

Artículo original

## Modelos de media móvil integrada autorregresiva de la radiación solar global en el distrito San Jerónimo de Andahuaylas, Perú

### ARIMA models of global solar radiation in the San Jerónimo de Andahuaylas district, Perú

Reynaldo Ricardo Quispe-Infantes

Departamento Académico de Ciencias Básicas, Universidad Nacional José María Arguedas, Andahuaylas, Perú

#### Resumen

El distrito de San Jerónimo de Apurímac presenta una elevada radiación solar que afecta las actividades agrícolas, ganaderas y mineras. Si se tiene un pronóstico confiable, es posible aumentar la producción y el nivel socioeconómico. En este estudio se elaboraron y compararon modelos de media móvil autorregresiva (*Autoregressive Integrated Moving Average*, ARIMA) de la radiación solar global (RSG) en el distrito de San Jerónimo con los datos de las estaciones meteorológicas de la Universidad Nacional José María Arguedas (UNAJMA) y de la Administración Nacional de Aeronáutica y del Espacio de Estados Unidos (NASA). Se hizo un estudio experimental aplicado de enfoque cuantitativo y nivel descriptivo propositivo con una muestra de 1.037 datos históricos de RSG registrados desde el 1 de enero de 2022 hasta el 2 de noviembre de 2024 mediante observación con un sensor de luz en la estación terrestre y técnicas documentales de datos recolectados del satélite geoestacionario operacional ambiental (*Geostationary Operational Environmental Satellite*, GOES) en la estación espacial (**POWER**, 2024). Se aplicaron pruebas de normalidad gráfica, la Q-Q normal, la de Dickey-Fuller, pruebas de estacionariedad, la de Levene y la de D'Agostino, gráficas de autocorrelación simple (*autocorrelation function*, ACF) y parcial para el cálculo de retrasos, y el criterio de información de Akaike (*Akaike information criterion*, AIC) para la elección del mejor modelo. Se obtuvieron modelos predictivos de RSG, ARIMA (3,0,2) y (5,0,4) precisos en las estaciones NASA y UNAJMA. Se obtuvieron modelos ARIMA(3,0,2) para la estación NASA y ARIMA(5,0,4) para la estación UNAJMA, con valores de error absoluto medio (*mean absolute error*, MAE), error porcentual absoluto medio (*mean absolute percentage error*, MAPE) y la raíz del error cuadrático medio (*root mean squared error*, RMSE) de 0,290; 5,211% y 0,384, respectivamente, en el primer caso; y de 0,610; 10,623% y 0,702, en el segundo. Todos estos permitieron pronosticar la RSG en el distrito de San Jerónimo desde el 3 hasta el 12 de noviembre de 2024.

**Palabras clave:** Modelos autorregresivos; radiación solar; estacionariedad; pronósticos; autocorrelaciones.

#### Abstract

The San Jerónimo de Apurímac district experiences high solar radiation, which impacts agricultural, livestock, and mining activities. A reliable forecast would increase production and socioeconomic status. Here, we developed and compared autoregressive moving average (ARIMA) models of global solar radiation (GSR) for the San Jerónimo district using the meteorological data from the stations at the José María Arguedas National University (UNAJMA) and the USA National Aeronautics and Space Administration (NASA). We conducted an applied experimental research with a quantitative approach and a propositional descriptive level, with a sample of 1,037 historical RSG data recorded from January 1, 2022, to November 2, 2024 at the ground station using a light sensor and at the space station through documentary techniques of the data from the geostationary operational environmental satellite (GOES) (**POWER**, 2024). The following normality tests were applied: normal, Q-Q plot, Dickey-Fuller Test, stationarity tests, Levene and D'Agostino tests, simple autocorrelation (ACF) and partial ACF plots for calculating delays, and the Akaike information criterion (AIC) likelihood

**Citación:** Quispe-Infantes RR. Modelos de media móvil integrada autorregresiva de la radiación solar global en el distrito San Jerónimo de Andahuaylas, Perú. Revista de la Academia Colombiana de Ciencias Exactas, Físicas y Naturales. 2025 Ago 19. doi: <https://doi.org/10.18257/raccefyn.3206>

**Editor:** Santiago Vargas Domínguez

**\*Correspondencia:**

Reynaldo Ricardo Quispe Infantes;  
[rrquispe@unajma.edu.pe](mailto:rrquispe@unajma.edu.pe)

**Recibido:** 22 de abril de 2025

**Aceptado:** 21 de junio de 2025

**Publicado en línea:** 19 de agosto de 2025



Este artículo está bajo una licencia de Creative Commons Reconocimiento-NoComercial-Compartir Igual 4.0 Internacional

for choosing the best model. ARIMA(3,0,2) models were obtained for the NASA station and ARIMA(5,0,4) for the UNAJMA station, with mean absolute error (MAE), mean absolute percentage error (MAPE), and root mean squared error (RMSE) values of 0.290; 5.211% and 0.384, respectively, in the first case; and 0.610; 10.623% and 0.702, in the second. Which allowed forecasting the RSG in the district of San Jerónimo from November 3 to 12, 2024.

**Keywords:** Autoregressive models; solar radiation; stationarity; forecasts; autocorrelations.

## Introducción

Los modelos de media móvil integrada autorregresiva (ARIMA) son muy importantes para la revisión de la radiación solar global (RSG) (Odejobi *et al.*, 2024) y para su pronóstico (Ismail *et al.*, 2021; Kim *et al.*, 2022; Melquíades *et al.*, 2022), al igual que los implementados con redes neuronales (Garg *et al.*, 2020; Nugroho *et al.*, 2024a; Meng *et al.*, 2023; Nugroho *et al.*, 2024) o híbridas (Jaihuni *et al.*, 2020; Guermoui *et al.*, 2020). El conocimiento de la RSG tiene impacto en la previsión de la energía solar (Salman *et al.*, 2024; Mughal *et al.*, 2022; Saxena *et al.*, 2024) y su uso (Tarmanini *et al.*, 2023; Atique *et al.*, 2020; Basmadjian *et al.*, 2021; Kurniadi *et al.*, 2024; Sedai *et al.*, 2023), así como para la generación de energía fotovoltaica (Ahmed *et al.*, 2020; Fan *et al.*, 2022) y de potencia solar fotovoltaica (Mellit *et al.*, 2020; Z. F. Liu *et al.*, 2021; Mohamed *et al.*, 2022).

## Antecedentes

En 11 estados de la península de Malasia se han empleado modelos ARIMA de pronóstico de la radiación solar diaria. Los datos se recopilaron del visor del Power Data Access proporcionado por el sitio web de la Administración Nacional de Aeronáutica y del Espacio de Estados Unidos (NASA) a lo largo de casi diez años, desde el 1 de enero de 2009 hasta el 31 de agosto de 2019 (3.895 observaciones por estado). Mediante la metodología de Box y Jenkins se analizó la estacionariedad de los datos y se generó el modelo ARIMA (1, 1, 2) para Pulau Pinang, Perak, Kuala Lumpur, Negeri Sembilan, Melaka, Pahang, Terengganu; el ARIMA (2, 1, 1) para Kedah y Selangor, y el ARIMA (1, 1, 3) para Johor y Kelantan. Los modelos demostraron una precisión RSME de 1,00, 1,02, 0,93, 1,05, 1,00, 1,12, 1,22, 0,98, 1,11, 1,15, 1,20 y una precisión MAE de 0,77, 0,80, 0,73, 0,82, 0,78, 0,85, 0,93, 0,75, 0,88, 0,90, 0,90 para cada estado, lo que indica que los valores pronosticados tendían a los reales (Ismail *et al.*, 2021).

En otro estudio se desarrolló un modelo de pronóstico de irradiancia solar horizontal global (*Global Horizontal Irradiance*, GHI) y uno de irradiancia normal directa (*Direct Normal Irradiance*, DNI) a corto plazo, con el fin de usar la energía solar en el mercado de comercio de energía en Daejeon, Corea del Sur. Los datos se recogieron desde las 18:45 del 21 de enero de 2019 hasta las 23:45 del 31 de diciembre de 2021 (tres años y un minuto) y se desarrolló un modelo ARIMA (4, 1, 2) a partir de datos de GHI de 15 a 75 minutos, un modelo de media móvil integrada autorregresiva estacional (*seasonal autoregressive integrated moving average*, SARIMA) (1, 0, 2)(0, 1, 0) de 90 a 120 minutos y sus errores de evaluación RMSE (Kim *et al.*, 2022).

Por otro lado, en la región de la meseta Qinghai-Tíbet se construyó un modelo ARIMA de predicción de radiación promedio a ultracorto plazo, uno de bosque aleatorio (*random forest model*, RF) y uno de memoria a corto-largo plazo (*long short-term memory*, LSTM) para los 10 minutos siguientes. Se usaron los datos de un radiómetro de cuatro componentes MR-60 del Observatorio Atmosférico de Yangbajing con rango espectral de 285 a 3.000 nm utilizando la unidad W/m<sup>2</sup>, y un muestreo con una frecuencia de un minuto durante 366 días, desde el 1 de junio de 2019 hasta el 31 de mayo de 2020. Los resultados mostraron que la precisión de los modelos RF y LSTM fue superior al ARIMA por influencia del tamaño muestral en cada estación: primavera (1980, 4356, 3564), verano (4752, 2772, 2772), otoño (3564, 4752, 3564) e invierno (3168, 4752, 3168). Para una misma estación y horizonte, el modelo RF tuvo mayor precisión de RMSE que el ARIMA, de 65,6–258,3 W/m<sup>2</sup>, e inferior al de LSTM en 3,7–83,3 W/m<sup>2</sup> (Meng *et al.*, 2023).

En Bhadla, Jodhpur (India), se hizo la predicción de la radiación solar mediante un análisis comparativo de diferentes modelos estadísticos: el de Markov, el ARIMA y un modelo de red neuronal artificial (*artificial neural network*, ANN), con datos recogidos en el periodo 2010–2014. Además, de una comparación gráfica entre la radiación solar observada y pronosticada para los días 31 de enero y 20 de mayo de 2014, con el fin de evaluar su desempeño. Las medidas del RMSE, el error porcentual absoluto medio (*mean absolute percentage error*, MAPE) y el error medio absoluto (*mean absolute error*, MAE) mostraron que el modelo de Markov fue mejor que los otros para las zonas estudiadas (**Garg et al.**, 2020).

La predicción de RSG traza el camino para una planificación y gestión de las reservas en las latitudes medias del hemisferio norte y del hemisferio sur debido a la naturaleza esporádica de la energía solar. Existen varios modelos para dicha predicción: los generadores de imágenes del cielo, que proporcionan un valor de la raíz del error cuadrático medio normalizado (nRMSE) del 6 % al 9 % durante 30 minutos, y la técnica de imágenes satelitales con un RMSE de 61,28 W/m<sup>2</sup> a 346,05 W/m<sup>2</sup> para cuatro horas de predicción. También están los modelos de mesoescala de predicción numérica del tiempo (*numerical weather prediction*, NWP), que proporcionan un RMSE de 411,6 W/m<sup>2</sup> durante los tres días previos a la previsión con una resolución espacial de 50 km, y el de aprendizaje automático (*machine learning*, ML), que ofrece resultados precisos hasta con un día de antelación y un RMSE en el rango de 0,1170 W/m<sup>2</sup> a 93,04 W/m<sup>2</sup> (**Tarmanini et al.**, 2023).

En otro proyecto se planteó la técnica de pronóstico de radiación solar como ayuda al operador del sistema de la red durante su planificación a través de un análisis de datos de mediciones directas obtenidas de [indonesiasolarmap.com](http://indonesiasolarmap.com) y la colaboración de la Asociación de Energía Solar de Indonesia (AESI) y la compañía Perseroan Terbatas (PT) Synkrona Enjiniring Nusantara de Yogyakarta en la isla de Java, Indonesia. Los datos utilizados son mediciones a lo largo de un año (de enero de 2022 a enero de 2023), tomadas en intervalos de una hora desde las 7 am hasta las 5 pm. Los resultados evidenciaron que el modelo de pronóstico LSTM fue más preciso que el de redes neuronales recurrentes (*recurrent neural networks*, RNN) y el ARIMA, con valores de RMSE, MAPE, MAE y coeficiente de determinación (R<sup>2</sup>) de 33,01 W/m<sup>2</sup>, 7,72 %, 24,51 W/m<sup>2</sup> y 0,96, respectivamente. El cielo parcialmente nublado, nublado o lluvioso tuvo menor rendimiento predictivo que el soleado o despejado (**Nugroho et al.**, 2024).

En algunos casos, como en la Universidad Nacional de Gyeongsang, en Jinju, República de Corea del Sur, los modelos de previsión independientes fueron insuficientes, por lo que se propuso un modelo híbrido parcialmente ajustado (*partially adjusted hybrid model*, PAHM), el cual utilizó el modelo de unidades recurrentes cerradas (*bidirectional gated recurrent unit*, BiGRU) y el ARIMA para predecir la irradiación solar en intervalos de 5 y 60 minutos, con una validación cruzada de 11 pasos clasificados según sus costos computacionales; se utilizaron datos de registros de radiación solar correspondientes a un período de 32 meses a partir de marzo de 2017, de las 05:00 a las 19:00, con 174.914 y 14.756 registros para períodos de cinco minutos y una hora, respectivamente. Los modelos individuales BiGRU y ARIMA obtenidos superaron el modelo PAHM y el clásico en las predicciones de cinco minutos. Sin embargo, el PAHM fue 5 % más preciso que el clásico en 60 minutos en promedio, y la eficiencia computacional del modelo BiGRU fue mejor (**Jaihuni et al.**, 2020).

La predicción de radiación global horizontal (GHI) cumple un papel importante en la contaminación del aire y el calentamiento global y es un parámetro determinante en la producción de energía solar de sistemas fotovoltaicos, la cual está determinada por la posición solar y la presencia de nubes. Dado que esto último es difícil de modelar, en una estación meteorológica de Turín (Italia) se propuso una metodología de pronóstico horizontal de corto (15 min a 60 min) y mediano plazo (60 a 120 min). Se utilizó una muestra de seis años de mediciones de GHI dividida en años para el entrenamiento (2010-2014) y un año para la prueba (2015), con 175.296 y 35.038 datos y muestreos cada 15 minutos. Se

diseñaron, optimizaron y compararon las siguientes redes neuronales: una autorregresiva no lineal (*non-linear autoregressive*, NAR), una prealimentada (*feedforward*, FFNN), una LSTM y una red de estado de eco (*echo state network*, ESN), con lo que mejoró el preprocesamiento para el índice de cielo despejado (Aliberti *et al.*, 2021).

La energía solar fotovoltaica (PV) es utilizada por agricultores en regiones agrícolas con climas áridos, como Hail, Arabia Saudita, para bombear agua de pozos profundos, por lo que su predicción es un factor que afecta la eficiencia y la confiabilidad del diseño de un sistema de bombeo fotovoltaico de agua. Allí se recopilaron 6.205 datos de irradiación horizontal global para el entrenamiento y 1.096 para la prueba en el periodo 2000-2019. Los modelos fueron el de predicción inteligente autorregresivo persistente (*smart persistence forecast autoregressive*, AR), el de ANN, el AR de orden 2, el AR de orden 3, y el de ANN de orden 2, con indicadores de rendimiento MAPE (%) de 7,027, 7,047, 6,739, 6,943, 6,712 y 6,707 (Boubaker *et al.*, 2021).

Otro caso en Java y Bali permite ver cómo la predicción precisa de la radiación solar a corto plazo es esencial en la planificación energética de la red y la política de transición energética del gobierno de Indonesia. Por ello se propuso un modelo LSTM basado en mediciones de radiación solar durante 1,5 años para pronosticar la radiación horaria de un día posterior. Los resultados obtenidos se compararon con los modelos ARIMA y RNN. El modelo LSTM resultó ser el más preciso, con un RMSE de 25,56 W/m<sup>2</sup>, un MAPE de 7,27 % y un R<sup>2</sup> de 0,99; sus valores de predicción fueron buenos en la estación seca, con un MAPE de 13,99 %, en tanto que en la estación lluviosa el MAPE fue de 34,04 % (Nugroho *et al.*, 2024).

Sin embargo, la selección del modelo incorrecto, o la presencia de fluctuaciones aleatorias en las series de radiación solar, podrían provocar un bajo rendimiento predictivo. Por ello, para pronosticar la radiación solar entre las 6:00 y las 18:00 en cuatro ciudades importantes de Brasil, Florianópolis, Fortaleza, Salvador y São Paulo, se propuso un modelo denominado HetDS (*heterogeneous ensemble dynamic selection*), basado en los métodos ARIMA, de regresión de soporte vectorial (*support vector regression*, SVR), de red neuronal de perceptrón multicapa (*multilayer perceptron*, MLP), de máquina de aprendizaje extremo (*extreme learning machine*, ELM), de red de creencia profunda (*deep belief network*, DBN), de RF y de refuerzo de gradiente (*gradient boosting*, GB). El modelo HetDS (3,20) alcanzó una precisión de RMSE igual a 0,0931, MAPE igual a 19,87, y de MAE igual a 0,0643 para la serie de Florianópolis (Santos *et al.*, 2022).

Por otro lado, los altos niveles de radiación solar constituyen un factor importante en la radiación solar ultravioleta (UV), a la cual están expuestos los trabajadores de limpieza en vías públicas del distrito de Los Olivos de la capital de Perú. En ese contexto, se hizo un estudio de tipo cualitativo con enfoque no experimental. Las mediciones se realizaron el 20 de febrero del 2022 desde las 11 hasta las 13 horas utilizando un medidor ultravioleta A (UVA), uno ultravioleta C (UVC), y la combinación de UVA y UVB en un rango de intensidad de hasta 40 mW/cm<sup>2</sup>, obteniéndose valores entre 57,1 y 71 W/cm<sup>2</sup>, que luego se compararon con la normativa internacional (Borda-Luna & Lahura-Albujar, 2022).

Dado que el distrito de San Jerónimo, de la provincia de Andahuaylas, departamento de Apurímac, en la Cordillera de los Andes, se encuentra a una altitud elevada y a una baja latitud, sus niveles de radiación solar son altos y afectan las actividades de los agricultores, los ganaderos y los mineros, lo que se refleja en su baja producción socioeconómica.

Frente a este problema, se propuso la elaboración y comparación de modelos de predicción de la radiación solar global de corto alcance utilizando los datos de una estación meteorológica terrestre y una estación de datos en línea provenientes del GOES (POWER, 2024), con el objeto de proveer a los habitantes del distrito valores confiables de radiación solar que les permitan planificar adecuadamente sus actividades agrícolas y ambientales para mejorar su producción y nivel socioeconómico y en la idea de contribuir al desarrollo de los primeros lineamientos de generación y utilización de la energía fotovoltaica en una red eléctrica de energía renovable no contaminante.

### Modelos de media móvil integrada autorregresiva

El modelo ARIMA está constituido por tres partes: el componente autorregresivo (AR), que hace que la variable de estudio regrese a sus valores anteriores, la media móvil (MA), que representa el error de regresión como una combinación lineal de valores de error en intervalos de tiempo pasado, y el integrado (I), que es el número de veces de diferenciación. ARIMA (p, d, q) es un modelo ARIMA no estacional, donde p es el orden de retardo, d es el orden de diferenciación y q es el orden de la media móvil. Las limitaciones de este modelo dependen de los valores de la variable de estudio y funciona mejor cuando trabaja con gran cantidad de datos (Dimri *et al.*, 2020).

En un modelo de media móvil integrada autorregresiva, el valor futuro de una variable se asume como una función lineal de varias observaciones pasadas y errores aleatorios (Quispe & Huamani, 2024). Es decir, el proceso subyacente que genera la serie temporal tiene la siguiente forma:

$$y_t = \theta_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}, \quad (1)$$

donde  $y_t$  y  $\varepsilon_t$  son el valor real y el error aleatorio en el período  $t$ , respectivamente;  $\phi_i$  ( $i = 1, 2, \dots, p$ ) y  $\theta_j$  ( $j = 0, 1, 2, \dots, q$ ) son parámetros del modelo, y  $p$  y  $q$  a menudo se denominan órdenes del modelo. Los errores aleatorios,  $\varepsilon_t$ , se supone que están distribuidos de forma independiente e idéntica con una media de cero y una varianza constante de  $\sigma^2$  (Zhang, 2003). En una serie de tiempo es posible generar modelos ARIMA a partir de las funciones de autocorrelación y parciales propuestas por Box y Jenkins, que se basan en la coincidencia entre el patrón de autocorrelación empírica y el teórico (Box & Pierce, 1970). Sin embargo, los modelos ARIMA (p,q,d) están limitados a patrones lineales, no estacionales, cuyo rendimiento depende del ruido de la serie (Kontopoulou *et al.*, 2023).

### La radiación solar global

Toda la radiación solar que ingresa a la atmósfera de la Tierra tiene los siguientes componentes: radiación dispersada, absorbida, reflejada al espacio y la que pasa directamente (Figura 1). La RSG es la suma de la radiación solar difusa (Mutombo & Numbi, 2022) y la directa que llega a la superficie (Blal *et al.*, 2020).

Existen varios modelos predictivos de RSG en la superficie horizontal que trabajan con datos meteorológicos como la temperatura, la humedad relativa (Mirzabe *et al.*, 2022) y la duración de la exposición solar (Makade *et al.*, 2021; Reynaldo & Verónica, 2024), los cuales poseen un comportamiento no estacionario, lo que se debe a la variedad de las condiciones atmosféricas. Estos datos son medidos por diferentes estaciones terrestres

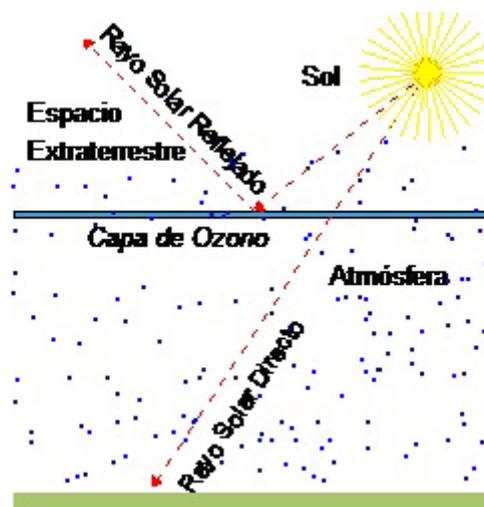


Figura 1. Componentes de la radiación global (Iqbal, 1983)

o espaciales, como el GOES. Los métodos para realizar pronósticos de RSG a corto y mediano plazo son importantes para abordar los problemas de las redes de energía fotovoltaica (Hassan *et al.*, 2022).

### Métricas de precisión

Las métricas de precisión miden las diferencias entre los  $n$  valores de las observaciones reales  $z_t$  y los pronosticados por el modelo de pronóstico  $\hat{z}_t$  (Hwang, 2024).

La raíz del error cuadrático medio (RMSE),

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (z_t - \hat{z}_t)^2}{n}} \quad (2)$$
 (Chandra & Sahu, 2024) se utiliza comúnmente en pronósticos, climatología y análisis de regresión para verificar resultados experimentales (Sahinli, 2020).

El error absoluto medio (MAE),  $\text{MAE} = \frac{1}{n} \sum_{t=1}^n |z_t - \hat{z}_t|$  (Mani *et al.*, 2022) (3)

El error porcentual absoluto medio (MAPE),  $\text{MAPE} = \frac{100}{n} \sum_{t=1}^n \left| \frac{z_t - \hat{z}_t}{z_t} \right|$  (4)

Los valores de rango MAPE: <10 %, 10-20 %, 20-50 %, >50 %, corresponderían a un desempeño de predicción alto, bueno, razonable e impreciso, respectivamente (Quartey-Papafio *et al.*, 2021).

## Materiales y métodos

### Ubicación del área de estudio

La estación meteorológica de la Universidad Nacional José María Arguedas, distrito de San Jerónimo, provincia de Andahuaylas del Departamento de Apurímac en Perú, se ubica en las coordenadas  $-13,6653^\circ$  de latitud y  $-73,3485^\circ$  de longitud, a los 3.039 m de altitud (Figura 2a). Está rodeada de montañas en el valle del río Chumbao y en ella se han realizado observaciones de variables climatológicas desde 2018.

### Descripción experimental

El equipo experimental (Figuras 2b, 2c) esta compuesto por un sensor de luz DAVIS que captura los rayos solares en el rango espectral de 280 a 3.000 nm y está conectado a una computadora. La unidad de medición fue  $\text{W}/\text{m}^2$ ; se hicieron muestreos cada 10 minutos entre las 00:00 y las 24:00. Se obtuvieron 144 muestras por día y los valores de la serie temporal de radiación solar global se procesaron en  $\text{kW}/\text{m}^2\text{d}$ , promediados en periodos de un día. Para el análisis se obtuvieron 1.037 datos, desde el 1 de enero de 2022 hasta el 2 de noviembre de 2024, y se descartaron los valores atípicos dada su inconsistencia.



**Figura 2.** a) Ubicación del distrito de San Jerónimo dentro del departamento de Apurímac. b) y c) Estación meteorológica UNAJMA

### Datos del satélite geoestacionario

El estudio utilizó, asimismo, el conjunto de datos de radiación solar global (RSG) obtenido del satélite GOES (POWER, 2024), que está a una elevación de 3.209,1 m en la estación meteorológica de la NASA. A través de su plataforma se obtuvieron 1.037 datos de alta resolución en línea, lo que constituye un tamaño muestral que permitió encontrar un patrón en la serie para la ubicación del área de estudio.

### Métodos

La investigación se hizo en el laboratorio de experimentación de física 2 de la Universidad Nacional José María Arguedas (UNAJMA) en un ambiente controlado. Se trabajó con los datos experimentales de la estación UNAJMA, y, mediante la técnica de revisión documental y fichas de registros como instrumento de recolección de datos, se creó una base de datos en hojas de EXCEL y lenguaje de programación R Versión (10.0). Se aplicó un enfoque cuantitativo, de nivel descriptivo propositivo y diseño longitudinal, con datos históricos de RSG. Se evaluó y analizó la eficacia de la predicción a corto plazo; el tamaño muestral fue preponderante en el margen de error de las pruebas estadísticas aplicadas. La variable temporal  $d$  (día) y la RSG se establecieron como independiente y dependiente, respectivamente.

Las etapas de estimación de los modelos ARIMA de RSG (Figura 3) garantizaron una representación adecuada de las diferentes condiciones de su variabilidad de la siguiente manera:

- Se determinaron los valores atípicos mediante un diagrama de cajas y un histograma en el lenguaje de programación R, los cuales se filtraron para luego volver a aplicar el diagrama de cajas y el histograma sin dichos valores atípicos.
- Se graficó la serie temporal de ambas estaciones (NASA y UNAJMA).
- Se hicieron pruebas de normalidad y estacionariedad: el gráfico Q-Q normal y las pruebas de Dickey-Fuller, Levene y D'Agostino. Dado que los datos satisfacían las pruebas de normalidad y estacionariedad, el orden de diferenciación de los datos fue  $d=0$ .
- Se obtuvieron las gráficas de ACF y de ACF parcial para determinar los retrasos y los modelos ARIMA.
- Se tomó en cuenta la estimación de máxima verosimilitud, el AIC, el AICc o el criterio de información bayesiano (BIC), para elegir el mejor modelo.

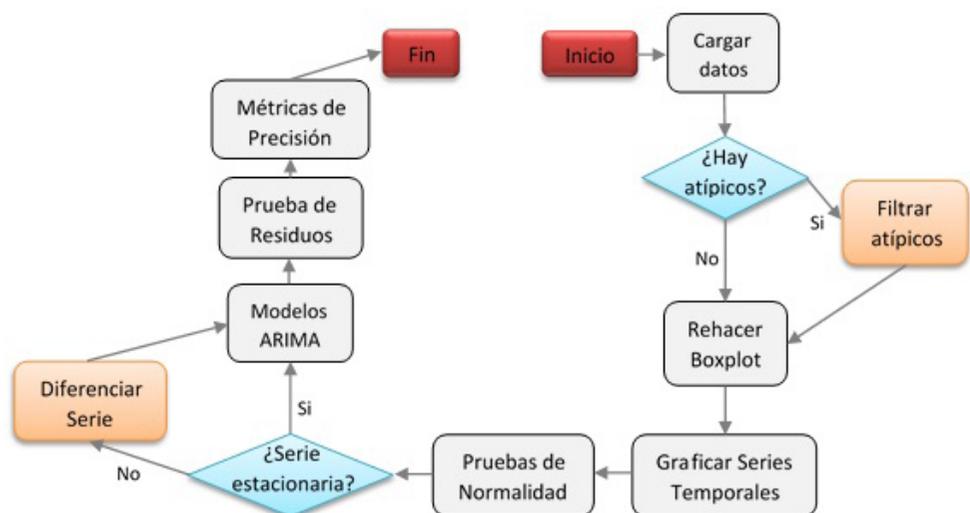


Figura 3. Etapas de estimación de los modelos ARIMA de pronóstico de radiación solar global, 2024

- Se aplicó la prueba de Kwiatkowski-Phillips-Schmidt-Shin (KPSS) para todos los modelos de las series de datos de radiación solar global de las estaciones, con el fin de evaluar la estacionaridad de los residuos generados.
- Se aplicaron las métricas de precisión MAE, MAPE y RMSE.

Se sugiere obtener datos experimentales de radiación solar global de las estaciones meteorológicas del Gobierno Regional de Apurímac (GORE) y el Servicio Nacional de Meteorología e Hidrología (SENAMHI) en diferentes localizaciones de la región de Apurímac para analizar el potencial de pronóstico en la previsión solar.

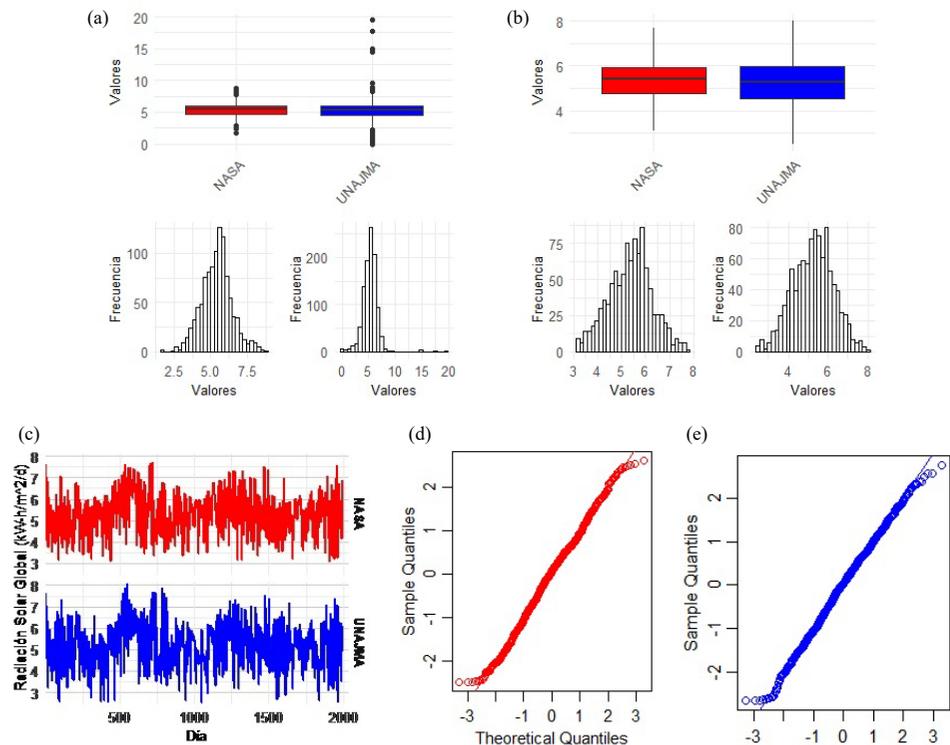
### Resultados

En la **Figura 4a** se observan los diagramas de cajas de las estaciones NASA y UNAJMA para la muestra, incluidos los valores atípicos de RSG y en la **Figura 4b** los diagramas de cajas para la muestra sin valores atípicos de la RSG de la estación:

- NASA, con  $5.361 \text{ Wm}^{-2}\text{d}^{-1}$  de promedio, en un intervalo de  $[3.110; 7.710] \text{ Wm}^{-2}\text{d}^{-1}$ .
- UNAJMA, con  $5.248 \text{ Wm}^{-2}\text{d}^{-1}$  de promedio, en un intervalo de  $[2.521; 8.050] \text{ Wm}^{-2}\text{d}^{-1}$ .

La estación NASA presentó radiación solar global ligeramente más alta, en promedio, que la estación UNAJMA. La **Figura 4c** muestra los cambios que experimentó la radiación solar global a través de los días para el periodo desde el 1 de enero de 2022 hasta el 2 de noviembre de 2024 en las estaciones NASA y UNAJMA, localizadas en el distrito San Jerónimo de la provincia de Andahuaylas.

La **Figura 4e** muestra las gráficas Q-Q normal. En las dos estaciones la serie temporal tuvo una tendencia de distribución lineal, lo que confirmó que los datos satisfacían una distribución normal.



**Figura 4.** Diagrama de cajas para las estaciones NASA y UNAJMA. **a)** Con valores atípicos. **b)** Sin valores atípicos. **c)** Variación de la radiación solar global en función de la variación de los días. Gráfico Q-Q normal para **d)** NASA y **e)** UNAJMA en R

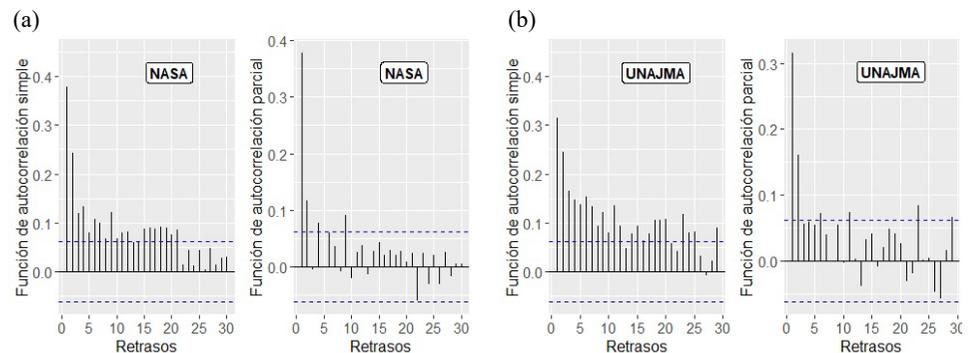
La **Tabla 1** muestra las siguientes pruebas estadísticas en las dos estaciones: Dickey-Fuller, con un valor t superior a los del valor crítico tau en valor absoluto, lo que demostró la inexistencia de una raíz unitaria de comportamiento estacionario. La prueba de Levene, con un  $Pr < 0,05$ , demostró la homogeneidad de varianzas, por lo que no se requirió ninguna diferenciación, y la prueba de D’Agostino, con un  $Pr > 0,05$ , demostró que la serie respondía a una distribución normal.

En la **Figura 5a** se visualizan las siguientes gráficas para la estación NASA:

- La gráfica ACF, con 31 retrasos que escapan del rango de confiabilidad. Se construyeron modelos MA(q) para  $q=1, 2, \dots, 31$ .
- La gráfica de la función de la autocorrelación parcial (PACF), con 30 retrasos que escapaban del rango de confiabilidad. Se construyeron modelos AR(p), para  $p=1, 2, \dots, 30$ .
- Se generaron 930 combinaciones del modelo ARMA (p, q) con una diferenciación de  $d=0$ .

**Tabla 1.** Pruebas estadísticas para la serie temporal en R

Pruebas de estacionariedad y normalidad			
Prueba de Dickey-Fuller			
Estación	Estimación estándar	valor t	Pr(> t )
NASA	-0,017078	-2,949	0,00326
UNAJMA	-0,025400	-3,621	0,000309
Valores críticos de tau1 para estadísticas de prueba			
	1pct	5pct	10pct
	-2,58	-1,95	-1,62
Prueba de asimetría de D’Agostino			
Estación	Sesgo	Z	p
NASA	-0,085628	-1,11216	0,2661
UNAJMA	-0,11363	-1,47102	0,1413
Prueba de Levene			
	Estación	Valor F	Pr(>F)
	NASA	3,322	6,638e-06
	UNAJMA	3,8435	0,0001663



**Figura 5.** ACF y ACF parcial en R para la estación **a)** NASA y **b)** UNAJMA en el distrito de San Jerónimo de la provincia de Andahuaylas

En la **Figura 5b** para la estación UNAJMA se visualiza:

- La gráfica ACF, con 30 retrasos que escapaban del rango de confiabilidad. Se construyeron modelos MA(q), con q=1, 2, ..., 30.
- La gráfica PACF, con 29 retrasos que escapaban del rango de confiabilidad. Se construyeron modelos AR(p), para p=1, 2, ..., 29.
- Se generaron 930 combinaciones ARMA (p, q) con una diferenciación de d=0.

**Estimación de modelos de predicción**

*Modelo de predicción elegido*

En la **Tabla 2** se ven los siguientes datos para las estaciones NASA y UNAJMA:

- Los coeficientes del modelo de predicción ARIMA (p,d,q) de RSG mediante el criterio de máxima verosimilitud del AIC o el BIC.
- Una tendencia de estacionariedad residual de la serie temporal mediante la prueba Kwiatkowski-Phillips-Schmidt-Shin (KPSS) > 0,05.

**Tabla 2.** Parámetros del código auto.arima en R

Modelo ARIMA		
Coeficientes	NASA ARIMA (3,0,2)	UNAJMA ARIMA (5,0,4)
ar1	0,6865	0,1350
s.e.	0,1469	0,7625
ar2	0,5553	0,4882
s.e.	0,1757	0,1145
ar3	-0,2603	0,8159
s.e.	0.0465	0,3079
ar4	-	-0,3877
s.e.	-	0,7108
ar5	-	-0,0777
s.e.	-	0,1995
ma1	-0,3638	0,1067
s.e.	0,1480	0,7627
ma2	0,1382	-0,3477
s.e.	-	0,3286
ma3	-	-0,8394
s.e.	-	0,1866
ma4	-	0,2021
s.e.	-	0,7452
$\sigma^2$	0,6733	0,8927
AIC	2453,13	2728,73
AICc*	2453,24	2729
BIC	2487,49	2782,68
KPSS(p)	0,084093	0,1
MAE	0,290	0,610
MAPE	5,211 %	10,623 %
RMSE	0,384	0,702

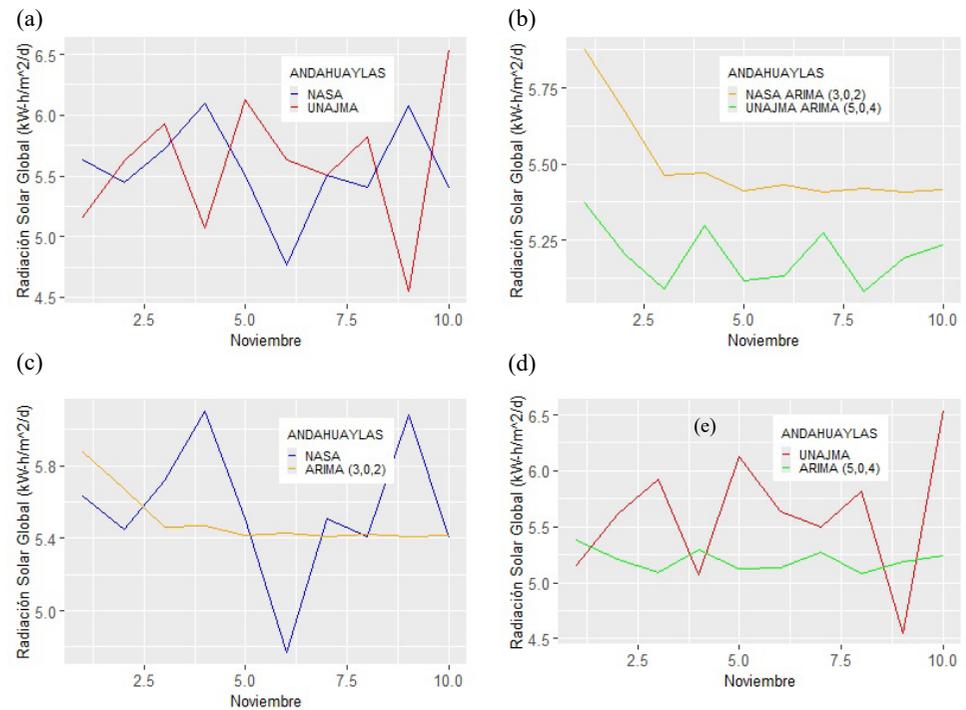
\*AICc: criterio de información de Akaike de segundo orden

Los valores de las métricas de precisión MAE, MAPE y RMSE fueron menores para la estación NASA que para la UNAJMA, lo que evidenció el mejor desempeño de la primera en su modelo de predicción de radiación solar global.

#### Valores de los modelos de predicción

En la **Figura 6** se presenta una comparación de la serie temporal de RSG desde el 3 al 12 de noviembre de 2024 entre:

- La estación NASA y UNAJMA, con similitud entre sus valores.
- El modelo ARIMA(3,0,2) de la estación NASA y el modelo ARIMA(5,0,4) de la estación UNAJMA, en el cual los valores de predicción de NASA fueron ligeramente superiores a los de UNAJMA.
- La estación NASA y su modelo ARIMA(3,0,2), en el cual se aprecia similitud entre sus valores.
- La estación UNAJMA y su modelo ARIMA(5,0,4), en el cual se aprecia similitud entre sus valores.



**Figura 6.** Comparación entre los valores de RSG de: **a)** estación NASA y estación UNAJMA. **b)** Modelos ARIMA. **c)** Estación NASA y su modelo ARIMA (3,0,2). **d)** Estación UNAJMA y su modelo ARIMA (5,0,4) en R, desde el 3 al 12 de noviembre de 2024, distrito de San Jerónimo, provincia de Andahuaylas

## Discusión

San Jerónimo (Andahuaylas) está a más de 2.800 metros sobre el nivel del mar (m s.n.m), lo que le otorga una ventaja en radiación solar frente a lugares cerca del nivel del mar como Kedah (Ismail *et al.*, 2021), Yogyakarta (Nugroho *et al.*, 2024a), Java-Bali (Nugroho *et al.*, 2024b), Fortaleza (Santos *et al.*, 2022) y Jinju (Jaihuni *et al.*, 2020). La altitud influye en la radiación solar, y por eso San Jerónimo y Qinghai-Tíbet (Meng *et al.*, 2023) reciben más radiación que lugares como Fortaleza (Santos *et al.*, 2022) o Kedah (Ismail *et al.*, 2021). Sin embargo, su ubicación tropical andina implica variabilidad climática y nubosidad frecuente, lo que modera la radiación solar global.

En los modelos ARIMA de nuestro estudio se trabajó con datos en línea de la estación meteorológica de la NASA (**POWER**, 2024), como los empleados en los 11 estados de la península de Malasia (**Ismail et al.**, 2021). Por otro lado, también se trabajó con datos medidos en la estación UNAJMA mediante un sensor de luz DAVIS de rango espectral de 280 a 3000 nm. La unidad fue W/m<sup>2</sup> a diferencia de los modelos ARIMA, RF, LSTM empleados en la región de la meseta Qinghai-Tíbet, los cuales recurrieron a un radiómetro de cuatro componentes MR-60 en el Observatorio Atmosférico de Yangbajing y rango espectral de 285 a 3000 nm; la unidad fue W/m<sup>2</sup> (**Meng et al.**, 2023).

Los mejores modelos obtenidos en NASA ARIMA (3,0,2) y UNAJMA ARIMA (5,0,4) en San Jerónimo de Andahuaylas tuvieron un orden de diferenciación de  $d=0$ , al igual que la radiación solar normal directa (DNI) ARIMA (5, 0, 0) en Daejeon, Corea del Sur; sin embargo, su tamaño muestral fue ligeramente inferior (**Kim et al.**, 2022).

La precisión del modelo ARIMA (3,0,2) obtenido para la estación NASA con un MAPE igual a 5,21 % fue mayor que la obtenida con el LSTM MAPE de 7,72 % en Yogyakarta, isla de Java, Indonesia. Sin embargo, la precisión del modelo ARIMA (5,0,4) obtenida para la estación UNAJMA MAPE, de 10,62 %, fue inferior (**Nugroho et al.**, 2024a).

Por otro lado, la precisión del modelo ARIMA (3,0,2) obtenida en la estación NASA con un MAPE de 5,21 %, fue mayor que la obtenida con los modelos AR, ANN, autorregresivo de orden 2, autorregresivo de orden 3, y de red neural artificial de orden 2, con MAPE (%) de 7,027, 7,047, 6,739, 6,943, 6,712 y 6,707 en Hail, Arabia Saudita. Sin embargo, la precisión del modelo ARIMA obtenida en la estación UNAJMA con un MAPE igual a 10,62 % fue inferior (**Boubaker et al.**, 2021).

Para la obtención de los modelos ARIMA, se trabajó con una muestra de 1.037 datos recogidos desde el 1 de enero de 2022 hasta el 2 de noviembre de 2024, que fue inferior en comparación a la que se trabajó en Hail, Arabia Saudita, donde se recopilaban 6.205 datos de irradiación horizontal global para el entrenamiento y 1.096 para la prueba en el periodo 2000-2019. Sin embargo, el modelo ARIMA (3,0,2) obtenido para la estación NASA, demostró mayor precisión, con un MAPE igual a 5,21 %, que los modelos en Hail, con valores de MAPE (%) de 7,027, 7,047, 6,739, 6,943, 6,712, 6,707 (**Boubaker et al.**, 2021).

## Conclusiones

En este estudio se obtuvo un único modelo ARIMA (3,0,2) para la estación meteorológica NASA y un modelo ARIMA (5,0,4) para la estación meteorológica UNAJMA en la ubicación de San Jerónimo, Andahuaylas, Apurímac (Perú). Los dos modelos fueron lineales, ya que se logró modelar las series temporales de la radiación solar global. A partir de los modelos ARIMA generados, se obtuvieron valores de predicción de la RSG de corto plazo en San Jerónimo. Dichos valores fueron confiables debido a la precisión a partir de los MAE, MAPE y RMSE. Los valores de predicción de RSG generados por el modelo ARIMA (3,0,2) de la estación NASA fueron ligeramente más precisos, con un MAE igual a 0,290, un MAPE igual a 5,211 %, y un RMSE de 0,384, que los del modelo ARIMA (5,0,4) de la estación UNAJMA con un MAE de 0,611, un MAPE de 10,624 % y un RMSE de 0,703. Con base en este estudio de predicción de radiación solar global de corto plazo, se pueden replicar los modelos ARIMA en diferentes lugares de la región de Apurímac, de manera que sus autoridades puedan emitir alertas a los habitantes para que adopten medidas de protección de la piel cuando los niveles de radiación solar global sean elevados. Además, los agricultores y ganaderos podrían planificar sus actividades de forma que puedan aumentar su producción y mejorar su nivel socioeconómico. Los métodos y resultados del estudio pueden servir para futuras investigaciones relacionadas con la energía de la red eléctrica y la generación y utilización de la energía fotovoltaica, sobre todo en lugares donde los niveles de radiación solar global son altos.

## Agradecimientos

El autor desea agradecer a la Universidad Nacional José María Arguedas (UNAJMA) por el acceso a la estación meteorológica UNAJMA.

## Conflicto de intereses

El autor declara que no tiene ningún interés financiero en competencia ni relaciones personales conocidas que pudieran influir en el trabajo presentado en este artículo.

## Referencias

- Ahmed, R., Sreeram, V., Mishra, Y., Arif, M. D.** (2020). A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization. In *Renewable and Sustainable Energy Reviews* (Vol. 124). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2020.109792>
- Aliberti, A., Fucini, D., Bottaccioli, L., Macii, E., Acquaviva, A., Patti, E.** (2021). Comparative Analysis of Neural Networks Techniques to Forecast Global Horizontal Irradiance. *IEEE Access*, 9, 122829-122846. <https://doi.org/10.1109/ACCESS.2021.3110167>
- Atique, S., Noreen, S., Roy, V., Bayne, S., MacFie, J.** (2020). Time series forecasting of total daily solar energy generation: A comparative analysis between ARIMA and machine learning techniques. *IEEE Green Technologies Conference, 2020-April*, 175-180. <https://doi.org/10.1109/GreenTech46478.2020.9289796>
- Basmadjian, R., Shaafeyoun, A., Julka, S.** (2021). Day-ahead forecasting of the percentage of renewables based on time-series statistical methods. *Energies*, 14(21), 7443. <https://doi.org/10.3390/en14217443>
- Blal, M., Khelifi, S., Dabou, R., Sahouane, N., Slimani, A., Rouabhia, A., Ziane, A., Neçaibia, A., Bouraiou, A., Tidjar, B.** (2020). A prediction model for estimating global solar radiation and evaluation meteorological effect on solar radiation potential under several weather conditions at the surface of Adrar environment. *Measurement: Journal of the International Measurement Confederation*, 152, 107348. <https://doi.org/10.1016/j.measurement.2019.107348>
- Borda-Luna, B. E. & Lahura-Albujar, N. E.** (2022). Riesgos a exposición de radiación solar a trabajadores de limpieza pública, Lima (Perú). *Yotantsipanko*, 2(2). <https://doi.org/10.54288/yotantsipanko.v2i2.22>
- Boubaker, S., Kamel, S., Kolsi, L., Kahouli, O.** (2021). Forecasting of One-Day-Ahead Global Horizontal Irradiation Using Block-Oriented Models Combined with a Swarm Intelligence Approach. *Natural Resources Research*, 30(1), 1-26. <https://doi.org/10.1007/s11053-020-09761-w>
- Box, G. E. P. & Pierce, D. A.** (1970). Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models. *Journal of the American Statistical Association*, 65 (332), 1509-1526. <https://doi.org/10.2307/2284333>
- Chandra, R. P. & Sahu, B. P.** (2024). Time Series Modeling and Forecasting of Finger Millet Cultivation Area, Production and Productivity in Chhattisgarh, India: The Box Jenkins Methodology. *Asian Research Journal of Agriculture*, 17(4), 18-30. <https://doi.org/10.9734/arja/2024/v17i4494>
- Dimri, T., Ahmad, S., Sharif, M.** (2020). Time series analysis of climate variables using seasonal ARIMA approach. *Journal of Earth System Science*, 129(1), 149. <https://doi.org/10.1007/s12040-020-01408-x>
- Fan, G.-F., Wei, H.-Z., Chen, M.-Y., Hong, W.-C.** (2022). Photovoltaic Power Generation Forecasting Based on the ARIMA-BPNN-SVR Model. *Global Journal of Energy Technology Research Updates*, 9, 18-38. <https://doi.org/10.15377/2409-5818.2022.09.2>
- Fara, L., Diaconu, A., Craciunescu, D., Fara, S.** (2021). Forecasting of Energy Production for Photovoltaic Systems Based on ARIMA and ANN Advanced Models. *International Journal of Photoenergy*, 2021, 6777488. <https://doi.org/10.1155/2021/6777488>
- Garg, S., Agrawal, A., Goyal, S., Verma, K.** (2020, December 16). *Day ahead solar irradiance forecasting using different statistical techniques*. 9th IEEE International Conference on Power Electronics, Drives and Energy Systems, PEDES 2020. <https://doi.org/10.1109/PEDES49360.2020.9379907>
- Guermoui, M., Melgani, F., Gairaa, K., Mekhalfi, M. L.** (2020). A comprehensive review of hybrid models for solar radiation forecasting. *Journal of Cleaner Production*, 258, 120357. <https://doi.org/10.1016/j.jclepro.2020.120357>

- Hassan, M. A., Al-Ghussain, L., Ahmad, A. D., Abubaker, A. M., Khalil, A.** (2022). Aggregated independent forecasters of half-hourly global horizontal irradiance. *Renewable Energy*, *181*, 365-383. <https://doi.org/10.1016/j.renene.2021.09.060>
- Hwang, E.** (2024). Improvement on Forecasting of Propagation of the COVID-19 Pandemic through Combining Oscillations in ARIMA Models. *Forecasting*, *6*(1), 18-35. <https://doi.org/10.3390/forecast6010002>
- Iqbal, M.** (1983). The solar constant and spectral distribution. *An Introduction to Solar Radiation* (pp. 43-58). Academic Press. <https://doi.org/10.1016/B978-0-12-373750-2.50008-2>
- Ismail, M. T., Shah, N. Z. A., Karim, S. A. A.** (2021). Modeling solar radiation in peninsular Malaysia using arima model. *Green Energy and Technology* (pp. 53-71). Springer Science and Business Media Deutschland GmbH. [https://doi.org/10.1007/978-981-15-9140-2\\_3](https://doi.org/10.1007/978-981-15-9140-2_3)
- Jaihuni, M., Basak, J. K., Khan, F., Okyere, F. G., Arulmozhi, E., Bhujel, A., Park, J., Hyun, L. D., Kim, H. T.** (2020). A partially amended hybrid Bi-Gru—ARIMA model (PAHM) for predicting solar irradiance in short and very-short terms. *Energies*, *13*(2), 435. <https://doi.org/10.3390/en13020435>
- Kim, D., Kim, Y., Kim, C., Kim, H., Lee, Y.** (2022). Development of Short-term Solar Irradiance Forecasting Model Using ARIMA and Seasonal ARIMA in Daejeon. *Journal of the Korean Solar Energy Society*, *42*(6), 105-114. <https://doi.org/10.7836/kses.2022.42.6.105>
- Kontopoulou, V. I., Panagopoulos, A. D., Kakkos, I., Matsopoulos, G. K.** (2023). A Review of ARIMA vs. Machine Learning Approaches for Time Series Forecasting in Data Driven Networks. *Future Internet*, *15* (8), 255. <https://doi.org/10.3390/fi15080255>
- Kurniadi, A. P., Aimon, H., Salim, Z., Ragimun, Sonjaya, A., Setiawan, S., Siagian, V., Nasution, L. Z., Nurhidajat, R., Mutaqin, Sabtohadhi, J.** (2024). Analysis of Existing and Forecasting for Coal and Solar Energy Consumption on Climate Change in Asia Pacific: New Evidence for Sustainable Development Goals. *International Journal of Energy Economics and Policy*, *14*(4), 352-359. <https://doi.org/10.32479/ijeeep.16187>
- Liu, Z. F., Luo, S. F., Tseng, M. L., Liu, H. M., Li, L., Hashan Md Mashud, A.** (2021). Short-term photovoltaic power prediction on modal reconstruction: A novel hybrid model approach. *Sustainable Energy Technologies and Assessments*, *45*, 101048. <https://doi.org/10.1016/j.seta.2021.101048>
- Makade, R. G., Chakrabarti, S., Jamil, B.** (2021). Development of global solar radiation models: A comprehensive review and statistical analysis for Indian regions. *Journal of Cleaner Production*, *293*, 126208. <https://doi.org/10.1016/j.jclepro.2021.126208>
- Mani, G., Joshi Kumar, V., Stonier, A. A.** (2022). Prediction and forecasting of air quality index in Chennai using regression and ARIMA time series models. *Journal of Engineering Research (Kuwait)*, *10*(2 A), 179-194. <https://doi.org/10.36909/jer.10253>
- Mellit, A., Pavan, A. M., Ogliaeri, E., Leva, S., Lughi, V.** (2020). Advanced methods for photovoltaic output power forecasting: A review. *Applied Sciences (Switzerland)*, *10*(2), 487. <https://doi.org/10.3390/app10020487>
- Melquíades, T. F., Diniz, F. F., Nunes, A. M. M., Martins, J. M., Santos Júnior, E. P., Coelho Junior, L. M.** (2022). Previsão da radiação solar global em João Pessoa, Paraíba, Brasil: Uma aplicação dos modelos da família ARIMA. *Concilium*, *22*(3), 213-224. <https://doi.org/10.53660/clm-197-214>
- Meng, H., Wu, L., Li, H., Song, Y.** (2023). Construction and Research of Ultra-Short Term Prediction Model of Solar Short Wave Irradiance Suitable for Qinghai–Tibet Plateau. *Atmosphere*, *14*(7), 1150. <https://doi.org/10.3390/atmos14071150>
- Mirzabe, A. H., Hajjahmad, A., Keyhani, A., Mirzaei, N.** (2022). Approximation of daily solar radiation: A comprehensive review on employing of regression models. *Renewable Energy Focus*, *41*, 143-159. <https://doi.org/10.1016/j.ref.2022.02.003>
- Mohamed, M., Mahmood, F. E., Abd, M. A., Chandra, A., Singh, B.** (2022). Dynamic Forecasting of Solar Energy Microgrid Systems Using Feature Engineering. *IEEE Transactions on Industry Applications*, *58*(6), 7857-7869. <https://doi.org/10.1109/TIA.2022.3199182>
- Mughal, S. N., Sood, Y. R., & Jarial, R. K.** (2022). Design and optimization of photovoltaic system with a week ahead power forecast using autoregressive artificial neural networks. *Materials Today: Proceedings*, *52*, 834-841. <https://doi.org/10.1016/j.matpr.2021.10.223>
- Mutombo, N. M. A. & Numbi, B. P.** (2022). The Development of ARIMA Models for the Clear Sky Beam and Diffuse Optical Depths for HVAC Systems Design Using RTSM: A Case Study of the Umlazi Township Area, South Africa. *Sustainability (Switzerland)*, *14*(6), 3662. <https://doi.org/10.3390/su14063662>

- Nugroho, M. V., Mardiansah, F., Pratama, T. O., Fikriyadi, Z. A., Dianti, D. V., Prastawa, A.** (2024a). A Comparative Study of the Effect of Weather Conditions on Solar Irradiance Forecasting Using Various Methods in Yogyakarta, Indonesia. *Journal of Physics: Conference Series*, 2828(1), 012028. <https://doi.org/10.1088/1742-6596/2828/1/012028>
- Nugroho, M. V., Prastawa, A., Mardiansah, F., Rezavidi, A., Fudholi, A., Odejobi, O. A., Alawode, K. O., Lawal, M. O.** (2024b). Efficient method for forecasting solar irradiance - a review. *Fudma Journal of Sciences*, 8(6), 285-298. <https://doi.org/10.33003/fjs-2024-0806-2786>
- Palaloi, S.** (2024). A stacked LSTM model for day-ahead solar irradiance forecasting under tropical seasons in Java-Bali. *International Journal of Power Electronics and Drive Systems*, 15(3), 1878-1891. <https://doi.org/10.11591/ijped.v15.i3.pp1878-1891>
- POWER.** (2024). *POWER Data Access Viewer*. NASA Langley Research Center. <https://power.larc.nasa.gov/data-access-viewer/>
- Quispe, R. & Huamani, R.** (2024). Autoregressive Models for Forecasting Wind Speed in the Rural Area of Socabaya, Peru, 2022. *Revista Politécnica*, 54(1), 7-14. <https://doi.org/10.33333/rp.vol54n1.01>
- Quartey-Papafio, T. K., Javed, S. A., Liu, S.** (2021). Forecasting cocoa production of six major producers through ARIMA and grey models. *Grey Systems*, 11(3), 434-462. <https://doi.org/10.1108/GS-04-2020-0050>
- Reynaldo, Q. & Verónica, J.** (2024). Use of Unrestricted Minimization of a Spectral Function to Estimate the Visible Zone in Matlab 19.0. *Revista Politécnica*, 54(1), 87-96. <https://doi.org/10.33333/rp.vol54n1.09>
- Şahinli, M. A.** (2020). Potato Price Forecasting with Holt-Winters and ARIMA Methods: A Case Study. *American Journal of Potato Research*, 97(4), 336-346. <https://doi.org/10.1007/s12230-020-09788-y>
- Salman, D., Direkoglu, C., Kusaf, M., Fahrioglu, M.** (2024). Hybrid deep learning models for time series forecasting of solar power. *Neural Computing and Applications*, 36(16), 9095–9112. <https://doi.org/10.1007/s00521-024-09558-5>
- Santos, D. S. de O., de Mattos Neto, P. S. G., de Oliveira, J. F. L., Siqueira, H. V., Barchi, T. M., Lima, A. R., Madeiro, F., Dantas, D. A. P., Converti, A., Pereira, A. C., de Melo Filho, J. B., Marinho, M. H. N.** (2022). Solar Irradiance Forecasting Using Dynamic Ensemble Selection. *Applied Sciences (Switzerland)*, 12(7), 3510. <https://doi.org/10.3390/app12073510>
- Saxena, N., Kumar, R., Rao, Y. K. S. S., Mondloe, D. S., Dhapekar, N. K., Sharma, A., Yadav, A. S.** (2024). Hybrid KNN-SVM machine learning approach for solar power forecasting. *Environmental Challenges*, 14, 100838. <https://doi.org/10.1016/j.envc.2024.100838>
- Sedai, A., Dhakal, R., Gautam, S., Dhamala, A., Bilbao, A., Wang, Q., Wightington, A., Pol, S.** (2023). Performance Analysis of Statistical, Machine Learning and Deep Learning Models in Long-Term Forecasting of Solar Power Production. *Forecasting*, 5(1), 256–284. <https://doi.org/10.3390/forecast5010014>
- Tarmanini, C., Sarma, N., Gezegin, C., & Ozgonenel, O.** (2023). Short term load forecasting based on ARIMA and ANN approaches. *Energy Reports*, 9, 550-557. <https://doi.org/10.1016/j.egy.2023.01.060>
- Zhang, G. P.** (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)