



**Diseño de una solución para la predicción a corto plazo de radiación solar en la
región de la Comunidad de Castilla y León, España, para la gestión de
proyectos de generación fotovoltaica**

Moisés Alfonso Guerrero Jiménez
Andrés Castaño Licona

Monografía presentada para optar al título de Especialista en Analítica y Ciencia de Datos

Asesor
Walter Mauricio Villa Acevedo, Dr.-Ing
Álvaro Jaramillo Duque, Ph.D

Universidad de Antioquia
Facultad de Ingeniería
Especialización en Analítica y Ciencia de Datos
Medellín, Antioquia, Colombia
2024

Cita	(Guerrero Jiménez & Castaño Licona, 2024)
Referencia	Guerrero Jiménez, M. A., & Castaño Licona, A. (2024). <i>Diseño de una solución para la predicción a corto plazo de radiación solar en la región de la Comunidad de Castilla y León, España, para la gestión de proyectos de generación fotovoltaica</i> Trabajo de grado especialización. Universidad de Antioquia, Medellín, Colombia.
Estilo APA 7 (2020)	



Especialización en Analítica y Ciencia de Datos, Cohorte VI.
 Centro de Investigación Ambientales y de Ingeniería (CIA).



Centro de Documentación Ingeniería (CENDOI)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: John Jairo Arboleda Céspedes.

Decano/Director Julio Cesar Saldarriaga Molina.

Jefe departamento: Diego José Luis Botia Valderrama.

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

A Dios y a mi familia. (Moisés)

A Faro y Willy, que siempre han estado y estarán. (Andrés)

Agradecimientos

A nuestros asesores y profesores por su acompañamiento y enseñanza.

Índice

Resumen	10
Abstract	11
1 Descripción del problema	12
1.1 Problema de negocio	14
1.2 Aproximación desde la analítica de datos	15
1.3 Origen de los datos	18
1.4 Métricas de desempeño	20
2 Objetivos	24
2.1 Objetivo general	24
2.2 Objetivos específicos	24
3 Datos	25
3.1 Datos originales	25
3.2 Datasets	27
3.3 Analítica descriptiva	32
4 Proceso de analítica.	37
4.1 Pipeline principal	37
4.2 Preprocesamiento	39
4.3 Modelos	41
4.4 Métricas	42

5	Metodología	45
5.1	Baseline	45
5.2	Validación	46
5.3	Iteraciones y evolución	47
5.4	Validación cruzada	47
5.5	Herramientas	48
6	Resultados y discusión	50
6.1	Resultados de los mejores modelos por día	50
6.2	Análisis promedio de los modelos	55
6.3	Validación cruzada con TimeSeriesSplit	57
6.4	Modelo Lag Llama	59
6.5	Discusión de resultados	60
7	Conclusiones	64
8	Recomendaciones	66
	Referencias	68
A	Métricas de los modelos entrenados para cada período	71

Lista de tablas

1	Comparación de modelos para predicción de radiación solar	19
2	Listado de archivos disponibles en la base de datos de Zenodo	25
3	Estaciones meteorológicas con menor cantidad de filas con valores nulos . . .	27
4	Descripción estadística de cada una de las variables del conjunto de datos . .	32
5	Valores de las ventanas de observación	41
6	Valores de la superposición	41
7	Combinaciones de ventanas de observación y superposición	47
8	Listado de fechas para las pruebas de validación	50
9	Métricas mejor modelo día de invierno.	51
10	Métricas mejor modelo día de primavera.	52
11	Métricas mejor modelo día de verano.	53
12	Métricas mejor modelo día de otoño.	54
13	Métricas mejor modelo promedio.	55
14	Métricas peor modelo promedio.	56
15	Resultados del mejor modelo tras validación cruzada	57
16	Resultados del peor modelo tras validación cruzada	58
17	Métrica del modelo con mejor desempeño medio Vs. Lag Llama	60

Lista de figuras

1	a) Ubicación de las 37 estaciones al norte de España b) Códigos de estación y sus ubicaciones c) Estaciones cercanas a AV01 dentro del conjunto de datos .	28
2	Comparación de variables AV01 y SG02 entre el 18 y 23 de febrero de 2003 .	29
3	Correlación líneal de Pearson para las variables meteorológicas medidas en la estación AV01 comparadas con SG02	30
4	Resultados de la imputación de datos de la estación AV01	31
5	Distribuciones de las variables del conjunto de datos	33
6	Matriz de correlación de las variables incluidas en el conjunto de datos . . .	34
7	GHI vs TOA a través del tiempo entre el 30 de abril y el 5 de mayo de 2008	35
8	GHI vs TOA durante el año 2008 para las 24 horas del día	35
9	Pipeline para la predicción de la radiación solar	37
10	Arquitectura de modelos 1.	43
11	Arquitectura de modelos 2.	44
12	Esquema de validación cruzada TimeSeriesSplit	48
13	Gráfica de predicción para el periodo de invierno el 1 de enero de 2008. . . .	51
14	Gráfica de predicción para el periodo de primavera el 1 de abril de 2008. . .	52
15	Gráfica de predicción para el periodo de verano el 1 de julio de 2008.	53
16	Gráfica de predicción para el periodo de otoño el 1 de octubre de 2008. . . .	54
17	Gráfica de predicción para el 1 de enero de 2008 mejor modelo promedio. . .	55
18	Gráfica de predicción para el 1 de enero de 2008 peor modelo promedio. . . .	56

19	Gráfica de predicción posterior a validación cruzada para el mejor modelo promedio.	57
20	Gráfica de predicción posterior a validación cruzada para el peor modelo promedio.	58
21	Predicción del modelo Lag Llama	61
22	Predicción del modelo con mejor desempeño medio	61

Siglas, acrónimos y abreviaturas

RNN	Recurrent Neural Networks
LSTM	Long Short-Term Memory
GRU	Gated Recurrent Units
CNN	Convolutional Neural Networks
MAE	Mean Absolute Error
MSE	Mean Squared Error
MAPE	Mean Absolute Percentage Error
sMAPE	Symmetric Mean Absolute Percentage Error
GHI	Global Horizontal Irradiance
TOA	Top of Atmosphere Radiation
UdeA	Universidad de Antioquia

Resumen

La energía solar fotovoltaica es una de las principales soluciones para mitigar el cambio climático. Sin embargo, la variabilidad de la radiación solar percibida por los paneles solares presenta un desafío técnico y operacional significativo. Esta variabilidad se debe a la interacción de la luz solar con la atmósfera, resultando en una radiación solar percibida diferente a la teórica. Esta monografía aborda la predicción de la radiación solar a diferentes escalas temporales, utilizando datos de una estación meteorológica en Castilla y León, España, para el período 2002-2010.

Para realizar las predicciones, se emplean Redes Neuronales Recurrentes (RNN), Long Short-Term Memory (LSTM) y Gated Recurrent Units (GRU). El desempeño de estos modelos se evalúa mediante métricas usadas comúnmente en la evaluación del desempeño de técnicas de aprendizaje profundo como el Error Absoluto Medio (MAE), el Error Cuadrático Medio (MSE) y el Error Porcentual Absoluto Medio (MAPE), permitiendo comparar la precisión y exactitud de las predicciones entre los distintos modelos.

Palabras clave: energía solar fotovoltaica, radiación solar, predicción, redes neuronales recurrentes, LSTM, GRU, aprendizaje profundo.

El repositorio de este proyecto puede encontrarse en el siguiente link: [Repositorio de GitHub](#)

Abstract

Photovoltaic solar energy is one of the main solutions to mitigate climate change. However, the variability of solar radiation perceived by solar panels presents a significant technical and operational challenge. This variability is due to the interaction of sunlight with the atmosphere, resulting in perceived solar radiation different from the theoretical one. This monograph addresses the prediction of solar radiation at different temporal scales, using data from a weather station in Castilla y León, Spain, for the period 2002-2010.

To make the predictions, Recurrent Neural Networks (RNN), Long Short-Term Memory (LSTM), and Gated Recurrent Units (GRU) are employed. The performance of these models is evaluated using deep learning metrics such as Mean Absolute Error (MAE), Mean Squared Error (MSE), and Mean Absolute Percentage Error (MAPE), allowing for a comparison of the precision and accuracy of the predictions among the different models.

Keywords: photovoltaic solar energy, solar radiation, prediction, recurrent neural networks, LSTM, GRU, deep learning.

The repository of this project can be found at the following link: [GitHub Repository](#)

1 Descripción del problema

La actual crisis climática es uno de los problemas más complejos e importantes a los que se enfrenta la humanidad. Los efectos del cambio climático están teniendo un fuerte impacto en el planeta y en la vida humana: aumento del nivel del mar, intensificación de los fenómenos meteorológicos extremos (lluvias, sequías, oleadas de calor, huracanes), cambios en los patrones de precipitación, son solo algunos de los ejemplos más nombrados ([Jentsch and Beierkuhnlein, 2008](#)).

Uno de los principales motores del cambio climático son los gases de efecto invernadero (GEI) que se emiten de manera más acelerada en la atmósfera desde la era industrial. Una de las fuentes de emisiones de GEI son las centrales térmicas, que utilizan combustibles fósiles para la generación de energía ([Stern and Kaufmann, 2013](#)).

En este contexto, las energías renovables, como la energía solar, eólica e hidráulica, son una alternativa que de adoptarse a gran escala podrían contribuir a la mitigación del cambio climático ([Panwar et al., 2011](#)). Estas, comparadas con las energías convencionales, son más limpias, renovables y, en muchos casos, más asequibles ([Verbruggen et al., 2010](#)).

En particular la transición o mayor implementación de energía renovable a partir de la radiación solar, también llamada energía solar fotovoltaica, supone un gran desafío en aspectos técnicos y operacionales. Uno de ellos está relacionado con la variabilidad de la radiación solar que perciben los paneles solares, puesto que la radiación teórica es diferente a la radiación solar percibida, afectada principalmente por la interacción de la luz con la atmósfera ([Sehrawat et al., 2023](#)).

Radiación solar teórica

Según [Whiteman and Allwine \(1986\)](#) la radiación solar extraterrestre es el término que recibe la radiación electromagnética emitida por el sol y que llega a la tierra. La radiación que percibe un punto en la tierra depende de varios factores, incluyendo la latitud, longitud y día del año. Por ejemplo, los puntos más cercanos al ecuador geográfico reciben en promedio más radiación solar extraterrestre que los puntos más cercanos a los polos, esto debido a la inclinación de la tierra sobre su eje de rotación. La longitud no tiene un efecto directo sobre la cantidad de radiación solar que percibe un punto, sin embargo, se utiliza como referencia para estimar la zona horaria y la franja del día en la que se percibe luz solar.

El día del año también influye en la cantidad de radiación solar que percibe un punto, por lo menos de dos maneras. En primer lugar, la tierra describe una órbita alrededor del sol en forma elíptica, por lo que la distancia entre el sol y la tierra varía a lo largo del año. La tierra está más cerca del sol en el perihelio (el punto de la órbita que es más cercano al sol) y más lejos del sol en el afelio (el punto de la órbita que es más lejano del sol). Durante el perihelio la tierra percibe una mayor radiación solar, comparado con el afelio. En segundo lugar, la duración del día varía a lo largo del año, por lo que durante el verano, cuando los días son más largos, se recibe una mayor radiación, contrario a los días de invierno, que son en promedio más cortos.

Radiación solar percibida

La atmósfera de la tierra está compuesta por diferentes gases, vapor de agua y aerosoles, como partículas de polvo y polen. Estos componentes interactúan con la radiación solar de diversas formas, haciendo que se modifique su intensidad y distribución ([Kumari and Toshniwal, 2021](#)). La capa de ozono, por ejemplo, es capaz de absorber la radiación ultravioleta, mientras que los aerosoles y el vapor de agua pueden absorber la radiación en el espectro infrarrojo. Así, a medida que la luz solar atraviesa la atmósfera, parte de ella puede ser reflejada, dispersada o absorbida por las moléculas de aire (nitrógeno, oxígeno, helio), el vapor de agua, las nubes, los aerosoles, entre otros ([Hassan et al., 2016](#)).

De esta forma, la radiación solar percibida en la superficie de la tierra difiere de la radiación solar teórica por las diferentes interacciones que tiene con la atmósfera. Pronosticar este tipo de radiación solar es supremamente complejo pues el sistema climático depende de numerosos aspectos físicos (como la temperatura, vapor de agua, velocidad de viento, presencia de núcleos de condensación), además de la variabilidad extrema introducida por el cambio climático ([Hassan et al., 2016](#)). Uno de los principales moderadores de la radiación solar percibida es la nubosidad. Las nubes reflejan y absorben la radiación solar, lo que puede reducir la cantidad de radiación que llega a la superficie terrestre. De acuerdo con [Cess et al. \(1995\)](#) la cantidad de radiación solar que se refleja o absorbe por las nubes depende de su tipo, espesor y tamaño.

1.1 Problema de negocio

Como se explicó previamente, estimar la radiación solar percibida en algún punto de la tierra, basados en su latitud, longitud y día del año puede ser una tarea compleja y completamente relevante para la implementación de un proyecto de generación de energía fotovoltaica.

Para cualquier sistema de generación de energía debe existir un correcto balance entre la demanda y la oferta. Las predicciones de estos dos componentes permiten a los integrantes del sistema (generadores, distribuidores, operadores, reguladores, entre otros) establecer las dinámicas del mercado energético, como la compra y venta de energía. Para un generador de energía fotovoltaica es completamente relevante establecer en el corto, mediano y largo plazo su capacidad de generación para ofrecer energía en firme y determinar si puede cumplir con sus obligaciones. Por tanto, grandes desviaciones en los predicciones tienen un alto costo en los actores del sistema energético ([Moreno-Munoz et al., 2008](#)).

Por tal motivo, es supremamente deseable poder realizar una predicción de la radiación solar, en diferentes escalas temporales, sobre todo si se tiene en cuenta que la implementación de proyectos fotovoltaicos ha ido en aumento en diferentes lugares del planeta. Estas predicciones tienen amplias aplicaciones: determinar los mejores lugares de instalación de parques solares, estimar el balance entre oferta y demanda, establecer la franja intra horaria para el despacho de energía al operador del sistema de energía, administrar el almacenamiento de energía, planear los ciclos de mantenimiento y de las transacciones en el mercado energético ([Hammer et al., 1999](#)).

La predicción de radiación solar percibida para un punto de la Tierra basado en su latitud, longitud y día del año se puede realizar utilizando modelos físicos o estadísticos. Los modelos físicos utilizan leyes físicas para calcular la cantidad de radiación solar que llega a la superficie de la tierra, combinando la radiación solar teórica y las estimaciones de las interacciones con la atmósfera. Los modelos estadísticos utilizan datos históricos de radiación solar para predecir la radiación solar futura.

En términos generales, los modelos físicos se consideran más precisos que los modelos estadísticos, pero son más complejos y requieren de muchos más datos. En contraposición, los modelos estadísticos son más simples y requieren una menor cantidad de datos, pero pueden resultar menos precisos que los modelos físicos ([Gautier et al., 1980](#)). Además, existen dificultades intrínsecas e instrumentales para la medición y predicción de la radiación solar. En primer lugar, la radiación solar es una onda electromagnética que se propaga en todas

las direcciones, por lo que dificulta su medición en una superficie pequeña, como la de un piranómetro, el instrumento usado para medir la radiación solar. En segundo lugar, los instrumentos de medida de las variables climatológicas tienen limitaciones y pueden estar sujetos a errores de calibración y a la degradación de los componentes con el tiempo.

Encontrar una solución para la predicción de la radiación solar a partir de los datos medidos en estaciones meteorológicas es una tarea obligatoria después de la fase de factibilidad de un proyecto fotovoltaico. En esta monografía se aborda este problema, buscando una alternativa para la toma de decisiones respecto a la implementación y operación de un sistema de generación de energía fotovoltaica, partiendo de información disponible de estaciones meteorológicas que permitan generalizar la solución y que pueda ser ajustada para cualquier proyecto específico.

1.2 Aproximación desde la analítica de datos

Según lo expuesto en la sección anterior, existen dos formas de determinar la radiación solar percibida, bien sea a través de cálculos físicos o mediante métodos estadísticos. La aproximación que se aborda en este trabajo está relacionada con la analítica de datos, mediante métodos estadísticos y machine learning para predecir la radiación solar en la escala de tiempo diaria.

Para ello se realiza un análisis estadístico con el fin de identificar dependencias entre predictores usados (variables meteorológicas). El tratamiento de los datos y el abordaje de los modelos será híbrido, combinando modelos de aprendizaje supervisado para predecir la radiación solar a partir de otras variables meteorológicas, incluida la radiación solar teórica, y modelos diseñados para el análisis de series de tiempo, en los que los datos son dependientes de los valores inmediatamente anteriores y los muestreos no son aleatorios.

Se seguirá un enfoque de aprendizaje conjunto presentado en [Sehrawat et al. \(2023\)](#), integrando predicciones de los modelos desarrollados, permitiendo combinar las fortalezas de diferentes enfoques de modelado para mejorar la precisión de las predicciones.

Factores que influyen en la predicción

En la actualidad, la predicción de la radiación solar depende del horizonte de tiempo de la predicción. Este horizonte hace referencia al período de tiempo en el futuro en el que la predicción es requerida o el paso de tiempo entre el momento actual y el momento para el cual se realiza la predicción. Dentro de la literatura, este horizonte de tiempo se suele dividir en tres escalas: corto, mediano y largo plazo (Kumari and Toshniwal, 2021).

La escala de corto plazo, generalmente entre 30 minutos a 72 horas, tiene una alta aplicabilidad en el mercado eléctrico: balance entre la oferta y la demanda, decisiones de despacho de energía, planeación de las transacciones en el mercado energético, por ejemplo (Ibrahim and Khatib, 2017).

La escala de mediano plazo, usualmente de unos días, semanas e incluso meses, es útil para la planificación de mantenimientos (Olatomiwa et al., 2015). Mientras que la escala de largo plazo es usada para la planificación de proyectos exitosos de generación de energía fotovoltaica. Esta escala va desde varios meses hasta algunos años (Mishra et al., 2008). Usualmente, entre más alta sea la escala habrá una menor exactitud en el pronóstico, donde es más difícil capturar la variabilidad climática asociada a la radiación percibida.

Otro factor determinante para la predicción de la radiación solar es el clima del lugar en el cual se realiza la predicción, tal como lo indican Nann and Riordan (1991). Como ya se mencionó, las condiciones meteorológicas como la presión atmosférica, temperatura, humedad relativa, cantidad de aerosoles en la atmósfera, velocidad del viento y nubosidad, modifican la cantidad de radiación solar percibida. Según la literatura existente, la clasificación del clima del sitio de predicción es uno de los factores que más afecta la mejora de los modelos, por lo que su inclusión es necesaria para una adecuada estimación de la radiación solar percibida.

Métodos de aprendizaje profundo para la predicción de energía solar

Los métodos más usados y altamente recomendados para el pronóstico de la radiación solar son LSTM (*long short-term memory*), redes de creencia profunda (*deep belief network*, *DBN*), redes neuronales convolucionales (*convolutional neural network*, *CNN*), redes de estado de eco (*echo state network*, *ESN*), redes neuronales recurrentes (*recurrent neural network*, *RNN*), unidades recurrentes cerradas (*gated recurrent network*, *GRU*) y sus híbridos. Kumari and Toshniwal (2021) explica de manera concisa la diferencia entre estos métodos.

En la literatura se encuentran numerosas referencias a modelos realizados utilizando estos métodos, que son usados normalmente de forma híbrida, en conjunto con otras técnicas, para optimizarlos y comparar su desempeño (Jentsch and Beierkuhnlein, 2008). Usualmente, su evaluación se realiza dividiendo la predicción para las diferentes estaciones del año, primavera, verano, otoño e invierno, cuando hacen parte de la caracterización del lugar de estudio (Jentsch and Beierkuhnlein, 2008). A continuación, se indican brevemente algunos resultados del desempeño y comparaciones de diferentes autores que han realizado aportes en la predicción de la radiación solar.

Los modelos de LSTM son uno de los más usados en este campo. Srivastava and Lessmann (2018) utilizaron esta técnica para predecir la radiación diaria de varias estaciones en Europa y Estados Unidos. Su modelo mejoró la predicción en un 52% respecto a los modelos de persistencia inteligente, un modelo físico que utiliza datos históricos para calcular el índice de cielo despejado y estimar la radiación percibida (Liu et al., 2021). Resultados similares a los obtenidos por Yu et al. (2019) que les permitió predecir la radiación solar horaria para diferentes lugares de Estados Unidos con un RMSE de 41,37 W/m². Algunos autores han agregado mecanismos adicionales a los modelos LSTM para mejorarlos. Brahma and Wadhvani (2020), por ejemplo utilizaron mecanismos de cerrado (*gating mechanism*) y celdas de memoria para desarrollar modelos a los que llamaron *BiLSTM* y *attention-based LSTM* para hacerlos más eficientes en el aprendizaje a largo plazo de las relaciones entre las variables de entrada, demostrando una alta precisión en la predicción. Estos modelos de LSTM son computacionalmente más demandantes, pero tienen muy buenos resultados.

Menos populares son los modelos GRU. Wojtkiewicz et al. (2019), desarrollaron un modelo basado en GRU en que integraron las técnicas de puerta de entrada y de olvido (*forget and input gates*) que hace más robusta la predicción. Como resultado obtuvieron un modelo que es computacionalmente menos demandante porque entrenan menos parámetros y usan una menor cantidad de memoria, por lo que ejecutan más rápido.

Usando CNN también se han realizado predicciones de radiación solar con un enfoque en análisis de imágenes. De esta manera se utilizan imágenes en tierra de la cobertura de nubes para estimar características espacio temporales. Así, se logró un modelo que mejoró la predicción en un 17.06% respecto a modelos de persistencia (Zhao et al., 2019). Los modelos CNN tienen como ventaja que pueden ser usados tanto si se disponen datos basados en imágenes o si disponen datos dispuestos de manera bidimensional.

Los modelos DBN, que tienen como estructura base las máquinas de Boltzman restringidas,

un tipo de redes neuronales artificiales estocásticas que pueden aprender la distribución de probabilidad de su conjunto de datos de entrada. De esta manera, los modelos DBN pueden usarse para realizar predicciones de radiación solar si las características típicas en los datos no son fácilmente detectables (Zang et al., 2020).

Otro grupo importante de modelos son los RNN en los que su principal característica radica en que las neuronas tienen métodos de retroalimentación y conexión hacia adelante (*feed forward*) y hacia atrás (*feed back*), simulando funciones de memoria lo que las hace ideales para el procesamiento de series de tiempo de radiación solar. Usando este enfoque, Mishra and Palanisamy (2018) propusieron un modelo predictivo para diferentes horizontes de tiempo, en el cual obtuvieron un RMSE de 18,57 W/m².

En un esfuerzo adicional para mejorar la predicción de la radiación solar, numerosos investigadores han desarrollado modelos híbridos que integran diferentes modelos de aprendizaje profundo. Por ejemplo se han realizado modelos híbridos que integran métodos CNN y LSTM (Zang et al., 2020), algoritmos genéticos para optimizar redes neuronales profundas: GRU, LSTM y RNN (Bendali et al., 2020). Los resultados obtenidos con modelos híbridos sugieren que ensamblar múltiples modelos juntos mejoran la predicción de la radiación solar. Las ventajas y desventajas de cada uno de los modelos son los que se relacionan en la Tabla 1 (Kumari and Toshniwal, 2021).

1.3 Origen de los datos

Los datos usados hacen parte de un repositorio abierto con licencia *Creative Commons Attribution*, que contiene mediciones de radiación horizontal global solar (GHI), para el período 2002-2019, con frecuencia de 30 minutos, para 37 estaciones de Castilla y León, en España.

Los datos fueron publicados por integrantes del Departamento de Ingeniería Topográfica y Cartográfica de la Escuela Técnica Superior de Ingenieros en Topografía, Geodesia y Cartografía, Universidad Politécnica de Madrid, y se encuentran disponibles para su uso con fines de investigación en un repositorio público. Los datos contienen información de marca de tiempo, datos meteorológicos (precipitación, temperatura, humedad relativa, radiación solar, velocidad y dirección del viento) y geoespaciales (latitud y longitud)

Tabla 1*Comparación de modelos para predicción de radiación solar*

Modelo	Ventaja	Desventaja	Escenarios de aplicación
LSTM	Capaz de manejar relaciones de dependencia de largo plazo en series de tiempo	Alto costo computacional	Existen registros de series de tiempo de radiación solar
GRU	Diseño poco complejo, menor consumo de memoria, rápida ejecución, menor costo computacional	Lenta convergencia y baja eficiencia de aprendizaje	Los recursos computacionales son limitados
CNN	Es capaz de procesar datasets de imágenes y puede extraer características espaciales	Alto costo computacional, las características deben ser predeterminadas	El dataset de radiación solar tiene imágenes (nubosidad) o los datos pueden ser convertidos a arreglos bi-dimensionales
DBN	Es capaz de extraer características no supervisadas y es menor en costo computacional	Incapaz de procesar datos meteorológicos multidimensionales	No se consideran múltiples variables
RNN	Es capaz de procesar series de tiempo y es eficiente computacionalmente	Incapaz de determinar características eficientemente	Existen registros de series de tiempo de radiación solar
Híbrido	Capaces de extraer diferentes tipos de características de los datos y son altamente precisos	Son costosos computacionalmente	Los datos de radiación contienen diferentes características, tales como información espacial y temporal

1.4 Métricas de desempeño

Métricas de machine learning (desempeño de los modelos)

Las métricas que se usarán para evaluar los modelos de machine learning son las estándar, según lo refiere la literatura (Kumari and Toshniwal, 2021), a saber:

Error absoluto medio (MAE): se calcula como el promedio de la diferencia absoluta entre el valor real y el valor predicho. Esta métrica es útil para penalizar el modelo tanto si realiza sobreestimaciones como subestimaciones. Matemáticamente, el MAE se calcula como:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

donde y_i es el valor real en la i ésima observación, \hat{y}_i es el valor predicho y N es el número total de observaciones.

El MAE tiene un valor entre 0 e infinito, donde 0 indica que las predicciones del modelo son perfectas e infinito indica que las predicciones del modelo son completamente inexactas. Es decir, un valor bajo del MAE indica que el modelo es preciso y un valor alto del MAE indica que el modelo es impreciso.

Error cuadrático medio (MSE): se calcula como el promedio del cuadrado de las diferencias entre el valor predicho y el valor real. Esta métrica penaliza los casos en los que las diferencias entre ambos valores son mayores. Matemáticamente, el MSE se calcula como:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Un valor bajo del MSE indica que el modelo es preciso y un valor alto del MSE indica que el modelo es impreciso.

El MSE es una métrica de error que es sensible a los valores extremos, por lo que valores atípicos pueden generar un alto MSE.

Raíz del error cuadrático medio (RMSE): se calcula como la raíz cuadrada del promedio del cuadrado de las diferencias entre el valor de predicho y el valor real. Esta métrica suele

ser una de las más utilizadas para evaluar el desempeño de un modelo. También ayuda a identificar y eliminar valores extremos en los datos. Matemáticamente, el RMSE se calcula como la raíz del MSE.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

Un valor bajo de la RMSE indica que el modelo es preciso, mientras que un valor alto indica que el modelo es impreciso.

Error porcentual medio (MAPE): se calcula como la media del error absoluto, expresado como porcentaje de los valores reales. Matemáticamente, el MAPE se calcula como:

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (4)$$

Ejemplificando, si el MAPE de un modelo es 10 %, entonces el modelo comete un error del 10 % en promedio. Esto significa que las predicciones del modelo están alejadas de los valores reales en un promedio de 10 %. Un MAPE bajo indica que el modelo es preciso y uno alto indica que el modelo es impreciso.

Es importante tener en cuenta que el MAPE puede verse afectado por la escala de los datos. Por ejemplo, si los datos están en una escala pequeña, entonces un MAPE de 10 % puede ser significativo. Sin embargo, si los datos están en una escala grande, entonces un MAPE de 10 % puede ser insignificante.

Error porcentual absoluto medio simétricos (sMAPE): a diferencia del MAPE, el sMAPE considera tanto los valores reales como los valores predichos en el denominador, lo que lo hace más robusto en presencia de valores cero o cercanos a cero. Matemáticamente, el sMAPE se calcula como:

$$\text{sMAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\frac{|y_i| + |\hat{y}_i|}{2}} \times 100 \quad (5)$$

Valores cercanos al 0 % indican que el modelo es muy preciso y que los valores predichos son muy cercanos a los valores reales. Valores más altos indican una mayor imprecisión del

modelo.

Huber Loss: es una función de pérdida robusta utilizada en la predicción de series de tiempo, que combina las ventajas del error cuadrático medio (MSE) y el error absoluto medio (MAE). La métrica Huber Loss es más eficiente y suave que la MAE para errores pequeños, y menos sensible a valores atípicos en los datos que la MSE. Es particularmente útil cuando se desea una función de pérdida que sea robusta a outliers pero que también se comporte bien para errores pequeños. Matemáticamente, la Huber Loss se calcula como:

$$L_{\delta}(y, \hat{y}) = \begin{cases} \frac{1}{2}(y - \hat{y})^2 & \text{si } |y - \hat{y}| \leq \delta \\ \delta|y - \hat{y}| - \frac{1}{2}\delta^2 & \text{si } |y - \hat{y}| > \delta \end{cases} \quad (6)$$

donde δ es un umbral que determina el punto de transición entre el MSE y el MAE.

De esta manera, para diferencias entre el valor real y el predicho que son pequeñas (menores o iguales a δ), se penalizan los errores cuadráticamente, mejorando la precisión. Para diferencias grandes (mayores a δ), el error se penaliza linealmente, lo cual la hace robusta frente a outliers.

Métricas de negocio

En vista de que el objetivo de este proyecto está relacionado con la predicción de la radiación solar percibida con el fin de ser usada para la evaluación, implementación u operación de un sistema de generación de energía fotovoltaico, las métricas de negocio están orientadas a los agentes responsables de dicho sistema. Estas métricas son:

Tiempo de respuesta: el tiempo de respuesta se refiere al tiempo que tarda la solución propuesta para realizar la predicción de la energía solar percibida. Es importante que el tiempo de respuesta sea lo suficientemente rápido para que la predicción pueda utilizarse en tiempo real. Por ejemplo, si se pretende predecir la radiación solar en escala intra horaria para un período de un día, no tiene sentido que la solución tarde horas en realizar la predicción.

Costo: el costo se refiere a los recursos necesarios para generar una predicción. Incluye el costo de los datos, el costo del hardware y el costo del software. El responsable del negocio deberá determinar si el costo de la predicción, sumado a los demás costos del proyecto, viabilizan el caso de negocio.

Radiación solar percibida por unidad de tiempo: esta métrica es importante para los negocios que utilizan la predicción de la energía solar para tomar decisiones. Por ejemplo, un operador de una planta de energía solar fotovoltaica puede utilizar la predicción de la energía solar para planificar la producción y el almacenamiento de energía. Un desarrollador de proyectos de energía solar puede utilizar la predicción de la energía solar para evaluar el potencial de un proyecto. La radiación solar se mide en vatios por metro cuadrado (W/m^2). Esta unidad de medida representa la cantidad de energía solar que llega a un área de un metro cuadrado. Se dispondrá la radiación solar percibida por unidad de tiempo como la radiación percibida en dicho período, por ejemplo la radiación solar por hora o por día.

Métricas de aplicación

Según ([Voyant et al., 2017](#)) en una revisión que realizaron de aplicación de diferentes modelos para la predicción de radiación solar en varios lugares del planeta, la métrica de RMSE promedio fue de 13% para los modelos con predicciones de un horizonte de 1 hora. Por lo tanto, una estimación razonable para este proyecto será realizar predicciones con un horizonte de tiempo de 24 horas, un RMSE del 15% para el modelo con mejor desempeño, el cual deberá poder realizar la estimación (tiempo de respuesta) en un tiempo inferior a 1 hora y que en el que el costo de implementación, asociado a pago de infraestructura, sea cero, es decir, que pueda implementarse con los recursos disponibles como estudiantes, sin ningún tipo de pago adicional.

2 Objetivos

2.1 Objetivo general

Desarrollar un modelo de pronóstico de la radiación solar para el corto plazo usando herramientas de aprendizaje profundo e información de las estaciones meteorológicas de la Comunidad de Castilla y León, España, que permitan la toma de decisiones alrededor de proyectos de generación solar fotovoltaica.

2.2 Objetivos específicos

- Seleccionar y analizar datos de variables meteorológicas, incluida radiación solar, de diferentes estaciones de la Comunidad de Castilla y León, España, para detectar patrones, tendencias y relaciones entre las variables a través de un análisis estadístico.
- Procesar y transformar los datos relevantes para realizar una predicción de la radiación solar de una de las estaciones meteorológicas seleccionadas.
- Desarrollar modelos de aprendizaje automático que permitan predicción de la radiación solar a partir del *dataset* generado para la estación meteorológica.
- Evaluar y comparar el desempeño de los diferentes modelos implementados para determinar si son una solución viable al problema de negocio.

3 Datos

3.1 Datos originales

Los datos usados hacen parte de un repositorio abierto con licencia *Creative Commons Attribution*, que contiene mediciones de radiación horizontal global solar (GHI), recopiladas durante un período de 18 años, desde enero de 2002 hasta diciembre de 2019, con una frecuencia de 30 minutos, que fueron medidos en 37 estaciones ubicadas en la región española de Castilla y León. El conjunto de datos no solo cuenta con datos crudos, sino también con datos refinados y etiquetados por estaciones de medición, contando además con variables meteorológicas y geográficas que complementan el valor de los datos de radiación.

Los datos fueron publicados por integrantes del Departamento de Ingeniería Topográfica y Cartográfica de la Escuela Técnica Superior de Ingenieros en Topografía, Geodesia y Cartografía, Universidad Politécnica de Madrid, y se encuentran disponibles para su uso con fines de investigación en un repositorio público con nombre “CyL_GHI” disponible en el sitio web Zenodo y además cuentan con una documentación detallada (Cesar et al., 2022), que describe de manera precisa el preprocesamiento, estandarización y limpieza realizado por los autores.

Los archivos se encuentran almacenados en formatos `csv` y `zip` y se encuentran ordenados de acuerdo a lo descrito en Tabla 2.

Tabla 2

Listado de archivos disponibles en la base de datos de Zenodo

Nombre del Archivo	Descripción	Tamaño
<code>CyL.raw.zip</code>	Datos crudos sin refinamiento	232.6 MB
<code>CyL.GHI_ast.csv</code>	Datos GHI preprocesados con variables teóricas	281.9 MB
<code>CyL.meteo.csv</code>	Datos meteorológicos durante periodo de 18 años	313.2 MB
<code>CyL.geo.csv</code>	Datos geográficos de las 37 estaciones	2.4 kB
<code>CyL.by_stations.zip</code>	Datos GHI preprocesados separados por estaciones.	263.2 MB

Para el desarrollo de las actividades, se seleccionaron los archivos `CyL.by_stations.zip` y `CyL.geo.csv`. El primero incluye los datos de radiación solar horizontal (GHI) preprocesados agrupados por estaciones de medición, donde cada estación tiene sus datos individuales organizados y listos para su análisis específico. El segundo aporta información relevante relacionada con la ubicación de las estaciones, incluyendo coordenadas y elevación.

Datos Geográficos

Los datos geográficos disponibles en `CyL_geo.csv` contienen un total de 37 registros, donde cada uno está asociado a una estación. Este archivo cuenta con 5 columnas descritas a continuación:

- **station_code:** Código alfanumérico que identifica a cada estación.
- **name:** Nombre de la estación.
- **latitude:** Latitud en la cual se encuentra ubicada la estación.
- **longitude:** Longitud en la cual se encuentra ubicada la estación.
- **height:** Altitud sobre el nivel del mar en metros.

Datos de Radiación Solar Horizontal

El archivo `CyL_by_stations.zip` incluye todas las mediciones de radiación solar horizontal, así como las variables meteorológicas, separadas por cada estación. El documento comprimido contiene un total de 37 archivos en formato `csv`, donde cada archivo lleva el nombre del código alfanumérico de la estación descrito en el conjunto de datos geográficos.

Cada archivo cuenta con un total de 315600 registros, donde cada registro corresponde a un conjunto de mediciones y datos teóricos complementarios asociados a una marca de tiempo, con una frecuencia de registro de 30 minutos. La estructura de los datos está detalladamente definida, incluyendo las unidades de medición de cada variable, en ([Cesar et al., 2022](#)), y se describen a continuación:

- **timestamp:** Corresponde a una marca de tiempo en el cual se tomaron las mediciones en formato `yyyy-mm-dd HH:MM:SS`.
- **GHI:** Indica la radiación horizontal global (Global Horizontal Irradiance) en (W/m^2) medida en la estación meteorológica.
- **toa:** Corresponde a una variable teórica complementaria que indica la radiación de la parte superior de la atmósfera (Top of Atmosphere Radiation) en (W/m^2).

- **wind_dir**: Medición de la dirección del viento en grados.
- **humidity**: Porcentaje de humedad relativa medida en la estación.
- **precipitation**: Precipitaciones medidas en milímetros (mm).
- **air_temp**: Temperatura del aire medida en grados Celsius (°C).
- **wind_sp**: Velocidad del viento (m/s).
- **sun_elev**: Variable teórica complementaria que indica el ángulo de elevación solar en grados.
- **sun_azim**: Variable teórica complementaria que indica el ángulo azimuth en grados.

3.2 Datasets

La creación de los conjuntos de entrenamiento y validación se inició seleccionando una única estación para todo el proceso. Esta selección se basó en dos criterios principales: la cantidad de valores no nulos disponibles y la proximidad a otras estaciones que pudieran complementar los valores faltantes en la estación de referencia elegida.

Para generar el conjunto de datos, se realizó un proceso preliminar de limpieza y preparación de los datos. Este proceso comenzó con la elección de la estación de medición que presentaba la menor cantidad de valores nulos en su conjunto de datos. Para identificar esta estación, se calculó el número de filas con valores nulos para cada estación meteorológica. La tabla 3 muestra las estaciones meteorológicas con la menor cantidad de filas con valores nulos.

Tabla 3

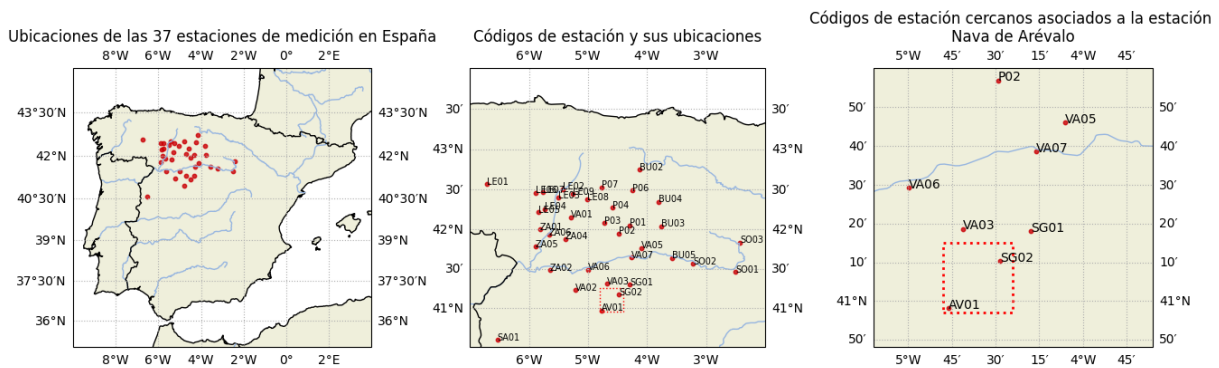
Estaciones meteorológicas con menor cantidad de filas con valores nulos

Código estación	Nombre estación	Cantidad de filas con nulos
AV01	Nava de Arévalo	6828
LE04	Zotes del Páramo	7014
LE02	Mansilla mayor	7317
BU05	Vadocondes	7441
LE03	Cubillas de los Oteros	7529

El cálculo de la cantidad de filas con valores nulos en cada conjunto de datos reveló que la estación con menor cantidad de nulos fue Nava de Arévalo (AV01). Por lo tanto, esta estación fue seleccionada como referencia para todo el proceso. A partir de esta selección, se utilizaron los datos geográficos para identificar la estación más cercana a AV01 que pudiera complementar las mediciones con valores nulos en ciertos periodos de tiempo. Según este criterio, se identificó como estación complementaria a Nava de la Asunción (SG02), como se muestra en la figura 1c.

Figura 1

a) Ubicación de las 37 estaciones al norte de España b) Códigos de estación y sus ubicaciones c) Estaciones cercanas a AV01 dentro del conjunto de datos



Preparación de los datos

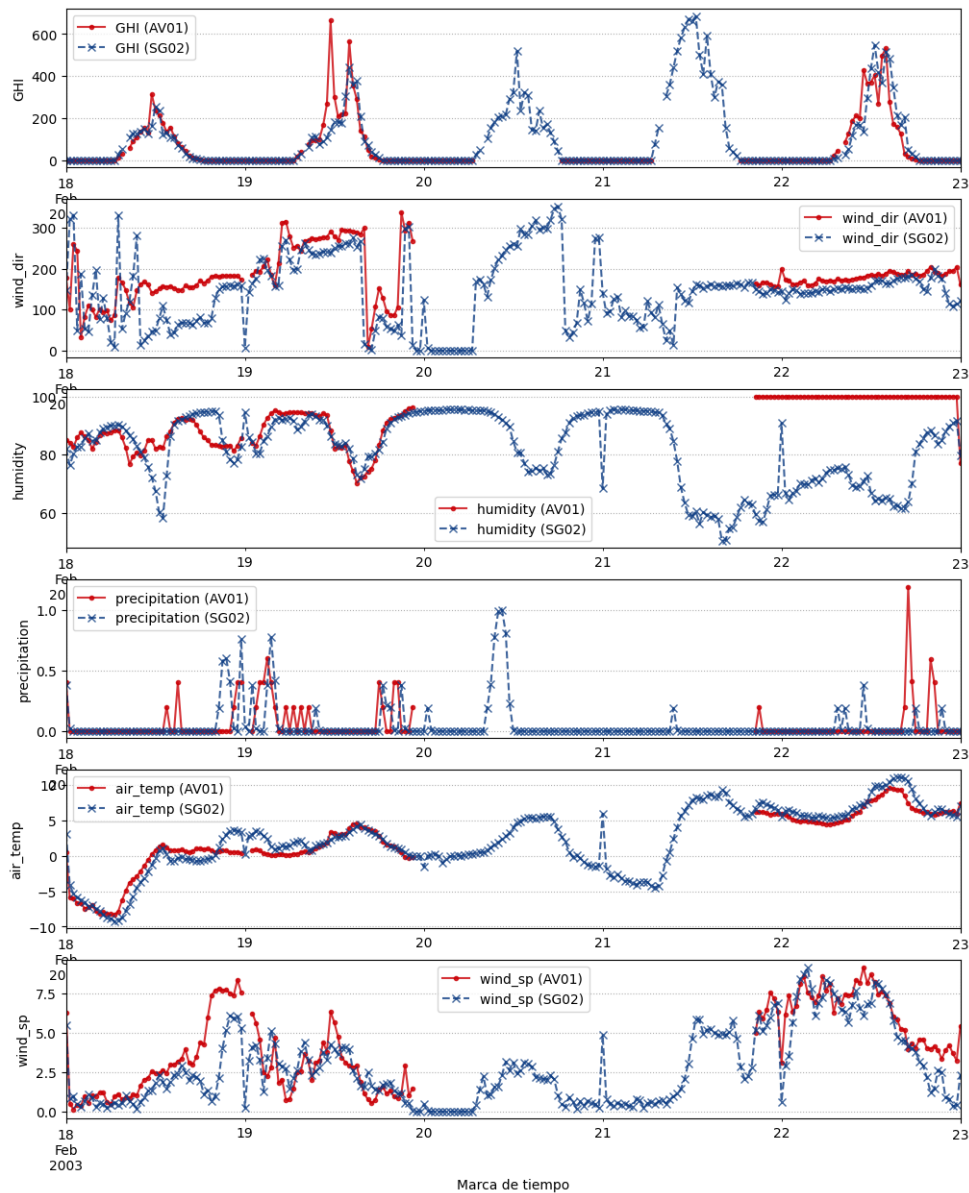
Una vez definidos los conjuntos de datos de referencia para la generación del dataset, el siguiente paso fue la imputación de datos en AV01 utilizando información complementaria de SG02 y técnicas de interpolación para los valores nulos restantes no presentes en ninguno de los dos conjuntos de datos.

Para preparar los datos, se desarrolló una clase de Python llamada `DataPreparation()`, que permite obtener los conjuntos de datos de ambas estaciones de referencia y realizar comparaciones para ciertas variables seleccionadas del dataset. La figura 2 muestra una comparación inicial de las variables meteorológicas medidas en las dos estaciones. En ella, se observan claramente valores nulos para la estación AV01 entre el 20 y el 22 de febrero, mientras que la estación SG02 dispone de datos para ese mismo periodo. Dada la cercanía entre las dos estaciones, se observa que, en los intervalos de tiempo en los cuales se tienen datos para

ambas estaciones, las variaciones presentan proporciones y características similares en cada una de las variables medidas.

Figura 2

Comparación de variables AV01 y SG02 entre el 18 y 23 de febrero de 2003




Estas similitudes fueron verificadas a través de un análisis de correlación lineal de Pearson entre las variables de los conjuntos de datos para ambas estaciones, tal como se observa en la Figura 3, obteniendo un R^2 cercano o mayor a 0.8 para las variables de radiación solar

horizontal, humedad relativa temperatura y velocidad del viento, y menor para la dirección del viento y las precipitaciones, siendo estas mas aleatorias y dependientes de la ubicación específica.

Figura 3

Correlación lineal de Pearson para las variables meteorológicas medidas en la estación AV01 comparadas con SG02

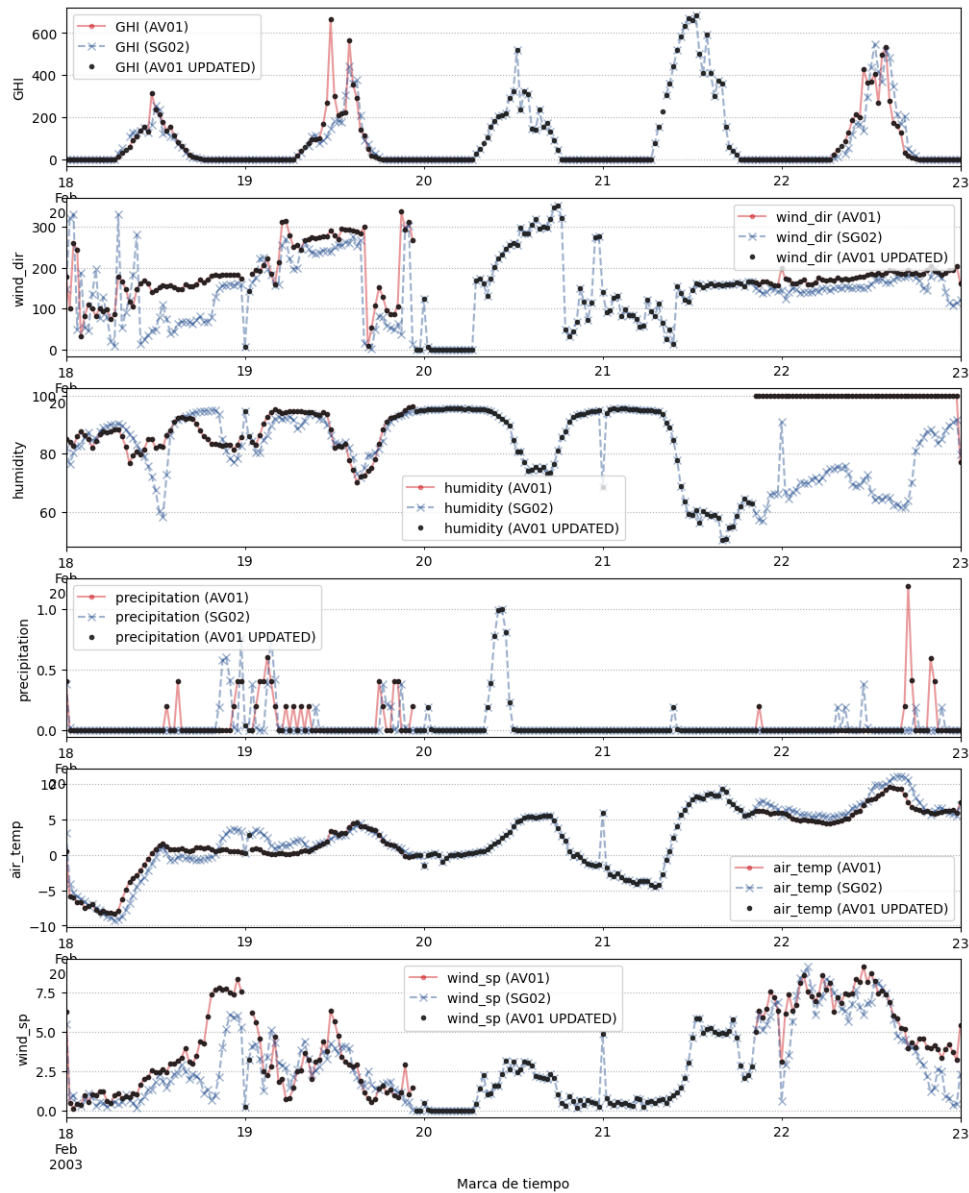


A pesar de que las variables de dirección del viento y precipitaciones presentaron un R^2 menor debido a su naturaleza más aleatoria y dependiente de la ubicación específica, la proximidad geográfica entre las estaciones y la coherencia observada en las demás variables ofrecieron una base razonable para el uso complementario de los datos de SG02.

Tal como se observa en la Figura 4, la herramienta de imputación de datos permitió obtener una versión que complementa los datos nulos de AV01 con los datos de SG02, y la interpolación de datos permitió reducir los valores nulos, logrando así una versión más limpia del dataset. Esta interpolación fue limitada aun máximo de 5 muestras de forma que no afectara

Figura 4

Resultados de la imputación de datos de la estación AV01



Resultados de la imputación de la comparación de variables AV01 y SG02 en el espacio de tiempo entre el 18 y 23 de febrero de 2003. La curva AV01 UPDATED indica los datos luego de la imputación.

la integridad de los datos originales y evitara una posible distorsión significativa del conjunto de datos.

Dada la persistencia de valores nulos en los datos obtenidos desde el año 2011 en adelante, se optó por restringir el análisis al período comprendido entre 2002 y 2010 para garantizar la fiabilidad de los datos utilizados en el estudio. Esta decisión marcó el inicio de la construcción de los conjuntos de entrenamiento y prueba, fundamentales para el desarrollo y entrenamiento de los modelos correspondientes.

3.3 Analítica descriptiva

Después de completar la construcción del dataset, resultó crucial llevar a cabo un análisis de los datos disponibles con el fin de identificar patrones, tendencias y relaciones significativas entre las variables. Este análisis proporcionó una comprensión de la estructura subyacente de los datos y reveló características relevantes, sirviendo como base fundamental para la toma de decisiones y el desarrollo de estrategias.

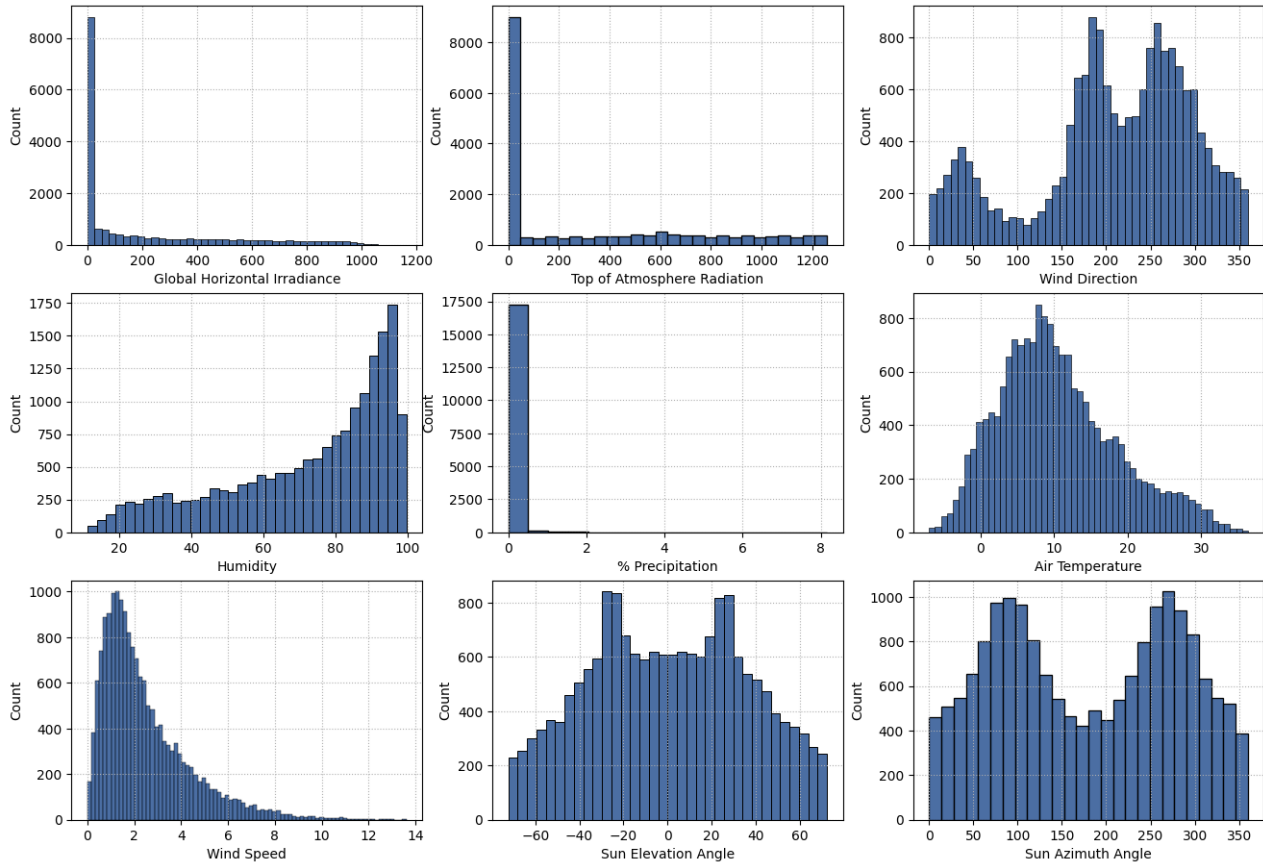
Tabla 4

Descripción estadística de cada una de las variables del conjunto de datos

	count	mean	std	min	25 %	50 %	75 %	max
GHI	17544.0	197.619181	281.885189	0.00	0.0000	24.060	340.2925	1163.26
toa	17544.0	325.314255	408.537254	0.00	0.0000	19.615	640.9500	1259.03
wind_dir	17544.0	208.039005	88.919718	0.00	166.3175	220.840	274.6450	359.99
humidity	17544.0	72.417934	22.835132	11.26	57.5075	79.910	91.5000	99.70
precipitation	17544.0	0.025325	0.188129	0.00	0.0000	0.000	0.0000	8.16
air_temp	17544.0	10.488811	8.054266	-7.01	4.6775	9.330	15.2500	36.35
wind_sp	17544.0	2.480699	1.904968	0.00	1.1200	1.930	3.3300	13.61
sun_elev	17544.0	0.278600	35.647457	-72.24	-27.4225	0.305	27.9800	72.28
sun_azim	17544.0	179.312009	100.979620	0.00	89.1275	179.735	269.9025	360.00

Una revisión de las distribuciones de las variables, tal como se observa en la Figura 5 mostró que:

- Los datos de radiación solar y radiación de atmósfera superior, TOA, mayormente presentan valores en cero, lo cual es esperado debido a los períodos nocturnos a lo largo del tiempo.
- La dirección del viento en grados muestra una alta variabilidad, con mayor frecuencia en tres ángulos cercanos a 40°, 190° y 260°.

Figura 5*Distribuciones de las variables del conjunto de datos*


- El porcentaje de humedad relativa presenta cierta variabilidad, con mayor frecuencia en un porcentaje cercano al 100 %.
- El porcentaje de precipitaciones mayormente es bajo, cercano a cero.
- La temperatura del aire en promedio es cercana a 10.5°C, como se indica en la Tabla 4, con una temperatura mínima de aproximadamente -7°C y una máxima de más de 36°C.
- La velocidad del viento mayormente se encuentra cercana a los 2.5 m/s

Al examinar la correlación lineal de Pearson entre cada variable, como se observa en la Figura 6, se destaca una correlación más notable entre el GHI y el TOA, así como entre ambos y el ángulo de elevación solar "sun_elev". Por otro lado, se observa una correlación negativa alta,

cercana a -0.8, entre el porcentaje de humedad relativa y la temperatura del aire, así como correlaciones negativas, aunque no tan fuertes, entre el porcentaje de humedad relativa y la radiación solar, tanto GHI como TOA.

Figura 6

Matriz de correlación de las variables incluidas en el conjunto de datos



Esta alta correlación entre el GHI y el TOA es evidente en el gráfico temporal, como se muestra en la Figura 7. Al comparar ambas variables, se observan claramente los cambios

en la radiación solar global horizontal (GHI) debido a factores meteorológicos adicionales, en contraste con el TOA, que presenta una curva con un valor mayor de W/m^2 . Incluso en fechas donde la curva de GHI es más suave, como el caso 1 de mayo de 2008, el valor de TOA sigue siendo mayor, pero sigue la misma tendencia que la curva de GHI.

Figura 7

GHI vs TOA a través del tiempo entre el 30 de abril y el 5 de mayo de 2008

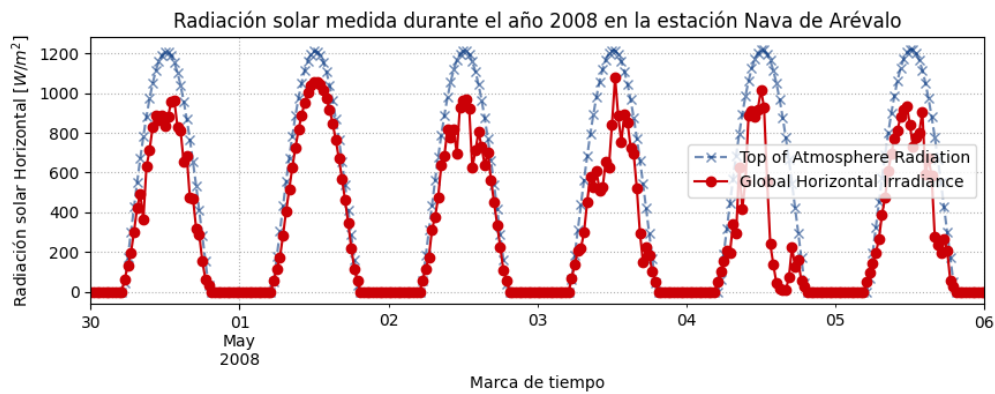
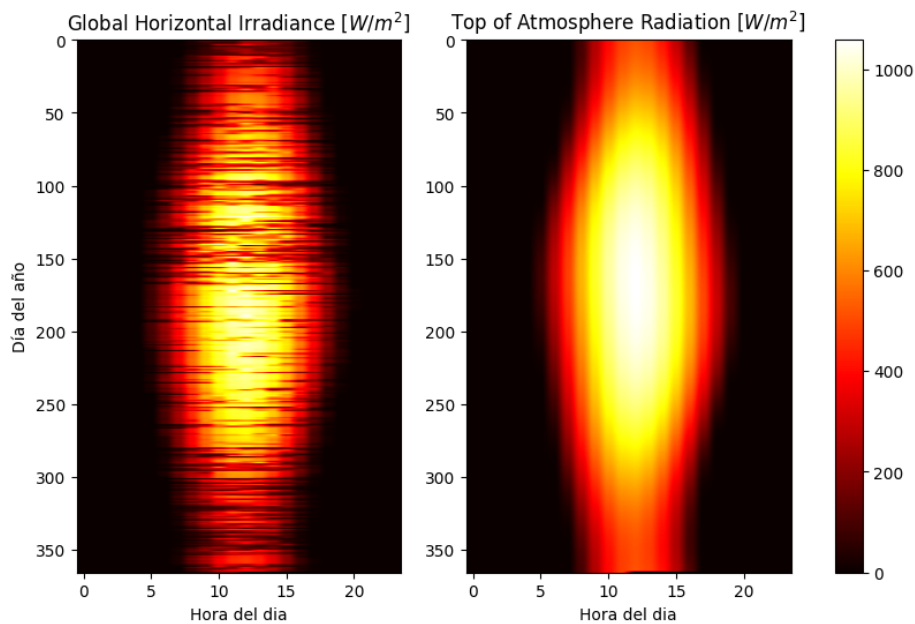


Figura 8

GHI vs TOA durante el año 2008 para las 24 horas del día



Adicionalmente, se observan diferencias a lo largo del año debido a la alta variación en la cantidad de luz disponible en las distintas estaciones. La Figura 8 muestra estacionalidad y claras diferencias en las horas de disponibilidad solar a lo largo del año, así como el impacto de los factores meteorológicos en la disponibilidad de radiación solar. Esto genera ciertos patrones oscuros en la imagen de GHI.

Estos factores se tuvieron en cuenta para la inclusión de variables relevantes que complementaran el conjunto de datos, como el día del año para capturar la variabilidad interanual y los minutos del día para capturar la variabilidad intradía, así como un índice de atenuación definido a partir de la ecuación:

$$attenuation_index = \frac{TOA - GHI}{TOA} \quad (7)$$

el cual representa las interacciones de la atmósfera con la radiación solar. Estos datos fueron adicionados al dataset original para complementar los datos de entrenamiento y validación a ser usados posteriormente.

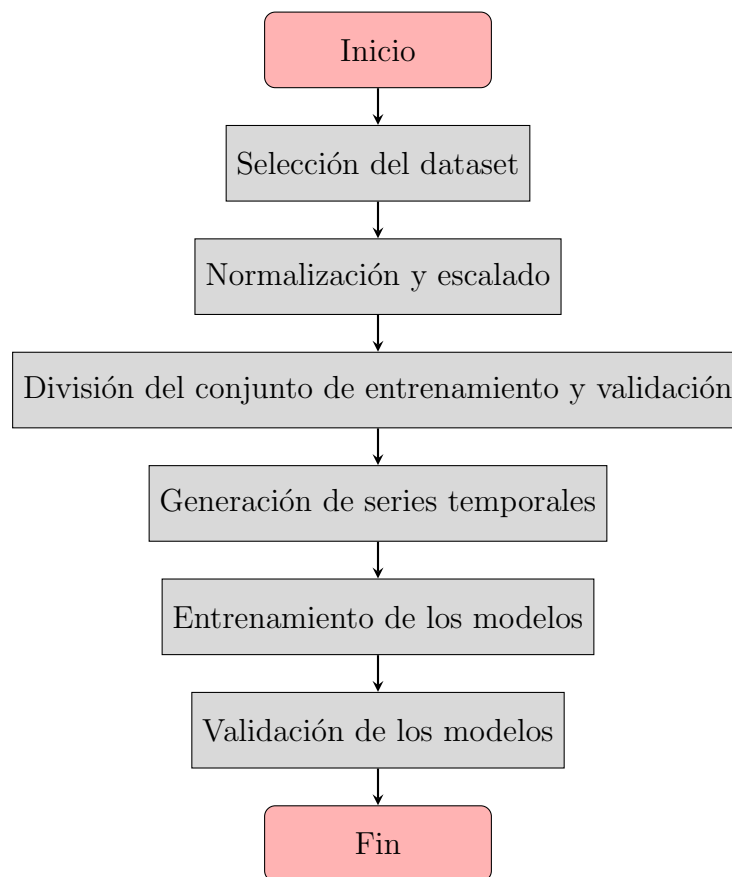
4 Proceso de analítica

4.1 Pipeline principal

En la Figura 9 se muestra el pipeline general para el desarrollo del modelo para la predicción de la radiación solar en el corto plazo que fue utilizado, a continuación se explica en mayor detalle en qué consiste cada uno de los procesos definidos allí.

Figura 9

Pipeline para la predicción de la radiación solar



Selección del Dataset

Como se señaló en la sección *Dataset* (3.2), se eligieron los datos de la estación Nava de Arévalo (AV01) entre las 37 estaciones disponibles, abarcando el período de 2002 a 2010. El conjunto de datos resultante consta de 157,776 registros, con una frecuencia de muestreo

de 30 minutos. Estos datos se almacenaron en un archivo en formato Feather utilizando la biblioteca Pandas, y posteriormente se emplearon para entrenar todos los modelos.

Normalización y Escalado

En el preprocesamiento de datos se realizó normalización y escalado de los datos para mejorar la convergencia del algoritmo durante el entrenamiento y para evitar el sesgo hacia ciertos atributos. En este caso de estudio, se empleó la técnica de Min-Max Scaling (*MinMaxScaler* de Scikit-learn) para escalar los valores de los datos entre 0 y 1. Esta técnica busca asegurar que todos los atributos contribuyan de manera equitativa durante el proceso de entrenamiento del modelo, optimizando así el rendimiento del algoritmo y mejorando su capacidad de predicción.

División del conjunto de entrenamiento y validación

Para el entrenamiento y validación del modelo se hizo una división del dataset en dos subconjuntos de datos. Para este ejercicio se dividió el dataset en un 70 % para el entrenamiento y un 30 % para la validación. Esta división se hizo a través de la función *train_test_split* de Scikit-learn con el parámetro *shuffle* en *False*, para que los datos sean secuenciales y no los elija de manera aleatoria.

De esta forma se puede minimizar el riesgo de sobreajuste, garantizando que el modelo generalice bien ante datos nuevos.

Generación de secuencias de series temporales

Dado que el problema de la predicción multivariada de series de tiempo es inherentemente secuencial, se adoptó un enfoque de entrenamiento series temporales mediante la creación de ventanas móviles. Este método transforma el dataset original en múltiples secuencias temporales, donde cada secuencia se utiliza para predecir el valor (o valores) siguiente(s) en la serie. Esta técnica permite capturar de manera efectiva los patrones y tendencias temporales presentes en los datos, mejorando así la exactitud de las predicciones realizadas por el modelo. La generación de las secuencias se describe más detalladamente en la sección *Preprocesamiento* (4.2).

Entrenamiento del modelo y validación

Se entrenaron varios modelos de machine learning, incluyendo redes neuronales recurrentes (RNN), unidades recurrentes cerradas (GRU), redes de memoria de largo y corto plazo (LSTM) y redes convolucionales (CNN) con el fin de comparar su desempeño. Cada modelo fue entrenado utilizando el conjunto de entrenamiento y posteriormente validado con el conjunto de prueba. Para la evaluación del rendimiento del modelo, se utilizaron métricas como el MSE, el MAE, MAPE y Huber. Para los modelos que obtuvieron el mejor y el peor desempeño se utilizó el método de validación cruzada *TimeSeriesSplit* de Scikit-learn, el cual es una variación del *k-fold* adaptado a series de tiempo, para mejorar los resultados obtenidos en términos de robustez y que el modelo no estuviera sobreajustado, aumentando la confiabilidad y permitiendo una mejor generalización del modelo ante datos nuevos de entrada.

4.2 Preprocesamiento

Para la predicción de series de tiempo es necesario la creación de secuencias para el entrenamiento de modelos. Este proceso dispone los datos de entrada de tal manera que el modelo pueda aprender patrones a partir de datos históricos y hacer predicciones más exactas. Los términos "ventana de observación" (*look-back*), "superposición" (*overlapping*) y "número de pasos de predicción" (*number of forecasts*) son relevantes para la creación de las secuencias, estos términos se desarrollan a continuación.

Ventana de observación

La ventana de observación define el número de pasos temporales pasados que se usarán como características de entrada para el modelo. Esto es crucial porque los datos de series temporales dependen del contexto histórico para hacer predicciones futuras.

Superposición

Las ventanas superpuestas permiten la creación de múltiples ejemplos de entrenamiento a partir de los datos de series temporales, donde cada ejemplo se desplaza ligeramente del anterior. Esta técnica maximiza el uso de los datos disponibles, especialmente cuando el conjunto de datos es pequeño.

Número de pasos de predicción

Este parámetro especifica cuántos pasos temporales futuros debe predecir el modelo. Puede variar dependiendo del horizonte de predicción requerido por la aplicación específica.

Creación de las secuencias

Una vez definidos los parámetros anteriores (ventana de observación, superposición y número de pasos de predicción), se deben construir las secuencias para que el modelo sea entrenado. Estas secuencias se crean tanto para los datos de entrada (x) y los datos de salida (y) que fueron definidos en la sección Datos (3).

Las secuencias de entrada (x) están constituidas por una cantidad de observaciones igual al parámetro *ventana de observación*. La manera como se desliza la ventana de observación depende del parámetro de superposición, el cual da cuenta de la cantidad de datos compartidos entre dos secuencias contiguas. Para ejemplificar la construcción de las secuencias tome por ejemplo una serie temporal con observaciones $[x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9]$, con una ventana de observación de 3, una superposición igual a la ventana de observación, menos uno (es decir, cada nueva secuencia desplaza la ventana de observación un solo paso) y un número de pasos de predicción igual a 1. Para este ejemplo las secuencias superpuestas serían:

$$[x_1, x_2, x_3] \rightarrow x_4$$

$$[x_2, x_3, x_4] \rightarrow x_5$$

$$[x_3, x_4, x_5] \rightarrow x_6$$

$$[x_4, x_5, x_6] \rightarrow x_7$$

$$[x_5, x_6, x_7] \rightarrow x_8$$

$$[x_6, x_7, x_8] \rightarrow x_9$$

La secuencia sería distinta si la superposición fuera de 1 y el número de pasos de predicción fuera igual a 2:

$$[x_1, x_2, x_3] \rightarrow [x_4, x_5]$$

$$[x_3, x_4, x_5] \rightarrow [x_6, x_7]$$

$$[x_5, x_6, x_7] \rightarrow [x_8, x_9]$$

Cada secuencia será un ejemplo de entrenamiento y se debe asegurar que la arquitectura del modelo sea compatible con la estructura de las secuencias generadas.

La selección de los parámetros puede hacer a través de un conocimiento técnico del problema o través de experimentación. Para este caso de estudio se realizaron varios experimentos dejando fijo el número de pasos de predicción (48, que corresponden a 24 horas debido a que los datos tienen una frecuencia de cada 30 minutos) y variando el valor de la ventana de observación y la superposición, como se definen en las tablas 5 y 6.

Tabla 5

Valores de las ventanas de observación

Valor	Relación respecto al número de pasos de predicción
48	1
72	1.5
96	2

Tabla 6

Valores de la superposición

Valor superposición respecto a la ventana de observación (n)
n-1
n/2
0

4.3 Modelos

Se generaron 8 modelos utilizando la librería Tensorflow de Python que responden básicamente a 2 arquitecturas en las que se usaron 4 tipos de redes neuronales: RNN, LSTM, GRU y CNN+GRU. Las arquitecturas se muestran en las figuras 10 y 11. En ambas arquitecturas las capas punteadas solo fueron parte de los dos modelos denominados CNN+GRU que conjugan una capa convolucional y varias capas de redes GRU.

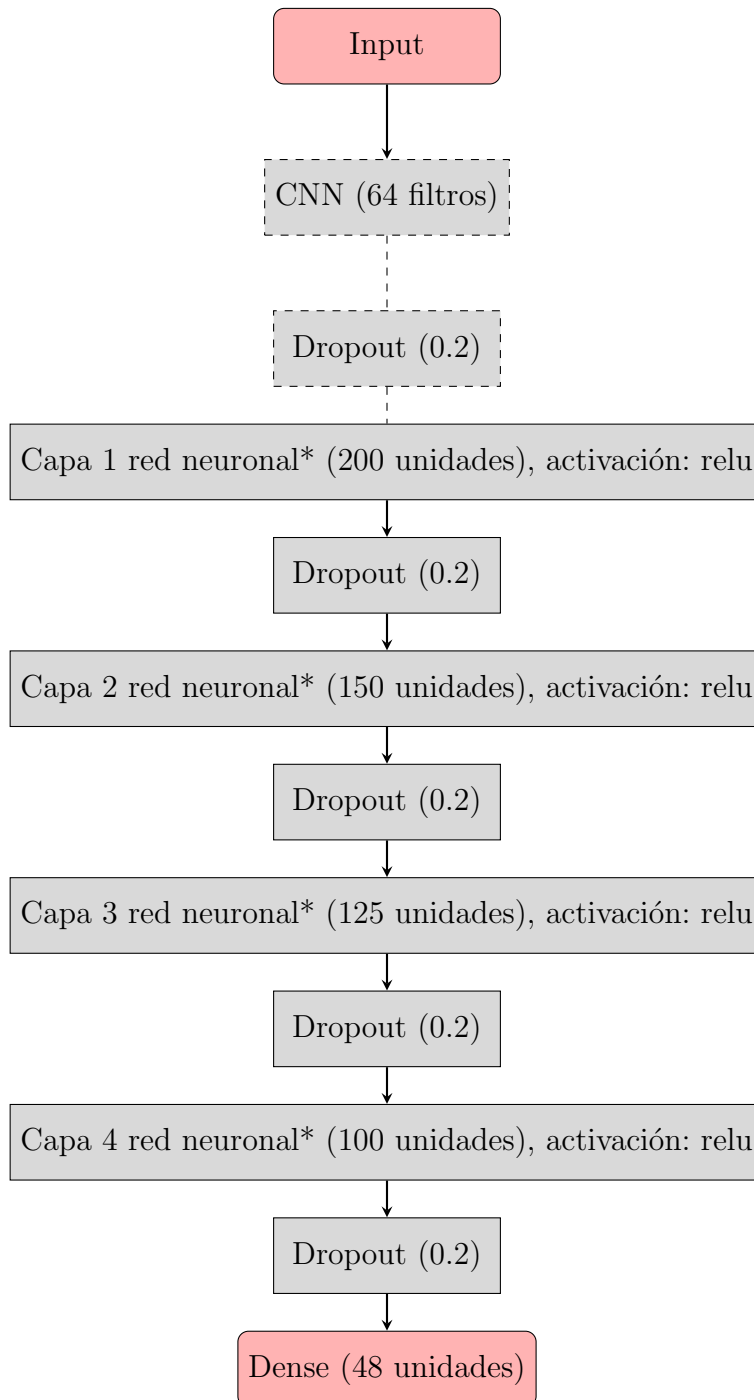
En la arquitectura 2 se introducen capas bidireccionales, un tipo de capa del módulo de Keras de Tensorflow que provee contexto adicional para cada secuencia de entrada. Estas capas procesan la secuencia de entrada en ambas direcciones, hacia adelante y hacia atrás, permitiendo al modelo capturar información del pasado y del futuro.

En cada una de las arquitecturas se utilizó una función de activación diferente, para la arquitectura 1 se utilizó la función de activación *relu* y para la arquitectura 2 se utilizó la función *tanh* con el fin de explorar cuáles eran los mejores resultados.

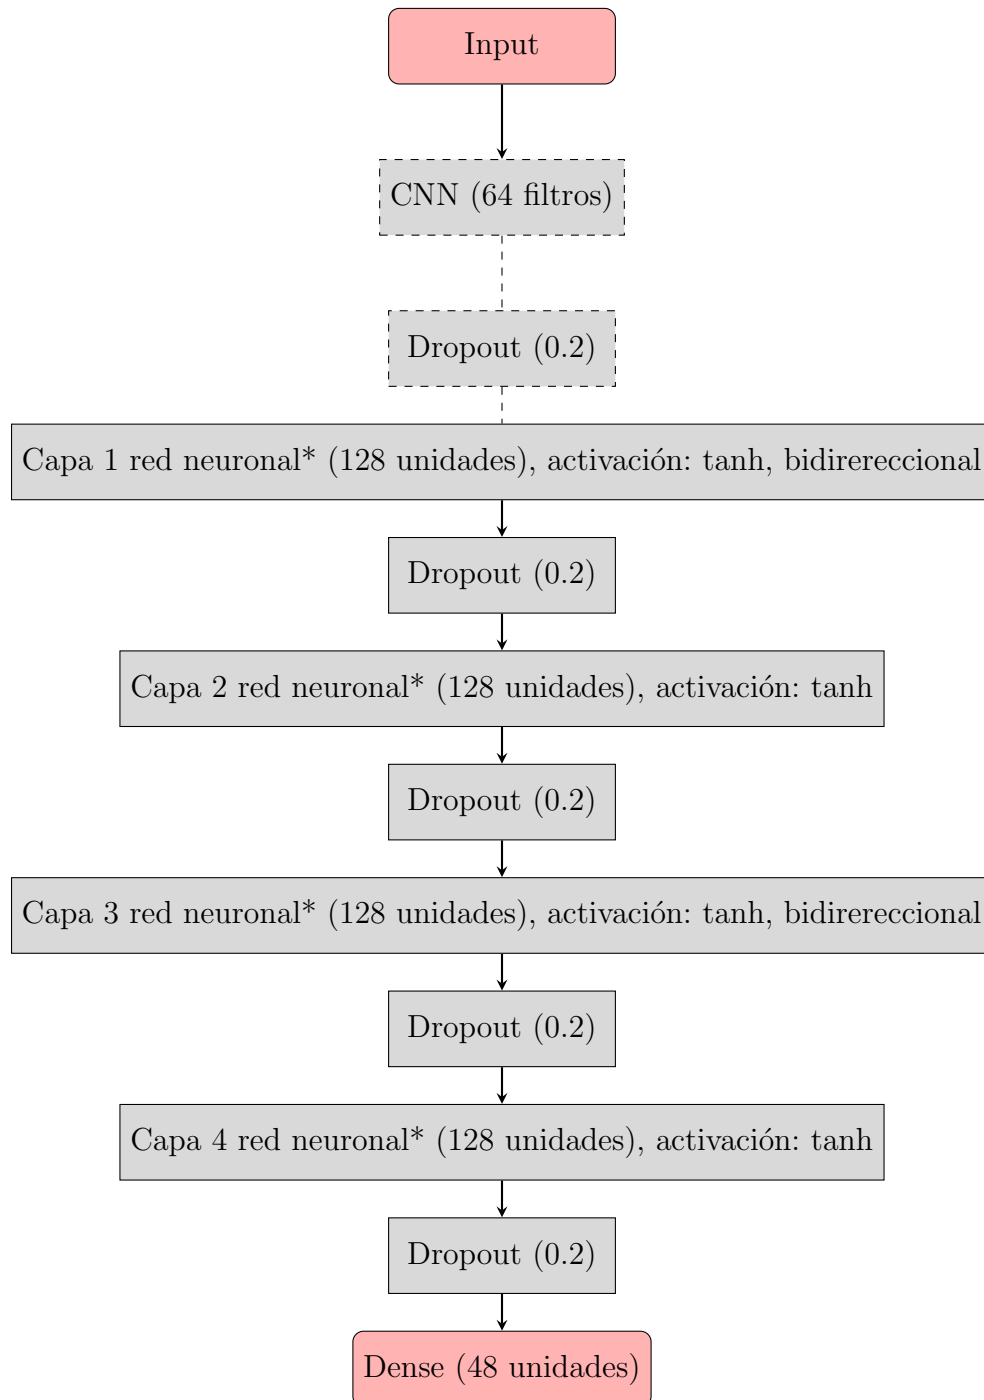
4.4 Métricas

Para la evaluación de los modelos se generó un módulo para el cálculo del MSE, RMSE, MAPE, sMAPE, MAE y Huber loss. Todos los algoritmos para las métricas, salvo Huber loss, fueron elaborados por el equipo usando comandos simples de la librería Numpy de Python. Esto porque la variable objetivo, GHI, puede tener valores cero (la radiación nocturna, por lo menos) y en algunas métricas como el MAPE y el sMAPE hacen parte del denominador, por lo que generaba una indeterminación. En ese caso se generó una máscara para que solo se consideraran los valores diferentes de cero en el denominador.

La métrica Huber loss fue calculada mediante el módulo `tensorflow.keras.losses.huber` de Python.

Figura 10*Arquitectura de modelos 1.*

* La capa de red neuronal puede hacer referencia a RNN, LSTM o GRU, por lo que serían 3 modelos distintos. Las capas punteadas solo hacen parte del cuarto modelo, denominado ConvGRU, en el que se utilizó una capa convolucional al inicio y varias capas de redes GRU posteriormente.

Figura 11*Arquitectura de modelos 2.*

* La capa de red neuronal puede hacer referencia a RNN, LSTM o GRU, por lo que serían 3 modelos distintos. Las capas punteadas solo hacen parte del cuarto modelo, denominado ConvGRU, en el que se utilizó una capa convolucional al inicio y varias capas de redes GRU posteriormente.

5 Metodología

5.1 Baseline

El primer abordaje para la construcción de los modelos fue crear una estructura sencilla de la capa de entrada, una capa de red recurrente (LSTM, GRU o RNN), un dropout y la capa densa de salida con el número correcto de pasos de predicción.

Una vez comprobamos que el resultado de salida, si bien no muy acertado, era coherente, iniciamos un proceso exploratorio para agregarle más capas. Se definió la métrica Huber Loss como el factor para escoger las dos arquitecturas que después de unas pocas iteraciones mostraba los mejores resultados.

Las dos arquitecturas que exhibieron un rendimiento prometedor fueron seleccionadas para realizar los experimentos variando las secuencias de entrada. En este proceso modificaron también algunos hiperparámetros como la cantidad de unidades por capa, el tipo de función de activación y en algunos casos modificar la misma arquitectura. Allí, por ejemplo implementamos las capas bidireccionales en busca de mejorar su capacidad predictiva.

Sin embargo, durante este proceso de experimentación y refinamiento, hubo limitaciones en términos de capacidad de cómputo. Se disponía de dos computadores locales que no eran suficientes para realizar experimentos exhaustivos y refinamientos adicionales en un tiempo razonable.

Para superar esta limitación, se implementaron adecuaciones en el algoritmo para ser usado en plataformas en la nube como Kaggle y Google Colab. Estas plataformas ofrecen una mayor capacidad de cómputo con acceso a GPUs. El mecanismo básico fue generar un script adicional que permitiera descargar en el ambiente en la nube el repositorio de GitHub, configurar los permisos de escritura en disco y crear las carpetas necesarias para guardar los modelos entrenados, cuya arquitectura y parámetros de entrenamiento y validación estaban previamente configurados en un archivo JSON, haciendo legibles los Notebooks de entrenamiento y ahorrando mucho tiempo para la implementación de los 72 modelos a entrenar.

De esta manera se pudieron entrenar los modelos en un tiempo razonable y proporcionando una mayor flexibilidad y portabilidad de la solución, permitiendo la colaboración de los miembros del equipo y el acceso a los modelos entrenados desde diferentes entornos de manera conveniente.

En nuestro caso, encontramos más conveniente el entrenamiento de los modelos en la plataforma Kaggle, que dispone de una cantidad de recursos de GPU gratis con una capacidad ideal para nuestro problema.

5.2 Validación

Para llevar a cabo la validación de cada modelo, se implementó un proceso que permitiera una evaluación precisa de su rendimiento y que fuera homóloga entre los 72 modelos entrenados. Este proceso se dividió en varias etapas:

1. **Entrenamiento inicial:** Los modelos se entrenaron utilizando el conjunto de datos de entrenamiento. Se configuraron 50 épocas de entrenamiento para cada modelo.
2. **Validación en cada época:** En cada época de entrenamiento, se realizó una validación del modelo utilizando el conjunto de datos de prueba. Durante esta validación, se calculó y monitoreó la métrica Huber Loss para evaluar el desempeño del modelo en los datos no vistos.
3. **Early Stopping:** Se configuró una técnica de detención temprana (*early stopping*) para evitar el sobreajuste y optimizar el tiempo de entrenamiento. Se estableció una paciencia de 5 épocas, lo que significa que si la métrica Huber Loss no mejoraba durante 5 épocas consecutivas en el conjunto de validación, el entrenamiento del modelo se detenía automáticamente.
4. **ModelCheckpoint:** Durante el entrenamiento, se utilizó la función *ModelCheckpoint* de TensorFlow para guardar el modelo durante el entrenamiento. Esta función permitió guardar el modelo con el mejor desempeño en términos de la métrica Huber Loss en el conjunto de validación. De esta manera, incluso si se detenía el entrenamiento debido al *early stopping*, se conservaba el mejor modelo hasta ese punto.

Con este sistema de validación se pudieron obtener resultados más robustos a la vez que era práctico al no permitir el sobre entrenamiento y asegurando que el mejor modelo entrenado se guardaba.

5.3 Iteraciones y evolución

Después de completar la fase de validación inicial, se procedió a realizar una exploración en términos de las secuencias de entrada de los modelos, variando la ventana de observación y la superposición, como se definió en las Tablas 5 y 6, con el objetivo de identificar como estos influían en el desempeño de los modelos. Para lograr esto, se llevaron a cabo un total de 9 experimentos para cada uno de los 8 modelos generados. Las combinaciones de los experimentos se describen en la Tabla 7

Tabla 7

Combinaciones de ventanas de observación y superposición

Ventana de observación (n)	Superposición
48	47 (n-1)
48	24 (n/2)
48	0
72	71 (n-1)
72	36 (n/2)
72	0
96	95 (n-1)
96	48 (n/2)
96	0

De esta manera se entrenaron 72 modelos y para cada uno de ellos se guardó el modelo en formato keras, la historia del entrenamiento del modelo a través de las épocas y los objetos con la información de escalado y normalización de los datos para ser utilizados en el desescalamiento posterior de las predicciones en la etapa de evaluación de los resultados.

5.4 Validación cruzada

La validación cruzada (cross-validation) es una técnica utilizada para mejorar la capacidad de generalización de un modelo, es decir, su rendimiento en datos no vistos. Consiste en dividir el conjunto de datos disponible en múltiples subconjuntos o pliegues (folds) y luego entrenar y validar el modelo en diferentes combinaciones de estos pliegues.

Para este proyecto se utilizó una versión adaptada de validación cruzada para series de tiempo llamada TimeSeriesSplit. A diferencia de la validación cruzada tradicional, TimeSeriesSplit

respeta el orden temporal de los datos, asegurando que los datos de entrenamiento siempre precedan a los datos de prueba. Esta técnica divide los datos en múltiples pliegues (splits) de forma secuencial y permite que en cada iteración se entrene al modelo con todos los splits anteriores y se valide con el split posterior. Esta técnica se puede ver esquematizada en la Figura 12.

Figura 12

Esquema de validación cruzada TimeSeriesSplit




Imagen tomada de [Scikit-learn \(2024\)](#)

5.5 Herramientas

Durante el desarrollo de este proyecto, se utilizaron varias herramientas y tecnologías para el desarrollo y evaluación de modelos de aprendizaje automático. A continuación, se detalla la relación de las herramientas más utilizadas:

1. **Python 3.11:** Se utilizó Python como el lenguaje de programación principal para el desarrollo de todo el proyecto. La versión 3.11 de Python proporcionó acceso a las últimas características de forma estable. Además, los paquetes más recientes ampliamente utilizados en aprendizaje automático están disponibles de manera optimizada para esta versión de Python.
2. **Jupyter Notebooks:** Se emplearon Jupyter Notebooks a manera de entorno de desarrollo interactivo para escribir y ejecutar código de Python en forma modular y estructurada. Esto facilitó la experimentación rápida y la visualización de resultados intermedios, que no sería fáciles de obtener con scripts tradicionales de Python.

3. **TensorFlow 2.16:** Se utilizó TensorFlow como la principal biblioteca de aprendizaje automático para la implementación de modelos de redes neuronales. La versión 2.16 de TensorFlow proporcionó herramientas y funcionalidades actualizadas para la construcción y entrenamiento de modelos, en particular todo el módulo de Keras.
4. **Pandas:** Se empleó Pandas para la manipulación y el análisis de datos. Esta biblioteca proporcionó las herramientas para el preprocesamiento de los datos, exploración de ellos, experimentos para la selección del dataset y generación de las secuencias para el entrenamiento de los modelos.
5. **NumPy:** NumPy se utilizó para operaciones numéricas y computacionales eficientes en Python. Esta biblioteca se utilizó para transformar datos de entrada a los modelos y la generación de métricas y validación de datos nulos.
6. **scikit-learn:** Se empleó scikit-learn como una biblioteca de aprendizaje automático de propósito general para tareas como preprocesamiento de datos, técnicas de validación cruzada y evaluación de rendimiento.
7. **Kaggle** Es una plataforma utilizada por científicos de datos y desarrolladores de machine learning. Esta herramienta dispone de recursos de un ambiente de desarrollo gratuito en el que fueron entrenados los modelos haciendo uso de las GPU que ofrecen para experimentación.
8. **GitHub:** Se utilizó GitHub como plataforma de control de versiones para colaborar en el desarrollo del proyecto y mantener un registro de los cambios realizados en el código fuente. Además, permitió la integración del ambiente de Kaggle con los scripts y datasets requeridos para el entrenamiento de los modelos.

6 Resultados y discusión

Como se describió en la sección 5 se entrenaron 72 modelos. En esta sección se presentan los resultados obtenidos en la evaluación de dichos modelos.

Como el número de pasos de predicción corresponde a 24 horas y los datos corresponden a un lugar geográfico donde suceden las cuatro estaciones del año, se seleccionaron 4 días del período de pruebas, uno para cada estación: invierno, primavera, verano y otoño (Ver Tabla 8) y con cada modelo se obtuvieron las predicciones para cada uno de ellos.

En el Anexo A se presentan las métricas para los 72 modelos para los 4 períodos. En la sección 6.1 se muestran los resultados para los modelos que mejor predijeron cada uno de los días. En la sección 6.2 se muestran los dos modelos que en promedio, para todos los períodos, obtuvieron el mejor y el peor desempeño. A estos dos modelos se les aplicó una técnica de validación cruzada (descrita en la sección 5.4). Los resultados obtenidos y la comparación con los modelos iniciales se presentan en la sección 6.3. Por último, los resultados obtenidos se discuten en la sección 6.5.

Tabla 8

Listado de fechas para las pruebas de validación

Fecha	Nombre
2008-01-01	Día de invierno
2008-04-01	Día de primavera
2008-07-01	Día de verano
2008-10-01	Día de otoño

6.1 Resultados de los mejores modelos por día

A continuación se relacionan los modelos que tuvieron los mejores resultados para cada uno de los días seleccionados, con el fin de identificar si ellos son particularmente buenos generalizando el comportamiento intraestacional.

Día de invierno

Modelo: *LSTM*

Arquitectura: *Arquitectura de modelos 2 (ver Figura 11)*

Ventana de observación: *48 muestras (24 horas)*

Superposición: *1 muestra*


Tabla 9

Métricas mejor modelo día de invierno.

MAE	MSE	RMSE	MAPE	Huber loss
19.35	1052.94	32.45	16.96 %	18.85

Figura 13

Gráfica de predicción para el periodo de invierno el 1 de enero de 2008.



La estimación obtenida muestra una buena aproximación a la curva real de los datos de radiación solar global horizontal (GHI). Sin embargo, no es capaz de predecir con exactitud la reducción del GHI que se observa en el pico más alto de radiación esperada, que ocurre antes y poco después del mediodía el 1 de enero de 2008. Esta diferencia sugiere que, aunque el modelo captura adecuadamente la tendencia general de la radiación solar, hay factores específicos, posiblemente relacionados con condiciones atmosféricas locales o eventos transitorios, que no están siendo completamente representados en la estimación.

Día de primavera

Modelo: *LSTM*

Arquitectura: *Arquitectura de modelos 2 (ver Figura 11)*

Ventana de observación: *48 muestras (24 horas)*

Superposición: *1 muestra*


Tabla 10

Métricas mejor modelo día de primavera.

MAE	MSE	RMSE	MAPE	Huber loss
30.83	2799.76	52.91	22.68 %	30.35

Figura 14

Gráfica de predicción para el periodo de primavera el 1 de abril de 2008.



La estimación obtenida muestra una buena aproximación a la curva real de los datos de radiación solar global horizontal (GHI). Sin embargo, no es capaz de predecir con precisión la reducción del GHI que se observa a lo largo del día, siendo la curva predicha más suave que el comportamiento esperado durante el día 1 de abril de 2008. De igual manera, esto sugiere que, aunque el modelo captura adecuadamente la tendencia general de la radiación solar, hay factores específicos, posiblemente relacionados con condiciones atmosféricas locales o eventos transitorios, que no están siendo completamente representados en la estimación.

Día de verano

Modelo: *GRU*

Arquitectura: *Arquitectura de modelos 1 (Ver Figura 10)*

Ventana de observación: *72 muestras (36 horas)*

Superposición: *36 muestras*


Tabla 11

Métricas mejor modelo día de verano.

MAE	MSE	RMSE	MAPE	Huber loss
29.79	1709.07	41.34	12.44 %	29.29

Figura 15

Gráfica de predicción para el periodo de verano el 1 de julio de 2008.



La estimación obtenida muestra nuevamente una buena aproximación a la curva real de los datos de GHI. Sin embargo, no fue capaz de predecir con precisión algunos pico de variación en el GHI que se observa durante el espacio de la tarde del 1 de julio de 2008, siendo la curva predicha más suave que el comportamiento esperado. De igual manera, esto sugiere que, aunque el modelo captura adecuadamente la tendencia general de la radiación solar, hay factores específicos, posiblemente relacionados con condiciones atmosféricas locales o eventos transitorios, que no están siendo completamente representados en la estimación.

Día de otoño

Modelo: *ConvGRU*

Arquitectura: *Arquitectura de modelos 1 (Ver Figura 10)*

Ventana de observación: *72 muestras (36 horas)*

Superposición: *1 muestra*

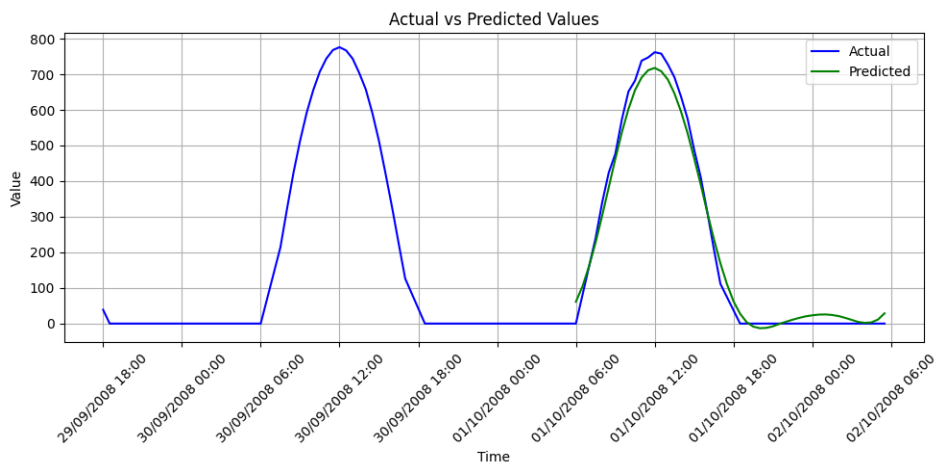
Tabla 12

Métricas mejor modelo día de otoño.

MAE	MSE	RMSE	MAPE	Huber loss
24.30	850.43	29.16	13.29%	23.80

Figura 16

Gráfica de predicción para el periodo de otoño el 1 de octubre de 2008.



La predicción obtenida muestra una aproximación muy cercana a la curva real de los datos de GHI. En el caso particular del 1 de octubre de 2008, la radiación disponible medida no se vio significativamente afectada por las condiciones atmosféricas locales, lo que resultó en una predicción bastante exacta. Sin embargo, la estimación es levemente más baja que la curva real de los datos de GHI.

6.2 Análisis promedio de los modelos

Se promediaron los resultados de cada uno de los 72 modelos para los 4 días de pruebas. Basado en la métrica MAE, se seleccionaron el mejor y el peor modelo.

Mejor modelo promedio

Modelo: *GRU*

Arquitectura: *Arquitectura de modelos 1 (Ver Figura 10)*

Ventana de observación: *72 muestras (36 horas)*

Superposición: *36 muestras*

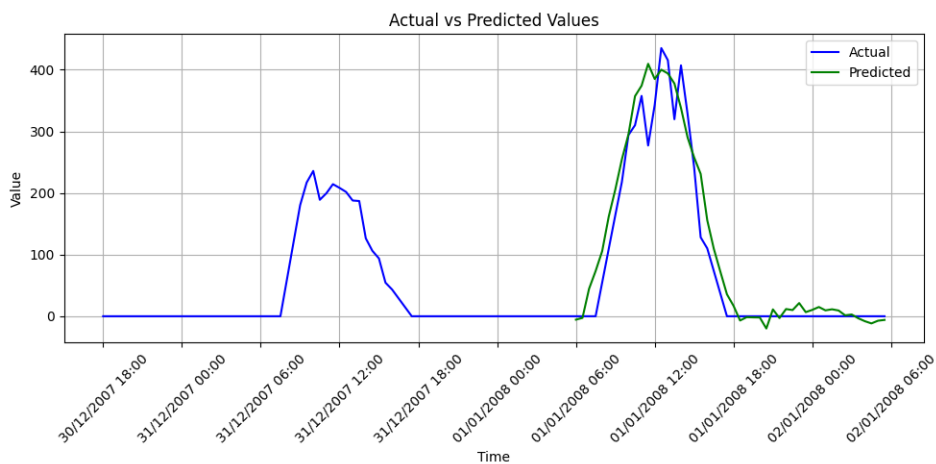
Tabla 13

Métricas mejor modelo promedio.

MAE	MSE	RMSE	MAPE	Huber loss
30.93	2157.20	45.87	25.74 %	30.43

Figura 17

Gráfica de predicción para el 1 de enero de 2008 mejor modelo promedio.



Tras promediar los resultados por modelo, se identificó que las mejores métricas fueron obtenidas por el modelo GRU con una ventana de observación de 36 horas y una superposición de 36 muestras. Este modelo muestra una predicción muy cercana al valor medido para el

1 de enero de 2008, aunque presenta algunas variaciones más aleatorias que no terminan de coincidir con las variaciones medidas, posiblemente relacionadas con factores locales.

Peor modelo promedio

Modelo: *RNN*

Arquitectura: *Arquitectura de modelos 2 (Ver Figura 11)*

Ventana de observación: *48 muestras (24 horas)*

Superposición: *48 muestras*


Tabla 14

Métricas peor modelo promedio.

MAE	MSE	RMSE	MAPE	Huber loss
377.84	209149.17	450.80	238.64 %	377.34

Figura 18

Gráfica de predicción para el 1 de enero de 2008 peor modelo promedio.



Por otro lado, el peor desempeño promedio se observó en el modelo RNN con una ventana de observación de 24 horas y una superposición de 48 muestras. Este modelo no logra predecir con buena exactitud ninguna de las muestras esperadas, mostrando una alta aleatoriedad y una gran imprecisión al seguir la curva real de los datos medidos.

6.3 Validación cruzada con TimeSeriesSplit

Para evaluar el impacto de la técnica validación cruzada para series de tiempo (TimeSeriesSplit) se entrenaron el mejor y el mejor modelo (6.2) dividiendo el conjunto de entrenamiento en 10 secciones. Los resultados obtenidos se describen a continuación.

Tabla 15


Resultados del mejor modelo tras validación cruzada

	MAE	MSE	RMSE	MAPE	Huber loss
Antes de validación cruzada	30.93	2157.20	45.87	25.74 %	30.43
Después de validación cruzada	33.95	2681.49	49.88	27.42 %	33.45
Mejora*	-9.76 %	-24.30 %	-8.74 %	-6.52 %	-9.92 %

*Valores negativos en la mejora indican que no hubo tal, si no que se obtuvieron peores resultados.

Figura 19


Gráfica de predicción posterior a validación cruzada para el mejor modelo promedio.



Después de realizar la validación cruzada, se observa que el modelo GRU con la arquitectura de modelos 1, una ventana de observación de 36 horas y 36 muestras de superposición no muestra mejoras en sus métricas de desempeño. A pesar de esto, su rendimiento sigue siendo satisfactorio, como se evidencia en el gráfico al realizar la predicción para el 1 de enero de 2008, en comparación con otros modelos entrenados en el ejercicio anterior.

Tabla 16*Resultados del peor modelo tras validación cruzada*

	MAE	MSE	RMSE	MAPE	Huber loss
Antes de validación cruzada	377.84	209149.17	450.80	238.64 %	377.34
Después de validación cruzada	240.77	118333.39	325.02	100.76 %	240.27
Mejora	36.27 %	43.42 %	27.09 %	57.77 %	36.32 %

Figura 20*Gráfica de predicción posterior a validación cruzada para el peor modelo promedio.*

Después de realizar la validación cruzada, se observa que el modelo RNN con la arquitectura de modelos 2, una ventana de observación de 24 horas y 48 muestras de superposición presenta algunas mejorías en el desempeño a nivel de métricas. A pesar de esto, su rendimiento sigue sin ser muy bueno, cosa que se ve reflejada gráficamente en la predicción para la misma fecha del 1 de enero de 2008.

6.4 Modelo Lag Llama

Durante el levantamiento del estado del arte el equipo encontró un modelo de libre acceso liberado en marzo de 2024 denominado Lag Llama. Este modelo representa un avance significativo en la predicción de series temporales utilizando modelos de redes neuronales profundas con una configuración denominada "transformadores" que están preentrenados. Este enfoque se centra en superar las limitaciones tradicionales de los modelos de series temporales mediante la integración de técnicas avanzadas de machine learning y aprendizaje profundo, específicamente diseñadas para manejar datos secuenciales y temporales (Tashiro et al., 2023).

Fundamentalmente, Lag Llama emplea un red del tipo transformador que está preentrenado, una arquitectura que ha demostrado ser extremadamente eficaz en el procesamiento del lenguaje natural. Los transformadores son capaces de capturar relaciones complejas en los datos, gracias a su mecanismo de atención, que permite ponderar la importancia de diferentes partes de la secuencia de entrada de manera dinámica (Vaswani et al., 2017). Esta capacidad es crucial para manejar las dependencias a largo plazo en las series temporales, donde los eventos pasados pueden influir significativamente en el futuro (Woo et al., 2018).

El modelo Lag Llama se entrena inicialmente en un conjunto de datos amplio y variado de series temporales, permitiéndole aprender patrones generales y transferibles. Esta etapa de preentrenamiento facilita una capacidad de generalización superior cuando se aplica a nuevas series temporales específicas. La ventaja de utilizar un modelo preentrenado radica en la reducción del tiempo de entrenamiento y en la mejora de la exactitud en la predicción, dado que el modelo ya posee un conocimiento base robusto que puede afinarse con datos específicos del problema en cuestión.

En términos de implementación, Lag Llama convierte los datos de series temporales en tokens, similar a cómo se procesan las palabras en un modelo de lenguaje. Este enfoque permite que el modelo aplique su mecanismo de atención de manera efectiva a los datos temporales, identificando patrones y relaciones que serían difíciles de detectar con métodos tradicionales. La conversión a tokens también facilita la manipulación y el análisis de datos temporales de diversas frecuencias y escalas.

Uno de los aspectos más innovadores de Lag Llama es su capacidad para realizar predicciones probabilísticas, proporcionando no solo una estimación puntual, sino también una distribución de probabilidad sobre las posibles salidas futuras. Esto es particularmente útil

en contextos donde es importante entender la incertidumbre asociada con las predicciones, como en la planificación de recursos energéticos o la gestión de inventarios. De tal manera que tiene una ventaja respecto a los modelos entrenados en este proyecto y puede ser especialmente útil en para la toma de decisiones en la producción de energía fotovoltaica en un proyecto real.

Finalmente, Lag Llama ha mostrado resultados prometedores en múltiples estudios y aplicaciones, superando a los modelos de referencia en precisión y eficiencia (Tashiro et al., 2023). Su arquitectura flexible y su capacidad de manejar grandes volúmenes de datos lo convierten en una herramienta poderosa para una amplia gama de aplicaciones de series temporales. La adopción de este modelo puede transformar significativamente cómo las organizaciones abordan la predicción y el análisis de series temporales, ofreciendo nuevas oportunidades para la toma de decisiones informadas y estratégicas.

Para este proyecto, se comparó el resultado del mejor modelo en términos promedio (6.2) con la predicción del modelo de Lag Llama para el período del 2010-12-31 00:00:00. En las Figuras 21 y 22 se muestran los resultados de la predicción y en la Tabla 17 se observan las métricas para cada uno de los modelos.

Se puede observar que el modelo Lag Llama tiene mejores métricas de desempeño que el modelo generado en el proyecto, demostrando que es un modelo que promete tener buenas aplicaciones en este tipo de problemas y que deberá explorarse más a fondo para conocer otros casos de uso.

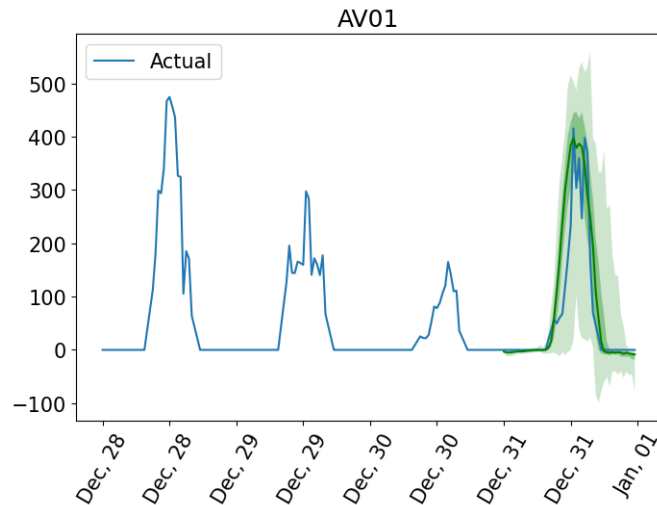

Tabla 17

Métrica del modelo con mejor desempeño medio Vs. Lag Llama

	MAE	MSE	RMSE	MAPE
Lag Llama	29.44	3515.09	59.29	87.16 %
Modelo mejor desempeño medio	41.98	4936.04	70.26	111.70 %

6.5 Discusión de resultados

Los resultados muestran que, en general, los modelos basados en GRU presentaron un mejor desempeño en términos de métricas de error promedio como MAE, MSE, y RMSE en comparación con otros modelos como RNN y LSTM. Esto sugiere que la arquitectura GRU es más efectiva para capturar patrones temporales en los datos de radiación solar.

Figura 21*Predicción del modelo Lag Llama***Figura 22***Predicción del modelo con mejor desempeño medio*

La implementación de la técnica de validación cruzada específica para series de tiempo, `TimeSeriesSplit`, permitió obtener una evaluación más robusta del desempeño de los modelos. Los resultados tras aplicar esta técnica indicaron una mejora general en las métricas de error, destacándose una reducción significativa en el MAE y el MSE, especialmente en el peor modelo, lo que evidencia la importancia de utilizar métodos de validación adecuados para

series temporales. Este enfoque asegura que el modelo no solo es evaluado en un conjunto fijo de datos, sino que su capacidad de generalización es probada en múltiples subconjuntos de datos. No obstante, para el mejor modelo no se obtuvieron mejoras utilizando esta técnica, lo que puede significar que la arquitectura utilizada se comporta mejor con el universo completo de datos.

En particular, el modelo ConvGRU, que combina convoluciones con GRU, mostró un rendimiento destacable durante el periodo de otoño, con métricas significativamente mejores que otros modelos en la predicción de la radiación solar en ese periodo específico. Esto indica que las arquitecturas híbridas que combinan características de modelos convolucionales y recurrentes pueden ofrecer ventajas en la predicción de series temporales complejas como la radiación solar, capturando tanto patrones espaciales (si se dispone de imágenes) como temporales.

Al comparar los resultados obtenidos con estudios previos, se observó que los modelos de deep learning, en particular las arquitecturas basadas en GRU e híbridas (ConvGRU), proporcionan una mejora considerable en la precisión de las predicciones en comparación con enfoques tradicionales como los modelos de regresión lineal o los modelos ARIMA. Sin embargo, es importante notar que la efectividad de estos modelos puede variar según la ventana de observación y la superposición de los datos, lo cual fue evidenciado en los diferentes experimentos realizados con diversas configuraciones, donde valores de superposición iguales a la ventana de observación fueron los que peor desempeño tuvieron en términos generales. Mientras que valores superposición cercanos a la mitad de la ventana de observación fueron mucho mejor en su desempeño.

Además, los resultados sugieren que aunque los modelos de deep learning tienen una capacidad superior para aprender patrones complejos en los datos, su desempeño puede ser afectado por factores como la selección de hiperparámetros y la configuración del preprocesamiento de los datos. Esto resalta la necesidad de realizar un proceso iterativo y exhaustivo de ajuste de modelos para obtener el mejor desempeño posible. Con ello surge un tema profundo a resolver y es costo computacional derivado del proceso de sintonización de los hiperparámetros de las redes neuronales que podrían hacer altamente costoso un proyecto en términos de tiempo o costo de dinero.

Finalmente, se identificaron varias áreas de mejora y futuras líneas de investigación, tales como la integración de datos adicionales (por ejemplo, datos meteorológicos en tiempo real) y la exploración de otras arquitecturas de modelos avanzadas, como los transformers, que

hacen parte del model Lag Llama y cuyos resultados mostraron ser mejores que los modelos generados con las arquitecturas propuestas en este trabajo. Estas mejoras potenciales podrían contribuir a una mayor precisión y robustez en las predicciones de radiación solar, beneficiando aplicaciones prácticas en la planificación y gestión del despacho de los recursos energéticos renovables.

7 Conclusiones

El estudio realizado sobre la predicción de la radiación solar utilizando modelos de deep learning ha demostrado que las arquitecturas RNN, GRU, LSTM y CNN, combinadas con técnicas de preprocesamiento y validación adecuadas, pueden ofrecer resultados más exactos y robustos.

A lo largo del análisis, se observó que la elección de la ventana de observación y la superposición tienen un impacto significativo en el desempeño de los modelos. Los modelos híbridos (CNN + GRU), en particular, mostraron una mejora considerable en términos de las métricas MAE y RMSE después de aplicar técnicas de validación cruzada con TimeSeriesSplit, lo cual valida la importancia de este tipo de técnicas para la evaluación adecuada del desempeño en series temporales.

El análisis de los mejores modelos para cada uno de los días evaluados y la comparación con estudios previos indican que la metodología utilizada es eficaz y puede ser aplicada a otros contextos de predicción de series temporales. Además, el uso de técnicas de optimización como el EarlyStopping y ModelCheckpoint permitió evitar el sobreajuste y asegurar que se conservaran los mejores modelos durante el entrenamiento.

A lo largo del estudio, se observó que el modelo GRU con ventanas de observación de 72 muestras y superposiciones de 36 muestras lograron predecir con mayor exactitud, especialmente en condiciones donde la radiación solar no se vio significativamente afectada por condiciones atmosféricas locales. En contraste, los modelos RNN con distintas ventanas de observación y superposición mostraron un desempeño inferior, con alta aleatoriedad y gran inexactitud en sus predicciones. Adicionalmente, a pesar de no tener información espacial o de imágenes, el tratamiento de las secuencias de entrada a los modelos como matrices, como si fueran imágenes, destacan que el uso de modelos híbridos de redes GRU y LSTM con redes convolucionales tienen mejoras en las predicciones, consecuente con los resultados de [Souahlia et al. \(2023\)](#).

También se pudo evidenciar que en dos de los cuatro días evaluados para las estaciones, invierno y primavera, las redes LSTM pudieron capturar las dependencias a largo plazo y tuvieron mejor desempeño que los otros modelos probados. Esto es consistente con otros estudios donde las redes LSTM obtuvieron un RMSE significativamente más bajo que otros modelos ([Venu et al., 2023](#)).

Este trabajo también destaca la importancia de seleccionar correctamente los hiperparámetros y la arquitectura del modelo según el contexto específico de los datos. En modelos como Random Forest y Supported Vector Regression, la optimización de hiperparámetros con técnicas como Gridsearch, Random Search, Bayesian Optimization y Genetic Algorithms mejoran significativamente el rendimiento de los modelos (Kumar et al., 2022). Estas herramientas también son extensibles a los modelos que se entrenaron para este proyecto y que pueden explorar una mayor cantidad de hiperparámetros con el fin de mejorar la exactitud en la predicción.

La capacidad de los modelos de deep learning para capturar patrones complejos en series temporales de radiación solar demuestra su potencial para aplicaciones en energía renovable, donde una predicción exacta es crucial para la planificación y gestión del despacho de recursos renovables intermitentes.

8 Recomendaciones

A lo largo de este trabajo se encontró con limitaciones de capacidad computacional lo que conllevó a la realización de una cantidad ajustada de experimentos. Para trabajos futuros se sugiere realizar más experimentos con diferentes valores de superposición. Aunque los resultados actuales han demostrado que una superposición cercana a la mitad de la ventana de observación (n) tiende a ser más efectiva, sería beneficioso explorar una gama más amplia de valores en el rango entre $n/2$ y $n-1$. También se podrían incluir configuraciones dinámicas que ajusten la superposición en función de las características temporales de los datos específicos, por ejemplo variando según la temporada del año.

Además de las arquitecturas RNN, GRU, LSTM e híbridas ya exploradas, es recomendable probar modelos más avanzados como los encoder-decoder y transformers. Estos modelos han mostrado un gran potencial en diversas tareas de series temporales y podrían ofrecer mejoras significativas en la predicción de la radiación solar al capturar relaciones más complejas entre las variables temporales.

En este proyecto se implementó el método de validación cruzada `TimeSeriesSplit`, con algunos resultados positivos y otros no tanto, como fue discutido en la sección 6.3. En futuras investigaciones se podrían experimentar otros métodos de validación cruzada, como la validación cruzada por bloques (donde los datos de entrenamiento se dividen en n dobleces con la misma cantidad de muestras y cada pliegue se divide a su vez en un conjunto de entrenamiento y uno de validación), o métodos anidados como el de *predicción de la segunda mitad* (donde el conjunto de datos se divide en 4 partes. La primera sirve de conjunto de entrenamiento, la segunda parte de conjunto de validación y las dos últimas, la segunda mitad, son el conjunto de pruebas del modelo) o *encadenamiento del siguiente día* (similar al `TimeSeriesSplit`, pero en el que el conjunto de entrenamiento se va acumulando un día a la vez y el conjunto de validación corresponde al día siguiente) (Chess, 2023). De esta manera se podrían obtener mejores resultados que permitan generalizar la solución para un mayor tipo de escenarios, evitando que el sobre entrenamiento.

Ampliar el período de validación de los modelos a más días de cada temporada podría proporcionar una evaluación más robusta y generalizable de su desempeño. Esto no solo permitirá observar el comportamiento de los modelos en diferentes condiciones atmosféricas y estacionales, sino que también ayudará a identificar patrones y tendencias que puedan no ser evidentes en períodos más cortos.

Un enfoque no abordado en el proyecto fue la integración de modelos físicos o datos meteorológicos asociados con la nubosidad, más allá de la precipitación. El uso de estos, acoplados a los modelos de deep learning podrían arrojar resultados más confiables para la toma de decisiones en tiempo real.

De otro lado, en este proyecto se utilizó el reciente modelo Lag Llama. Un campo de experimentación se abre con este y otros modelos preentrenados como TimeGPT, ya que estos modelos han sido entrenados en vastas cantidades de datos y tienen la capacidad de generalizar mejor. Al realizar una sintonización fina (fine-tuning) de estos modelos con los datos específicos del estudio se podría aprovechar su conocimiento previo para mejorar la exactitud y robustez de las predicciones de radiación solar.

También es importante fortalecer el proceso de sintonización de hiperparámetros con otras alternativas como GridSearch y optimización bayesiana, estableciendo la estrategia correcta porque este proceso es computacionalmente intensivo y requiere de servicios de pago en la nube para realizar una mayor cantidad de experimentos en un tiempo razonable.

Referencias

- Bendali, W., I. Saber, B. Bourachdi, M. Boussetta, and Y. Mourad (2020, October 21). Deep learning using genetic algorithm optimization for short term solar irradiance forecasting. In *2020 Fourth International Conference On Intelligent Computing in Data Sciences (ICDS)*.
- Brahma, B. and R. Wadhvani (2020). *Symmetry*. 12(11), 1830.
- Cesar, B., M. Callejo, C.-I. Cira, and A. Garrido (2022, December 6). *Cyl.ghi*.
- Cesar, L. B., M. Ángel Manso Callejo, C.-I. Cira, and R. P. A. Garrido (2022, December). *Cyl.ghi*.
- Cess, R. D., M. H. Zhang, P. Minnis, L. Corsetti, E. G. Dutton, B. W. Forgan, D. P. Garber, W. L. Gates, J. J. Hack, E. F. Harrison, et al. (1995). *Science*. 267(5197), 496–499.
- Chess, S. (2023). Cross-validation in time series.
- Gautier, C., G. Diak, and S. Masse (1980). *Journal of Applied Meteorology*. 19(8), 1005–1012.
- Hammer, A., D. Heinemann, E. Lorenz, and B. Lückehe (1999). *Solar Energy*. 67(1–3), 139–150.
- Hassan, G. E., M. E. Youssef, Z. E. Mohamed, M. A. Ali, and A. A. Hanafy (2016). New temperature-based models for predicting global solar radiation. *Applied Energy* 179, 437–450.
- Ibrahim, I. A. and T. Khatib (2017). A novel hybrid model for hourly global solar radiation prediction using random forests technique and firefly algorithm. *Energy Conversion and Management* 138, 413–425.
- Jentsch, A. and C. Beierkuhnlein (2008). *Comptes Rendus Geoscience*. 340(9–10), 621–628.
- Kumar, M., K. Namrata, and N. Kumari (2022). Hyper-parametric improved machine learning models for solar radiation forecasting. *Concurrency and Computation: Practice and Experience* 34.
- Kumari, P. and D. Toshniwal (2021). Deep learning models for solar irradiance forecasting: A comprehensive review. *Journal of Cleaner Production* 318, 128566.

-
- Liu, W., Y. Liu, X. Zhou, Y. Xie, Y. Han, S. Yoo, and M. Sengupta (2021). Use of physics to improve solar forecast: Physics-informed persistence models for simultaneously forecasting ghi, dni and dhi. *Solar Energy* 215, 252–265.
- Mishra, A., N. D. Kaushika, G. Zhang, and J. Zhou (2008). International Journal of Sustainable Energy. 27(3), 95–103.
- Mishra, S. and P. Palanisamy (2018, September). Multi-time-horizon solar forecasting using recurrent neural network. In 2018 IEEE Energy Conversion Congress and Exposition (ECCE).
- Moreno-Munoz, A., J. J. G. de la Rosa, R. Posadillo, and F. Bellido (2008, May). Very short term forecasting of solar radiation. In 2008 33rd IEEE Photovoltaic Specialists Conference.
- Nann, S. and C. Riordan (1991). Journal of Applied Meteorology. 30(4), 447–462.
- Olatomiwa, L., S. Mekhilef, S. Shamshirband, K. Mohammadi, D. Petković, and C. Sudheer (2015). A support vector machine–firefly algorithm-based model for global solar radiation prediction. *Solar Energy* 115, 632–644.
- Panwar, N. L., S. C. Kaushik, and S. Kothari (2011). *Renewable and Sustainable Energy Reviews*. 15(3), 1513–1524.
- Scikit-learn (2024). Cross-validation indices example. https://scikit-learn.org/stable/_images/sphx_glr_plot_cv_indices_013.png. Accessed: 2024-06-10.
- Sehrawat, N., S. Vashisht, and A. Singh (2023). *International Journal of Intelligent Networks*. 4(1), 90–102.
- Souahlia, A., A. Rabehi, and A. Rabehi (2023). Hybrid models for daily global solar radiation assessment. *The Journal of Engineering and Exact Sciences*.
- Srivastava, S. and S. Lessmann (2018). A comparative study of lstm neural networks in forecasting day-ahead global horizontal irradiance with satellite data. *Solar Energy* 162, 232–247.
- Stern, D. I. and R. K. Kaufmann (2013). *Climatic Change*. 122(1–2), 257–269.
- Tashiro, Y., C. N. Ellison, H. Chen, K. Tell, H. Ren, W. Sultani, L. Jing, S. Khan, and R. Zemel (2023). *Lag-llama: Towards foundation models for probabilistic time series forecasting*. arXiv preprint arXiv:2310.08278.

-
- Vaswani, A., N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin (2017). *Attention is all you need*. Advances in neural information processing systems 30.
- Venu, K., K. I. Prakash, S. Jayaram, N. Karan, M. Raja, and K. Renu (2023). Solar radiation prediction using machine learning model. In *2023 International Conference on Sustainable Computing and Data Communication Systems (ICSCDS)*, (pp. 52–57). IEEE.
- Verbruggen, A., M. Fishedick, W. Moomaw, T. Weir, A. Nadaï, L. J. Nilsson, J. Nyboer, and J. Sathaye (2010). *Energy Policy*. 38(2), 850–861.
- Voyant, C., G. Notton, S. Kalogirou, M.-L. Nivet, C. Paoli, F. Motte, and A. Fouilloy (2017). Machine learning methods for solar radiation forecasting: A review. *Renewable Energy* 105, 569–582.
- Whiteman, C. D. and K. J. Allwine (1986). *Environmental Software*. 1(3), 164–169.
- Wojtkiewicz, J., M. Hosseini, R. Gottumukkala, and T. L. Chambers (2019). *Energies*. 12(21), 4055.
- Woo, M., S. Wang, and K. Chaudhuri (2018). *International Journal of Forecasting*. 34(4), 803–819.
- Yu, Y., J. Cao, and J. Zhu (2019). *An lstm short-term solar irradiance forecasting under complicated weather conditions*. IEEE Access 7, 145651–145666.
- Zang, H., L. Cheng, T. Ding, K. W. Cheung, M. Wang, Z. Wei, and G. Sun (2020). Application of functional deep belief network for estimating daily global solar radiation: A case study in china. *Energy* 191, 116502.
- Zang, H., L. Liu, L. Sun, L. Cheng, Z. Wei, and G. Sun (2020). *Short-term global horizontal irradiance forecasting based on a hybrid cnn-lstm model with spatiotemporal correlations*. Renewable Energy 160, 26–41.
- Zhao, X., H. Wei, H. Wang, T. Zhu, and K. Zhang (2019). 3d-cnn-based feature extraction of ground-based cloud images for direct normal irradiance prediction. *Solar Energy* 181, 510–518.

Anexos

A Métricas de los modelos entrenados para cada período

Nota: el nombre del modelo hace referencia a la arquitectura y parámetros tenidos en cuenta en el entrenamiento, de acuerdo a la estructura:

[NOMBRE MODELO]_[NRO. ARQUITECTURA]_look[VENTANA OBSERV.]_overlap[SUPERPOSICIÓN]

(Ejemplo: RNN_1_look96_overlap48).

model	val.timestamp	MSE	RMSE	MAPE	sMAPE	MAE	Huber_loss
RNN_2_look96_overlap96	2008-01-01 06:00:00	86538.48	294.17	129.58 %	159.96 %	222.27	221.77
RNN_2_look96_overlap96	2008-04-01 06:00:00	149716.86	386.93	276.53 %	161.57 %	314.50	314.00
RNN_2_look96_overlap96	2008-07-01 06:00:00	261166.46	511.04	215.64 %	157.89 %	415.13	414.63
RNN_2_look96_overlap96	2008-10-01 06:00:00	170060.56	412.38	171.86 %	165.25 %	334.12	333.62
RNN_2_look96_overlap48	2008-01-01 06:00:00	90367.13	300.61	118.08 %	165.74 %	227.60	227.10
RNN_2_look96_overlap48	2008-04-01 06:00:00	143628.92	378.98	269.22 %	157.63 %	305.06	304.56
RNN_2_look96_overlap48	2008-07-01 06:00:00	258482.24	508.41	167.85 %	154.60 %	402.90	402.40
RNN_2_look96_overlap48	2008-10-01 06:00:00	166418.58	407.94	201.12 %	159.77 %	327.38	326.88
RNN_2_look96_overlap1	2008-01-01 06:00:00	44744.02	211.53	178.99 %	145.76 %	164.60	164.10
RNN_2_look96_overlap1	2008-04-01 06:00:00	5448.47	73.81	65.37 %	113.87 %	60.87	60.38
RNN_2_look96_overlap1	2008-07-01 06:00:00	42491.61	206.13	43.78 %	107.61 %	152.34	151.84
RNN_2_look96_overlap1	2008-10-01 06:00:00	8482.01	92.10	55.77 %	119.68 %	78.06	77.56
RNN_2_look72_overlap72	2008-01-01 06:00:00	63329.36	251.65	164.35 %	181.16 %	206.88	206.38
RNN_2_look72_overlap72	2008-04-01 06:00:00	146088.60	382.22	159.81 %	173.80 %	292.83	292.33
RNN_2_look72_overlap72	2008-07-01 06:00:00	261339.23	511.21	158.49 %	168.93 %	386.18	385.68
RNN_2_look72_overlap72	2008-10-01 06:00:00	153511.37	391.81	129.86 %	177.10 %	298.91	298.41
RNN_2_look72_overlap36	2008-01-01 06:00:00	11579.46	107.61	53.03 %	135.62 %	90.28	89.78
RNN_2_look72_overlap36	2008-04-01 06:00:00	14178.03	119.07	57.50 %	122.47 %	95.86	95.36
RNN_2_look72_overlap36	2008-07-01 06:00:00	30382.35	174.31	50.52 %	106.07 %	137.05	136.55
RNN_2_look72_overlap36	2008-10-01 06:00:00	13833.35	117.62	55.28 %	121.88 %	98.00	97.50
RNN_2_look72_overlap1	2008-01-01 06:00:00	72765.78	269.75	233.90 %	153.30 %	235.25	234.75
RNN_2_look72_overlap1	2008-04-01 06:00:00	4030.86	63.49	39.57 %	105.81 %	47.90	47.40
RNN_2_look72_overlap1	2008-07-01 06:00:00	37436.48	193.49	50.32 %	111.56 %	156.63	156.13
RNN_2_look72_overlap1	2008-10-01 06:00:00	3066.47	55.38	29.83 %	111.13 %	47.78	47.28
RNN_2_look48_overlap48	2008-01-01 06:00:00	114697.59	338.67	198.64 %	161.14 %	269.75	269.25
RNN_2_look48_overlap48	2008-04-01 06:00:00	186850.92	432.26	357.07 %	156.58 %	360.10	359.60
RNN_2_look48_overlap48	2008-07-01 06:00:00	302103.56	549.64	206.71 %	149.53 %	465.63	465.13
RNN_2_look48_overlap48	2008-10-01 06:00:00	232944.60	482.64	192.13 %	165.99 %	415.88	415.38
RNN_2_look48_overlap24	2008-01-01 06:00:00	63000.62	251.00	141.31 %	173.87 %	212.52	212.02
RNN_2_look48_overlap24	2008-04-01 06:00:00	126651.32	355.88	108.16 %	158.57 %	274.07	273.57
RNN_2_look48_overlap24	2008-07-01 06:00:00	249383.20	499.38	131.11 %	155.72 %	372.82	372.32
RNN_2_look48_overlap24	2008-10-01 06:00:00	129821.45	360.31	99.27 %	166.11 %	276.68	276.18
RNN_2_look48_overlap1	2008-01-01 06:00:00	37415.68	193.43	189.72 %	154.26 %	143.02	142.52
RNN_2_look48_overlap1	2008-04-01 06:00:00	2859.14	53.47	28.73 %	101.93 %	34.31	33.81
RNN_2_look48_overlap1	2008-07-01 06:00:00	33288.93	182.45	47.43 %	111.92 %	137.50	137.00
RNN_2_look48_overlap1	2008-10-01 06:00:00	2286.57	47.82	24.86 %	109.07 %	36.94	36.44
RNN_1_look96_overlap96	2008-01-01 06:00:00	36700.16	191.57	120.56 %	176.15 %	150.02	149.52
RNN_1_look96_overlap96	2008-04-01 06:00:00	106734.53	326.70	157.36 %	172.72 %	243.48	242.98
RNN_1_look96_overlap96	2008-07-01 06:00:00	235786.03	485.58	134.25 %	163.10 %	353.22	352.72
RNN_1_look96_overlap96	2008-10-01 06:00:00	122985.15	350.69	106.16 %	177.38 %	247.04	246.54
RNN_1_look96_overlap48	2008-01-01 06:00:00	38036.30	195.03	116.13 %	174.62 %	149.52	149.03
RNN_1_look96_overlap48	2008-04-01 06:00:00	106754.10	326.73	158.70 %	171.03 %	241.78	241.28
RNN_1_look96_overlap48	2008-07-01 06:00:00	237076.33	486.90	153.53 %	164.22 %	359.20	358.71
RNN_1_look96_overlap48	2008-10-01 06:00:00	122965.02	350.66	119.19 %	174.65 %	255.11	254.61
RNN_1_look96_overlap1	2008-01-01 06:00:00	3562.49	59.69	45.97 %	132.71 %	54.31	53.81
RNN_1_look96_overlap1	2008-04-01 06:00:00	3046.67	55.20	29.63 %	102.99 %	33.07	32.58
RNN_1_look96_overlap1	2008-07-01 06:00:00	38768.29	196.90	45.09 %	109.73 %	144.58	144.08

RNN_1.look96_overlap1	2008-10-01 06:00:00	18766.82	136.99	38.62 %	123.13 %	98.56	98.06
RNN_1.look72_overlap72	2008-01-01 06:00:00	32339.67	179.83	80.80 %	164.73 %	138.81	138.31
RNN_1.look72_overlap72	2008-04-01 06:00:00	102856.72	320.71	99.53 %	159.18 %	232.84	232.34
RNN_1.look72_overlap72	2008-07-01 06:00:00	222686.81	471.90	102.46 %	151.72 %	340.68	340.18
RNN_1.look72_overlap72	2008-10-01 06:00:00	113154.95	336.39	77.59 %	160.82 %	236.54	236.04
RNN_1.look72_overlap36	2008-01-01 06:00:00	3971.05	63.02	55.76 %	134.55 %	51.41	50.91
RNN_1.look72_overlap36	2008-04-01 06:00:00	11559.62	107.52	41.07 %	110.11 %	70.92	70.43
RNN_1.look72_overlap36	2008-07-01 06:00:00	8456.24	91.96	33.72 %	97.96 %	75.72	75.22
RNN_1.look72_overlap36	2008-10-01 06:00:00	9837.60	99.18	38.29 %	116.31 %	69.63	69.15
RNN_1.look72_overlap1	2008-01-01 06:00:00	20451.16	143.01	132.60 %	149.06 %	102.52	102.02
RNN_1.look72_overlap1	2008-04-01 06:00:00	2866.45	53.54	28.59 %	102.00 %	33.88	33.38
RNN_1.look72_overlap1	2008-07-01 06:00:00	46204.31	214.95	41.85 %	106.53 %	155.81	155.32
RNN_1.look72_overlap1	2008-10-01 06:00:00	27403.26	165.54	46.24 %	129.67 %	122.88	122.38
RNN_1.look48_overlap48	2008-01-01 06:00:00	32298.20	179.72	104.97 %	172.07 %	135.97	135.47
RNN_1.look48_overlap48	2008-04-01 06:00:00	104853.76	323.81	142.67 %	174.37 %	237.54	237.04
RNN_1.look48_overlap48	2008-07-01 06:00:00	241087.24	491.01	114.56 %	166.30 %	348.87	348.37
RNN_1.look48_overlap48	2008-10-01 06:00:00	121381.55	348.40	109.60 %	175.74 %	247.91	247.41
RNN_1.look48_overlap24	2008-01-01 06:00:00	40542.84	201.35	95.13 %	168.67 %	156.64	156.14
RNN_1.look48_overlap24	2008-04-01 06:00:00	108707.20	329.71	107.88 %	160.69 %	242.16	241.66
RNN_1.look48_overlap24	2008-07-01 06:00:00	225326.59	474.69	112.25 %	153.47 %	345.99	345.49
RNN_1.look48_overlap24	2008-10-01 06:00:00	118347.93	344.02	85.94 %	163.13 %	249.38	248.88
RNN_1.look48_overlap1	2008-01-01 06:00:00	4152.61	64.44	56.38 %	134.17 %	53.40	52.90
RNN_1.look48_overlap1	2008-04-01 06:00:00	3064.86	55.36	37.27 %	104.30 %	35.01	34.52
RNN_1.look48_overlap1	2008-07-01 06:00:00	51830.83	227.66	46.67 %	111.13 %	166.32	165.82
RNN_1.look48_overlap1	2008-10-01 06:00:00	36639.03	191.41	48.65 %	133.16 %	140.83	140.33
LSTM_2.look96_overlap96	2008-01-01 06:00:00	52255.31	228.59	154.06 %	197.61 %	161.03	160.53
LSTM_2.look96_overlap96	2008-04-01 06:00:00	118037.46	343.57	120.70 %	178.61 %	241.84	241.34
LSTM_2.look96_overlap96	2008-07-01 06:00:00	235961.51	485.76	172.10 %	162.19 %	369.25	368.75
LSTM_2.look96_overlap96	2008-10-01 06:00:00	126486.58	355.65	116.10 %	175.17 %	257.80	257.31
LSTM_2.look96_overlap48	2008-01-01 06:00:00	36326.42	190.59	106.78 %	190.88 %	134.01	133.53
LSTM_2.look96_overlap48	2008-04-01 06:00:00	119989.35	346.39	136.94 %	179.22 %	242.16	241.66
LSTM_2.look96_overlap48	2008-07-01 06:00:00	245678.08	495.66	134.51 %	168.74 %	354.26	353.76
LSTM_2.look96_overlap48	2008-10-01 06:00:00	137191.58	370.39	108.07 %	184.46 %	251.92	251.42
LSTM_2.look96_overlap1	2008-01-01 06:00:00	1144.21	33.83	26.90 %	129.96 %	23.00	22.54
LSTM_2.look96_overlap1	2008-04-01 06:00:00	3217.41	56.72	21.85 %	101.74 %	35.21	34.72
LSTM_2.look96_overlap1	2008-07-01 06:00:00	4512.17	67.17	20.31 %	86.34 %	52.01	51.51
LSTM_2.look96_overlap1	2008-10-01 06:00:00	3792.47	61.58	28.33 %	117.05 %	47.81	47.31
LSTM_2.look72_overlap72	2008-01-01 06:00:00	37113.20	192.65	95.26 %	173.31 %	149.26	148.76
LSTM_2.look72_overlap72	2008-04-01 06:00:00	108192.83	328.93	123.12 %	160.83 %	238.75	238.25
LSTM_2.look72_overlap72	2008-07-01 06:00:00	216075.95	464.84	117.02 %	145.36 %	330.74	330.24
LSTM_2.look72_overlap72	2008-10-01 06:00:00	121717.77	348.88	95.66 %	162.68 %	249.80	249.30
LSTM_2.look72_overlap36	2008-01-01 06:00:00	1178.99	34.34	18.04 %	127.82 %	23.25	22.77
LSTM_2.look72_overlap36	2008-04-01 06:00:00	4742.82	68.87	26.00 %	101.87 %	43.75	43.26
LSTM_2.look72_overlap36	2008-07-01 06:00:00	3459.21	58.82	21.41 %	83.88 %	43.06	42.56
LSTM_2.look72_overlap36	2008-10-01 06:00:00	1507.47	38.83	22.77 %	108.55 %	31.05	30.55
LSTM_2.look72_overlap1	2008-01-01 06:00:00	930.33	30.50	20.03 %	128.45 %	20.93	20.43
LSTM_2.look72_overlap1	2008-04-01 06:00:00	3260.21	57.10	33.32 %	102.62 %	34.08	33.58
LSTM_2.look72_overlap1	2008-07-01 06:00:00	6518.12	80.73	25.83 %	91.41 %	64.08	63.58
LSTM_2.look72_overlap1	2008-10-01 06:00:00	7329.96	85.62	32.54 %	120.63 %	61.68	61.19
LSTM_2.look48_overlap48	2008-01-01 06:00:00	37814.96	194.46	117.01 %	184.90 %	141.55	141.05
LSTM_2.look48_overlap48	2008-04-01 06:00:00	117970.77	343.47	166.23 %	179.04 %	249.25	248.75
LSTM_2.look48_overlap48	2008-07-01 06:00:00	246321.79	496.31	182.73 %	166.24 %	378.08	377.58
LSTM_2.look48_overlap48	2008-10-01 06:00:00	132649.50	364.21	121.23 %	180.93 %	255.87	255.37
LSTM_2.look48_overlap24	2008-01-01 06:00:00	43629.29	208.88	116.49 %	188.86 %	149.65	149.15
LSTM_2.look48_overlap24	2008-04-01 06:00:00	124766.04	353.22	102.05 %	172.69 %	242.93	242.43
LSTM_2.look48_overlap24	2008-07-01 06:00:00	218144.81	467.06	121.34 %	145.08 %	333.51	333.01
LSTM_2.look48_overlap24	2008-10-01 06:00:00	130941.74	361.86	89.86 %	174.37 %	246.43	245.94
LSTM_2.look48_overlap1	2008-01-01 06:00:00	1052.94	32.45	16.96 %	126.68 %	19.35	18.85
LSTM_2.look48_overlap1	2008-04-01 06:00:00	2799.77	52.91	22.68 %	100.76 %	30.83	30.33
LSTM_2.look48_overlap1	2008-07-01 06:00:00	4342.25	65.90	27.23 %	91.53 %	52.93	52.43
LSTM_2.look48_overlap1	2008-10-01 06:00:00	5649.41	75.16	36.67 %	123.13 %	57.73	57.24
LSTM_1.look96_overlap96	2008-01-01 06:00:00	34471.15	185.66	115.96 %	180.48 %	136.09	135.60
LSTM_1.look96_overlap96	2008-04-01 06:00:00	112384.39	335.24	186.58 %	173.42 %	253.38	252.88
LSTM_1.look96_overlap96	2008-07-01 06:00:00	239351.52	489.24	169.34 %	164.31 %	368.20	367.70
LSTM_1.look96_overlap96	2008-10-01 06:00:00	130367.66	361.06	128.90 %	176.97 %	262.63	262.13
LSTM_1.look96_overlap48	2008-01-01 06:00:00	39103.97	197.75	130.57 %	179.31 %	149.88	149.39
LSTM_1.look96_overlap48	2008-04-01 06:00:00	112784.97	335.83	201.60 %	172.49 %	257.21	256.71
LSTM_1.look96_overlap48	2008-07-01 06:00:00	238009.65	487.86	174.42 %	164.20 %	370.17	369.67
LSTM_1.look96_overlap48	2008-10-01 06:00:00	131255.96	362.29	138.62 %	175.33 %	269.55	269.05
LSTM_1.look96_overlap1	2008-01-01 06:00:00	2372.52	48.71	37.53 %	131.47 %	44.33	43.83

LSTM_1.look96_overlap1	2008-04-01 06:00:00	2995.06	54.73	24.71 %	101.30 %	31.34	30.84
LSTM_1.look96_overlap1	2008-07-01 06:00:00	11060.54	105.17	41.46 %	105.55 %	86.50	86.00
LSTM_1.look96_overlap1	2008-10-01 06:00:00	10663.42	103.26	26.81 %	115.76 %	69.19	68.69
LSTM_1.look72_overlap72	2008-01-01 06:00:00	30925.56	175.86	80.79 %	165.63 %	138.44	137.94
LSTM_1.look72_overlap72	2008-04-01 06:00:00	100427.39	316.90	158.97 %	148.57 %	258.25	257.75
LSTM_1.look72_overlap72	2008-07-01 06:00:00	197571.80	444.49	164.16 %	132.37 %	354.53	354.03
LSTM_1.look72_overlap72	2008-10-01 06:00:00	111286.38	333.60	105.59 %	151.64 %	269.65	269.15
LSTM_1.look72_overlap36	2008-01-01 06:00:00	5731.48	75.71	49.62 %	136.44 %	59.50	59.01
LSTM_1.look72_overlap36	2008-04-01 06:00:00	5669.23	75.29	57.79 %	106.72 %	54.91	54.41
LSTM_1.look72_overlap36	2008-07-01 06:00:00	5689.15	75.43	26.48 %	87.80 %	64.38	63.88
LSTM_1.look72_overlap36	2008-10-01 06:00:00	6389.62	79.94	39.74 %	114.11 %	60.60	60.11
LSTM_1.look72_overlap1	2008-01-01 06:00:00	1413.04	37.59	20.98 %	128.11 %	32.20	31.71
LSTM_1.look72_overlap1	2008-04-01 06:00:00	3388.01	58.21	29.34 %	102.68 %	39.03	38.53
LSTM_1.look72_overlap1	2008-07-01 06:00:00	4241.10	65.12	22.55 %	88.33 %	53.62	53.12
LSTM_1.look72_overlap1	2008-10-01 06:00:00	1578.41	39.73	14.59 %	108.26 %	31.53	31.03
LSTM_1.look48_overlap48	2008-01-01 06:00:00	37843.22	194.53	124.15 %	177.83 %	147.71	147.22
LSTM_1.look48_overlap48	2008-04-01 06:00:00	110681.91	332.69	189.20 %	171.88 %	253.64	253.14
LSTM_1.look48_overlap48	2008-07-01 06:00:00	237528.55	487.37	175.67 %	163.83 %	369.35	368.86
LSTM_1.look48_overlap48	2008-10-01 06:00:00	129845.23	360.34	134.20 %	173.96 %	267.71	267.21
LSTM_1.look48_overlap24	2008-01-01 06:00:00	43094.38	207.59	97.36 %	166.67 %	164.21	163.71
LSTM_1.look48_overlap24	2008-04-01 06:00:00	103282.77	321.38	146.42 %	151.17 %	251.38	250.88
LSTM_1.look48_overlap24	2008-07-01 06:00:00	194911.05	441.49	145.75 %	138.21 %	335.57	335.07
LSTM_1.look48_overlap24	2008-10-01 06:00:00	116978.59	342.02	94.25 %	155.06 %	261.79	261.29
LSTM_1.look48_overlap1	2008-01-01 06:00:00	1747.26	41.80	25.38 %	129.59 %	34.92	34.42
LSTM_1.look48_overlap1	2008-04-01 06:00:00	3639.26	60.33	23.93 %	102.59 %	37.38	36.89
LSTM_1.look48_overlap1	2008-07-01 06:00:00	3952.03	62.87	30.67 %	92.88 %	51.91	51.41
LSTM_1.look48_overlap1	2008-10-01 06:00:00	1319.06	36.32	10.75 %	105.70 %	27.76	27.30
GRU_2.look96_overlap96	2008-01-01 06:00:00	39695.20	199.24	124.68 %	180.78 %	150.80	150.30
GRU_2.look96_overlap96	2008-04-01 06:00:00	109644.84	331.13	170.95 %	172.46 %	253.32	252.82
GRU_2.look96_overlap96	2008-07-01 06:00:00	228031.16	477.53	160.32 %	160.56 %	360.87	360.38
GRU_2.look96_overlap96	2008-10-01 06:00:00	129584.85	359.98	139.33 %	173.83 %	271.80	271.30
GRU_2.look96_overlap48	2008-01-01 06:00:00	40947.27	202.35	125.40 %	185.42 %	152.23	151.73
GRU_2.look96_overlap48	2008-04-01 06:00:00	119763.18	346.07	161.66 %	173.62 %	251.47	250.97
GRU_2.look96_overlap48	2008-07-01 06:00:00	247707.53	497.70	150.23 %	161.04 %	368.89	368.39
GRU_2.look96_overlap48	2008-10-01 06:00:00	137000.38	370.14	125.89 %	173.29 %	269.96	269.46
GRU_2.look96_overlap1	2008-01-01 06:00:00	2017.20	44.91	24.80 %	130.79 %	35.32	34.82
GRU_2.look96_overlap1	2008-04-01 06:00:00	3182.33	56.41	29.67 %	102.02 %	33.90	33.41
GRU_2.look96_overlap1	2008-07-01 06:00:00	10048.22	100.24	39.04 %	101.23 %	76.20	75.70
GRU_2.look96_overlap1	2008-10-01 06:00:00	6124.63	78.26	22.38 %	112.85 %	53.93	53.44
GRU_2.look72_overlap72	2008-01-01 06:00:00	57989.57	240.81	156.40 %	188.17 %	199.94	199.44
GRU_2.look72_overlap72	2008-04-01 06:00:00	154627.22	393.23	159.39 %	179.43 %	300.34	299.84
GRU_2.look72_overlap72	2008-07-01 06:00:00	267104.85	516.82	139.63 %	175.27 %	381.98	381.48
GRU_2.look72_overlap72	2008-10-01 06:00:00	148822.48	385.78	114.87 %	182.14 %	283.89	283.39
GRU_2.look72_overlap36	2008-01-01 06:00:00	4623.45	68.00	28.13 %	133.63 %	46.32	45.82
GRU_2.look72_overlap36	2008-04-01 06:00:00	5344.18	73.10	26.97 %	106.74 %	54.15	53.65
GRU_2.look72_overlap36	2008-07-01 06:00:00	5534.91	74.40	35.33 %	93.39 %	61.94	61.44
GRU_2.look72_overlap36	2008-10-01 06:00:00	10995.90	104.86	26.71 %	114.16 %	77.30	76.80
GRU_2.look72_overlap1	2008-01-01 06:00:00	1962.06	44.30	30.94 %	130.29 %	30.73	30.25
GRU_2.look72_overlap1	2008-04-01 06:00:00	6256.83	79.10	52.83 %	107.46 %	51.54	51.05
GRU_2.look72_overlap1	2008-07-01 06:00:00	6462.89	80.39	37.45 %	96.70 %	65.49	64.99
GRU_2.look72_overlap1	2008-10-01 06:00:00	4409.99	66.41	25.39 %	115.47 %	49.24	48.74
GRU_2.look48_overlap48	2008-01-01 06:00:00	52892.25	229.98	152.73 %	177.55 %	180.68	180.18
GRU_2.look48_overlap48	2008-04-01 06:00:00	121089.19	347.98	197.31 %	169.74 %	271.17	270.67
GRU_2.look48_overlap48	2008-07-01 06:00:00	244829.79	494.80	171.30 %	160.67 %	380.65	380.15
GRU_2.look48_overlap48	2008-10-01 06:00:00	140975.58	375.47	155.66 %	170.07 %	288.68	288.18
GRU_2.look48_overlap24	2008-01-01 06:00:00	42842.62	206.98	111.25 %	189.08 %	147.23	146.73
GRU_2.look48_overlap24	2008-04-01 06:00:00	129159.90	359.39	98.24 %	174.93 %	246.20	245.70
GRU_2.look48_overlap24	2008-07-01 06:00:00	235006.01	484.77	107.46 %	152.14 %	339.14	338.64
GRU_2.look48_overlap24	2008-10-01 06:00:00	137659.38	371.02	87.62 %	174.80 %	251.40	250.90
GRU_2.look48_overlap1	2008-01-01 06:00:00	25493.86	159.67	92.11 %	141.73 %	132.80	132.30
GRU_2.look48_overlap1	2008-04-01 06:00:00	51304.80	226.51	112.54 %	131.94 %	187.05	186.55
GRU_2.look48_overlap1	2008-07-01 06:00:00	247176.12	497.17	135.31 %	150.05 %	425.66	425.16
GRU_2.look48_overlap1	2008-10-01 06:00:00	64514.92	254.00	85.30 %	138.71 %	202.88	202.38
GRU_1.look96_overlap96	2008-01-01 06:00:00	35179.17	187.56	115.90 %	180.53 %	140.37	139.87
GRU_1.look96_overlap96	2008-04-01 06:00:00	110134.77	331.87	154.00 %	174.15 %	243.11	242.61
GRU_1.look96_overlap96	2008-07-01 06:00:00	238809.96	488.68	151.89 %	166.07 %	359.80	359.30
GRU_1.look96_overlap96	2008-10-01 06:00:00	127960.08	357.72	122.75 %	177.08 %	259.88	259.38
GRU_1.look96_overlap48	2008-01-01 06:00:00	34836.23	186.64	120.09 %	177.63 %	144.64	144.14
GRU_1.look96_overlap48	2008-04-01 06:00:00	106130.29	325.78	157.30 %	174.24 %	242.76	242.26
GRU_1.look96_overlap48	2008-07-01 06:00:00	235795.08	485.59	133.22 %	164.79 %	351.23	350.73

GRU_1.look96_overlap48	2008-10-01 06:00:00	123306.55	351.15	116.28 %	176.50 %	254.44	253.94
GRU_1.look96_overlap1	2008-01-01 06:00:00	2371.68	48.70	21.97 %	129.95 %	36.91	36.41
GRU_1.look96_overlap1	2008-04-01 06:00:00	2921.09	54.05	25.51 %	102.12 %	34.66	34.16
GRU_1.look96_overlap1	2008-07-01 06:00:00	7437.54	86.24	36.96 %	102.13 %	70.08	69.58
GRU_1.look96_overlap1	2008-10-01 06:00:00	1941.64	44.06	12.88 %	106.56 %	31.24	30.74
GRU_1.look72_overlap72	2008-01-01 06:00:00	49275.43	221.98	102.29 %	175.69 %	165.42	164.93
GRU_1.look72_overlap72	2008-04-01 06:00:00	116320.39	341.06	109.61 %	163.58 %	247.97	247.47
GRU_1.look72_overlap72	2008-07-01 06:00:00	230140.89	479.73	112.74 %	153.24 %	346.71	346.21
GRU_1.look72_overlap72	2008-10-01 06:00:00	124290.16	352.55	87.03 %	167.74 %	249.76	249.26
GRU_1.look72_overlap36	2008-01-01 06:00:00	1422.14	37.71	31.46 %	130.69 %	26.03	25.53
GRU_1.look72_overlap36	2008-04-01 06:00:00	3241.28	56.93	25.76 %	101.80 %	33.75	33.26
GRU_1.look72_overlap36	2008-07-01 06:00:00	1709.07	41.34	12.44 %	79.31 %	29.79	29.29
GRU_1.look72_overlap36	2008-10-01 06:00:00	2256.30	47.50	33.31 %	110.70 %	34.16	33.66
GRU_1.look72_overlap1	2008-01-01 06:00:00	1969.54	44.38	21.53 %	129.24 %	36.81	36.31
GRU_1.look72_overlap1	2008-04-01 06:00:00	3427.91	58.55	24.77 %	102.95 %	39.26	38.76
GRU_1.look72_overlap1	2008-07-01 06:00:00	4678.07	68.40	27.09 %	93.49 %	53.98	53.48
GRU_1.look72_overlap1	2008-10-01 06:00:00	3425.56	58.53	16.05 %	108.83 %	43.21	42.71
GRU_1.look48_overlap48	2008-01-01 06:00:00	44266.39	210.40	136.27 %	183.03 %	155.22	154.74
GRU_1.look48_overlap48	2008-04-01 06:00:00	116684.24	341.59	180.42 %	177.99 %	250.47	250.00
GRU_1.look48_overlap48	2008-07-01 06:00:00	243596.34	493.55	159.64 %	168.38 %	363.77	363.27
GRU_1.look48_overlap48	2008-10-01 06:00:00	135213.52	367.71	132.66 %	180.43 %	264.69	264.22
GRU_1.look48_overlap24	2008-01-01 06:00:00	42653.46	206.53	94.41 %	171.57 %	155.00	154.50
GRU_1.look48_overlap24	2008-04-01 06:00:00	112711.51	335.73	107.65 %	162.46 %	243.28	242.78
GRU_1.look48_overlap24	2008-07-01 06:00:00	229274.89	478.83	114.37 %	154.90 %	347.26	346.77
GRU_1.look48_overlap24	2008-10-01 06:00:00	122928.57	350.61	89.01 %	166.28 %	251.03	250.53
GRU_1.look48_overlap1	2008-01-01 06:00:00	3059.18	55.31	26.27 %	131.43 %	43.75	43.25
GRU_1.look48_overlap1	2008-04-01 06:00:00	3228.62	56.82	35.43 %	103.52 %	41.63	41.13
GRU_1.look48_overlap1	2008-07-01 06:00:00	6011.67	77.53	29.24 %	94.58 %	65.27	64.77
GRU_1.look48_overlap1	2008-10-01 06:00:00	2129.82	46.15	15.93 %	107.88 %	33.82	33.32
ConvGRU_2.look96_overlap96	2008-01-01 06:00:00	34102.64	184.67	100.64 %	187.86 %	123.90	123.40
ConvGRU_2.look96_overlap96	2008-04-01 06:00:00	121071.28	347.95	124.72 %	183.39 %	239.46	238.96
ConvGRU_2.look96_overlap96	2008-07-01 06:00:00	240761.24	490.67	124.61 %	162.46 %	352.83	352.33
ConvGRU_2.look96_overlap96	2008-10-01 06:00:00	129455.21	359.80	115.46 %	179.82 %	252.57	252.08
ConvGRU_2.look96_overlap48	2008-01-01 06:00:00	42217.38	205.47	128.00 %	172.37 %	162.67	162.18
ConvGRU_2.look96_overlap48	2008-04-01 06:00:00	118817.51	344.70	212.65 %	172.02 %	274.88	274.38
ConvGRU_2.look96_overlap48	2008-07-01 06:00:00	261859.93	511.72	203.48 %	164.16 %	403.12	402.62
ConvGRU_2.look96_overlap48	2008-10-01 06:00:00	149432.17	386.56	165.20 %	174.40 %	304.12	303.62
ConvGRU_2.look96_overlap1	2008-01-01 06:00:00	1153.24	33.96	21.04 %	128.26 %	24.34	23.84
ConvGRU_2.look96_overlap1	2008-04-01 06:00:00	3020.74	54.96	33.21 %	103.81 %	36.87	36.37
ConvGRU_2.look96_overlap1	2008-07-01 06:00:00	6597.25	81.22	30.35 %	95.20 %	63.05	62.55
ConvGRU_2.look96_overlap1	2008-10-01 06:00:00	4430.01	66.56	20.27 %	111.52 %	48.80	48.31
ConvGRU_2.look72_overlap72	2008-01-01 06:00:00	47575.76	218.12	124.24 %	188.51 %	165.71	165.21
ConvGRU_2.look72_overlap72	2008-04-01 06:00:00	136595.60	369.59	120.31 %	179.31 %	266.81	266.31
ConvGRU_2.look72_overlap72	2008-07-01 06:00:00	261429.93	511.30	125.58 %	173.97 %	372.56	372.06
ConvGRU_2.look72_overlap72	2008-10-01 06:00:00	145580.48	381.55	105.66 %	181.66 %	269.45	268.95
ConvGRU_2.look72_overlap36	2008-01-01 06:00:00	1426.74	37.77	24.21 %	128.66 %	29.07	28.58
ConvGRU_2.look72_overlap36	2008-04-01 06:00:00	5355.82	73.18	27.13 %	106.92 %	53.15	52.66
ConvGRU_2.look72_overlap36	2008-07-01 06:00:00	9896.57	99.48	58.21 %	102.01 %	79.11	78.61
ConvGRU_2.look72_overlap36	2008-10-01 06:00:00	3217.07	56.72	12.71 %	106.34 %	49.12	48.62
ConvGRU_2.look72_overlap1	2008-01-01 06:00:00	2631.39	51.30	45.35 %	133.60 %	33.96	33.47
ConvGRU_2.look72_overlap1	2008-04-01 06:00:00	3102.42	55.70	30.42 %	102.50 %	34.42	33.92
ConvGRU_2.look72_overlap1	2008-07-01 06:00:00	12451.79	111.59	33.40 %	98.49 %	83.42	82.94
ConvGRU_2.look72_overlap1	2008-10-01 06:00:00	4715.42	68.67	24.62 %	114.97 %	53.09	52.59
ConvGRU_2.look48_overlap48	2008-01-01 06:00:00	28916.10	170.05	103.59 %	179.09 %	123.22	122.72
ConvGRU_2.look48_overlap48	2008-04-01 06:00:00	107158.50	327.35	125.05 %	172.44 %	233.01	232.51
ConvGRU_2.look48_overlap48	2008-07-01 06:00:00	238492.56	488.36	115.72 %	161.20 %	348.00	347.50
ConvGRU_2.look48_overlap48	2008-10-01 06:00:00	122045.09	349.35	102.68 %	176.99 %	247.14	246.65
ConvGRU_2.look48_overlap24	2008-01-01 06:00:00	31173.31	176.56	74.34 %	171.29 %	126.61	126.11
ConvGRU_2.look48_overlap24	2008-04-01 06:00:00	118671.53	344.49	103.80 %	175.30 %	240.12	239.63
ConvGRU_2.look48_overlap24	2008-07-01 06:00:00	241109.01	491.03	107.57 %	165.36 %	349.77	349.27
ConvGRU_2.look48_overlap24	2008-10-01 06:00:00	126039.63	355.02	98.00 %	177.27 %	250.92	250.42
ConvGRU_2.look48_overlap1	2008-01-01 06:00:00	1017.93	31.91	21.91 %	128.70 %	23.09	22.59
ConvGRU_2.look48_overlap1	2008-04-01 06:00:00	3674.41	60.62	36.12 %	104.61 %	37.85	37.36
ConvGRU_2.look48_overlap1	2008-07-01 06:00:00	13650.06	116.83	34.72 %	101.40 %	88.53	88.04
ConvGRU_2.look48_overlap1	2008-10-01 06:00:00	4774.78	69.10	27.20 %	116.80 %	53.28	52.78
ConvGRU_1.look96_overlap96	2008-01-01 06:00:00	33725.88	183.65	112.67 %	177.39 %	138.84	138.36
ConvGRU_1.look96_overlap96	2008-04-01 06:00:00	107516.37	327.90	159.19 %	172.92 %	242.70	242.21
ConvGRU_1.look96_overlap96	2008-07-01 06:00:00	234660.64	484.42	151.49 %	166.04 %	358.71	358.21
ConvGRU_1.look96_overlap96	2008-10-01 06:00:00	125176.27	353.80	119.44 %	176.92 %	256.38	255.89
ConvGRU_1.look96_overlap48	2008-01-01 06:00:00	44270.13	210.40	136.57 %	182.02 %	155.19	154.71

ConvGRU_1.look96_overlap48	2008-04-01 06:00:00	115905.23	340.45	175.38 %	177.81 %	248.36	247.87
ConvGRU_1.look96_overlap48	2008-07-01 06:00:00	245300.34	495.28	146.65 %	168.99 %	356.13	355.63
ConvGRU_1.look96_overlap48	2008-10-01 06:00:00	134762.63	367.10	132.21 %	179.94 %	263.74	263.25
ConvGRU_1.look96_overlap1	2008-01-01 06:00:00	1525.92	39.06	26.36 %	129.37 %	35.89	35.39
ConvGRU_1.look96_overlap1	2008-04-01 06:00:00	11751.83	108.41	32.54 %	111.09 %	76.74	76.24
ConvGRU_1.look96_overlap1	2008-07-01 06:00:00	5230.54	72.32	28.71 %	95.07 %	55.76	55.26
ConvGRU_1.look96_overlap1	2008-10-01 06:00:00	3616.75	60.14	16.60 %	108.87 %	44.63	44.14
ConvGRU_1.look72_overlap72	2008-01-01 06:00:00	33911.08	184.15	86.27 %	167.28 %	143.10	142.60
ConvGRU_1.look72_overlap72	2008-04-01 06:00:00	105573.40	324.92	102.25 %	159.86 %	238.63	238.13
ConvGRU_1.look72_overlap72	2008-07-01 06:00:00	220936.77	470.04	110.91 %	151.72 %	345.72	345.22
ConvGRU_1.look72_overlap72	2008-10-01 06:00:00	113169.23	336.41	80.10 %	162.03 %	242.23	241.73
ConvGRU_1.look72_overlap36	2008-01-01 06:00:00	1535.98	39.19	26.39 %	130.02 %	27.52	27.02
ConvGRU_1.look72_overlap36	2008-04-01 06:00:00	3170.05	56.30	37.39 %	104.03 %	36.01	35.53
ConvGRU_1.look72_overlap36	2008-07-01 06:00:00	2327.44	48.24	13.78 %	79.31 %	38.27	37.77
ConvGRU_1.look72_overlap36	2008-10-01 06:00:00	2666.18	51.64	35.88 %	111.07 %	38.07	37.57
ConvGRU_1.look72_overlap1	2008-01-01 06:00:00	2217.62	47.09	36.28 %	131.30 %	42.36	41.86
ConvGRU_1.look72_overlap1	2008-04-01 06:00:00	2732.56	52.27	30.86 %	102.79 %	33.25	32.75
ConvGRU_1.look72_overlap1	2008-07-01 06:00:00	4913.24	70.09	33.31 %	97.91 %	56.16	55.67
ConvGRU_1.look72_overlap1	2008-10-01 06:00:00	850.44	29.16	13.29 %	105.85 %	24.30	23.80
ConvGRU_1.look48_overlap48	2008-01-01 06:00:00	42486.95	206.12	135.87 %	182.07 %	153.99	153.50
ConvGRU_1.look48_overlap48	2008-04-01 06:00:00	114099.69	337.79	176.41 %	176.09 %	247.29	246.79
ConvGRU_1.look48_overlap48	2008-07-01 06:00:00	243581.96	493.54	142.85 %	168.20 %	356.16	355.66
ConvGRU_1.look48_overlap48	2008-10-01 06:00:00	132762.28	364.37	130.80 %	179.23 %	262.41	261.92
ConvGRU_1.look48_overlap24	2008-01-01 06:00:00	52224.04	228.53	110.96 %	179.83 %	168.12	167.62
ConvGRU_1.look48_overlap24	2008-04-01 06:00:00	119762.54	346.07	116.90 %	165.82 %	250.91	250.41
ConvGRU_1.look48_overlap24	2008-07-01 06:00:00	230755.87	480.37	117.25 %	155.19 %	348.70	348.20
ConvGRU_1.look48_overlap24	2008-10-01 06:00:00	126930.60	356.27	92.53 %	168.20 %	254.49	253.99
ConvGRU_1.look48_overlap1	2008-01-01 06:00:00	1611.54	40.14	26.35 %	129.55 %	34.84	34.34
ConvGRU_1.look48_overlap1	2008-04-01 06:00:00	3139.95	56.04	19.93 %	101.21 %	33.37	32.87
ConvGRU_1.look48_overlap1	2008-07-01 06:00:00	6468.58	80.43	37.57 %	101.02 %	65.37	64.87
ConvGRU_1.look48_overlap1	2008-10-01 06:00:00	1835.13	42.84	11.83 %	106.27 %	30.35	29.85