

Bootstrap para calcular intervalos puntuales de predicción mediante modelos de redes neuronales de radiación UV en el periodo 2024–2025 en Riobamba, Ecuador.

Bootstrap for calculating point prediction intervals using neural network models of UV radiation in the 2024–2025 period in Riobamba, Ecuador.

Mayra Paulina Mallitasig Sinchiguano

Universidad Nacional de Chimborazo

mayra.mallitasig@unach.edu.ec

<https://orcid.org/0009-0002-3175-0114>

Ecuador

Manuel Antonio Meneses Freire

Universidad Nacional de Chimborazo

ameneses@unach.edu.ec

<https://orcid.org/0000-0001-8182-3153>

Ecuador

Formato de citación APA

Mallitasig, M. & Meneses, M. (2026). Bootstrap para calcular intervalos puntuales de predicción mediante modelos de redes neuronales de radiación UV en el periodo 2024–2025 en Riobamba, Ecuador. Revista REG, Vol. 5 (Nº. 3), p. 4623 – 4641.

CONOCIMIENTO SIN FRONTERAS

Vol. 5 (Nº. 3). julio – septiembre 2026.

ISSN: 3073-1259

Fecha de recepción: 15-08-2026

Fecha de aceptación :18-08-2026

Fecha de publicación:30-09-2026



RESUMEN

La predicción precisa de la radiación UV es un factor crítico para el dimensionamiento de proyectos energéticos, especialmente en zonas de altitud como Riobamba, donde la irradiancia supera frecuentemente los 48 W/m^2 y presenta un comportamiento altamente no lineal. La presente investigación tuvo como objetivo ajustar y fundamentar teóricamente un modelo de Redes Neuronales Autorregresivas (NNAR) para el pronóstico de la radiación UV. Metodológicamente, se procesaron 17 976 registros horarios provenientes de la estación meteorológica de la Universidad Nacional de Chimborazo, correspondientes al periodo entre febrero de 2024 y febrero de 2026. Los datos se estructuraron en 25 series temporales mensuales para aislar la tendencia estacional del ruido estocástico. Mediante una validación retrospectiva (Hold-out), el algoritmo se entrenó con los primeros 20 meses y se contrastó contra los 5 meses finales. El modelo demostró un desempeño predictivo sobresaliente, alcanzando una Raíz del Error Cuadrático Medio (RMSE) de 2.53 W/m^2 y un Error Porcentual Absoluto Medio (MAPE) del 14.53 %, evaluado estrictamente en horas de incidencia diurna útil ($> 3 \text{ W/m}^2$). Como aporte para la gestión del riesgo, se implementó la metodología Bootstrap con 5000 simulaciones, comprobando empíricamente que los datos reales fluctúan con exactitud dentro de los intervalos de confianza del 80 % y 95 %. Se concluye que la arquitectura NNAR es matemáticamente idónea y robusta para procesar la complejidad de la radiación UV, dotando al entorno local de una herramienta computacional validada para la toma de decisiones en ingeniería energética.

PALABRAS CLAVE: Radiación UV, Redes Neuronales Autorregresivas, NNAR, series temporales, Bootstrap, predicción.

ABSTRACT

The precise prediction of UV radiation is a critical factor for the sizing of energy projects, especially in high-altitude areas such as Riobamba, where irradiance frequently exceeds 48 W/m^2 and exhibits highly nonlinear behavior. The present research aimed to adjust and theoretically establish a Neural Network Autoregression (NNAR) model for forecasting UV radiation. Methodologically, 17,976 hourly records from the meteorological station of the Universidad Nacional de Chimborazo, corresponding to the period between February 2024 and February 2026, were processed. The data were structured into 25 monthly time series to isolate the seasonal trend from stochastic noise. Using retrospective validation (Hold-out), the algorithm was trained on the first 20 months and tested against the final 5 months. The model demonstrated outstanding predictive performance, achieving a Root Mean Square Error (RMSE) of 2.53 W/m^2 and a Mean Absolute Percentage Error (MAPE) of 14.53 %, strictly evaluated during useful daytime incidence hours ($> 3 \text{ W/m}^2$). As a contribution to risk management, the Bootstrap methodology was implemented with 5000 simulations, empirically verifying that actual data fluctuate accurately within the 80 % and 95 % confidence intervals. It is concluded that the NNAR architecture is mathematically suitable and robust for processing the complexity of UV radiation, providing the local environment with a validated computational tool for decision-making in energy engineering.

KEYWORDS: UV radiation, Neural Network Autoregression, NNAR, time series, Bootstrap, forecasting.

INTRODUCCIÓN

La radiación solar global es la principal fuente de energía que impulsa los procesos atmosféricos y sostiene la vida en la Tierra. Su cuantificación y monitoreo continuo son indispensables, ya que constituye la variable climatológica de mayor impacto para el diseño, dimensionamiento y rentabilidad de los sistemas de generación fotovoltaica. Además, su estudio es vital para aplicaciones en agricultura, meteorología y arquitectura bioclimática, donde la exposición a la irradiancia define el equilibrio de los ecosistemas y la eficiencia energética de las infraestructuras (Neale et al, 2023).

Esta variabilidad climática se vuelve sumamente crítica y compleja de predecir en zonas ecuatoriales de alta montaña. En el caso específico de ciudades andinas como Riobamba, confluyen dos factores geográficos determinantes que potencian la magnitud del recurso solar: la latitud y la elevación. Al estar en la franja ecuatorial, los rayos del sol inciden de manera casi perpendicular, atravesando una menor cantidad de masa atmosférica para llegar al suelo. A esto se suma la gran altitud de la ciudad. Físicamente, la menor densidad del aire en estas zonas de elevación reduce la dispersión de la luz, provocando que los niveles de irradiancia global alcancen y superen frecuentemente categorías extremas (por encima de los 800 W/m^2). Estas características topográficas particulares convierten a la predicción precisa de esta variable en un verdadero reto científico y técnico (Zúñiga & Meneses, 2024).


Frente a esta complejidad, las Redes Neuronales Artificiales (RNA) surgen como uno de los modelos de pronóstico más precisos y ampliamente utilizados. Las RNA son atractivas e interesantes para tareas de predicción (Pedrycz & Chen, 2020, 2020) debido a que constituyen una adaptación única de la base de datos, generalizando inferencias correctamente incluso en presencia de ruido. A diferencia de los enfoques tradicionales como la metodología de Box-Jenkins y ARIMA, que asumen que la serie temporal se corresponde mediante un proceso lineal, las RNA son aproximadores funcionales universales y no lineales gracias a sus funciones de activación (Kelleher, 2019).

Para la implementación computacional de esta arquitectura, la presente investigación recurre al entorno de programación estadística R, utilizando específicamente la librería forecast desarrollada por Hyndman y Khandakar. Dentro de este paquete, se emplea la función matemática nnetar(), la cual ajusta redes neuronales de una sola capa oculta con arquitectura feed-forward para series temporales univariantes con entradas rezagadas (NNAR(p, k)), donde p representa los rezagos de la serie de tiempo utilizados como entradas y k es el número de nodos en la capa oculta (Yin et al, 2024).

Las redes neuronales artificiales son métodos de predicción que se basan en modelos matemáticos sencillos del cerebro. Permiten modelar relaciones no lineales complejas (variables meteorológicas) entre la variable de respuesta y sus predictores.

Una red neuronal puede concebirse como una red de «neuronas» organizadas en capas. Los predictores (o entradas) forman la capa inferior (20 primeras series temporales mensuales de radiación solar), y los pronósticos (o salidas) forman la capa superior (5 series temporales siguientes a predecir). También puede haber capas intermedias que contengan «neuronas ocultas» (Saadati & Barutcu, 2025).

Figura 1. Red neuronal con cuatro entradas y una salida.




Fuente: Rob J & George, 2018

Las redes más sencillas no contienen capas ocultas y equivalen a regresiones lineales. La Figura 1 muestra la versión en red neuronal de una regresión lineal con cuatro predictores. Los coeficientes asociados a estos predictores se denominan «pesos». Los pronósticos se obtienen mediante una combinación lineal de las entradas. Las ponderaciones se seleccionan en el marco de la red neuronal mediante un «algoritmo de aprendizaje» que minimiza una «función de coste» como el MSE. Por supuesto, en este sencillo ejemplo podemos utilizar la regresión lineal, que es un método mucho más eficaz para entrenar el modelo (Hyndman & Athanasopoulos, 2018).

Una vez que añadimos una capa intermedia con neuronas ocultas, la red neuronal se vuelve no lineal. Un ejemplo sencillo se muestra en la Figura 2.

Figura 2. Una red neuronal con cuatro entradas y una capa oculta con tres neuronas.



Fuente: Rob J & George, 2018

Esto se conoce como red multicapa de alimentación hacia adelante (o multicapa feed-forward o perceptron multicapa), en la que cada capa de nodos recibe entradas de las capas anteriores. Las salidas de los nodos de una capa son entradas para la capa siguiente. Las entradas de cada nodo se agregan mediante una combinación lineal ponderada (Batres-Estrada, 2015). A continuación, el resultado se modifica mediante una función no lineal antes de ser propagado. Por ejemplo, las entradas de cada neurona oculta de la Figura 2 se combinan linealmente para obtener:

$$Z_j = b_j + \sum_{i=1}^4 w_{i,j}x_i$$

En la capa oculta, esto se modifica utilizando una función no lineal como una sigmoide:

$$s(z) = \frac{1}{1 + e^{-z}}$$

para dar entrada a la siguiente capa. Esto tiende a reducir el efecto de los valores extremos de entrada, por lo que la red es algo robusta a los valores atípicos.

Los parámetros b_1, b_2, b_3 y $w_{1,1}, \dots, w_{4,3}$ se «aprenden» (o estiman) a partir de los datos. Los valores de los pesos suelen restringirse para evitar que sean demasiado grandes. El parámetro que restringe las ponderaciones se conoce como «parámetro de decaimiento» y suele ser igual a 0.1.

Al principio, los pesos toman valores aleatorios que se actualizan con los datos observados. Por tanto, hay un elemento de aleatoriedad en las predicciones producidas por una red neuronal. Por eso, la red suele entrenarse varias veces utilizando diferentes puntos de partida aleatorios, y los resultados se promedian. El número de capas ocultas y el número de nodos de cada capa oculta deben especificarse de antemano (Gamboa, 2017).

Con datos de series temporales, pueden utilizarse valores retardados de las series temporales como entradas a una red neuronal, del mismo modo que utilizamos valores retardados en un modelo de autorregresión lineal. A esto lo llamamos modelo de autorregresión de red neuronal o NNAR.

Hay que considerar redes feed-forward con una capa oculta, y utilizamos la notación NNAR(p,k) para indicar que hay p entradas retardadas y k nodos en la capa oculta. Por ejemplo, un modelo NNAR(9,5) es una red neuronal con las últimas nueve observaciones ($y_{t-1}, y_{t-2}, \dots, y_{t-9}$) utilizadas como entradas para pronosticar la salida y_t , y con cinco neuronas en la capa oculta. Un modelo NNAR(p,0) es equivalente a un modelo ARIMA(p,0,0), pero sin las restricciones en los parámetros para garantizar la estacionariedad (Hyndman & Athanasopoulos, 2018).

Con datos estacionales, es útil añadir también los últimos valores observados de la misma estación como entradas. Por ejemplo, un modelo NNAR(3,1,2)₁₂ tiene entradas y_{t-1} , y_{t-2} , y_{t-3} y y_{t-12} , y dos neuronas en la capa oculta. De forma más general, un modelo NNAR(p,P,k)_m tiene entradas ($y_{t-1}, y_{t-2}, \dots, y_{t-p}, y_{t-m}, y_{t-2m}, \dots, y_{t-Pm}$) y k neuronas en la capa oculta. Un modelo NNAR(p,P,0)_m es equivalente a un modelo ARIMA(p,0,0)(P,0,0)_m pero sin las restricciones en los parámetros que aseguran la estacionariedad.

La función NNETAR() ajusta un modelo NNAR(p,P,k)_m. Si no se especifican los valores de p y P, se seleccionan automáticamente. Para series temporales no estacionales, el valor predeterminado es el número óptimo de retardos (según el AIC) para un modelo lineal AR(p). Para series temporales estacionales, los valores por defecto son P=1 y p se elige a partir del modelo lineal óptimo ajustado a los datos ajustados estacionalmente. Si no se especifica k, se establece $k = \frac{(p+P+1)}{2}$ (redondeado al número entero más próximo).

A la hora de hacer predicciones, la red se aplica de forma iterativa. Para las predicciones a un paso, se utilizan los datos históricos disponibles. Para la predicción a dos pasos, se utiliza la predicción a un paso y los datos históricos. Este proceso continúa hasta que se han calculado todas las predicciones necesarias (Hyndman & Athanasopoulos., 2018).

MÉTODOS MATERIALES

La investigación empleó un enfoque cuantitativo, fundamentado en la recopilación empírica y el modelado computacional. El estudio se llevó a cabo utilizando datos registrados en la estación meteorológica de la Facultad de Ingeniería de la Universidad Nacional de Chimborazo, ubicada en la ciudad de Riobamba.

El periodo de estudio abarcó 25 meses consecutivos, iniciando en febrero de 2024 y culminando en febrero de 2026. La variable principal analizada fue la radiación UV horaria expresada en vatios por metro cuadrado (W/m^2). Para estimar esta variable, los datos brutos de la radiación solar global se multiplicaron por un factor de conversión de 0.06 el cual representa la proporción aproximada de luz ultravioleta ajustada a las condiciones atmosféricas de gran altitud de la ciudad, se consideran además estudios que han identificado relaciones lineales entre ambas variables y han reportado que la fracción UV respecto de la radiación solar global puede variar entre aproximadamente 2 % y 9,4 %, dependiendo de las condiciones atmosféricas y del estado del cielo (Escobedo et al., 2009). Asimismo, en estaciones del altiplano tibetano ubicadas a más de 3000 metros de altitud, se registraron proporciones UV/global de hasta 6,8 % en condiciones nubladas (Hu et al., 2008). En consecuencia, el valor de 0,06 se utilizó como una aproximación empírica compatible con los rangos documentados en la literatura y no como una constante física universal. Los datos fueron sometidos a un proceso de depuración que incluyó la limpieza de valores atípicos y la interpolación de datos faltantes. Posteriormente, se calculó la media de radiación UV por horas para cada uno de los meses, generando perfiles representativos de 24 horas mensuales. Estos perfiles se concatenaron para construir la serie de tiempo analítica ininterrumpida de 600 observaciones (24 horas $\times$ 25 meses).

Para el modelado computacional en R se usaron técnicas de aprendizaje automático, se implementó una validación retrospectiva (Hold-out). Se segmentó la serie en un conjunto de entrenamiento, conformado por los primeros 20 meses (480 datos) para alimentar la función *nnetar()* del paquete *forecast*, y un conjunto de prueba, reservando los últimos 5 meses (120 datos) de forma oculta. Con el fin de gestionar el riesgo predictivo y dotar al modelo de márgenes de error, se implementó adicionalmente la metodología Bootstrap. A través de la simulación iterativa de 5000 trayectorias basadas en el remuestreo de los residuos de entrenamiento, se estimaron intervalos puntuales de predicción con niveles de confianza probabilísticos del 80 % y 95 %.

Para evaluar la función y cuantificar el desempeño del modelo sobre el conjunto de prueba, se aplicaron dos métricas matemáticas estándar extraídas del entorno estadístico R. En primer lugar, se calculó la Raíz del Error Cuadrático Medio (RMSE), la cual evalúa la magnitud absoluta del error de predicción penalizando las desviaciones más grandes:

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

En segundo lugar, se determinó el Error Porcentual Absoluto Medio (MAPE) para medir la desviación relativa. Con el fin de evitar indeterminaciones matemáticas generadas por las horas nocturnas (donde la radiación es nula), la fórmula fue calculada estrictamente sobre la ventana de incidencia diurna útil (radiación real > 3 W/m²):

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{y_i - \hat{y}_i}{y_i} \quad (2)$$


Donde n representa la cantidad de datos en el periodo de evaluación, y_i es el valor real observado y $\hat{y}_i$ corresponde a la predicción puntual arrojada por la red NNAR.

ANÁLISIS DE RESULTADOS

Evolución exploratoria de la radiación UV horaria

El análisis inició con la inspección de la base de datos, la cual abarca 17 976 registros capturados hora tras hora entre febrero de 2024 y febrero de 2026. Como se evidencia en la Figura 3, la visualización de la serie temporal original revela una extremada densidad de datos que refleja la alta volatilidad y los marcados ciclos día-noche, con picos sostenidos que superan los 48 W/m².

Figura 3. Radiación UV Horaria Total (Feb 2024 - Feb 2026).




Fuente: Autores (2026).

Comportamiento continuo de perfiles medios en 2024

Para reducir la información, se calculó el promedio de radiación UV para cada una de las 24 horas del día agrupadas por mes. Durante el año 2024 se dispuso de 11 meses de registro continuo. La concatenación de estos promedios, graficada en la Figura 4, generó un vector temporal de 264 horas (24 horas/mes × 11 meses). Este procedimiento permitió clarificar las fluctuaciones en la amplitud máxima de la radiación a medida que avanzaban las épocas del año, estabilizando la señal para el análisis posterior.

Figura 4. Curvas medias de radiación UV mensuales continuas (Feb-Dic 2024).




Fuente: Autores (2026).

Dispersión horaria superpuesta de la radiación UV en 2024

Al proyectar simultáneamente las 11 curvas medias correspondientes al año 2024 en un único plano coordenado de 0 a 23 horas (Figura 5). Esta matriz de superposición evidencia que la dispersión más significativa ocurre concentrada dentro de una ventana temporal acotada, específicamente entre las 10:00 y las 14:00 horas.

Figura 5. Perfil horario promedio superpuesto correspondiente a 2024.




Fuente: Autores (2026).

Comportamiento continuo de perfiles medios en 2025

El 2025 es el único año en su totalidad dentro de la muestra. Se generó 12 series temporales a lo largo de 288 horas (24 horas/mes × 12 meses). La Figura 6 despliega este periodo mostrando el patrón de campanas de Gauss estacional completo, evidenciando matemáticamente las caídas naturales de irradiancia UV media.

Figura 6. Curvas medias de radiación UV mensuales continuas (Ene-Dic 2025).




Fuente: Autores (2026).

Dispersión horaria superpuesta de la radiación UV en 2025

La Figura 7 ilustra el colapso de los 12 meses de 2025 sobre el eje de las 24 horas. Este análisis gráfico consolida la distribución diurna definitiva de todo un año, permitiendo observar que, independientemente del mes evaluado, la energía radiante es matemáticamente nula (0 W/m^2) entre las 19:00 horas y las 05:00 horas del día siguiente.

Figura 7. Perfil horario promedio superpuesto correspondiente a 2025.




Fuente: Autores (2026).

Comportamiento continuo de perfiles medios en 2026

El tramo final del análisis exploratorio abarcó únicamente las mediciones registradas en enero y febrero del año 2026. Como ilustra la Figura 8, se obtuvo un perfil corto de 48 horas continuas. La relevancia de este segmento radica en que va a servir para evaluar la predicción de la red neuronal con series temporales reales.

Figura 8. Curvas medias de radiación UV mensuales continuas (Ene-Feb 2026).




Fuente: Autores (2026).

Dispersión horaria superpuesta de la radiación UV en 2026

Al superponer los dos meses correspondientes a 2026 (Figura 9), se observa una alta similitud y escasa dispersión vertical entre ambas curvas, denotando una estabilidad atmosférica relativa durante los meses de arranque de año en la ciudad de Riobamba.

Figura 9. Perfil horario promedio superpuesto correspondiente a 2026.




Fuente: Autores (2026).

Estructuración de la serie temporal concatenada (25 meses)

Para el entrenamiento del modelo de aprendizaje automático, se unificaron cronológicamente todas las series temporales mensuales de los tres años. Como se muestra en la Figura 10, el resultado es una única matriz unidimensional estructurada con 600 puntos exactos (25 meses $\times$ 24 horas/mes).

Figura 10. Curvas medias de radiación UV concatenadas de 25 Meses (Febrero 2024 – Febrero 2026)




Fuente: Autores (2026).

Dinámica de la red NNAR: Entrenamiento y proyección general

Se procedió a la partición de los datos bajo la técnica de Hold-out. A través de la librería *forecast*, la función *nnetar()* se entrenó el modelo usando las primeras 20 series temporales mensuales. Una vez que la arquitectura interna optimizó sus pesos, proyectó autónomamente un horizonte futuro de 120 horas (equivalente a los 5 meses restantes). La Figura 11 demuestra que el algoritmo (línea azul punteada) infirió correctamente la fase y el tamaño de los picos esperados sin degenerar a la media, manteniendo el patrón periódico característico de la radiación UV.

Figura 11. Modelo NNAR: Entrenamiento (20 Meses) y Predicción de 5 Meses (Octubre 2025 - Febrero 2026)




Fuente: Autores (2026).

Evaluación de la predicción del modelo de red neuronal NNAR

Para dictaminar la validez científica del modelo, se contrastaron los 120 datos de predicción contra las 120 observaciones reales que se habían ocultado intencionalmente al algoritmo. La Figura 12 muestra un solapamiento muy preciso entre la predicción del modelo de los últimos 5 meses con las series temporales reales de los datos. Para respaldar esta afirmación gráfica, se evaluaron numéricamente las diferencias (Tabla 1), obteniendo un RMSE de 2.5323 W/m^2 , y un MAPE de 14.5312 % aplicable a las franjas horarias de aprovechamiento energético útil ($> 3 \text{ W/m}^2$).

Figura 12. Predicción NNAR vs Datos Reales de los últimos 5 meses (Octubre 2025 - Febrero 2026)



Fuente: Autores (2026).

Tabla 1.

Resultados de la validación predictiva de los últimos 5 meses (Octubre 2025 - Febrero 2026)

Métrica de Precisión	Valor de Validación
Raíz del Error Cuadrático Medio (RMSE)	2.5323 W/m^2
Error Porcentual Absoluto Medio (MAPE)	14.5312 %


Nota. Fuente: Autores (2026).

Estimación de intervalos puntuales de predicción mediante metodología Bootstrap

Para generar intervalos predictivos, se implementó la metodología Bootstrap mediante 5000 simulaciones de los residuos de entrenamiento. Computacionalmente, este proceso se ejecutó habilitando el argumento lógico $PI = TRUE$ dentro de la función `forecast()` en R, el cual calcula por defecto los niveles de confianza probabilísticos estándar del 80 % y 95 %. La Figura 13 muestra las franjas de confianza resultantes para los 5 meses del horizonte de predicción, abarcando desde octubre de 2025 hasta febrero de 2026. El intervalo al 80 % se representa en color gris claro y el del 95 % en gris oscuro. Se evidencia gráficamente que la serie temporal real (línea roja) fluctúa casi en su

totalidad dentro del estricto margen interno del 80 %, demostrando empíricamente que el algoritmo NNAR acota con alta precisión la incertidumbre de la radiación UV.

Figura 13. Intervalos puntuales de predicción Bootstrap para la serie de radiación UV (Octubre 2025 - Febrero 2026).



Fuente: Autores (2026).

DISCUSIÓN

Los hallazgos de esta investigación sustentan el marco teórico planteado, las Redes Neuronales Autorregresivas (NNAR) poseen una capacidad robusta para modelar la no linealidad de la radiación UV. La evaluación del desempeño mediante validación permitió cuantificar el error predictivo en un RMSE de 2.53 W/m^2 . Este error predictivo es bajo en relación con la escala de la variable al considerar que, en la ciudad de Riobamba y a causa de los factores de latitud y elevación, la magnitud real de la irradiancia supera frecuentemente el umbral de los 48 W/m^2 .

Adicionalmente, la integración de la metodología Bootstrap para la generación de intervalos de predicción complementa las limitaciones de las redes neuronales: la carencia de un modelo estocástico paramétrico formal para definir márgenes de error. El hecho de que la irradiancia real observada durante el conjunto de prueba se mantenga fielmente contenida dentro de las franjas de confianza del 80 % (gris claro) y 95 % (gris oscuro) confirma que la red NNAR no solo estima con precisión la tendencia media, sino que acota el rango de incertidumbre sin requerir la asunción restrictiva de normalidad en los residuos.

El MAPE obtenido del 14.53 % confirma que el modelo posee un excelente desempeño predictivo. Para el cálculo preciso de este indicador, fue necesario filtrar la serie y evaluar únicamente los registros con una radiación superior a 3 W/m^2 . Este umbral se aplicó por dos razones

fundamentales: matemáticamente, evita las indeterminaciones y distorsiones porcentuales extremas que ocurren al dividir por valores cercanos o iguales a cero durante las noches y transiciones (amaneceres y atardeceres); y, desde el punto de vista práctico, garantiza que el error predictivo se evalúe exclusivamente sobre la ventana de incidencia diurna donde la energía solar es verdaderamente útil para el aprovechamiento y la generación fotovoltaica.

A pesar del sobresaliente ajuste algorítmico, el estudio presenta limitaciones asociadas a su naturaleza univariante. El modelo no integró variables como humedad o nubosidad, las cuales influyen directamente en las caídas de niveles de radiación. Por lo tanto, el sistema resulta óptimo para identificar tendencias climáticas y sus intervalos de riesgo subyacentes, pero posee un margen de vulnerabilidad ante anomalías atmosféricas repentinas.

CONCLUSIONES

La investigación cumplió integralmente con el objetivo de ajustar y fundamentar teóricamente modelos de Redes Neuronales Autorregresivas (NNAR) mediante el uso de algoritmos de aprendizaje automático, demostrando que esta arquitectura es matemáticamente idónea para procesar la alta no linealidad de la radiación UV.

En relación a la fase de procesamiento, la depuración y estructuración de los datos provenientes de la estación meteorológica de la Universidad Nacional de Chimborazo permitió transformar 17976 registros por hora, en 25 series temporales mensuales, desde febrero 2024 a febrero 2026. Este proceso es clave para aislar la tendencia estacional, permitiendo a la red neuronal realizar el proceso de aprendizaje libre de las interferencias del ruido horario o diario.

La implementación de la validación retrospectiva (Hold-out) permitió confirmar el sobresaliente desempeño del modelo ajustado al contrastarlo contra datos no observados. Las predicciones puntuales para el horizonte de los últimos 5 meses alcanzaron una precisión sustentada por un (RMSE) de 2.5323 W/m^2 y un (MAPE) de 14.5312% evaluado en horas de incidencia diurna útil ($> 3 \text{ W/m}^2$).

Se logró implementar la metodología Bootstrap para estimar intervalos puntuales de predicción más robustos. Mediante la simulación de 5000 trayectorias basadas en el remuestreo de residuos históricos, se comprobó que los datos reales de radiación entre octubre de 2025 y febrero de 2026 se ajustan estrictamente a los márgenes de confianza del 80 y 95% proyectados por la red neuronal.

Estas métricas y sus respectivos intervalos de confianza indican que las estimaciones cuantitativas arrojadas por la red neuronal son altamente confiables y controladas, dotando al entorno local de Riobamba de una herramienta computacional validada que facilita el dimensionamiento efectivo y la toma de decisiones integrales en proyectos de ingeniería energética.

REFERENCIAS BIBLIOGRÁFICAS

- Efron, B., & Hastie, T. (2021). *Computer age statistical inference, student edition: Algorithms, evidence, and data science*. Cambridge University Press. <https://www.cambridge.org/highereducation/books/computer-age-statistical-inference-student-edition/D9E017E05F047BE6A1702D847CB38DB9>
- Häder, D.-P., Helbling, E. W., Williamson, C. E., & Worrest, R. C. (2011). Effects of UV radiation on aquatic ecosystems and interactions with climate change. *Photochemical & Photobiological Sciences*, 10(2), 242–260. <https://doi.org/10.1039/C0PP90036B>
- Härdle, W., Horowitz, J. L., & Kreiss, J.-P. (2003). Bootstrap methods for time series. *International Statistical Review*, 71(2), 435–459. <https://doi.org/10.1111/j.1751-5823.2003.tb00485.x>
- Kelleher, J. D. (2019). *Deep learning*. MIT Press. <https://mitpress.mit.edu/9780262537551/deep-learning/>
- Neale, R. E., Lucas, R. M., Byrne, S. N., Hollestein, L., Rhodes, L. E., Yazar, S., Young, A. R., Berwick, M., Ireland, R. A., & Olsen, C. M. (2023). The effects of exposure to solar radiation on human health. *Photochemical & Photobiological Sciences*, 22(5), 1011–1047. <https://doi.org/10.1007/s43630-023-00375-8>
- Organización Mundial de la Salud. (2022, 21 de junio). *La aplicación SunSmart Global UV ayuda a protegerse de los peligros de la exposición al sol y promueve la salud pública*. <https://www.who.int/es/news/item/21-06-2022-sunsmart-global-uv-app-helps-protect-you-from-the-dangers-of-the-sun-and-promotes-public-health>
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). OTexts. <https://otexts.com/fpp2/>
- Saadati, T., & Barutcu, B. (2025). Forecasting solar energy: Leveraging artificial intelligence and machine learning for sustainable energy solutions. *Journal of Economic Surveys*, 39(5), 1929–1946. <https://doi.org/10.1111/joes.12678>
- Pedrycz, W., & Chen, S.-M. (Eds.). (2020). *Deep learning: Algorithms and applications*. Springer. <https://doi.org/10.1007/978-3-030-31760-7>
- Yin, Z., Wang, B., Zhang, B., & Shen, X. (2024). Prediction intervals for bus travel time based on road segment sharing, multiple routes' driving style similarity, and bootstrap method. *Applied Sciences*, 14(7), 2935. <https://doi.org/10.3390/app14072935>

- Hu, B., Wang, Y., & Liu, G. (2008). Influences of the clearness index on UV solar radiation for two locations in the Tibetan Plateau—Lhasa and Haibei. *Advances in Atmospheric Sciences*, 25, 885–896. <https://doi.org/10.1007/s00376-008-0885-8>
- Escobedo, J. F., Gomes, E. N., Oliveira, A. P., & Soares, J. (2009). Modeling hourly and daily fractions of UV, PAR and NIR to global solar radiation under various sky conditions at Botucatu, Brazil. *Applied Energy*, 86(3), 299–309. <https://doi.org/10.1016/j.apenergy.2008.04.013>
- Batres-Estrada, G. (2015). *Deep learning for multivariate financial time series* [Master's thesis, KTH Royal Institute of Technology]. KTH Royal Institute of Technology. <https://www.math.kth.se/matstat/seminarier/reports/M-exjobb15/150612a.pdf>
- Gamboa, J. C. B. (2017). Deep learning for time-series analysis. *arXiv*. <https://doi.org/10.48550/arXiv.1701.01887>
- Torres, J. F., Galicia, A., Troncoso, A., & Martínez-Álvarez, F. (2018). A scalable approach based on deep learning for big data time series forecasting. *Integrated Computer-Aided Engineering*, 25(4), 335–348. <https://doi.org/10.3233/ICA-180580>
- Zúñiga Lema, J. D., & Meneses Freire, M. A. (2024). *Bootstrap para calcular intervalos de predicción mediante modelos no paramétricos de regresión funcional de radiación solar*. *Polo del Conocimiento*, 9(8).

CONFLICTO DE INTERÉS:

Los autores declaran que no existen conflicto de interés posibles

FINANCIAMIENTO

No existió asistencia de financiamiento de parte de pares externos al presente artículo.

NOTA:

El artículo no es producto de una publicación anterior.

