradiancia destacando así la eficacia del modelo propuesto.

En lo que respecta a la administración de baterías, los resultados del estudio revelan que el uso de valores pronosticados facilita una comprensión preliminar y bastante aproximada tanto de los potenciales ahorros como del deterioro estimado en la vida útil de estos dispositivos. Sin embargo, se ha identificado una oportunidad significativa para afinar esta gestión, a través de la integración de predicciones intradiarias, permitiendo una optimización superior en la utilización de los recursos disponibles.

Esta identificación abre la puerta a futuras extensiones de este TFG, explorando la viabilidad de diseñar una estrategia que discrimine entre días de alta y baja generación fotovoltaica. Dicha estrategia permitiría focalizar la potencia computacional en aquellos períodos con mayor potencial de generación energética, desarrollando predicciones intradiarias que faciliten una gestión más refinada y, por ende, más eficiente de los recursos energéticos disponibles.

Se concluye, por tanto, que este TFG no solo ha logrado un avance considerable en la predicción de variables cruciales para la gestión energética mediante redes LSTM, sino que además ha sentado una sólida base para investigaciones futuras, que permitan llevar a cabo una explotación aún más óptima de los recursos energéticos renovables y los sistemas de almacenamiento de energía.

8 Bibliografía

[1] Moreno Baeza, G., & Guillermo. (2022). Prediction techniques adapted to the estimation of energy production of photovoltaic installations integrated in virtual power plants. Universidad de Alcalá, 143.

Retrieved from <http://hdl.handle.net/10017/53830>

[2] «Market Report Series: Renewables 2021. Analysis and forecasts for 2026. International Energy Agency (IEA),» 2021. [En línea]. Available: <https://www.iea.org/reports/renewables-2021>.

[3] M. Perez, R. Perez, K. R. Rábago y M. Putnam, «Overbuilding & curtailment: The cost-effective enablers of firm PV generation,» Solar Energy, vol. 180, pp. 412-422, 2019.

[4] B. Lin y J. Zhu, «The role of renewable energy technological innovation on climate change: Empirical evidence from China,» Science of the Total Environment, vol. 659, pp. 1505-1512, 2019.

[5] X. Li, D. Hui y X. Lai, «Battery energy storage station (BESS)-based smoothing control of photovoltaic (PV) and wind power generation fluctuations,» IEEE transactions on sustainable energy, vol. 4, n° 2, pp. 464- 473, 2013.

[6] M. Katsanevakis, R. A. Stewart y J. Lu, «Aggregated applications and benefits of energy storage systems with application-specific control methods: A review,» Renewable and Sustainable Energy Reviews, vol. 75, pp. 719-741, 2017.

[7] S. Grillo, M. Marinelli, S. Massucco y F. Silvestro, «Optimal management strategy of a battery-based storage system to improve renewable energy integration in distribution networks,» IEEE Transactions on Smart Grid, vol.

[8] D. Pudjianto, C. Ramsay y G. Strbac, «Virtual power plant and system integration of distributed energy resources,» IET Renewable power generation, vol. 1, n° 1, pp. 10-16, 2007.

[9] S. Ghavidel, L. Li, J. Aghaei, T. Yu y J. Zhu, «A review on the virtual power plant: Components and operation systems,» de IEEE International Conference on Power System Technology (POWERCON), Wollongong, NSW, Australia, 2016.

[10] H. Saboori, M. Mohammadi y R. Taghe, «Virtual power plant (VPP), definition, concept, components and types,» de Asia-Pacific Power and Energy Engineering Conference, Wuhan, China, 2011.

[11] K. Dielmann y A. van der Velden, «Virtual power plants (VPP)-a new perspective for energy generation?,» de Proceedings of the 9th International Scientific and Practical Conference of Students, Post-graduates Modern Techniques and Technologies, Tomsk, Rusia, 2003.

- [12] K. El Bakari y W. L. Kling, «Virtual power plants: An answer to increasing distributed generation,» de 2010 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT Europe), Gotemburgo, Suecia, 2010.
- [13] C. Tarazona, M. Muscholl, R. Lopez y J. C. Passelergue, «Integration of distributed energy resources in the operation of energy management systems,» de 2009 IEEE PES/IAS Conference on Sustainable Alternative Energy (SAE), Valencia, España, 2009.
- [14] P. Lombardi, M. Powalko y K. Rudion, «Optimal operation of a virtual power plant,» de 2009 IEEE Power & Energy Society General Meeting, Calgary, Canadá, 2009. 134
- [15] D. Hropko, J. Ivanecký y J. Turček, «Optimal dispatch of renewable energy sources included in virtual power plant using accelerated particle swarm optimization,» de 2012 ELEKTRO, Rajecské Teplice, Eslovaquia, 2012.
- [16] E. Mashhour y S. Moghaddas-Tafreshi, «Trading models for aggregating distributed energy resources into virtual power plant,» de 2nd International Conference on Adaptive Science & Technology (ICAST), Accra, Ghana, 2009.
- [17] T. Sikorski, M. Jasiński, E. Ropuszyńska-Surma, M. Węglarz, D. Kaczorowska, P. Kostyla, Z. Leonowicz, R. Lis, J. Rezmer, W. Rojewski, M. Sobierajski, J. Szymanda, D. Bejmert, P. Janik y B. Solak, «A case study on distributed energy resources and energy-storage systems in a virtual power plant concept: Technical aspects,» *Energies*, vol. 13, n° 12, p. 3086, 2020.
- [18] P. Lombardi, M. Stötzer, Z. Styczynski y A. Orths, «Multi-criteria optimization of an energy storage system within a Virtual Power Plant architecture,» de 2011 IEEE Power and Energy Society General Meeting, Detroit, Michigan, EE.UU., 2011.
- [19] L. Nikonowicz y J. Milewski, «Virtual power plants-general review: structure, application and optimization,» *Journal of power technologies*, vol. 92, n° 3, p. 135, 2012.
- [20] M. Salmani, S. Tafreshi y H. Salmani, «Operation optimization for a virtual power plant,» de 2009 IEEE PES/IAS Conference on Sustainable Alternative Energy (SAE), Valencia, España, 2009.
- [21] U. K. Das, K. S. Tey, M. Seyedmahmoudian, S. Mekhilef, M. Y. I. Idris, W. Van Deventer, B. Horan y A. Stojcevski, «Forecasting of photovoltaic power generation and model optimization: A review,» *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 912-928, 2018.
- [22] M. Kudo, A. Takeuchi, Y. Nozaki, H. Endo y J. Sumita, «Forecasting electric power generation in a photovoltaic power system for an energy network,» *Electrical Engineering in Japan*, vol. 167, n° 4, pp. 16-23, 2009.
- [23] M. Q. Raza y C. Ekanayake, «On recent advances in PV output power forecast,» *Solar Energy*, vol. 136, pp. 125-144, 2016.
- [24] C. Wan, J. Zhao, Y. Song, Z. Xu, J. Lin y Z. Hu, «Photovoltaic and solar power forecasting for smart grid energy management,» *CSEE Journal of Power and Energy Systems*, vol. 1, n° 4, pp. 38-46, 2015.

[25] L. Massidda y M. Marrocu, «Smart meter forecasting from one minute to one year horizons,» *Energies*, vol. 11, nº 12, p. 3520, 2018.

[26] M. Diagne, M. David, P. Lauret, J. Boland y N. Schmutz, «Review of solar irradiance forecasting methods and a proposition for small-scale insular grids,» *Renewable and Sustainable Energy Reviews*, vol. 27, pp. 65-76, 2013.

[27] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martínez-de-Pison y F. Antonanzas-Torres, «Review of photovoltaic power forecasting,» *Solar energy*, vol. 136, pp. 78-111, 2016.

[28] «Copernicus Atmosphere Monitoring Service (CAMS) radiation service provides time series of Global, Direct, and Diffuse Irradiations on horizontal surface, and Direct Irradiation on normal plane (DNI) for the actual weather conditions as well as for clear-sky conditions. The geographical coverage is the field-of-view of the Meteosat satellite, roughly speaking Europe, Africa, Atlantic Ocean, Middle East (-66° to 66° in both latitudes and longitudes). Time coverage is 2004-02-01 up to 2 days ago» [En línea]. Available: <https://www.soda-pro.com/web-services/radiation/cams-radiation-service>

[29] «Agencia Estatal de Meteorología (AEMET) Modelo numérico de predicción meteorológica,» [En línea].

Available:

http://www.aemet.es/es/eltiempo/prediccion/modelosnumericos/harmonie_aro_me_ccaa?opc2=mad

[30] «ERA5 is the fifth generation ECMWF reanalysis for the global climate and weather for the past 8 decades. Data is available from 1940 onwards. ERA5 replaces the ERA-Interim reanalysis. » [En línea].

Available: <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=overview>

[31] «¿Qué es el error cuadrático medio RMSE?» [En línea].

Available: [https://acolita.com/que-es-el-err-\(Española & , 2023\)or-cuadratico-medio-rmse/](https://acolita.com/que-es-el-err-(Española-&,2023)or-cuadratico-medio-rmse/)

[32] Unai Casado Galdeano, Macarena Larrea Basterra «Determinantes del precio de la electricidad en España» *Estadística Española • Volumen 59, número 194 / 2017*, pp. 119-149 (2023).

[33] «ESIOS generación media» [En línea].

Available: <https://www.esios.ree.es/es/insertado/generacion-medida?date=17-05-2023>

[34] «Red Eléctrica publica los precios de la electricidad de la nueva tarifa para el pequeño consumidor» [En línea].

Available: <https://www.ree.es/es/sala-de-prensa/actualidad/nota-de-prensa/2021/05/red-electrica-publica-los-precios-de-la-nueva-tarifa-pequeno->

[consumidor#:~:text=El%20operador%20del%20sistema%20el%C3%A9ctrico,vigor%20ma%C3%B1ana%2C%201%20de%20junio.](#)

[35] «PREVISIÓN DE LA PRODUCCIÓN EÓLICA PENINSULAR» [En línea].

Available: https://www.esios.ree.es/es/analisis/541?vis=1&start_date=13-08-2023T00%3A00&end_date=13-08-2023T23%3A55&compare_start_date=12-08-2023T00%3A00&groupby=minutes15

[36] «GENERACIÓN PREVISTA SOLAR» [En línea]

Available: https://www.esios.ree.es/es/analisis/10034?vis=1&start_date=13-08-2023T00%3A00&end_date=13-08-2023T23%3A55&compare_start_date=12-08-2023T00%3A00&groupby=minutes15

[37] A. Feijt y P. De Valk, «The use of NWP model surface temperatures in cloud detection from satellite, » International Journal of Remote Sensing, vol. 22, nº 13, pp. 2571-2584, 2001.

[38] S. E. Berrizbeitia, E. Jadraque Gago y T. Muneer, «Empirical Models for the Estimation of Solar Sky-Diffuse Radiation. A Review and Experimental Analysis,» Energies, vol. 13, nº 3, p. 701, 2020.

[39] J. A. Kratochvil, W. E. Boyson y D. L. King, Photovoltaic array performance model, Albuquerque y Livermore, EE.UU.: Sandia National Laboratories 140 (SNL), 2004.

[40] S. Rodríguez, «Influencia de las variaciones espectrales en la corriente de cortocircuito de módulos fotovoltaicos. Trabajo de Fin de Grado de la Universidad de Alcalá en el departamento de Teoría de la Señal y Comunicaciones. Tutor: Peña, R.,» 2016. [En línea].

Available:

https://github.com/sandialabs/MATLAB_PV_LIB/tree/master/Example%20Data.

[41] «Redes neuronales de memoria de corto-largo plazo» [En línea].

Available: <https://es.mathworks.com/help/deeplearning/ug/long-short-term-memory-networks.html>

[42] «Pylontech Force L2 48V 10.65kWh Managed Battery System (3 Cassettes + BMS Controller and Base)» [En línea]

Available: [Force-L2-48-222 Force L2 48V 10.65kWh Managed Battery System \(3 Cassettes + BMS Controller and Base\) CE, TÜV, UL, RoHS, UN38.3, IEC62619, IEC62040, IEC62477, IEC61000-6-2, IEC61000-3 \(master-instruments.com.au\)](#)

[43] M. Ding, L. Wang y R. Bi, «An ANN-based approach for forecasting the power output of photovoltaic system,» Procedia Environmental Sciences, vol. 11, pp. 1308-1315, 2011.

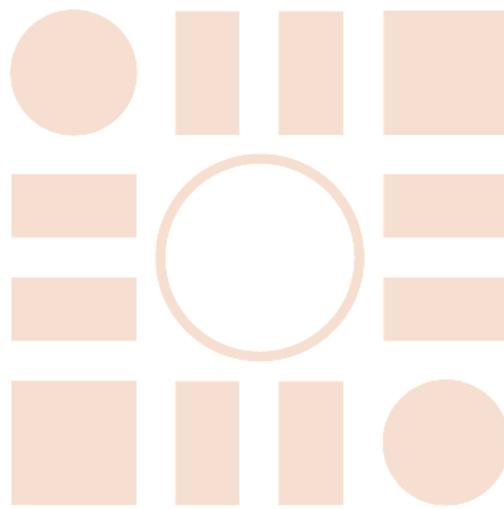
- [44] Y. Zhang, M. Beaudin, R. Taheri, H. Zareipour y D. Wood, «Day-ahead power output forecasting for small-scale solar photovoltaic electricity generators,» IEEE Transactions on Smart Grid, vol. 6, n° 5, pp. 2253-2262, 2015.
- [45] J. G. D. S. Fonseca Junior, T. Oozeki, H. Ohtake, T. Takashima y O. Kazuhiko, «On the use of maximum likelihood and input data similarity to obtain prediction intervals for forecasts of photovoltaic power generation,» Journal of Electrical Engineering and Technology, vol. 10, n° 3, pp. 1342- 1348, 2015.
- [46] E. Akarslan y F. O. Hocaoglu, «A novel method based on similarity for hourly solar irradiance forecasting,» Renewable Energy, vol. 112, pp. 337-346, 2017.
- [47] C. Du y Z. Liu, «Solar irradiance interval prediction based on set pair analysis theory,» Energy Science and Applied Technology, 2016.
- [48] P. Mandal, T. Senjyu, N. Urasaki, T. Funabashi y A. K. Srivastava, «A novel approach to forecast electricity price for PJM using neural network and similar days method,» IEEE Transactions on Power Systems, vol. 22, n° 4, pp.
- [49] X. Zhang, B. Jiang, X. Zhang, F. Fang, Z. Gao y T. Feng, «Solar photovoltaic power prediction based on similar day approach,» de 2017 36th Chinese Control Conference (CCC), Dalian, China, 2017.
- [50] C. Monteiro, T. Santos, L. A. Fernandez-Jimenez, I. J. Ramirez-Rosado y M. S. Terreros-Olarte, «Short-term power forecasting model for photovoltaic plants based on historical similarity,» Energies, vol. 6, n° 5, pp. 2624-2643, 2013.
- [51] Toshiba Energy Systems & Solutions Corporation [En línea]
Available: <https://www.global.toshiba/ww/products-solutions/renewable-energy/products-technical-services/vpp.html>
- [52] Z. Li, K. Wang, C. Li, M. Zhao y J. Cao, «Multimodal Deep Learning for Solar Irradiance Prediction,» de 2019 International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData), Atalanta, Georgia, EE.UU., 2019.
- [53] S. Makridakis, E. Spiliotis y V. Assimakopoulos, «Statistical and Machine Learning forecasting methods: Concerns and ways forward,» PloS one, vol. 13, n° 3, p. e0194889, 2018.
- [54] F. Wang, Z. Zhang, J. Li, Z. Zhen y K. Li, «Wavelet decomposition and convolutional LSTM networks based improved deep learning model for solar irradiance forecasting,» applied sciences, vol. 8, n° 8, p. 1286, 2018.
- [55] G. Li, H. Wang, S. Wang, J. Xin y H. Liu, «Recurrent neural networks based photovoltaic power forecasting approach,» Energies, vol. 12, n° 13, p. 2538, 2019.

- [56] V. Cerqueira, L. Torgo y C. Soares, «Machine learning vs statistical methods for time series forecasting: Size matters,» arXiv preprint, p. arXiv:1909.13316, 2019.
- [57] C. Voyant, G. Notton, S. Kalogirou, M. L. Nivet, C. Paoli, F. Motte y A. Fouilloy, «Machine learning methods for solar radiation forecasting: A 137 review,» *Renewable Energy*, vol. 105, pp. 569-582, 2017.
- [58] V. Kostylev y A. Pavlovski, «Solar power forecasting performance—towards industry standards,» de 1st international workshop on the integration of solar power into power systems, Aarhus, Dinamarca, 2011.
- [59] R. A. Rajagukguk, R. A. Ramadhan y H. J. Lee, «A Review on Deep Learning Models for Forecasting Time Series Data of Solar Irradiance and Photovoltaic Power,» *Energies*, vol. 13, n° 24, p. 6623, 2020.
- [60] A. Mellit y S. A. Kalogirou, «Artificial intelligence techniques for photovoltaic applications: A review,» *Progress in energy and combustion science*, vol. 34, n° 5, pp. 574-632, 2018.
- [61] Y. Y. Hong, J. J. F. Martinez y A. C. Fajardo, «Day-ahead solar irradiation forecasting utilizing gramian angular field and convolutional long short-term memory,» *IEEE Access*, vol. 8, pp. 18741-18753, 2020.
- [62] E. Lorenz, J. Hurka, G. Karampela, D. Heinemann, H. Beyer y M. Schneider, «Qualified forecast of ensemble power production by spatially dispersed gridconnected PV systems,» de 23rd European Photovoltaic Solar Energy Conference, Valencia, España, 2008.
- [63] X. Qing y Y. Niu, «Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM,» *Energy*, vol. 148, pp. 461-468, 2018.
- [64] C. R. Osterwald, «Translation of device performance measurements to reference conditions,» *Solar cells*, vol. 18, n° 3-4, pp. 269-279, 1986.
- [65] D. F. Menicucci, «Photovoltaic array performance simulation models,» de PV and Isolation Measurements Workshop, Vail, Colorado, EE.UU., 1985.
- [66] B. Marion, «Comparison of predictive models for photovoltaic module performance,» de 2008 33rd IEEE Photovoltaic Specialists Conference, San Diego, California, EE.UU., 2008.
- [67] R. Peña, A. M. Diez-Pascual, P. G. Díaz y L. V. Davoise, «A new method for current–voltage curve prediction in photovoltaic modules,» *IET Renewable Power Generation*, vol. 15, n° 6, pp. 1331-1343, 2021.
- [68] B. Marion, S. Rummel y A. Anderberg, «Current–voltage curve translation by bilinear interpolation,» *Progress in Photovoltaics: Research and Applications*, vol. 12, n° 8, pp. 593-607, 2004.

[69] « Total cloud cover High resolution forecast» [En línea]

Available:https://charts.ecmwf.int/products/medium-clouds?base_time=202309190000&projection=opencharts_europe&valid_time=202309190000

Universidad de Alcalá
Escuela Politécnica Superior



ESCUELA POLITECNICA
SUPERIOR



Universidad
de Alcalá