



Revisión de la Literatura Sobre los Modelos de Estimación de Potencia Fotovoltaica según el Origen de los Datos

Literature Review of Photovoltaic Power Estimation Models based on the data source.

Josep Atencio¹, Fernando Arias^{1,2*}, Mayteé Zambrano^{1,2}, Edson Galagarza¹

¹Grupo de Investigación en Tecnologías Avanzadas de Telecomunicación y Procesamiento de Señales (GITTS), Universidad Tecnológica de Panamá, Panamá.

²Centro de Estudios Multidisciplinarios en Ciencias, Ingeniería y Tecnología AIP (CEMCIT-AIP), Universidad Tecnológica de Panamá, Panamá.

*Autor de correspondencia: fernando.arias@utp.ac.pa

RESUMEN. La integración de las energías renovables no convencionales para la generación de energía eléctrica ha experimentado un crecimiento considerable en América Latina y el Caribe (ALC) desde inicios del siglo XXI, ganando importancia estratégica en la matriz eléctrica de los diversos países de la región. Entre estas formas de generación eléctrica se encuentra la tecnología fotovoltaica, cuya integración genera diversos desafíos que llegan a afectar la estabilidad de la red y la gestión del despacho eléctrico debido a la intermitencia del recurso principal empleado por estas centrales: irradiancia solar o Surface Solar Irradiance (SSI). Para hacer frente a estos retos, muchos investigadores han desarrollado diversos modelos de estimación de potencia y/o SSI basados en redes neuronales como las redes neuronales recurrentes (RNN) y redes neuronales convolucionales (CNN), métodos estadísticos y algoritmos híbridos. El desempeño de estos modelos depende intrínsecamente de la naturaleza de los datos de entrada, de los cuales se encuentran las imágenes satelitales, variables meteorológicas y series temporales de potencia. Este artículo presenta una revisión de los modelos actuales presentados en publicaciones previas, estableciendo un marco comparativo sobre el origen de los datos y estableciendo un punto de partida para su selección óptima en el desarrollo de modelos de estimación solar.

Palabras clave. *Estimación fotovoltaica, energías renovables, redes neuronales.*

ABSTRACT. The integration of non-conventional renewable energies for electricity generation has experienced considerable growth in Latin America and the Caribbean since the beginning of the 21st century, gaining strategic importance within the power grids of various countries in the region. Among these, photovoltaic technology stands out; however, its integration poses critical challenges that affect the grid stability and the energy dispatch due to the intermittency of the surface solar irradiance. To address these challenges, various power estimation and/or SSI estimation models based on neural networks such as recurrent neural networks and convolutional neural networks, statistical methods, and hybrid algorithms have been developed. The performance of these models depends on the nature of the data input, such as satellite images, meteorological variables, and power time series. This article presents a review of the current models presented in earlier publications, setting up a comparative framework on the origin of the data in the development of solar estimation models.

Keywords. Photovoltaic forecasting, renewable energy, neural networks.

1. Introducción

La búsqueda de alternativas diferentes a la generación de energía eléctrica convencional basada en combustibles fósiles ha ido en aumento para cumplir con

las metas de la reducción de emisiones de gases de efecto invernadero que los países de la región de ALC se han propuesto para cumplir con el acuerdo de París [1], [2]. Para mitigar estos efectos, las matrices energéticas de los

Citación: J. Atencio, F. Arias, M. Zambrano y E. Galagarza, "Revisión de los modelos implementados en la estimación de potencia fotovoltaica con un enfoque en el origen de los datos", *Revista de I+D Tecnológico*, vol. 22, no. 1, pp. (0), 2026.

Tipo de artículo: Original. **Recibido:** 16 de enero de 2026. **Recibido con correcciones:** 19 de marzo de 2026. **Aceptado:** 30 de marzo de 2026.

DOI.

Copyright: 2026 J. Atencio, F. Arias, M. Zambrano y E. Galagarza. This is an open access article under the CC BY-NC-SA 4.0 license (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).

países de ALC han ido migrando y evolucionando hacia una con mayor influencia de las energías renovables, tal como la solar, eólica, hídrica y geotérmica [3].

En ALC, las energías renovables llegaron a representar casi un 64% de la capacidad instalada en el 2024 [4], representando hasta 555GW de capacidad instalada en energías renovables. También llegaron a representar hasta un 69% o 1180TWh en generación de energía eléctrica[3]. Dentro de este grupo, la tecnología fotovoltaica destaca entre otras teniendo una capacidad instalada de 80GW, representando el 7% (135.34TWh) de la generación total de energía eléctrica en el 2024 [3],[4]. Esta fuente desempeña un rol importante en los diversos planes de transición energética de los países de la región ALC, a través de la instalación de centrales solares, y de instalaciones fotovoltaicas de media y baja tensión a través de las redes de generación distribuida[1],[4].

Conociendo la importancia creciente del papel de la energía fotovoltaica en ALC es necesario hacer frente a aquellos factores que pueden llegar a alterar el comportamiento adecuado de las centrales fotovoltaicas. Estos factores son la aleatoriedad, volatilidad e intermitencia del SSI que es la más aprovechada en la generación eléctrica [5], y a su vez tiene una fuerte dependencia de las estaciones climáticas o alteraciones del clima [3]. De no tomarse en cuenta esta variabilidad puede derivar en predicciones de baja precisión, afectando negativamente a las operaciones de la central [5] y su vez afecta la estabilidad y fiabilidad del suministro eléctrico despachado a la red eléctrica interconectada [6]. En ciertos mercados eléctricos de la región, la desviación entre la energía despachada y la energía pronosticada en las plantas fotovoltaicas puede transformarse en penalizaciones económicas [2].

Para contrarrestar estos efectos, existen diversas metodologías de predicción basadas en redes neuronales, como las redes de memoria de corto-largo plazo o *Long-short Term Memory* (LSTM), redes neuronales convolucionales (CNN), redes neuronales artificiales (RNA) y también otras técnicas computacionales como modelos matemáticos o estadísticos [6],[7],[8]. En la Figura 1 se demuestra el interés creciente en estudios para la estimación de potencia fotovoltaica a través de los últimos años tomando en cuenta la fecha de publicación de las referencias citadas en este artículo. Todas estas herramientas son utilizadas ya sea de forma individual o

en conjunto para predecir la potencia eléctrica generada o la irradiación solar horizontal incidente en determinadas zonas de estudio para mejorar los procesos de operación y despacho de la energía eléctrica en las plantas fotovoltaicas.

En un estudio realizado por Montecinos et al. [9] que explora la situación de las estimaciones de las energías renovables variables como la energía solar y eólica, este reveló que países como Bolivia y Chile han empezado a desarrollar proyectos que buscan emplear modelos de estimación de potencia para la mejora en el despacho energético. Mientras que otros países como México emplean modelos que llegan a tener hasta 20% de error.

Un aspecto importante en estos modelos predictivos son los horizontes de estimación, ya que la precisión empieza a disminuir a medida que el pronóstico se aleja en el tiempo. Dada esta dependencia, los horizontes ya han sido clasificados de diversas formas en distintas literaturas dependiendo de su utilidad en las operaciones [6]:

- **Periodo ultracorto (*Nowcasting*):** destinado a un horizonte de 0 a 4 horas. Al ser la resolución temporal más corta, permite detectar problemas transitorios, prepararse ante una eventualidad de esta índole y mitigarla.
- **Periodo corto:** tiene un rango de estimación para 4 a 72 horas, el cual permite planificar las operaciones para el despacho de la energía eléctrica y las operaciones de mantenimiento dentro de las centrales.
- **Periodo de mediano y largo plazo:** el cual va desde las 72 horas hasta un año de predicción, este horizonte de estimación es muy utilizado para la toma de decisiones estratégicas en la evaluación del potencial que tenga un sitio para instalación de nuevas plantas solares.

El pronóstico realizado por estos modelos es realizado a través de diferentes fuentes de datos basados en diferentes tecnologías como imágenes satelitales, fotografías de cielo o *Sky Imaging*, irradiancia solar obtenido a partir de sensores como el piranómetro y datos meteorológicos obtenidos de estaciones meteorológicas.

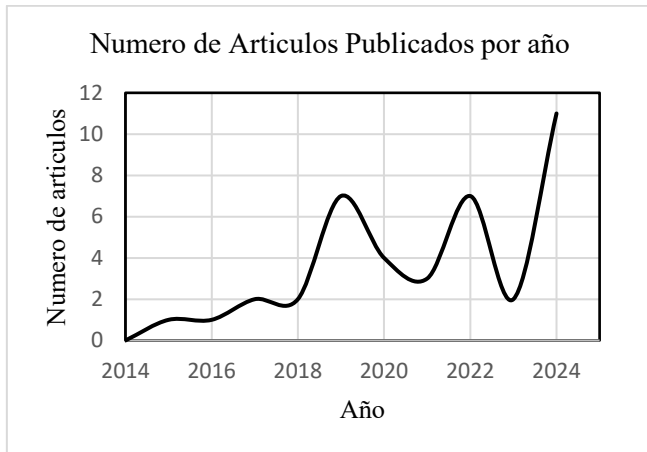


Figura 1: Numero de artículos revisados por año entre el 2014 y 2024.

En búsqueda de mitigar los efectos que generan la volatilidad e intermitencia de la irradiancia solar en las centrales eléctricas solares, se desarrollará una revisión sistemática y comparativa de los diferentes modelos empleados en literaturas de la última década (2014-2024), enfocándose en el rendimiento de las fuentes de datos en la estimación.

El resto del artículo posee la siguiente estructura: la sección 2 clasifica y describe las fuentes de datos empleados en la predicción de irradiación solar o potencia y como han sido empleados, la sección 3 recopilara los resultados que estos modelos obtuvieron dependiendo de la fuente de dato empleada y también las tendencias ahondará en las tendencias que están tomando los diversos países de la región de ALC y la sección 4 se darán las conclusiones del artículo.

2. Fuentes de datos

Considerando los diversos tipos de información que se emplean en los modelos de estimación de potencia eléctrica mediante tecnología fotovoltaica, este artículo clasificara los métodos de estimación según las fuentes de datos utilizadas. Estas son las imágenes de cielo (Sky imaging), datos satelitales, irradiancia solar histórica, variables meteorológicas, registros de potencia fotovoltaica y datos multifuente. Dependiendo de la metodología y objetivo de estimación, generalmente se combinan dos tipos de variables para relacionarlas con el parámetro principal y generar la estimación de la potencia eléctrica o la irradiancia solar.

2.1. Sky Imaging:

Las nubes sobre las centrales eléctricas llegan a ser elementos que afectan la producción de energía eléctrica. Las imágenes del cielo son obtenidas a través de cámaras especiales, llamados sistemas de adquisición de imágenes automatizados, el cual incorpora un lente gran angular u ojo de pez para la captura completa del cielo sobre la zona de estudio [10],[11],[12]. Otra forma en la que se obtienen las imágenes del cielo es a partir de sistemas que permiten seguir la posición del sol en el cielo, en donde periódicamente se toman fotografías centradas en la posición del sol [13]. Estos métodos permiten realizar diversas operaciones como la detección del tipo de nubes, movimiento de nubes y clasificación de las nubes [14].

Estos sistemas se complementan con sistemas de adquisición de datos con una tasa de muestreo entre treinta segundos a cinco minutos. La imagen capturada es procesada e introducida a el modelo de predicción, permitiendo realizar estimaciones con un horizonte ultracorto de tiempo.

Los modelos predictivos que han implementado la fotografía del cielo como fuente principal en la estimación de potencia se basan en Deep-Learning, como las redes CNN capaces de extraer características espaciales en datos adquiridos; además, una de las variantes de las redes neuronales convolucionales es la 1D CNN utilizada en diferentes sectores, ha demostrado una gran efectividad en el procesamiento de datos en tiempo real [15],[16]. También se utilizan las redes LSTM, las cuales tienen la capacidad de aprender características a partir de series de datos. Al combinar la capacidad de reconocimiento de patrones de las CNN en arreglos matriciales con las series temporales de las LSTM, se puede crear modelos más robustos como la arquitectura CNN-LSTM propuesto por Kong et al. [10]. Otra red de reconocimiento de parámetros en series de tiempo son las Gated Recurrent Unit (GRU), la cual es similar a la LSTM, pero requiere de menos parámetros para su utilización, esta última es capaz de identificar que dato del pasado mantener y cual descartar [17].

Una desventaja intrínseca de esta fuente de datos es la presencia de gotas de lluvia en el lente de la cámara. Estas pueden llegar a alterar los algoritmos de detección de tipos y movimientos de nubes. Para esto es necesario que los modelos incluyan algoritmo que detecte este fenómeno. Un trabajo realizado en Wels, Austria; se llegó a implementar un algoritmo que permite detectar las gotas de agua al detectar los bordes de las gotas que se generan al binarizar las imágenes [18].

2.2. Datos satelitales

Actualmente existen diferentes programas espaciales de observación terrestre que emplean satélites geoestacionarios en distintas regiones del planeta. En la región Asia-Pacífico, opera el satélite Geo-Kompsat-2A(GK2A), gestionado por la Administración Meteorológica de Corea; en América y el Caribe opera la misión GOES-R de la *National Oceanic and Atmospheric Administration*; en Japón operan los satélites Himawari-8/9; y en China se utiliza el satélite FengYun-4. Estos satélites son capaces de generar imágenes en diferentes longitudes de ondas de la luz entre 14 y 16 canales espectrales a través de los instrumentos *Advanced Meteorological Imager (AMI)*, *Advanced Baseline Imager (ABI)*, *Advanced Himawari Imager (AHI)* y el *Advanced Geosynchronous Radiation Imager (AGRI)*. Estos instrumentos permiten generar imágenes a través de canales del espectro visible, infrarrojo cercano e infrarrojo, con resolución temporal entre 1 y 2 minutos, siendo ideal para periodos de estimación de corto plazo [19],[20],[21],[22].

Los datos que son generados por las diferentes bandas espectrales de estos satélites han sido empleados en diferentes modelos de estimación de potencia fotovoltaica e irradiancia solar. Por ejemplo en Corea del Sur se implementó una red 1D-CNN que utiliza datos espectrales obtenidos del satélite GK2A, posición solar y datos de SSI que fueron obtenidos en diversas estaciones meteorológicas repartidas por todo Corea del Sur [23]. En otro estudio vinculado al satélite GK2A realizado por Kim et al. [5], estos datos fueron introducidos en un modelo de selección de características llamado *DeepFS* para seleccionar las bandas espectrales que tienen mayor influencia en el SSI. Realizando estimaciones con las arquitecturas GRU y LSTM.

El satélite Himawari de Japón fue utilizado por Xia et al. [21] para estimar la fracción de nubes sobre diferentes centrales solares en China, limitando las zonas de interés a 40 km², estas imágenes fueron utilizadas con redes neuronales recurrentes basadas en las LSTM llamadas PredRNN y PredRNN++ en donde se pudieron obtener resultados con horizontes de estimación ultracorto entre 0 a 4 h.

Los datos obtenidos por el satélite GOES-16 fueron utilizados por Frincu et al. [24] para estimar el SSI a través del movimiento de las nubes con un horizonte de

estimación de 5 horas en adelante. Y el satélite FengYun-4 fue utilizado por Liu et al. [25] para la estimación de potencia fotovoltaica en lugares donde se implementan sistemas de generación distribuida a través de una red CNN-LSTM.

La disponibilidad de los datos provenientes de satélites geoestacionarios tiene una frecuencia entre 1 a 10 minutos; pero no siempre están disponibles de forma inmediata debido a diversos factores relacionados al procesamiento y distribución de estos datos. Debido a la baja latencia en la disponibilidad de los datos llega a limitar la operatividad de estos modelos en tiempo real. Además, la disponibilidad de los datos puede verse limitada por los mantenimientos realizados a estos sistemas [26].

2.3. Datos meteorológicos

Las variables meteorológicas tales como humedad, temperatura ambiente, niveles de precipitación y presiones atmosféricas han sido fuentes de datos ampliamente utilizados en distintos estudios y modelos de estimación de potencia fotovoltaica y SSI. Estos datos son utilizados para entrenar redes neuronales tales como las LSTM, CNN o el *Multilayer Perceptron* utilizados por Saad et al. [27]. En donde se incluyó las características de los paneles, tales como el área, voltaje, corriente, temperatura del panel, número de celdas en series y en paralelo.

En el modelo empleado por Bouziane et al. [28] en Alger se utilizaron datos meteorológicos como la humedad relativa y temperatura del ambiente para estimar el SSI a través de modelos híbridos como las CNN-LSTM y CNN-RNN. Esta combinación permite obtener las características de los datos en periodos de tiempo a través de la red recurrente y extraer patrones de los datos a través de la red convolucional.

En el Politécnico de Milán Nespoli et al. [29] logró aplicar fuentes de datos que involucran condiciones meteorológicas como la temperatura ambiente, SSI, velocidad del viento, dirección del viento, presión atmosférica, cobertura y tipos de nubes para la estimación de potencia fotovoltaica a través de modelos obtenidos a través del SolarTechLab. Esta base de datos fue clasificada según de los valores promedio de un día para el SSI, siendo los mayores a 150W/m² considerados como días soleados y los menores a este valor, considerados días nublados. Estos datos fueron utilizados para entrenar un modelo de red neuronal

llamado Physical Hybrid Artificial Neural Network (PHANN) compuesto por 3 etapas, la primera detecta si la irradiancia corresponde a un día es un día nublado o soleado, la segunda y tercera etapa genera la estimación de la potencia fotovoltaica dependiendo si el día es nublado o soleado [29],[30].

A través de datos obtenidos en las centrales solares de Harran Ges y el centro meteorológico de GAPYENEV de la universidad de Harran, Turquía, se emplearon modelos de estimación basados en las arquitecturas CNN y LSTM. En donde se utilizaron fuentes de datos meteorológicos tales como la radiación solar, temperatura ambiental, humedad y velocidad del viento, en conjunto con datos de los módulos fotovoltaicos [31].

Una limitante de las variables meteorológicas se debe a la ubicación de las estaciones de medición meteorológicas ya meteorológicas tienden a encontrarse en sitios remotos. Haciendo que la cobertura espacial de los datos sea limitada. Esto llega a generar incertidumbre que reducen la precisión en las estimaciones y generando que los modelos pierdan fiabilidad [32].

2.4 Series temporales de potencia

Hay ocasiones en las que se pueden utilizar de datos históricos de potencia o irradiancia para diseñar modelos que solo funcionen con estos datos y obtener resultados aceptables en la estimación de potencia. Un ejemplo fue realizado en Nicosia, Chipre [33], cuya fuente principal de datos solo utilizaron la potencia de salida de una planta fotovoltaica local omitiendo datos utilizados en otros trabajos como la irradiancia solar, cobertura de nubes o velocidad. La metodología implementada fue basada en las arquitecturas LSTM, llamada *Stacked LSTM* o LSTM Apilado. Esta metodología cuenta con capas ocultas de apilamiento, esto es una ventaja ya que permite adquirir información de series temporales sin ser preprocesada y puede llegar a acelerar la convergencia de los resultados [34].

En California, se realizó un estudio donde se compararon diversos modelos para la estimación de potencia en periodos ultracorto de tiempo o en tiempo real [35]. Entre ellos, el *K-Nearest Neighbors (KNN)* que permite vincular registros pasados con la generación de potencia con un paso en adelante [36]. También se utilizó el *Support Vector machine (SVR)*, que permite utilizarse sin un entrenamiento previo, solo necesita unas pocas muestras de datos llamadas vectores de soporte para la toma de decisiones [37]. El *Random Forest (RF)*

también fue utilizado, este es un arreglo aleatorio de árboles de decisiones, que ha demostrado tener un buen rendimiento en tareas de clasificación y regresiones [38]. Se empleo el modelo ARIMA o *Auto-Regresive Integrated Moving Average*, este es un modelo que puede dividirse en 3 partes, el cual es una combinación de valores pasados (AR), términos de ruido (MA) y procesos de diferenciación (I) [39] [39]. Por último, se utilizó una regresión lineal que genera una combinación lineal de valores históricos de potencia [35].

La dependencia exclusiva de datos del pasado sin incluir datos meteorológicos hace que la precisión de los datos estimados sea menor y se espera que el comportamiento meteorológico del futuro sea igual al del pasado. Es esencial conocer esto, ya que en zonas donde la variabilidad climática es demasiado alta, la eficiencia al emplear estos modelos puede llegar a ser baja [40].

2.5 Datos Multifuente

En ciertas investigaciones debido a la disponibilidad, presupuesto y facilidades de acceso a los datos, se ha logrado hacer uso de diversas fuentes de datos como entradas de los modelos de predicción. Como los que se abordaran a continuación.

En el trabajado realizado por Cui et al. [41] en una localidad de Países Bajo se desarrolló un modelo donde se incluyeron datos satelitales obtenidos a través del instrumento SEVIRI del satélite METEOSAT-11 capaz generar imágenes en 12 canales espectrales a una resolución temporal de 15 minutos [42]. También se emplearon datos meteorológicos del modelo de predicción HARMONIE y de mediciones de la estación meteorológica de Cabauw. Se propuso el modelo basado en Deep Learning (DL) llamada U-net, esta emplea capas convolucionales estructuradas en un diseño de codificadores y decodificadores dispuestos en forma de U [41].

En un estudio donde se buscaba comparar metodologías basadas en DL y ML, datos como la irradiación solar, temperatura ambiente, velocidad del viento y potencia histórica de una planta fotovoltaica ubicada en el *Desert Alice Spring Center* de Australia. Respecto al modelo basado en DL, se utilizó una red LSTM y los modelos basados en ML implementados fueron *Decisión Tree*, *Support Vector Machine*, *Random Forest* y *Artificial Neural network* [43].

A través de sets de datos de uso público creados por el *Solar Radiation Research Laboratory* del *National*

Renewable Energy Laboratory se evaluó una metodología propuesta por Gao et al. [44], estos paquetes de datos consisten en fotografía del Cielo, humedad relativa, temperatura del aire, velocidad del viento, presión del aire, entre otras variables meteorológicas [11]. Esta metodología utiliza datos obtenidos en la última hora para predecir hasta 4 horas de irradiancia, los datos de entrada que utiliza son la fotografía del cielo como dato principal y los datos meteorológicos como datos secundarios [44].

En un estudio realizado por Thaker et al. [45] en Austria a través de diferentes plantas fotovoltaicas se emplearon distintos modelos de estimación de potencia fotovoltaica que utilizan datos de potencia generada, SSI, imágenes satelitales del satélite EUMESAT y datos meteorológicos. El primer modelo *Plane of array irradiance model* integra dos modelos empíricos conocidos como descomposición y transposición, la descomposición descompone la irradiancia solar en sus dos componentes, la irradiancia normal directa y la irradiancia horizontal difusa, basándose en dos parámetros físicos: índice de claridad y fracción difusa [46]. La transposición transforma la irradiancia normal directa y horizontal difusa en irradiancia global en la superficie inclinada del módulo fotovoltaico, esta irradiancia sobre la superficie del módulo se define como irradiancia efectiva. Para estimar la potencia fotovoltaica el modelo paramétrico propuesto por Perez-Ineichen [47] en donde se consideran la temperatura ambiente, velocidad del viento y la irradiancia efectiva y es utilizada para obtener la irradiancia difusa. En este estudio se hace uso del *Kalman Filter Smoothing*, es una especie de filtro que ha dado buenos resultados al implementarse la estimación de potencia fotovoltaica y el SSI, este permite estimar el estado de un sistema dinámico utilizando una serie de mediciones con ruido [48].

2.5.1 Clear Sky Model

El *Clear Sky Model* (CMS) o modelos de cielo despejado se sitúa como una metodología relevante en la estimación de potencia fotovoltaica e irradiancia solar en condiciones de cielo despejado implementando datos meteorológicos y atmosféricos dependiendo del modelo [49],[50]. Los datos de entrada de los CMS pueden dividirse en 2 grupos, basados en la geometría del sol y parámetros atmosféricos obtenidos por satélites o por

centros meteorológicos [51]. A continuación, se explorarán diversas implementaciones de este tipo de modelo en la predicción de potencia e irradiancia solar.

Se validaron diversos modelos y sistemas basados en el CMS para la estimación de irradiancia solar sobre diversas localidades de Marruecos, estos fueron el *Global Forecast Systems* (GFS), el *Integrated Forecast Systems* (IFS) y *McClear Model*, los primeros dos modelos son operados por la NOAA [52] y el *European Center for Medium Range Forecasts* respectivamente [53], estos también son modelos basados en predicción de datos meteorológicos o *Numerical Weather prediction* (NWP.) El modelo McClear es un modelo físico que provee datos de irradiancia a través de condiciones de cielo despejado [54].

En Alger se realizó otra investigación que compara diversas metodologías basadas en CSM. El primero en utilizar fue el *ESRA Model*, desarrollado por el *European Solar Radiation Atlas* y requiere de datos atmosféricos para poder utilizarse. El siguiente modelo fue el *Ineiche-Perez Model* el cual incluye turbiedad atmosférica y el coeficiente de altura de Kasten como datos de entrada [47]. El modelo Solis también se utilizó en este estudio, este es una aproximación de la transferencia radiativa, utiliza como datos de entrada al modelo datos meteorológicos como vapor de agua, presión atmosférica del sitio y presión al nivel del mar. Otro modelo empleado fue el *Algerian Solar Model* el cual permite estimar tres componentes de la radiación solar, en este modelo la irradiancia directa y difusa se expresan en función a la turbiedad provocado factores atmosféricos como la dispersión y absorción de la radiación. Y el último modelo es el *Hottel-Liu-Jordan*, este modelo estima la transmisión de la radiación directa en cielo despejado [55].

Otro estudio comparativo entre diversos modelos de CSM, fue realizado en Singapur en donde se compararon 3 modelos, dos de ellos ya fueron presentados en este artículo, estos fueron el *Ineichen-Perez model* y el *McClear*. Adicional a este, se presenta el modelo REST2 el donde se resalta la cantidad de datos de entrada que son necesarios para utilizar esta metodología, estos son la irradiancia normal de haz extraterrestre, ángulo del zenit, albedo de la superficie, presión de la superficie, profundidad óptica de aerosoles a 550nm, exponente de Angstrom, ozono en la columna, cantidad total de

dióxido de nitrógeno y vapor de agua precipitable total [56].

La implementación de una gran cantidad de datos para los modelos de estimación, aumentan la complejidad computacional y requiriendo de un poder computacional mayor y aumentando los tiempos de entrenamiento, dificultando la aplicación de estos modelos. Otro punto para destacar de estos modelos es la necesidad de sincronizar los datos con distintas resoluciones temporales y espaciales, añadiendo un desafío más para la implementación en las operaciones de las plantas de generación [57].

3. Resultados y discusión

Esta sección condensa y presenta un análisis comparativo de los resultados de los estudios presentados en la Sección 2. Para mantener el orden establecido previamente, esta sección presentara los resultados de las metodologías presentadas en la sección anterior con el mismo orden y clasificación, permitiendo una correspondencia directa entre la metodología planteada y su desempeño.

Se busca comparar de manera estandarizada los resultados que comparan el valor medido contra el valor estimado por los modelos estudiados, con el fin de dar una visión general de su desempeño. Para cada caso, se consideran las métricas más empleadas en el sector como lo son el RMSE, MAE, nRMSE y MAPE.

3.1. Fotografía del cielo:

En el trabajo realizado por Kong et al. [10] se presentaron los rendimientos a través de las métricas RMSE y MAPE. Estos resultados se presentan en la Tabla 1. Donde se puede observar una mejora en el rendimiento al utilizar un modelo híbrido como el CNN-LSTM. En ese trabajo realizado en Corea por Xu et al. [17] para estimar la irradiancia, se obtuvieron diversos resultados, en la Tabla 1. Se presentan los rangos en donde se encontraron estos resultados, la naturaleza de estos resultados depende mucho de la época climática del país de Corea, en donde en temporadas cálidas, como la que se presenta en agosto y septiembre, se obtuvieron resultados de 0.25MJ m² y 0.194 para el RMSE y el nRMSE respectivamente debido a la alta cantidad de nubes en la época. En abril se presentaron valores más bajos, siendo 0.150 MJ m² y 0.104 para el RMSE y nRMSE respectivamente. En la table 1. Se encapsulan los

resultados que obtuvieron los modelos que utilizan la fotografía del cielo.

Tabla 1. Resumen de resultados de los modelos que emplean fotografía del cielo.

Ref.	Modelo	Datos de entrada	Horizonte de estimación	Error medido
[10]	LSTM	Fotografía del cielo	5 min	RMSE: 50.57 MAPE: 47.91%
	CNN-LSTM			RMSE: 43.69 MAPE: 21.09%
[17]	GRU	Fotografía del cielo	5 min	RMSE: 0.105MJ/m ² - 0.25MJ/m ² nRMSE: 0.104-0.194

3.2. Datos satelitales

En la Tabla 2 se presentan los resultados de los modelos vistos previamente que implementan datos satelitales en la estimación de irradiancia solar o potencia fotovoltaica. En el uno de los trabajos realizados en Corea por Jang et al. [23] se obtuvieron diversos valores para el RMSE, debido a que este modelo fue evaluado en diferentes puntos en la península coreana en donde se sitúan estaciones meteorológicas y con diferentes condiciones climáticas. En el trabajo realizado por Kim et al. [5] se evaluaron dos modelos, el primer modelo evaluado es el CNN-LSTM donde se obtuvo 0.1966 MJ m² y 0.1316 MJ m² para el RMSE y el MAE respectivamente, el segundo modelo es el CNN-GRU que obtuvo 0.1986 MJ m² y 0.1360 MJ m² para el RMSE y MAE respectivamente. Observando y comparando ambos modelos, se puede mencionar que ambos tienen un desempeño similar estimando la irradiancia similar. El modelo PredRNN++ evaluado por Xia et al. [21] logro obtener un resultado de 0.35 para el RMSE en una estimación para un horizonte de 4h. El último estudio presentado en esta sección realizado en China [23] se obtuvo un nRMSE de 96.46% demostrando un gran rendimiento en la estimación de potencia fotovoltaica. En la Tabla 2. Se presentan los resultados que obtuvieron los modelos que utilizan datos satelitales

Tabla 2. Resumen de resultados de los modelos que emplean datos satelitales

Ref.	Modelo	Datos de entrada	Horizonte de estimación	Error medido
[23]	CNN-1D	16 canales espectrales (GK2A/AMI) Irradiancia solar (KMA)	1 h	RMSE: 0.091 MJ m ² - 0.314 MJ m ²

[5]	CNN-LSTM	16 canales espectrales (GK2A/AMI) Irradiancia solar (KMA)	1 h	RMSE: 0.1966 MJ m ² MAE: 0.1316 MJ m ²
	CNN-GRU			RMSE: 0.1986 MJ m ² MAE: 0.1360 MJ m ²
[21]	PredRNN+	16 canales espectrales (Himawari-8/9/AHI) Cobertura de nubes	4 h	RMSE: 0.35 MBE: -0.03
[25]	CNN-LSTM	14 bandas espectrales (FengYung-4) Potencia histórica	4 h	nRMSE:96.46%

3.3. Datos meteorológicos

Los resultados que obtuvieron los estudios que emplean datos meteorológicos para la estimación de potencia o irradiancia solar serán presentados en la Tabla 3.

En el artículo Saad et al. [27], se evaluaron los modelos de estimación propuestos para demostrar su eficacia en diferentes horizontes temporales, en donde se demostró que entre más alto sea el horizonte de estimación, mayor será la incertidumbre en los datos estimados. Entre todos los modelos del estudio referenciado quien demostró un mejor rendimiento fue el CNN.

El horizonte de estimación de Bouziane et al. [28] no es especificado en el estudio y métricas comunes utilizadas en otros estudios similares no fueron utilizadas, como el RMSE, MAE, R2, entre otras. Para evaluar cada modelo se utilizó el rendimiento como una métrica, el CNN-RNN fue el modelo con un mejor rendimiento con un valor de 0.99.

El trabajo realizado por Nespoli et al. [29] comparo ambos modelos en días soleados y en días nublado utilizando como métricas el MAPE, NMAE, Y el WMAE. Ambos modelos medidos a través del MAPE% presentaron buenos resultados en días soleados, en días nublados el PHANN fue quien obtuvo mejores resultados en comparación con el modelo basado en ANN. Para el nMAE se presentan diferentes rangos de valores que dependen si fue un día nublado o un día soleado y para el WMAE también se demuestra mejores resultados en días

soleados, con valores de 10.1% y 12.4% comparados con los 78.1% y 151.0%.

En el último trabajo de esta sección, Alay et al. [31], se evaluaron los modelos basados en CNN y LSTM con las métricas MSE, RMSE y MAE. El CNN fue quien obtuvo mejores resultados en estimación con valores de 0.0039, 0.0039 y 0.0205 para el MSE, RMSE y MAE; demostrando un mejor rendimiento que el modelo basado en redes LSTM.

Tabla 3. Resumen de resultados de los modelos que emplean datos meteorológicos

Ref.	Modelo	Datos de entrada	Horizonte de estimación	Error medido
[27]	LSTM	Humedad (%) Temperatura ambiente (°C) Precipitaciones (mm) Presiones (hPa) Características del Panel	5 min 15 min 1 h 1 día	nMAE (5 min): 1.69% nMAE (15 min): 1.94% nMAE (1 h): 2.10% nMAE (1 día): 3.86%
	CNN			nMAE (5 min): 1.82% nMAE (15 min): 2.00% nMAE (1 h): 2.12% nMAE (1 día): 2.61%
	Multilayer Perceptron			nMAE (5 min): 7.15% nMAE (15 min): 7.82% nMAE (1 h): 8.03% nMAE (1 día): 13.48
[28]	CNN	Humedad Relativa (%) Temperatura ambiente (°C) Potencia (kW) Corriente(A) Voltaje(V)	(No se especifica)	Rendimiento: 0.84
	LSTM			Rendimiento: 0.94
	CNN-RNN			Rendimiento: 0.99
[29]	PHANN	Temperatura Ambiente (°C) Irradiancia Solar Irradiación sobre el panel solar	24 horas con una resolución de 1h	MAPE (Soleado): 23.6% MAPE (Nublado): 54.0% NMAE (Soleado): 1%-2%

	ANN	Velocidad del viento (m/s)		NMAE (Nublado): 2%-6%
		Presión Atmosférica (hPa)		WMAE (Soleado): 10.1%
		Precipitación (mm)		WMAE (Nublado): 78.1%
		Cobertura de nubes		MAPE (Soleado): 10.0%
		Tipos de nubes		MAPE (Nublado): 68.9%
				NMAE (Soleado): 2%-5%
				NMAE (Nublado): 1%-11%
				WMAE (Soleado): 12.4
				WMAE (Nublado): 151.0 %
[31]	CNN	Radiación solar (W/ m ²)	(No se especifica)	MSE: 0.0039
	LSTM	Temperatura ambiental (°C)		RMSE: 0.0039
		Temperatura del módulo (°C)		MAE: 0.0205
		Humedad (%)		MSE: 0.0039
		Velocidad del viento (m/s)		RMSE: 0.0039
				MAE: 0.0182

3.4. Series temporales de potencia

Para el primer modelo explorado en la estimación de potencia utilizando solamente series temporales de potencia donde se utilizó el Stacked LSTM, se implementó como métrica el RMSE donde obtuvo un 0.11369, de acuerdo con el estudio de Konstantinou et al. [33], indica que es un buen resultado para la estimación de potencia fotovoltaica. Este estudio también presenta graficas comparativas de la potencia estimada y la generada, donde se puede visualizar el rendimiento del modelo evaluado en diferentes días y se observa que tiende a fallar en la predicción en aquellos días donde se presentan grandes fluctuaciones en la generación.

El trabajo realizado por Majidpuor et al. [35] se evaluaron diferentes modelos que utilizan las series temporales de potencia como fuente principal de datos para estimar la potencia fotovoltaica en un horizonte de estimación de al menos 1 minuto. A través del MAE y SMAPE como métricas de comparación entre los

modelos, se descubrió que el K-Nearest- Neighbor y el Random-Forest resaltan entre los demás modelos evaluados.

Tabla 4. Resumen de resultados de los modelos que emplean series temporales de potencia

Ref.	Modelo	Datos de entrada	Horizonte de estimación	Error medido
[33]	Stacked LSTM	Series temporales de Potencia	1.5 h	RSME: 0.11369
[35]	<i>K-Nearest</i>	Series Temporales de potencia	1 min	MAE: 0.014
	<i>Support Vector Regression</i>			SMAPE: 2.8%
	<i>Random Forest</i>			MAE: 0.017
	<i>ARIMA</i>			SMAPE: 3.6%
				MAE: 0.015
				SMAPE: 3.2%
				MAE: 0.020
				SMAPE: 4.2%

3.5. Datos Multifuente

El modelo U-Net se evaluó al compararlo con datos de irradiancia solar obtenidos de la plataforma HARMONIE, donde se descubrió que esta tiende a fallar en capturar ciertos detalles que el modelo U-Net si logra captar [41], a través de las métricas MAE, RMSE y rRMSE se logró determinar el rendimiento de este modelo en dos diferentes horizontes de estimación en donde ambos casos se logró obtener buenos resultados.

En el trabajo de Mansouri et al. [43] se evaluaron diferentes modelos basados en DL y se compararon con una red LSTM, en donde se logró obtener resultados que establecen a la LSTM como la que mejores resultados obtuvo en comparación con los modelos de *Decision Tree*, *Random Forest* y *el ANN*.

El modelo diseñado por Gao et al. [44] implementan fotografías del cielo y datos meteorológicos. La métrica implementada para evaluar este modelo fue el nMAP, este obtuvo valores entre 4.2% y 7.9%, esta variabilidad

en los resultados es debido a que fue probado en diferentes condiciones meteorológicas.

El modelo empleado por Thaker et al. [45], tiene un horizonte de estimación de 6h, además fue evaluado en diferentes horizontes siendo estos entre 1 hora a 6 horas. Se encontró que este tiende a bajar el rendimiento después del horizonte de 3 horas. Al ser aplicado en diferentes tecnologías fotovoltaicas, se logró demostrar que se pueden obtener resultados similares al estimar la potencia a través de modelos bien calibrados.

Tabla 5. Resumen de resultados de los modelos que emplean datos multifuente

Ref.	Modelo	Datos de entrada	Horizonte de estimación	Error medido
[41]	UNet (60min)	Imágenes satelitales NWP Irradiancia solar	1 h	MAE: 24.24 RMSE: 28.91 rRMSE: 14.62
	UNet (240 min)		4 h	MAE: 23.58 RMSE: 29.23 rRMSE: 21.86
[43]	Decision tree	Irradiancia solar (W/m ²) Temperatura Ambiente (°C) Velocidad del viento (m/s) Humedad (%) Potencia generada (kW)	Short-term forecasting	MAE: 0.26% RMSE: 5.16%
	SVM			MAE: 0.48% RMSE: 6.98%
	Random Forest			MAE: 0.29% RMSE: 5.43%
	ANN			MAE: 0.21% RMSE: 5.14%
	LSTM			MAE: 0.51% RMSE: 1.03%
[44]	Gao Model	Sky Imaging Humedad relativa (%) Temperatura del aire (°C) Velocidad del viento (m/s) presión del aire (hPa)	4 h	nMAP: 4.2-7.9%

[45]	Perez-Ineichen	Temperatura ambiente (°C) Velocidad del viento (m/s) Irradiancia Efectiva (W/m ²)	6 h	nMAE: 6.65% nRMSE: 10.28%
------	----------------	---	-----	------------------------------------

3.5.1. Clear Sky Model

En la Tabla 6 se presentan los resultados que obtuvieron los estudios que emplearon el Clear Sky Modeling como fuente de datos en la estimación de potencia e irradiancia solar.

En el estudio realizado en Marruecos por El Alani et al. [54] se buscó estimar la irradiancia solar en cuatro diferentes localidades del país. Al evaluar los tres modelos, se encontró que el que mejor resultado presento entre los 3 modelos fue el IFS en comparación al IFS y el modelo McClear.

En los modelos evaluados en Alger [55], el que resulto con mejor evaluación fue el Ineichen-Perez, seguido por el ESRA en la localidad de Bouzaréah. En la localidad de Ghardaïa, el modelo que resalto fue el ESRA sobre los demás. Los datos obtenidos a través de estos modelos fueron comparados con mediciones locales para determinar la eficacia de estos.

El último estudio evaluado en esta sección, indica que todos tuvieron un rendimiento similar al estimar la irradiancia solar. La métrica utilizada fue el RMSE y fue evaluada en dos horizontes temporales diferentes, el primero en un periodo ultracorto donde se obtuvieron resultados entre 70 y 100 W/m². El segundo horizonte de periodo corto, se obtuvo un resultado de 150 - 200W/ m² [56].

Tabla 6. Resumen de resultados de los modelos que el Clear Sky Model

Ref.	Modelo	Datos de entrada	Horizonte de estimación	Error medido
[54]	IFS	<ul style="list-style-type: none"> ▪ NWP ▪ Irradiancia global ▪ Datos satelitales ▪ fotografía del cielo 	1 día	MBE: 1.87 W/m ² a 26.19 W/m ² RMSE: 37.82 W/m ² a 125.66 W/m ²
	GFS			MBE: -1.94 W/m ² a 49.59 W/m ² RMSE: 97.32 W/m ² a 164.84 W/m ²
	McClea			MBE:

				12.92 W/m ² a 30.36 W/m ² RMSE: 72.98 W/m ² a 141.72 W/m ²
[55]	ESRA	<ul style="list-style-type: none"> ▪ Irradiancia Directa ▪ Irradiancia Difusa ▪ Irradiancia Global ▪ Turbiedad atmosférica ▪ Angulo del zenit ▪ Transmitancia atmosférica 	5-10 min	nRMSE: 6.94% MBE: 0.75%
	Ineichen-Perez			nRMSE: 3.84% MBE: -0.97%
	Solis			nRMSE: 6.02% MBE: 4.64%
	Algerian Solar Model			nRMSE: 6.79% MBE: -1.23%
	Hottel-Liu-Jordan			nRMSE: 8.18% MBE: -1.23%
[56]	Ineichen-Perez	<ul style="list-style-type: none"> ▪ Irradiancia normal de haz extraterrestre ▪ Ángulo del zenit ▪ Albedo de la superficie ▪ Presión de la superficie ▪ Profundidad óptica de aerosoles a 550nm ▪ Exponente de Angstrom ▪ Ozono en la columna ▪ Cantidad total de dióxido de nitrógeno ▪ Vapor de agua ▪ Precipitable total 	15 min – 6 h	RMSE (15-30 min): 70 -100W/m ² RMSE (3-6 h): 150 - 200W/m ²

3.6. Comparativa entre las diferentes categorías

Para poder realizar una comparativa entre las diferentes categorías se tomaron los modelos que obtuvieron un mejor rendimiento respaldadas a través de las métricas que fueron usadas en para determinar el desempeño de cada modelo. Otro aspecto fundamental para poder hacer una comparación entre las diferentes categorías es la unidad que fue utilizada en cada trabajo ya que algunos se dedicaron a estimar la potencia en watts que entrega la planta fotovoltaica, otros estimaron la irradiancia solar incidente en w m-2 o MJ m-2 sobre la planta fotovoltaica; debido a esto, para esta comparación solo se tomaron en cuenta aquellos que su rendimiento fue medido de forma porcentual.

En el grafico de la Figura 2 se muestran los resultados que obtuvo cada categoría. El mejor resultado fue de

1.82% en el modelo CNN que implementa data satelital, seguido por los modelos que implementan series de potencia temporal con un 2.8% y de tercer lugar se encuentra el modelo Ineichen-Perez de los modelos de cielo despejado con un 3.84%.

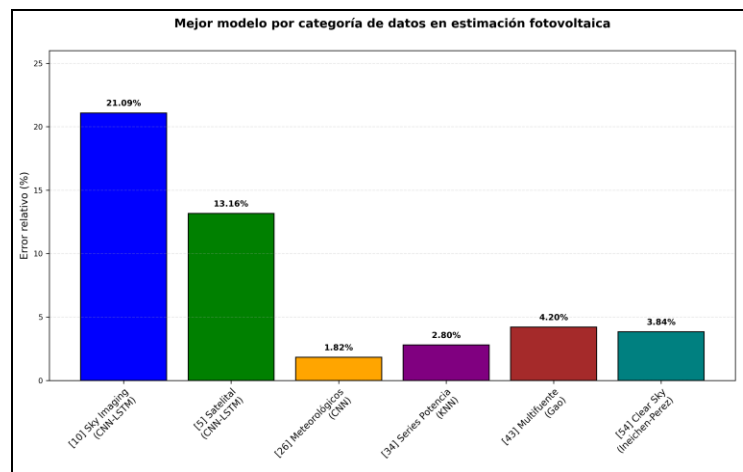


Figura 2: Grafico de barras comparativo entre las diferentes categorías de datos y el modelo empleado.
Fuente: Elaboración propia

3.7. Horizonte de estimación:

Un aspecto para considerar al momento de utilizar uno de estos tipos de datos meteorológicos, es el horizonte de estimación. La mayoría de estos modelos estimación independientemente de los datos que utiliza como entrada, son empleados para el periodo ultracorto de estimación, es decir que pueden generar estimaciones desde 1 minuto a 4 horas sin tener una gran pérdida de precisión. De los artículos revisados, solo dos tipos de datos han sido implementado en modelos que generan un periodo de estimación de corto plazo, es decir hasta 72 horas para el horizonte de estimación y manteniendo un margen de error aceptable. Ninguno de los modelos fue probado para horizontes de estimación de mediano y largo plazo, esto debido a que la precisión e incertidumbre que existía entre los valores estimados y los valores medidos empezaba incrementar una vez pasada las 24 horas.

4. Conclusión

En este artículo se exploraron diversas literaturas que proponen modelos de estimación de potencia fotovoltaica y el SSI. Estos fueron clasificados en base a la fuente de datos empleados y se compararon los

rendimientos que estos tuvieron en sus respectivas literaturas.

Las centrales solares han empezado a aumentar su implementación en las matrices eléctricas de la mayoría de los países de ALC ganando importancia en las mismas. en países como México, se realizan pronósticos para la generación solar, pero estos llegan a tener errores mayores al 20% y otros como Chile y Bolivia que han desarrollado diversos proyectos para la mejora en los pronósticos empleando datos meteorológicos, potencia generada en las centrales e imágenes satelitales.

Es crucial para los demás países de ALC empiecen a implementar modelos de estimación de potencia fotovoltaica para asegurar la estabilidad en la red y mantener la fiabilidad del suministro. Para esto se puede emplear diversas fuentes de datos exploradas en este artículo como los meteorológicos que lograron obtener el error evaluado más bajo, de un 1.82% con el uso de una red CNN. Esto último no descarta el uso de las demás fuentes para tener una variedad de datos para generar las estimaciones y no solo depender de una sola, en caso de que esas estén disponibles para utilizar. Otro aspecto importante de estos modelos es el uso de datos de buena calidad para que los modelos puedan llegar a tener una mejor precisión en sus resultados.

AGRADECIMIENTOS

Este trabajo se ha realizado bajo soporte de SENACYT a través de: financiamiento de los proyectos FID21-207, FID23-098 y FID23-158, y al Sistema Nacional de Investigación (SNI) del Dr. Fernando Arias y la Dra. Mayteé Zambrano.

CONFLICTO DE INTERESES

Los autores declaran no tener algún conflicto de interés.

CONTRIBUCIÓN Y APROBACIÓN DE LOS AUTORES

J. A.: Conceptualización, Metodología, Software, Curación de datos, Análisis formal, Investigación, Redacción – borrador original, Redacción – Revisión y Edición.

F. A.: Supervisión, Financiamiento, Recursos y equipamiento, Administración del proyecto, Revisión y Edición, Correspondencia.

M. Z.: Financiamiento, Gestión administrativa, Adquisición de recursos, Redacción – Revisión y

Edición.

E. G.: Recolección y procesamiento de datos, Validación, Análisis, Revisión.

REFERENCIAS

- [1] United Nations Environment Programme, «The state of distributed solar photovoltaic generation in Latin America and the Caribbean», 2022, [En línea]. Disponible en: <https://wedocs.unep.org/handle/20.500.11822/40538>
- [2] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martínez-de-Pison, y F. Antonanzas-Torres, «Review of photovoltaic power forecasting», *Sol. Energy*, vol. 136, pp. 78-111, oct. 2016, doi: 10.1016/j.solener.2016.06.069.
- [3] Organización Latinoamericana de Energía (OLADE), «Año 2024: Reporte de Generación eléctrica en América Latina y el Caribe», Organización Latinoamericana de Energía (OLADE), Quito, Ecuador, TR-07042025, abr. 2025.
- [4] Sistema de Información Energética de Latinoamérica y el Caribe, «Capacidad instalada por fuente - Anual». 2024. [En línea]. Disponible en: <https://sielac.olade.org/WebForms/Reportes/ReporteDato7.aspx?oc=181&or=392&ss=2&v=1>
- [5] J. Kim, E. Kim, S. Jung, M. Kim, B. Kim, y S. Kim, «Spatio-Temporal Deep Learning-Based Forecasting of Surface Solar Irradiance: Leveraging Satellite Data and Feature Selection», *Remote Sens.*, vol. 16, n.º 5, p. 888, mar. 2024, doi: 10.3390/rs16050888.
- [6] C. Liu, M. Li, Y. Yu, Z. Wu, H. Gong, y F. Cheng, «A Review of Multitemporal and Multispatial Scales Photovoltaic Forecasting Methods», *IEEE Access*, vol. 10, pp. 35073-35093, 2022, doi: 10.1109/ACCESS.2022.3162206.
- [7] H. Min, S. Hong, J. Song, B. Son, B. Noh, y J. Moon, «SolarFlux Predictor: A Novel Deep Learning Approach for Photovoltaic Power Forecasting in South Korea», *Electronics*, vol. 13, n.º 11, p. 2071, may 2024, doi: 10.3390/electronics13112071.
- [8] S. Y. Diaba, A. A. Alola, M. G. Simoes, y M. Elmusrati, «Deep learning-based evaluation of photovoltaic power generation», *Energy Rep.*, vol. 12, pp. 2077-2085, dic. 2024, doi: 10.1016/j.egy.2024.08.007.
- [9] Sonia Montecinos Geisse, Natalia Escobosa, Manasés Mercedez, Nataly Montezuma, y Tatiana Orellana, «Pronósticos de Generación Eólica y Solar Fotovoltaica en América Latina», GIZ, Quito, Ecuador, 2021. [En línea]. Disponible en: https://energypedia.info/images/a/af/Pronosticos_eolico_FV_LATM.pdf
- [10] W. Kong, Y. Jia, Z. Y. Dong, K. Meng, y S. Chai, «Hybrid approaches based on deep whole-sky-image learning to photovoltaic generation forecasting», *Appl. Energy*, vol. 280, p. 115875, dic. 2020, doi: 10.1016/j.apenergy.2020.115875.
- [11] T. Stoffel y A. Andreas, «NREL Solar Radiation Research Laboratory (SRRL): Baseline Measurement System (BMS);

- Golden, Colorado (Data)». National Renewable Energy Laboratory (NREL), Golden, CO (United States), p. 19,700 MB; continuing growth, 1981. doi: 10.7799/1052221.
- [12] H. T. C. Pedro, D. P. Larson, y C. F. M. Coimbra, «A comprehensive dataset for the accelerated development and benchmarking of solar forecasting methods», *J. Renew. Sustain. Energy*, vol. 11, n.º 3, p. 036102, may 2019, doi: 10.1063/1.5094494.
- [13] G. Terrén-Serrano, A. Bashir, T. Estrada, y M. Martínez-Ramón, «Girasol, a sky imaging and global solar irradiance dataset», *Data Brief*, vol. 35, p. 106914, abr. 2021, doi: 10.1016/j.dib.2021.106914.
- [14] H. Wen *et al.*, «Deep Learning Based Multistep Solar Forecasting for PV Ramp-Rate Control Using Sky Images», *IEEE Trans. Ind. Inform.*, vol. 17, n.º 2, pp. 1397-1406, feb. 2021, doi: 10.1109/TII.2020.2987916.
- [15] I. Cacciari y A. Ranfagni, «Hands-On Fundamentals of 1D Convolutional Neural Networks—A Tutorial for Beginner Users», *Appl. Sci.*, vol. 14, n.º 18, p. 8500, sep. 2024, doi: 10.3390/app14188500.
- [16] Z. Wu, F. Pan, D. Li, H. He, T. Zhang, y S. Yang, «Prediction of Photovoltaic Power by the Informer Model Based on Convolutional Neural Network», *Sustainability*, vol. 14, n.º 20, p. 13022, oct. 2022, doi: 10.3390/su142013022.
- [17] S. Xu, R. Zhang, H. Ma, C. Ekanayake, y Y. Cui, «On vision transformer for ultra-short-term forecasting of photovoltaic generation using sky images», *Sol. Energy*, vol. 267, p. 112203, ene. 2024, doi: 10.1016/j.solener.2023.112203.
- [18] O. Voronych, R. Höller, G. Longhi Beck, y W. Traunmüller, «Solar PV nowcasting based on skycamera observations», *Adv. Sci. Res.*, vol. 16, pp. 7-10, feb. 2019, doi: 10.5194/asr-16-7-2019.
- [19] National Meteorological Satellite Center, «Geo-KOMPSAT-2A Overview». KMA, Corea, 2018. [En línea]. Disponible en: https://nmsc.kma.go.kr/resources/homepage/pdf/210428_GK2A_Fact_Sheets.pdf
- [20] NASA GOES-R Series Program Office, «GOES-R Series Data Book». National Aeronautics and Space Administration GOES-R Series Program Office. [En línea]. Disponible en: <https://www.goes-r.gov/downloads/resources/documents/GOES-RSeriesDataBook.pdf>
- [21] P. Xia *et al.*, «Accurate nowcasting of cloud cover at solar photovoltaic plants using geostationary satellite images», *Nat. Commun.*, vol. 15, n.º 1, p. 510, ene. 2024, doi: 10.1038/s41467-023-44666-1.
- [22] CMA, «CMA Report on Preparations for FY-4», CMA, Reporte C.2. [En línea]. Disponible en: https://img.nsmc.org.cn/PORTAL/NSMC/ATTACHMENT_EN/files/CMA%20Report%20on%20Preparations%20for%20FY-4.pdf
- [23] J.-C. Jang, E.-H. Sohn, y K.-H. Park, «Estimating Hourly Surface Solar Irradiance from GK2A/AMI Data Using Machine Learning Approach around Korea», *Remote Sens.*, vol. 14, n.º 8, p. 1840, abr. 2022, doi: 10.3390/rs14081840.
- [24] M. Frincu, M. Penteliuc, y A. Spataru, «A Solar Radiation Forecast Platform Spanning over the Edge-Cloud Continuum», *Electronics*, vol. 11, n.º 17, p. 2756, sep. 2022, doi: 10.3390/electronics11172756.
- [25] B. Liu, Z. Liu, Y. Wang, Z. Zhen, F. Wang, y Z. Tong, «Ultra-Short-Term Power Forecasting for Distributed PV based on Multi-Source Remote Sensing Information and Adaptive Feature Extraction», en *2024 IEEE/IAS Industrial and Commercial Power System Asia (I&CPS Asia)*, Pattaya, Thailand: IEEE, jul. 2024, pp. 484-489. doi: 10.1109/ICPSAsia61913.2024.10761674.
- [26] A. A. Prasad y M. Kay, «Prediction of Solar Power Using Near-Real Time Satellite Data», *Energies*, vol. 14, n.º 18, p. 5865, sep. 2021, doi: 10.3390/en14185865.
- [27] B. Saad, A. El Hannani, A. Aqal, y R. Errattahi, «Photovoltaic power prediction using deep learning models: recent advances and new insights», *Int. J. Electr. Comput. Eng. IJECE*, vol. 14, n.º 5, p. 5926, oct. 2024, doi: 10.11591/ijece.v14i5.pp5926-5940.
- [28] A. Bouziane, M. Bouziane, y K. Naima, «Enhancing Photovoltaic Power Forecasting through Hybrid Deep Learning Models: A CNN-RNN Approach for Grid Stability and Renewable Energy Optimization», *J. Renew. Energ.*, oct. 2024, doi: 10.54966/jreen.v1i3.1294.
- [29] A. Nespoli *et al.*, «Day-Ahead Photovoltaic Forecasting: A Comparison of the Most Effective Techniques», *Energies*, vol. 12, n.º 9, p. 1621, abr. 2019, doi: 10.3390/en12091621.
- [30] A. Dolara, F. Grimaccia, S. Leva, M. Mussetta, y E. Ogliari, «A Physical Hybrid Artificial Neural Network for Short Term Forecasting of PV Plant Power Output», *Energies*, vol. 8, n.º 2, pp. 1138-1153, feb. 2015, doi: 10.3390/en8021138.
- [31] F. Alay, N. İlhan, y M. Güllüoğlu, «Solar Radiation Prediction in PV Power Systems: a Comparison of Deep Learning Models Using Big Data», *Proc. Bulg. Acad. Sci.*, vol. 77, n.º 9, sep. 2024, doi: 10.7546/CRABS.2024.09.10.
- [32] N. Son y M. Jung, «Analysis of Meteorological Factor Multivariate Models for Medium- and Long-Term Photovoltaic Solar Power Forecasting Using Long Short-Term Memory», *Appl. Sci.*, vol. 11, n.º 1, p. 316, dic. 2020, doi: 10.3390/app11010316.
- [33] M. Konstantinou, S. Peratikou, y A. G. Charalambides, «Solar Photovoltaic Forecasting of Power Output Using LSTM Networks», *Atmosphere*, vol. 12, n.º 1, p. 124, ene. 2021, doi: 10.3390/atmos12010124.
- [34] M. Abdel-Nasser y K. Mahmoud, «Accurate photovoltaic power forecasting models using deep LSTM-RNN», *Neural Comput. Appl.*, vol. 31, n.º 7, pp. 2727-2740, jul. 2019, doi: 10.1007/s00521-017-3225-z.
- [35] M. Majidpour, H. Nazaripouya, P. Chu, H. Pota, y R. Gadh, «Fast Univariate Time Series Prediction of Solar Power for Real-Time Control of Energy Storage System», *Forecasting*, vol. 1, n.º 1, pp. 107-120, sep. 2018, doi: 10.3390/forecast1010008.
- [36] C. M. Bishop, *Pattern recognition and machine learning*. en Information science and statistics. New York: Springer, 2006.

- [37] A. J. Smola y B. Schölkopf, «A tutorial on support vector regression», *Stat. Comput.*, vol. 14, n.º 3, pp. 199-222, ago. 2004, doi: 10.1023/B:STCO.0000035301.49549.88.
- [38] L. Breiman, «Random Forests», *Mach. Learn.*, vol. 45, n.º 1, pp. 5-32, oct. 2001, doi: 10.1023/A:1010933404324.
- [39] G. Weisang y Y. Awazu, «Vagaries of the Euro: an Introduction to ARIMA Modeling», vol. Vol 2., n.º No. 1, 2008, [En línea]. Disponible en: <https://csbiggs.fr/index.php/csbiggs/article/view/350>
- [40] C. Voyant, M. Muselli, C. Paoli, M. L. Nivet, y P. Poggi, «Predictability of PV power grid performance on insular sites without weather stations: use of artificial neural networks», 2009, *arXiv*. doi: 10.48550/ARXIV.0905.3569.
- [41] Y. Cui, P. Wang, J. Fokke Meirink, N. Ntantis, y J. S. Wijnands, «Solar radiation nowcasting based on geostationary satellite images and deep learning models», *Sol. Energy*, vol. 282, p. 112866, nov. 2024, doi: 10.1016/j.solener.2024.112866.
- [42] J. Schmetz *et al.*, «An introduction to Meteosat Second Generation (MSG)», *Bull Amer Meteor Soc*, vol. 83, pp. 977-992, jul. 2002.
- [43] N. Mansouri, N. Zitouni, y A. Mouelhi, «AI Innovations in Photovoltaic Power Prediction», en *2024 IEEE International Conference on Artificial Intelligence & Green Energy (ICAIGE)*, 2024, pp. 1-6. doi: 10.1109/ICAIGE62696.2024.10776628.
- [44] H. Gao y M. Liu, *Short-term Solar Irradiance Prediction from Sky Images with a Clear Sky Model*. 2022, p. 3082. doi: 10.1109/WACV51458.2022.00313.
- [45] J. Thaker y R. Höller, «Hybrid model for intra-day probabilistic PV power forecast», *Renew. Energy*, vol. 232, p. 121057, oct. 2024, doi: 10.1016/j.renene.2024.121057.
- [46] E. Lorenzo, «Energy Collected and Delivered by PV Modules», en *Handbook of Photovoltaic Science and Engineering*, 1.ª ed., A. Luque y S. Hegedus, Eds., Wiley, 2003, pp. 905-970. doi: 10.1002/0470014008.ch20.
- [47] R. Perez, P. Ineichen, R. Seals, J. Michalsky, y R. Stewart, «Modeling daylight availability and irradiance components from direct and global irradiance», *Sol. Energy*, vol. 44, n.º 5, pp. 271-289, 1990, doi: 10.1016/0038-092X(90)90055-H.
- [48] L. Kleeman, «Understanding and Applying Kalman Filtering». Monash University, Clayton. [En línea]. Disponible en: https://www.cs.cmu.edu/~motionplanning/papers/sbp_papers/kalman/kleeman_understanding_kalman.pdf
- [49] K. Palani, R. Kota, A. P. Azad, y V. Arya, «Blue Skies: A Methodology for Data-Driven Clear Sky Modelling», en *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*, Melbourne, Australia: International Joint Conferences on Artificial Intelligence Organization, ago. 2017, pp. 3777-3783. doi: 10.24963/ijcai.2017/528.
- [50] A. Mendyl, B. Mabasa, H. Bouzghiba, y T. Weidinger, «Calibration and Validation of Global Horizontal Irradiance Clear Sky Models against McClear Clear Sky Model in Morocco», *Appl. Sci.*, vol. 13, n.º 1, p. 320, dic. 2022, doi: 10.3390/app13010320.
- [51] F. Antonanzas-Torres, R. Urraca, J. Polo, O. Perpiñán-Lamigueiro, y R. Escobar, «Clear sky solar irradiance models: A review of seventy models», *Renew. Sustain. Energy Rev.*, vol. 107, pp. 374-387, jun. 2019, doi: 10.1016/j.rser.2019.02.032.
- [52] «Global Forecast System (GFS)», National Centers for Environmental Information (NCEI). Accedido: 24 de marzo de 2026. [En línea]. Disponible en: <https://www.ncei.noaa.gov/products/weather-climate-models/global-forecast>
- [53] «Integrated Forecasting System». Accedido: 24 de marzo de 2026. [En línea]. Disponible en: <https://www.ecmwf.int/en/forecasts/documentation-and-support/changes-ecmwf-model>
- [54] O. el Alani, A. Ghennioui, H. Ghennioui, Y.-M. Saint-Drenan, y P. Blanc, *Evaluation of 24-Hours forecasts of global solar irradiation from IFS, GFS and McClear models*, vol. 2307. 2020. doi: 10.1063/5.0032744.
- [55] K. Gairaa, S. Benkacali, y M. Guermoui, «Clear-sky models evaluation of two sites over Algeria for PV forecasting purpose», *Eur. Phys. J. Plus*, vol. 134, oct. 2019, doi: 10.1140/epjp/i2019-12917-2.
- [56] D. Yang, «Choice of clear-sky model in solar forecasting», *J. Renew. Sustain. Energy*, vol. 12, p. 026101, mar. 2020, doi: 10.1063/5.0003495.
- [57] M. Alrashidi y S. Rahman, «Short-term photovoltaic power production forecasting based on novel hybrid data-driven models», *J. Big Data*, vol. 10, n.º 1, p. 26, mar. 2023, doi: 10.1186/s40537-023-00706-7.