

DESARROLLO DE MODELOS DE PREDICCIÓN DE LA RADIACIÓN SOLAR DIRECTA BASADOS EN REDES NEURONALES MEDIANTE EL USO DE IMÁGENES

Abad A. V.*, Castilla N. M. M.*, Álvarez H. J. D.*, Carballo L. J. A.**, Bonilla C. J.**

* Departamento de Informática, CIESOL—ceiA3, Universidad de Almería, Ctra. Sacramento s/n, La Cañada de San Urbano, Almería, 04120, España, vabadalcaraz@ual.es, mcastilla@ual.es, jhervas@ual.es

** CIEMAT-Plataforma Solar de Almería, Crta. de Senés, s/n, Tabernas, Almería, 04200, España, joseantonio.carballo@psa.es, javier.bonilla@psa.es

RESUMEN

La radiación solar es un recurso natural clave hoy en día para la integración de sistemas energéticos renovables en edificaciones. Conocer con detalle la naturaleza y la disponibilidad de este recurso es clave para poder aprovecharlo. Por eso esta investigación presenta una metodología robusta para desarrollar modelos de predicción de una de las componentes de la radiación solar, la radiación directa, mediante el uso de imágenes de la instalación CESA-1 en la Plataforma Solar de Almería, obtenidos a partir de una red neuronal híbrida que fusiona una Red Neuronal Convolutiva (CNN, del inglés Convolutional Neural Network) y una Red de Gran Memoria a Corto Plazo (LSTM, del inglés Long Short-Term Memory). Siguiendo este procedimiento, se obtienen seis modelos por cada tipo de día (despejados y parcialmente nublados) capaces de obtener resultados para la predicción de la radiación directa, en promedio, de un 22% de Error Cuadrático Medio Normalizado (NRMSE, del inglés Normalized Root Mean Square Error).

PALABRAS CLAVE: Radiación Solar Directa, Redes Neuronales, Predicción, Imágenes

ABSTRACT

Direct solar radiation is a key natural resource today for the integration of solar systems in buildings. This research presents a robust methodology to develop direct radiation prediction models using images from the CESA-1 facility at the Plataforma Solar de Almería, obtained from a hybrid neural network that fuses a Convolutional Neural Network (CNN) and a Long Short-Term Memory (LSTM) network. Following this approach, six models are obtained for each type of day (clear and partly cloudy) capable of obtaining results for the prediction of direct radiation, on average, of 22% Normalized Root Mean Square Error (NRMSE).

KEYWORDS: Direct Radiation, Deep Learning, Prediction, Images

INTRODUCCIÓN

La incorporación de sistemas solares en construcciones para la generación de electricidad a través de paneles fotovoltaicos o para proveer agua caliente mediante el uso de captadores solares planos es un elemento fundamental para lograr edificaciones con eficiencia energética. Sin embargo, la eficacia de estos sistemas se ve directamente afectada por la variación inherente de su principal fuente de energía: la radiación solar. Esta radiación fluctúa no solo a lo largo del año y del día, sino también en su composición, que incluye aspectos como la Irradiación Directa Normalizada (DNI, del inglés *Direct Normal Irradiation*), o la Irradiación Global Horizontal (GHI, del inglés *Global Horizontal Irradiation*), entre otros parámetros.

Las nubes desempeñan un papel crucial en la modificación de la radiación solar que alcanza la superficie terrestre al reflejar, absorber y transmitir la radiación incidente, lo que afecta la cantidad y calidad espectral de la misma. Además, las partículas de las nubes provocan procesos de dispersión que alteran las longitudes de onda más cortas del espectro solar, reduciendo las componentes globales y directas que llegan a la superficie terrestre.

Para asegurar un control óptimo de estos sistemas, es imprescindible contar con herramientas que permitan predecir con precisión la radiación solar, considerando tanto sus variaciones temporales como su relación con factores meteorológicos. En la literatura se pueden encontrar diversos modelos de predicción de la radiación global (Khatib et al. 2012), pero no tantos para la componente directa.

De manera generalizada, se identifican dos enfoques prominentes en la predicción, según el horizonte temporal considerado (Ogliari et al. 2024). El pronóstico futuro se emplea para proyectar condiciones a largo plazo, abarcando horas e incluso días, utilizando principalmente imágenes satelitales para obtener una visión amplia de las variables meteorológicas en una región específica. Por otro lado, la previsión inmediata (más comúnmente conocido por su término en inglés *nowcasting*) se enfoca en pronósticos a corto plazo, basados principalmente en imágenes del cielo para detectar eficazmente el tipo y movimiento de las nubes en tiempo real, como se observa en la Fig. 1. A pesar de ser más complejo, la previsión inmediata ofrece ventajas significativas al permitir una detección más precisa de las condiciones meteorológicas, especialmente útil en situaciones de cielos nublados. Actualmente, esta técnica es objeto de mayor investigación, ya que su combinación con otros métodos de predicción puede optimizar la gestión de recursos con resultados prometedores (Zamarbide-Ducun, 2014).

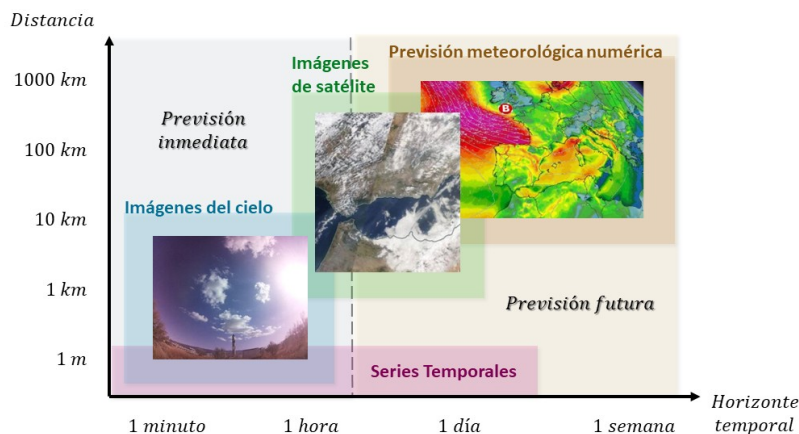


Fig. 1. Horizonte de predicción

En la búsqueda de alternativas a modelos matemáticos convencionales, cuya precisión se ve limitada en condiciones atmosféricas cambiantes, se impulsa la exploración de enfoques más efectivos, como las Redes Neuronales Artificiales (ANNs, del inglés *Artificial Neural Networks*). Las múltiples capas de neuronas que las componen son capaces de procesar información en entornos complejos y con un horizonte temporal pequeño, destacando por su capacidad excepcional de predicción.

Los modelos con ANNs convencionales se centran en el uso de datos numéricos por su fácil almacenamiento y rápido entrenamiento. Sin embargo, estas ANNs, en el contexto de la radiación solar directa, pueden enfrentar dificultades al intentar extraer patrones de las variables meteorológicas que de forma visual son más evidentes de identificar. Con el objetivo de poder anticipar de forma precisa la radiación futura, se ha planteado el uso de una arquitectura de redes neuronales que hace uso de imágenes capturadas del cielo.

El enfoque metodológico adoptado para la tarea de predicción de la radiación se basa en una red neuronal híbrida que fusiona una Red Neuronal Convolutiva (CNN, del inglés *Convolutional Neural Network*) y una Red Neuronal de Memoria de Corto-Largo Plazo (LSTM, del inglés *Long Short-Term Memory*). Esta estrategia permite abordar de manera integral la tarea de detectar patrones y extraer características visuales relevantes de las imágenes. Es crucial destacar que la inclusión de la red LSTM permite considerar la secuencia temporal de los datos, aportando un elemento crítico a la red neuronal en términos de la variable temporal. La arquitectura interna de la CNN se construye sobre las capas de *EfficientNet-B0* (Tan y Le, 2019), diseñadas específicamente por *Google Brain* para la implementación de métodos de escalado compuesto. La familia de redes *EfficientNet*, desde B0 (5.3M de parámetros) hasta B7 (66M de parámetros) han sido entrenadas con más de un millón de imágenes procedentes de la base de datos *ImageNet* (Deng, et al., 2009). *EfficientNet-B0* es la red base con buen compromiso entre precisión, uso de recursos y tiempo de ejecución.

El resto del documento se organiza en una breve descripción del marco en el que se ha desarrollado este trabajo, una explicación de la metodología seguida para la obtención del modelo de predicción, un análisis de los resultados obtenidos y un resumen de las principales conclusiones obtenidas y trabajos futuros a realizar.

MARCO DE INVESTIGACIÓN

En la búsqueda por la inclusión de la energía solar en el diseño y funcionamiento de edificaciones, lo cual representa un aspecto fundamental para alcanzar los objetivos establecidos por las diversas directivas promulgadas por la Unión Europea (Ciucci, 2023), resulta esencial contar con modelos de predicción de la componente directa de la radiación solar que posibiliten una gestión eficaz de los recursos disponibles. El presente estudio se ha llevado a cabo en el marco del Centro de Investigación en Energía Solar (CIESOL) (<https://ciesol.com/>), emplazado en el campus de la Universidad de Almería, en el sureste de España.

El edificio CIESOL, véase Fig. 2a, resultado de la colaboración entre la Universidad de Almería y la Plataforma Solar de Almería, se ha diseñado siguiendo principios de arquitectura bioclimática para maximizar la eficiencia energética. Equipado con paneles fotovoltaicos y captadores solares, busca aprovechar las condiciones climáticas locales para minimizar su consumo energético. Tras una reciente actualización del sistema de monitorización, se ha optado por utilizar datos meteorológicos de la Plataforma Solar de Almería, ubicada a menos de 30 km del centro CIESOL, debido a la falta de registros históricos suficientes.

La Plataforma Solar de Almería (PSA), perteneciente al Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas (CIEMAT), se erige en Tabernas, provincia de Almería, como uno de los principales centros de investigación en energía solar a nivel global, como se ilustra en la Fig. 2b, donde se muestra una vista aérea de la planta CESA-I. Este complejo dispone de una amplia gama de infraestructuras y equipamientos especializados, abarcando desde instalaciones basadas en tecnología termosolar hasta sistemas de almacenamiento térmico, pasando por receptores solares y plantas de tratamiento de aguas. Para la presente investigación, se ha empleado una estación meteorológica emplazada en la planta solar de receptor central (CESA-I), encargada de registrar las componentes de la radiación solar, imágenes del cielo y otras variables meteorológicas, con un intervalo de muestreo de 10 minutos.

En específico, esta estación cuenta con un pirheliómetro altamente preciso para registrar la radiación solar directa, junto con piranómetros diseñados para medir tanto la radiación solar difusa como la global (esta última es la suma de la radiación solar directa y la difusa). Las imágenes del cielo fueron tomadas con cámaras de bajo costo de alta resolución equipadas con un sensor de imagen Sony IMX219 de 8 megapíxeles, localizadas en el campo CESA-I. Este sensor proporciona una captura de imágenes de alta calidad y admite una resolución máxima de 3280 x 2464 píxeles. Las cámaras también están equipadas con una lente ojo de pez con un campo de visión de 160°.



Fig. 2a. Edificio CIESOL

Fig. 2b. Plataforma Solar de Almería

Fig. 2. Marco de investigación

DESARROLLO DE LOS MODELOS DE PREDICCIÓN DE RADIACIÓN DIRECTA

En la búsqueda continua de grandes avances en inteligencia artificial, las redes neuronales se han convertido en un elemento crítico para abordar intrincados retos en numerosos campos. Para la exigente tarea de predecir la radiación solar directa, se han recogido cada diez minutos datos e imágenes que captura una región del cielo que contiene el sol. Por tanto, se considera crucial centrarse inicialmente en el análisis de estas imágenes 2D para recopilar datos pertinentes sobre la radiación solar.

La red neuronal se ha diseñado para la identificación de patrones y extracción de características visuales a partir de las imágenes. La secuencialidad de las imágenes también es una característica clave del problema. La necesidad de combinar dichos datos visuales respetando su temporalidad ha dado origen a una red neuronal híbrida que fusiona dos arquitecturas poderosas: la Red Neuronal Convolutiva (CNN) y células de Memoria de Corto-Largo Plazo (LSTM).

El núcleo de la red neuronal híbrida propuesta se basa en *EfficientNet-B0*, un conjunto de arquitecturas diseñadas para ofrecer un excelente rendimiento en tareas de visión por computador, destacando por su notable eficiencia computacional. Sus capas, estructuradas jerárquicamente, emplean estrategias avanzadas como bloques de atención y conexiones residuales, además de operaciones convencionales de convergencia y escalado descendente, lo que permite a la red comprender características visuales en distintas escalas y sobresalir en la detección y extracción de patrones en imágenes.

Tras la extracción de características espaciales mediante las capas CNN, se emplea la arquitectura LSTM, perteneciente a las Redes Neuronales Recurrentes. LSTM se distingue por su utilización de la "puerta de olvido", "puerta de actualización" y "célula", permitiendo filtrar y seleccionar información relevante para producir predicciones altamente precisas.

Preparación de los datos

En el marco de este estudio, se dispuso de un conjunto inicial de datos compuesto por 41433 observaciones (imágenes y datos asociados) abarca desde el 26 de marzo de 2022 hasta el 26 de septiembre de 2023. Cada una de estas observaciones venía acompañada de imágenes tomadas con lentes gran angular y ojo de pez, sirviendo como base para el desarrollo de los modelos de predicción de la radiación solar directa. Sin embargo, se excluyeron las observaciones con imágenes de lentes ojo de pez debido a su impacto negativo en el rendimiento de las redes neuronales, obteniendo peores resultados. Finalmente, el conjunto de datos se redujo a 26.100 observaciones, que se emplearon en la construcción de los modelos mencionados anteriormente.


Se han considerado diversas clasificaciones de los días con objeto de obtener modelos más exactos. Ejemplo de ello ha sido determinar la necesidad de dividirlos según la temporada del año (Suárez-García et al. 2020). La radiación solar directa varía alrededor del solsticio de verano pudiendo alcanzar valores máximos mucho más elevados que durante el solsticio de invierno. La hora de salida y puesta del sol también varían significativamente según la época del año. No obstante, se concluyó que, dado el amplio volumen de fotos, esta clasificación no era necesaria, como sí que fue necesario realizar en investigaciones previas (Abad-Alcaraz et al. 2023).

A través de la experimentación, se ha considerado relevante distinguir entre días despejados y parcialmente nublados, ya que cada uno presenta patrones meteorológicos únicos que afectan significativamente la radiación solar directa. En los días nublados se establece la premisa de que la influencia de la DNI en comparación con las otras componentes de la radiación solar no es relevante. Para realizar dicha clasificación resulta fundamental determinar el umbral que define cuándo se considera parcialmente nublado o despejado. La clave para ello reside en un concepto conocido como Índice de Claridad (IC), que establece la relación entre la radiación global medida y la radiación solar extraterrestre ideal (GE), como se describe en la Ec. (1).

$$\dot{i} = I_0 \cdot E_0 \cdot (\sin(dc) \cdot \sin(l) + \cos(dc) \cdot \cos(l) \cdot \cos(ws)) \quad (1)$$

dónde, I_0 representa la constante solar en W/m^2 , E_0 es el factor de corrección debido a la excentricidad de la órbita, dc es la declinación solar resultante de la inclinación del eje de rotación de la tierra, l es la latitud y ws es el ángulo solar en el cenit local.

Según diversos estudios (Li y Lam, 2001), la amplitud de los valores de IC guarda una relación con el clima local, véase Fig. 3a. Algunas investigaciones se basan en la evaluación de expertos, mientras que otras consideran la



relación entre el índice de brillo y el índice difuso para clasificar los días (Meizoso-López, 2012). Los datos fueron recopilados en Almería, España, una zona caracterizada por un clima subdesértico, mediterráneo, cálido y seco, por lo que existe una predominancia de días despejados. Se ha establecido, tras una exhaustiva revisión, que los días con un índice de claridad igual o inferior a 0.2 se consideran demasiado nublados, aquellos con un índice igual o superior a 0.6 se consideran despejados y los valores intermedios se designan como parcialmente nublados.

Fig. 3. Relación entre radiación global e IC

Finalmente, también se emplearon técnicas de aumento de datos para incrementar el conjunto de datos inicial en un 200% con el objetivo de entrenar redes que sean robustas bajo distintas condiciones climáticas y de operación. Estas técnicas implican la aplicación de diversas transformaciones, como rotaciones, escalado, reflexiones en ejes X e Y, distorsiones, ajustes en saturación, contraste y brillo, así como la introducción de ruido gaussiano sintético y efectos de desenfoque gaussiano. Tras la selección de nueve transformaciones, se aplicaron entre una y cuatro de ellas de forma aleatoria por imagen.



Fig. 4. Ejemplo de resultado tras la aplicación de técnicas de aumento de datos para imágenes

Arquitectura de la red neuronal

Se empleó una red neuronal híbrida, combinando una red CNN y una LSTM, como se muestra en la Fig. 5. Tras numerosas pruebas se ha determinado que una ventana de máximo una hora era la más adecuada debido a la variabilidad de la radiación solar y el enfoque de previsión inmediata propuesto. En cuanto a la cantidad de imágenes pasadas que tienen en cuenta las capas de LSTM, como máximo la red tiene de referencia la hora anterior para la siguiente predicción. Las imágenes se escalaron a 224 x 224 debido a los requisitos de imágenes de entrada del modelo *EfficientNet-B0*. A pesar de que las imágenes originales eran ligeramente rectangulares (3280 x 2464), se decidieron ajustarlas a un tamaño de 224 x 224 debido a las limitaciones del modelo *EfficientNet-B0*, sacrificando calidad.




Fig. 5. Red neuronal híbrida CNN-LSTM usando la arquitectura de *EfficientNet-B0*

EfficientNet-B0 utiliza convoluciones de 1x1, 3x3 y 5x5 y ha demostrado un rendimiento adecuado. Las salidas de la CNN-LSTM se normalizaron entre 0 y 1 con una función sigmoide, ya que estandarizando (proceso de escalar la distribución de los datos, siendo la media igual a 0 y su desviación estándar igual a 1) resultaba inadecuado.

Entrenamiento y validación de los modelos de predicción

El algoritmo de optimización se basa en el método del Descenso de Gradiente Estocástico con Momento (SGDM) debido a la estabilidad demostrada en términos de convergencia y su eficiencia en cuanto al uso de recursos de memoria en comparación con otras alternativas como por ejemplo el algoritmo Adam. SGDM, una variante del algoritmo del descenso de gradiente estocástico, incorpora un parámetro conocido como "*momentum*", el cual se estableció en su valor típico de 0.9. Este valor ha demostrado ser efectivo para acelerar la convergencia del proceso de entrenamiento y actualizar los gradientes en cada paso.

La tasa de aprendizaje se estableció en 0.05 para regular la adaptación de los pesos de la red en cada iteración, mientras que se seleccionó un tamaño de lote de 64 con el objetivo de optimizar el uso de la RAM. En cuanto al número de *epochs*, varió de manera específica en cada experimento, oscilando entre 20 y 80. Un componente crítico del modelo es la función de *dropout*, utilizada para desactivar el 20% o el 30% de las capas neuronales para evitar el sobreajuste, el cual fue reducido mediante su aplicación.

Se seleccionaron días completos al azar para la construcción del modelo, asignando el 70% de los datos para entrenamiento, el 20% para validación y el 10% para el conjunto de pruebas. Esta estratificación, derivada de un proceso experimental minucioso, garantiza un equilibrio adecuado entre las etapas de entrenamiento, validación y evaluación final del modelo, asegurando así su robustez.

RESULTADOS Y DISCUSIÓN

Esta sección presenta los resultados derivados de los experimentos detallados en la sección anterior. Se han generado un total de doce modelos, seis para días despejados y otros seis para días parcialmente nublados, cubriendo predicciones que van desde diez minutos hasta una hora con intervalos de diez minutos. Para evaluar la idoneidad de cada modelo, se realizó un análisis estadístico, considerando índices como el Error Absoluto Medio (MAE, del inglés *Mean Absolute Error*) y el coeficiente de correlación de Pearson (R), pero principalmente se ha evaluado el rendimiento para extraer conclusiones comparando el Error Cuadrático Medio Normalizado (NRMSE, del inglés *Normalised Root Mean Square Error*). Además, se han incorporado los resultados gráficos para un día de los conjuntos de datos de prueba para cada condición meteorológica, como se muestra en la Fig. 6.




Fig. 6a. Modelo para días despejados




Fig. 6b. Modelo para días parcialmente nublados

Fig. 6. Modelos de predicción para días despejados y parcialmente nublados

La evaluación de las predicciones de los modelos presentados en la Fig. 6 revela una compleja dinámica en la radiación solar directa, lo que constituye un desafío considerable para los algoritmos de predicción. Estas fluctuaciones inherentes a la DNI pueden ser difíciles de capturar y prever de manera precisa, ya que las

variaciones, debido al paso de nubes, resultan abruptas, presentando obstáculos significativos en la identificación de patrones consistentes por parte de los modelos predictivos.

Sin embargo, es en el análisis numérico donde se revela plenamente la magnitud de esta variabilidad. Al examinar las Tablas 1 y 2, se constata que los índices de NRMSE oscilan entre el 20 y el 25%, dependiendo del modelo específico considerado. Es importante destacar que, como era de esperar, los modelos muestran un desempeño ligeramente superior en la predicción de días despejados en comparación con días parcialmente nublados. Esto se debe a que, en condiciones de cielo despejado, la radiación solar directa llega a la superficie terrestre con pocas incidencias atmosféricas, lo que facilita su predicción en comparación con los días con cobertura nubosa variable.

Cabe destacar que no existe una discrepancia excesiva entre los modelos con un horizonte de predicción de diez minutos y una hora, analizándolo desde el punto de vista numérico con los índices estadísticos. Esto se explica mejor al observar la Fig. 6, donde todos los modelos parecen capturar tendencias generales y patrones de comportamiento a más largo plazo, en lugar de enfocarse en fluctuaciones menores.

Tabla 1. Resultados obtenidos con la red neuronal híbrida CNN-LSTM para días despejados

Paso de predicción	DNI máxima (W/m ²)	<i>N</i>	<i>NRMSE</i> (%)	MAE (W/m ²)	<i>R</i>
10 min	1017,297	1460	21,992	105,653	0,696
20 min	1015,103	730	21,696	106,161	0,696
30 min	1015,103	486	21,638	107,228	0,698
40 min	1015,103	365	21,777	113,595	0,686
50 min	1010,908	292	21,670	117,092	0,697
60 min	1015,103	243	20,525	115,497	0,713

Tabla 2. Resultados obtenidos con la red neuronal híbrida CNN-LSTM para días parcialmente nublados

Paso de predicción	DNI máxima (W/m ²)	<i>N</i>	<i>NRMSE</i> (%)	MAE (W/m ²)	<i>R</i>
10 min	958,353	821	22,959	125,866	0,720
20 min	955,251	410	21,892	130,224	0,724
30 min	950,812	273	23,374	136,342	0,713
40 min	955,251	205	22,907	136,654	0,700
50 min	943,024	164	25,482	151,250	0,641
60 min	950,812	136	25,358	153,329	0,651

Algunas de las dificultades que estos modelos podrían estar teniendo, sería en la comprensión de la estación del año. Existen diferencias significativas en la cantidad de radiación directa registrada durante los solsticios de invierno y verano, así como en los equinoccios. Uno de los factores que influyen en ello es la mayor duración de las horas de luz solar, y por tanto de la radiación, durante un día.

Además, es crucial considerar la localización de los ensayos en Almería, España, donde se observan niveles notablemente más elevados de radiación solar durante los solsticios de verano en contraste con los del invierno. Por ejemplo, dada una mayor frecuencia de días parcialmente nublados durante el solsticio de invierno debido a la ubicación geográfica de los ensayos, es probable que las predicciones de radiación para tales días durante el solsticio de verano reflejen valores inferiores a la realidad.

Pese a las dificultades evidenciadas, todos los modelos consiguen capturar la dinámica fluctuante de la radiación solar directa, obteniendo unos resultados de gran utilidad que permiten comprender y prever la DNI en el intervalo máximo de una hora.

CONCLUSIONES

El aumento de la preocupación por el cambio climático ha impulsado significativamente la integración de energías renovables en nuestras rutinas diarias. En este contexto, la energía solar emerge como una protagonista clave de esta integración. Sin embargo, para asegurar una gestión efectiva de los recursos y la estabilidad del sistema eléctrico, resulta imperativo contar con pronósticos precisos de la radiación solar haciendo uso de técnicas relacionadas con la previsión inmediata o *nowcasting*.

En este estudio, se han desarrollado varios modelos que combinan distintas arquitecturas de redes neuronales mediante el uso de imágenes capturadas en la PSA, permitiendo una clasificación detallada de diferentes escenarios meteorológicos: despejado y parcialmente nublado. Los resultados usando exclusivamente imágenes del cielo, resultan todo un reto hoy en día, obteniéndose un rendimiento considerablemente bueno.

Los índices de rendimiento muestran que los modelos logran una precisión notable en las predicciones cada 10 minutos, con un NRMSE aproximado del 22 % en ambos escenarios considerados. Sin embargo, al ampliar el horizonte de predicción a una hora el NRMSE de los modelos, concretamente en el caso de los diseñados para días parcialmente nublados, asciende hasta el 25 %, siendo las predicciones horarias generalmente las menos precisas.

En futuras investigaciones, se planteará la exploración de estrategias para mejorar el desempeño de los modelos mediante la integración de imágenes satelitales junto con las del cielo, así como la consideración de variables numéricas. Estos enfoques multimodales, actualmente están siendo objeto de estudio en diversas investigaciones, ofreciendo la oportunidad de fusionar datos de distintas naturalezas, aportando nuevas perspectivas y aumentando la precisión de las predicciones. Dichas predicciones adquieren una relevancia particular para instalaciones como CESA-I, donde la exactitud en la predicción de la DNI es esencial para el funcionamiento óptimo de su campo solar compuesto por 300 helióstatos. La implementación exitosa de estas mejoras supondría un avance significativo en la investigación y aplicación de las energías renovables, contribuyendo a un futuro más sostenible y eficiente en términos energéticos.

AGRADECIMIENTOS

Este trabajo es parte del proyecto de I+D+i TED2021-131655B-I00, y ha sido realizado gracias a la financiación por AEI/10.13039/501100011033/ y “Unión Europea NextGenerationEU”. Asimismo, este trabajo ha sido parcialmente financiado por Proyecto del Plan Nacional I+D+i PID2021-126805OB-I00 (proyecto HELIOSUN) financiado por Ministerio de Ciencia e Innovación.

REFERENCIAS

Ogliari, E., Sakwa, M., & Cusa, P. (2024). Enhanced Convolutional Neural Network for solar radiation nowcasting: All-Sky camera infrared images embedded with exogeneous parameters. *Renewable Energy*, 221, 119735. <https://doi.org/10.1016/j.renene.2023.119735>.

Zamarbide-Ducun, I. (2014). Predicción de radiación solar a corto y medio plazo. Trabajo Fin de Máster, Escuela Técnica Superior de Ingenieros Industriales y de Telecomunicación, Universidad Pública de Navarra. Recuperado de <https://hdl.handle.net/2454/12164>

Rodríguez-Benítez, F. J., López-Cuesta, M., Arbizu-Barrena, C., Fernández-León, M. M., Pamos-Ureña, M. Á., Tovar-Pescador, J., Santos-Alamillos, F. J., & Pozo-Vázquez, D. (2021). Assessment of new solar radiation nowcasting methods based on sky-camera and satellite imagery. *Applied Energy*, 292, 116838. <https://doi.org/10.1016/j.apenergy.2021.116838>.

Ciucci, M. (2023). Fichas temáticas sobre la Unión Europea. *La Energía Renovable* [Ficha temática]. Recuperado el 29 de abril de 2024, de <https://www.europarl.europa.eu/factsheets/es/sheet/70/la-energia-renovable>

Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. & Fei-Fei, L. (2009) ImageNet: A large-scale hierarchical image database, *IEEE Conference on Computer Vision and Pattern Recognition*, Miami, FL, USA (pp. 248-255), <https://doi.org/10.1109/CVPR.2009.5206848>.

Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. *International Conference on Machine Learning*, pp. 6105–6114, PMLR.

Suárez-García, A., Díez-Mediavilla, M., Granados-López, D., González-Peña, D., & Alonso-Tristán, C. (2020). Benchmarking of meteorological indices for sky cloudiness classification. *Solar Energy*, 195, 499–513. <https://doi.org/10.1016/j.solener.2019.11.060>

Abad-Alcaraz, V., Castilla Nieto, M. D. M., Álvarez Hervás, J. D., Carballo, J. A., & Bonilla, J. (2023). Desarrollo de modelos de predicción de radiación solar mediante técnicas de machine learning. In *XLIV Jornadas de Automática* (pp. 382-387). Universidade da Coruña. Servizo de Publicacións.

Li, D. H. W., & Lam, J. C. (2001). An analysis of climatic parameters and sky condition classification. *Building and Environment*, 36(4), 435-445. [https://doi.org/10.1016/S0360-1323\(00\)00027-5](https://doi.org/10.1016/S0360-1323(00)00027-5)

Meizoso-López, M. C. (2012). Distribución de la irradiación solar global, directa y difusa, en la ciudad de A Coruña. Tesis Doctoral. Universidade da Coruña. Instituto Universitario de Xeoloxía. <http://hdl.handle.net/2183/12357>