

Forecasting Models of Solar Radiation and Air Temperature through Recurrent Neural Network

Modelos de Predicción de Radiación Solar y Temperatura Ambiente mediante Redes Neuronales Recurrentes

 A. Cuesta¹  J. Constante¹  D. Jijón¹

¹Instituto de Investigación Geológico y Energético, Quito, Ecuador
E-mail: manuel.cuesta@geoenergia.gob.ec; jessica.constante@geoenergia.gob.ec;
juan.jijon@geoenergia.gob.ec

Abstract

The aim of this study is to compare two architectures of recurrent neural networks of Elman and Jordan (RNRE and RNRJ), focus on the forecasting for two days of solar radiation and air temperature. The inputs of the forecasting model are meteorological variables as wind speed, atmospheric pressure, relative humidity and precipitation. The Research Institute for Geology and Energy of Ecuador provided the data of three meteorological stations situated in the provinces of Pichincha and Tungurahua for neural network training, validation and forecasting stages. Each network was trained with three different learning functions: backpropagation, backpropagation momentum and resilient propagation. The results shows the statistical parameters, Person correlation, mean square error and forecasting behavior on graphics for air temperature and solar radiation, according to RNRE and RNRJ model. This work shows correlation index greater than 0,9 in the validation stage. In the forecasting stage, the correlation index is higher than 0,8 and the mean square error shows values less than 0,02 kW for solar radiation and 2 °C for air temperature.

Index terms— Forecasting, recurrent neural network, learning function, artificial intelligence.

Resumen

El objetivo de este estudio es comparar dos arquitecturas de redes neuronales recurrentes de Elman y Jordan (RNRE y RNRJ), enfocadas en predicción de dos días de radiación solar y temperatura ambiente. Las entradas del modelo de predicción son variables meteorológicas como velocidad del viento, presión atmosférica, humedad relativa y precipitación. El Instituto de Investigación Geológico y Energético proveyó los datos de tres estaciones meteorológicas situadas en las Provincias de Pichincha y Tungurahua para las etapas de entrenamiento, validación y predicción de las redes. Cada red se entrenó con tres funciones de aprendizaje, retropropagación, retropropagación de momento y retropropagación resiliente. Los resultados muestran los parámetros estadísticos de correlación de Pearson, error cuadrático medio y el comportamiento de la predicción sobre gráficas de temperatura del aire y radiación solar, de acuerdo a los modelos de RNRE y RNRJ. Este trabajo presenta coeficientes de correlación superiores a 0,9 en la etapa de validación. En la etapa de predicción, el coeficiente de correlación es superior a 0,8 y el error cuadrático medio muestra valores inferiores a 0,02 kW de radiación solar y 2 °C de temperatura ambiente.

Palabras clave— Predicción, redes neuronales recurrentes, función de aprendizaje, inteligencia artificial.

Recibido: 31-10-2022, Aprobado tras revisión: 13-01-2023

Forma sugerida de citación: Cuestan A.; Constante, J.; Jijón, D. (2023). "Modelos de predicción de radiación solar y temperatura ambiente mediante redes neuronales recurrentes". Revista Técnica "energía". No. 19, Issue II, Pp. 81-89

ISSN On-line: 2602-8492 - ISSN Impreso: 1390-5074

Doi: <https://doi.org/10.37116/revistaenergia.v19.n2.2023.552>

© 2023 Operador Nacional de Electricidad, CENACE



1. INTRODUCCIÓN

El rápido crecimiento de tecnologías de generación por aprovechamiento de la energía solar, requieren de técnicas de procesamiento cada vez más elaboradas para entender la variabilidad en el comportamiento del recurso solar en pequeños instantes de tiempo [1].

La energía solar fotovoltaica es una fuente renovable intermitente que puede considerarse como una serie temporal no estacionaria [2]. Existen diversos métodos de predicción de series temporales con modelos estadísticos, numéricos y de inteligencia artificial (IA), basados en el comportamiento físico de la atmósfera [1], [3]. Estos métodos pueden ser del tipo de predicción autoregresivo (AR) y sus variantes como el Método Autoregresivo de Promedio Móvil (ARMA) o el método Autoregresivo Condicional de Heterocedasticidad (ARCH), como se explica en los trabajos de *Laily et al.* [4] y *Bettiza* [5]. Estas metodologías son univariadas y generalmente trabajan bien con series temporales estacionarias [6]. Los métodos de aprendizaje automático con inteligencia artificial, como las redes neuronales, permiten involucrar en el modelo otras variables relevantes al momento de predecir una serie temporal estacionaria, o no estacionarias [7], [8].

Una Red Neuronal Artificial (RNA) es un modelo computacional inspirado en el funcionamiento de una neurona biológica [9]. La red se compone de una serie de procesadores (neuronas) que se distribuyen en niveles o capas interconectadas [10]. Las neuronas procesan señales de entrada y generan una salida, se comunican unas con otras mediante la intensidad de la fuerza entre sus conexiones [11]. En consecuencia, una neurona artificial es un procesador que interactúa con otras neuronas formando una red, cuyo objetivo es resolver un problema específico. En la Figura 1 se observa la estructura general de una neurona artificial [12].

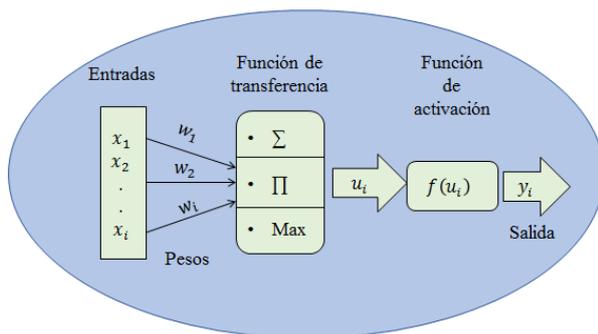


Figura 1: Estructura de una neurona artificial.

Entre las diferentes arquitecturas de las RNA, las Redes Neuronales Recurrentes (RNR) tienen aplicaciones en clasificación de patrones y predicción que involucran diversas variables como es explicado en los trabajos de *Septiawan et al.* [7] y *Kamanditya et al.* [13].

Las RNR se componen de unidades neuronales,

donde la información viaja desde la capa de entrada hasta la capa de salida con retroalimentación o memoria de eventos pasados, lo que significa que las señales se transmiten de vuelta a una neurona o capa anterior de la red [14], [15]. Esta retroalimentación en las neuronas permite obtener mejores soluciones con sistemas no lineales por su capacidad de representar sistemas dinámicos, como series temporales no estacionarias [16], [17]. Las Redes Neuronales Recurrentes Elman (RNRE) y Redes Neuronales Recurrentes Jordan (RNRJ) son un tipo de RNR que utiliza solo el estado del instante anterior de la salida en la capa de contexto para la predicción de variables.

El objetivo de esta investigación es evaluar y comparar los modelos de predicción de RNRE y RNRJ para la estimación de la radiación solar y temperatura en tres estaciones meteorológicas ubicadas en el Ecuador. El artículo es organizado de la siguiente manera. En la sección dos se presenta la metodología utilizada para predicción de las series temporales de temperatura y radiación por RNRE y RNRJ. En la sección tres, se muestran los resultados obtenidos mediante figuras y cuadros estadísticos comparativos de los dos métodos de predicción. Finalmente se presentan las conclusiones y recomendaciones del trabajo.

2. METODOLOGÍA

La metodología de este trabajo se divide en cuatro secciones. Datos y materiales, identificación de datos atípicos en los datos de análisis, aplicación de RNRE y RNRJ en predicción y criterios de selección del método de predicción por RNR.

2.1. Datos y materiales

Los datos usados provienen de 3 estaciones meteorológicas ubicadas en las Provincias de Pichincha y Tungurahua en el Ecuador. El detalle de la ubicación de las estaciones se muestra en la Tabla 1.

Tabla 1: Ubicación geográfica de las estaciones meteorológicas (WGS84 Zona 17 S)

Estación	Latitud (m)	Longitud (m)	Altura (m)
IIGE_001	9 977 607,9	779 916,2	2 788
IIGE_002	9 980 362,1	779 672,9	2 795
IIGE_003	9 859 567,8	774 655,3	3 077

En la Tabla 2 se observa el periodo de análisis de los datos de las estaciones meteorológicas. Del periodo de análisis utilizado, los datos se dividieron en dos secciones, el 75 % de los datos fueron usados para el entrenamiento de la RNR y el 25 % restante para la validación del modelo.

La especificación de las estaciones meteorológicas de la Tabla 1, es detallada en la Tabla 3.

Tabla 2: Periodo de análisis de datos de las estaciones meteorológicas

Estación	Periodo de análisis
IIGE_001	2020-12-08 – 2022-02-22
IIGE_002	2019-05-17 – 2020-12-07

IIGE_003 | 2018-05-17 – 2021-12-21

Tabla 3: Cuadro de descripción de las estaciones meteorológicas NIPPON Estación meteorológica automática

Descripción	Modelo	Unidad de medida
Barómetro	NBS61	hPa
Anemómetro	N564P11	m/s
Veleta		deg
Termómetro	TS301C	°C
Pirómetro	N7003E	kW/m ²
Higrómetro	NP110A	%RH
Pluviómetro	RS102N	mm
Data Logger	CF200	--
Controlador de carga solar	SABA10	--
Batería	FPX12100	--

La frecuencia de registro de datos es diezminutal, por lo que en un día completo de medición se obtendrán 144 muestras. El comportamiento de una serie de radiación solar y temperatura ambiente para la estación meteorológica IIGE_001 de un mes de datos, se muestra en la Fig. 2 y la **Fig. 3**.

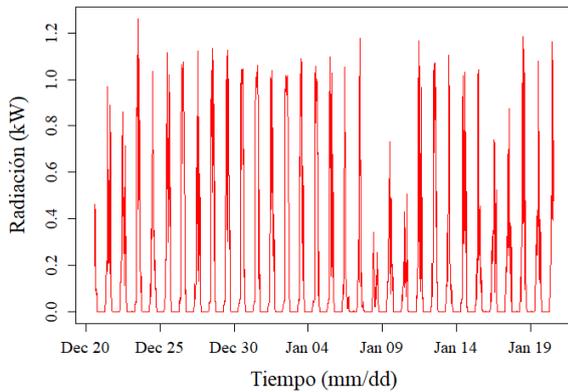


Figura 2: Serie temporal de radiación solar de la estación IIGE_001, periodo 20/12/2020 – 19/01/2021

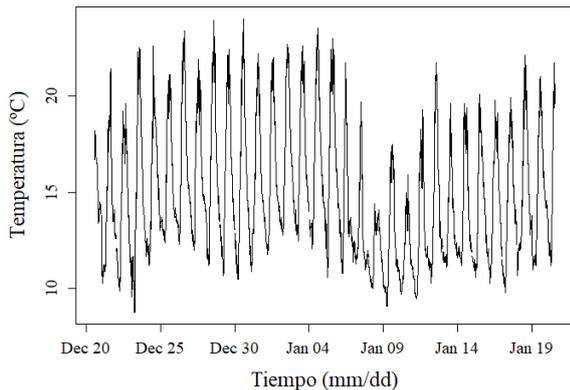


Figura 3: Serie temporal de temperatura la estación IIGE_001, periodo 20/12/2020 – 19/01/2021

Para el análisis de los datos provenientes de las estaciones meteorológicas y para la predicción de radiación solar y temperatura se utilizó el software estadístico RStudio (Versión 1.1.456) con compilador en R (versión 3.6.3). Además, la simulación de las redes RNRE y RNRJ usaron la librería RSNNN [18].

2.2. Identificación de datos atípicos

Los datos provenientes de las estaciones meteorológicas pasan por un tratamiento en la cual se evalúa la calidad de las mediciones registradas por los sensores. Las mediciones presentan datos inusuales o anómalos se los conoce como atípicos y no son considerados para el entrenamiento de la red neuronal.

La identificación de los valores atípicos se basa en encontrar valores que no cumplan los límites de medición de los sensores de la estación meteorológica, los cuales son presentados en la Tabla 4.

Tabla 4: Intervalo de valores de medición para cada sensor de la estación meteorológica

Sensor	Unidad	Intervalo de medida
Anemómetro	m/s	0 a 60
Piranómetro	kW/m ²	0 a 2 000
Termómetro	C	-50 a 50
Higrómetro	%	0 a 100
Pluviómetro	mm/h	0 a 500
Barómetro	hPa	500 a 1 100

Además, se consideraron los valores que no se registraron por falla en los sensores, pérdida de energía o mantenimientos en la estación.

2.3. Aplicación de RNRE y RNRJ en predicción.

Una RNR se caracteriza por tener una capa de contexto en donde parte de información se retroalimenta como una nueva entrada, esto permite que la red tenga mayor capacidad de aprendizaje al reconocer y generar patrones [5]. Lo que diferencia una RNRE de una RNRJ es que la retroalimentación en Elman va desde la salida de la capa oculta hacia la capa de contexto, en cambio en Jordan la retroalimentación ocurre desde la capa de salida hasta las neuronas de la capa de contexto. La arquitectura básica de una RNRE y RNRJ se observa en la Figura 4 y Figura 5, respectivamente.

Las RNRE tienen en su celda de contexto igual número de capas y neuronas que la capa oculta, en cambio, las RNRJ tienen en la capa de contexto el mismo número de neuronas que la salida.

Por la arquitectura de la red neuronal recurrente de tipo Elman, el tiempo computacional que se requiere para el entrenamiento será mayor que una red neuronal recurrente de tipo Jordan. Esto se debe a que la recurrencia de la RNRE se toma de las salidas de las neuronas de las capas ocultas y no de las capas de salida como en una RNRJ, donde el número de neuronas de las capas ocultas siempre fue mayor a las dos neuronas de la capa de salida.



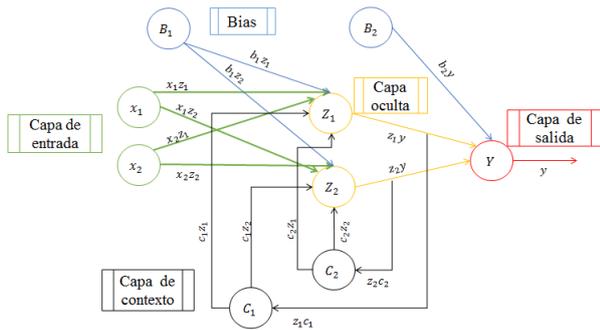


Figura 4: Arquitectura básica de una RNR Elman, adaptado de Bettiza M [5]

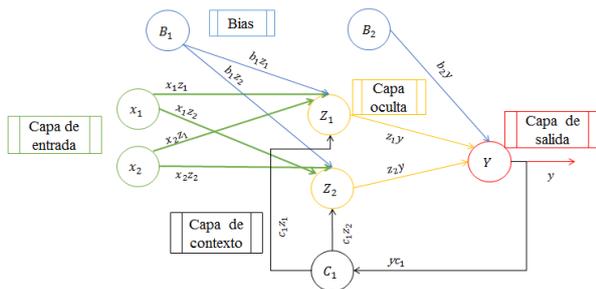


Figura 5: Arquitectura básica de una RNR Jordan, adaptado de Septiawan W. et al. [7]

El número de entradas de la RNR varió entre tres a siete neuronas; de las cuales la fecha (*F*), temperatura (*T*) y radiación (*I*) solar fueron variables fijas en el análisis. Además, las variables de velocidad de viento (*V*), humedad relativa (*H*), precipitación (*R*) y presión atmosférica (*P*) son variables que se probaron en modelo de predicción para temperatura ambiente y radiación solar. La predicción de los datos se realizó para dos días futuros, es decir, para los siguientes 288 diezminutales. La Estación IIGE_003 presentó lecturas anómalas en la serie temporal de humedad relativa, por lo que en este caso no se utilizó la variable *H*.

Las variables meteorológicas utilizadas para el análisis fueron escaladas en valores entre 0 y 1 como se muestra en (1), debido a los procesos de aprendizaje de la red. Cuando se obtienen los valores de salida de la red neuronal, los datos pasan por el proceso inverso de normalizado.

$$x_{escalado} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Donde, $x_{escalado}$ son los valores de la serie escalada y x los valores meteorológicos usados en el análisis.

El entrenamiento de la RNRE se realizó con una y dos capas ocultas con combinaciones entre cuatro y doce neuronas. En la RNRJ se utilizó una capa oculta con variaciones entre cuatro y doce neuronas.

Además, se utilizaron tres algoritmos de aprendizaje distintos; Retropropagación (RP), Retropropagación de momento (RPM) y Retropropagación Resiliente (RPR),

como se detalla en [18]. El algoritmo de RP propaga la señal del error hacia atrás permitiendo calcular el cambio del valor de los pesos en las capas anteriores en base a la minimización de la función de coste, en este caso mediante el descenso del gradiente de la función del error [19]. En RPM se introduce un término de momento que permite reducir las oscilaciones en el descenso del gradiente [20]. La diferencia entre RPR con algoritmos de propagación hacia atrás es que la derivada de la función del error se usa para determinar el sentido en el que los pesos deben ser corregidos y no para el cambio de su magnitud [21],[22].

Cada función de aprendizaje tiene hiperparámetros (Hip) específicos que fueron usados en el intervalo mostrado en la Tabla 5. En RP y RPM se varía los valores de la tasa de aprendizaje mientras que en RPR se varía los valores del exponente del decaimiento del peso (DP), los demás hiperparámetros permanecieron como valores constantes.

Tabla 5: Hiperparámetros usados en las funciones de aprendizaje

Hiperparámetros (Hip)	Función de aprendizaje	Valores probados
Ratio de aprendizaje (RA)	RP, RPM	[0,00001; 0,4]
Máximo error tolerado	RP, RPM	0
Término de momento	RPM	0,1
Eliminación puntos planos	RPM	0,3
Valor inicial de actualización de los pesos	RPR	0,1
Límite de la variación de actualización	RPR	30
Exponente del decaimiento del peso (DP)	RPR	[0,00001; 4]

En la

Tabla 6 se observan los parámetros de inicialización de la red. Los valores de los pesos iniciales en las conexiones que se propagan hacia adelantes son seleccionados aleatoriamente entre un intervalo de [-0,5; 0,5].

Tabla 6: Valores de los parámetros de inicialización de las RNRE y RNRJ

Parámetros iniciales	Pesos iniciales de las conexiones de prealimentación	Pesos iniciales de las conexiones hacia las celdas recurrentes	Pesos iniciales de las conexiones desde las celdas recurrentes	Activación inicial de las unidades de contexto
Valores	[-0,5, 0,5]	0	0,5	0,5

De las pruebas realizadas se seleccionaron doce RNR, seis de tipo Elman y seis de tipo Jordan. Los parámetros de entrenamiento utilizados para cada red se observan en la Tabla 7. Las etiquetas de las doce RNR, ubicadas en la primera columna, están escritas de la siguiente manera, F.Aprendizaje_Tipo de red_Estacion ► RP_E1_001

Tabla 7: Parámetros de entrenamiento de las RNRE y RNRJ

Aprendizaje_Red_Estación	Neuronas en capa(s)	Iteraciones	Hip	Entradas
RP_E1_001	(5,4)	800	1E-03 (RA)	F,I,T,V,R,P
RPR_E1_001	(6)	450	1E-05 (DP)	F,I,T,V,P

RP_J1_001	(12)	500	7E-05 (DP)	F,I,T,V,P
RPM_J1_001	(6)	450	3E-05 (RA)	F,I,T,V,R,P
RPM_E1_002	(12)	500	1E-04 (RA)	F,I,T,P
RPR_E2_002	(12)	250	3E-04 (DP)	F,I,T,V,P
RPM_J2_002	(11)	500	31E-06(RA)	F,I,T,P
RPR_J1_002	(8)	150	4E-05 (DP)	F,I,T
RP_E2_003	(11)	500	3E-04 (RA)	F,I,T,P
RPM_E2_003	(12)	400	9E-05 (RA)	F,I,T,V,R,P
RP_J2_003	(6)	500	7E-05 (DP)	F,I,T
RPR_J2_003	(8)	300	8E-04 (DP)	F,I,T

Definidos los parámetros e hiperparámetros de la RNR, se entrena la red el número de iteraciones deseadas hasta obtener el valor final de los pesos para el modelo. Durante cada iteración de la red las señales son propagadas desde la capa de entrada hacia las capas ocultas y después a la capa de salida, después, se realiza una actualización síncrona de las unidades de contexto. Al final de cada iteración se calcula la Suma de los Errores Cuadrados (SSE por sus siglas en ingles), el cual puede considerarse como el primer indicador de rendimiento de la red antes de su etapa de validación.

En la etapa de validación se consideró una correlación de Pearson mayor a 0,9 para validar el modelo, donde, según el trabajo de *M. De Liu et al.* [23], un valor mayor a 0,98 se considera como excelente resultado. Con los pesos sinápticos establecidos en modelo entrenado de la red, se obtienen las salidas de radiación y temperatura con el 20% de los datos de cada estación usados para la etapa de validación. Los datos de salida o los datos predichos son comparados con las salidas teóricas mediante los indicadores de rendimiento de la sección 2.4.

El proceso de predicción, entrenamiento y validación para una RNRE o RNRJ se muestran en la Figura 6, Figura 7 y Figura 8, respectivamente [6], [7], [24].

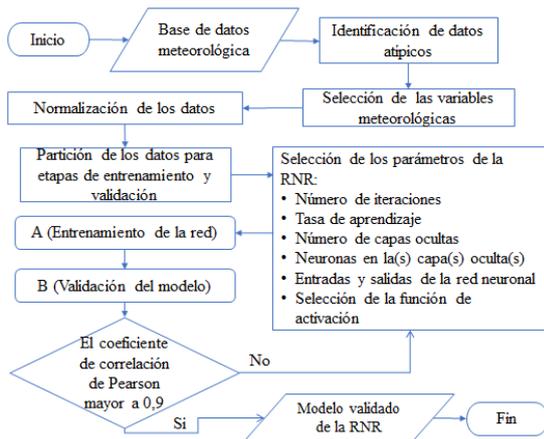


Figura 6: Diagrama de flujo de la aplicación de RNR en predicción

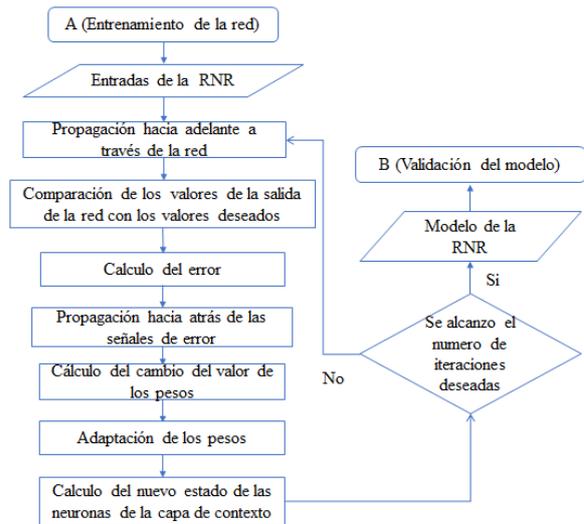


Figura 7: Diagrama de flujo del entrenamiento de la RNR

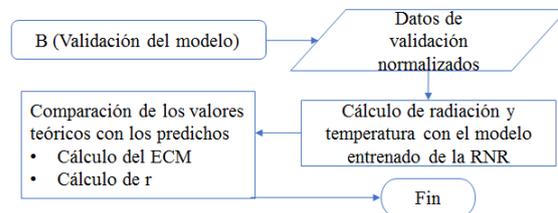


Figura 8: Diagrama de la etapa de validación de la RNR

2.4. Criterios de selección del método de predicción por RNR

Para evaluar el rendimiento de la predicción de radiación solar y temperatura se usaron dos indicadores apreciados en (2) y (3), el error cuadrático medio (ECM) [25] y el coeficiente de correlación de Pearson (r) [23], comparado entre los valores medidos y los valores obtenidos predichos por los modelo.

$$ECM = \frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2 \quad (2)$$

$$r = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\left(\left(\sum_{i=1}^N (x_i - \bar{x})^2 \right) \left(\sum_{i=1}^N (y_i - \bar{y})^2 \right) \right)^{1/2}} \quad (3)$$

Donde x_i es el valor medido por el sensor, y_i es el valor predicho por el modelo, N es el número de datos, \bar{x} y \bar{y} son las medias aritméticas de las variables x y y , respectivamente.

3. ANÁLISIS DE RESULTADOS

Cada modelo de red RNRE y RNRJ mostrado en la Tabla 7, pasó por una etapa de validación de resultados y por una etapa de predicción. En ambas etapas los modelos se evaluaron con 2 indicadores de rendimiento, la correlación de Pearson y el error cuadrático medio.

En la Tabla 8, se observa los valores de r y ECM de los modelos evaluados en la etapa de validación de datos.



Tabla 8: Evaluadores de rendimiento en la etapa de validación de las RNRE y RNRJ

Etapa de validación				
Aprendizaje_ Etiqueta_ Estación	r Radiación	ECM Radiación	r Temperatura	ECM Temperatura
RP_E1_001	0,94550	0,01345	0,96863	1,11856
RPR_E1_001	0,94710	0,01362	0,97725	0,91482
RP_J1_001	0,97195	0,01048	0,96346	1,42873
RPM_J1_001	0,97147	0,00765	0,96940	1,09036
RPM_E1_002	0,97385	0,00870	0,96841	1,11462
RPR_E2_002	0,96261	0,01191	0,97801	0,74341
RPM_J2_002	0,95524	0,01073	0,97008	0,88166
RPR_J1_002	0,93595	0,01708	0,96218	1,06062
RP_E2_003	0,97523	0,00646	0,95867	1,34079
RPM_E2_003	0,97345	0,01040	0,94783	1,38401
RP_J2_003	0,96833	0,01033	0,95000	1,40757
RPR_J2_003	0,90947	0,01536	0,92178	1,06393

Los valores de correlación r en radiación y temperatura superan 0,91 y los valores de ECM no superan los 0,018 kW en radiación solar y 1,43 °C en temperatura ambiente.

Los valores más altos de r en la etapa de validación de datos de radiación solar y temperatura ambiente son en su conjunto los del modelo RPM_J1_001, en la Tabla 8.

En la Tabla 9, se aprecian los valores de r y del ECM en la etapa de predicción para dos días posteriores.

Tabla 9: Evaluadores de rendimiento en la etapa de predicción de las RNRE y RNRJ

Etapa de predicción				
Aprendizaje_ Etiqueta_ Estación	r Radiación	ECM Radiación	r Temperatura	ECM Temperatura
RP_E1_001	0,90547	0,01113	0,97366	0,48372
RPR_E1_001	0,90234	0,0119	0,97605	0,42019
RP_J1_001	0,89729	0,01536	0,9614	0,89082
RPM_J1_001	0,90922	0,01092	0,97146	0,56325
RPM_E1_002	0,97782	0,01309	0,9761	2,00273
RPR_E2_002	0,97003	0,01997	0,97253	2,21039
RPM_J2_002	0,95794	0,01441	0,96989	2,15746
RPR_J1_002	0,93417	0,03181	0,91697	4,39514
RP_E2_003	0,93545	0,01632	0,92982	1,19404
RPM_E2_003	0,9286	0,01398	0,92868	1,02451
RP_J2_003	0,91386	0,01746	0,9486	0,85576
RPR_J2_003	0,88456	0,01954	0,83012	1,26010

Los valores de correlación más altos de r de la estación IIGE_001, IIGE_002 y IIGE_003 son respectivamente los modelos RPM_J1_001, RPM_E1_002 y RP_E2_003, en la Tabla 9. La arquitectura seleccionada para la predicción en las tres estaciones meteorológicas, depende del comportamiento de las series temporales de análisis.

Los valores más altos de r en la etapa de predicción de datos de radiación solar y temperatura ambiente son en su conjunto los del modelo RPM_E1_002, en la Tabla 9.

En la Figura 9 se observan la gráfica de predicción de radiación solar y en la Figura 10 la gráfica de temperatura ambiente, ambos de la Estación IIGE_001

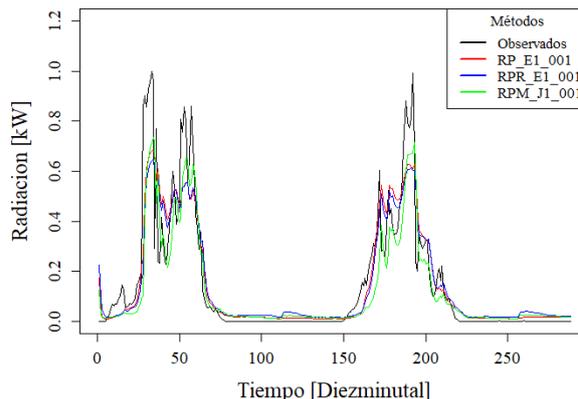


Figura 9: Predicción de radiación solar (RNRJ) para la Estación IIGE_001

En el comportamiento de las predicciones de radiación solar, los valores no llegan a 0 como mínimo valor de radiación, el cual es rectificado en base al comportamiento de la serie temporal (radiación=0 en horas nocturnas). Se observa una limitación en los métodos para alcanzar los mínimos y máximos de los valores observados.

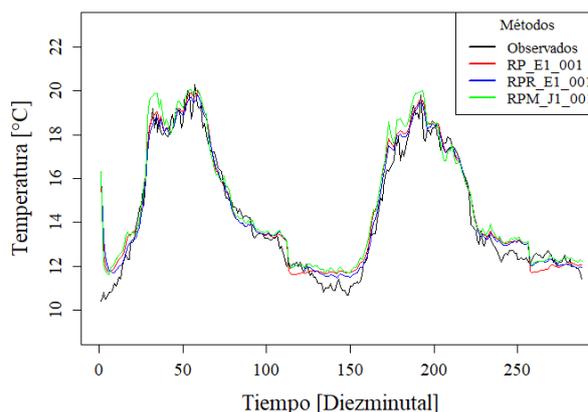


Figura 10. Predicción de temperatura (RNRJ) para la Estación IIGE_001

El comportamiento de temperatura ambiente de las predicciones se ajusta con similitud a las medidas tomadas por el sensor.

En la Figura 11 se observan la gráfica de predicción de radiación solar y en la Figura 12 la gráfica de temperatura ambiente, ambos de la Estación IIGE_002.



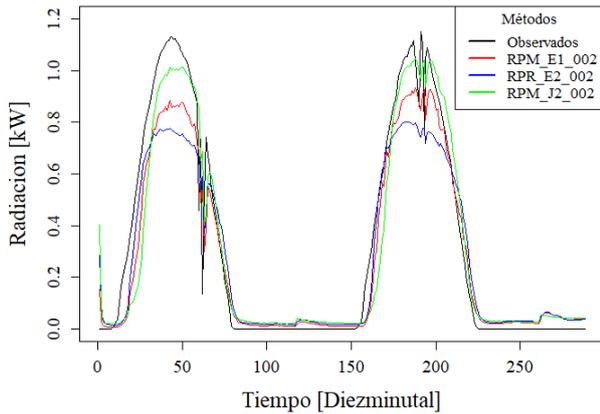


Figura 11: Predicción de radiación solar (RNRE) para la Estación IIGE_002

En el comportamiento de las predicciones de radiación solar, se observa un comportamiento similar al de la Estación IIGE_001, los valores no alcanzan el mínimo de 0 en radiación ni los valores máximos.

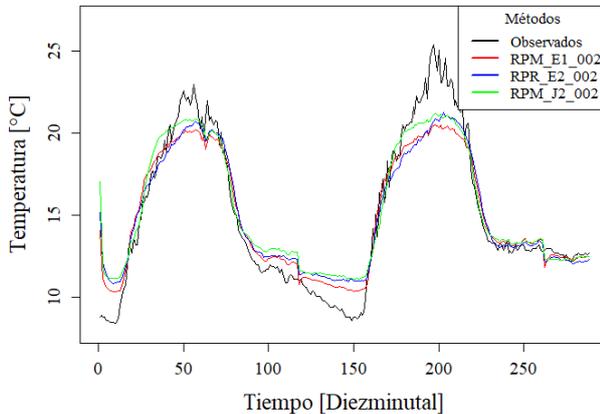


Figura 12: Predicción de temperatura (RNRE) para la Estación IIGE_002

El comportamiento de temperatura ambiente de las predicciones se ajusta a las medidas tomadas por el sensor, sin embargo, se observan limitaciones al llegar a los valores máximos y mínimos de temperatura.

4. CONCLUSIONES Y RECOMENDACIONES

Los modelos de RNR Elman y Jordan muestran convergencia con un número de iteraciones entre 300 y 600. El tiempo computacional empleado en el entrenamiento de cada modelo se relaciona directamente con la cantidad de datos del set y el número de iteraciones al entrenar la red, si estas variables aumentan el tiempo computacional también. Se pudo observar que, si las iteraciones son superiores a 600, los resultados de la correlación de Pearson varían en aproximadamente $\pm 2\%$.

Los resultados en la etapa de validación para las tres estaciones meteorológicas mostraron coeficientes de correlación mayores a 0,92 en temperatura y radiación solar para las RNRE y RNRJ. Esto demuestra que el

entrenamiento de las redes se ajusta al comportamiento de las series temporales.

Para la etapa de predicción, en la estación IIGE_001, el mejor resultado se obtuvo con una RNRJ con aprendizaje RPM. En la estación IIGE_002, el mejor resultado fue con una RNRE con aprendizaje RPM. En la estación IIGE_003, se obtuvieron dos resultados similares, uno con RNRJ y el otro con RNRE, ambos con algoritmo de aprendizaje RP. Los resultados demuestran que se puede entrenar satisfactoriamente una RNRE o una RNRJ para aplicaciones de predicción de series temporales.

En las gráficas de predicción de radiación solar, se tienen valores de radiación positivos en horas nocturnas. Estos valores no son altos, pero afectan el comportamiento esperado de la predicción, por lo que es importante realizar una depuración previa a la publicación del resultado, como una propuesta al implementar los métodos en una situación de seguimiento de recurso solar.

Los valores de correlación más altos bajo los parámetros de entrenamiento de las RNRE y RNRJ en la etapa de validación, tuvieron el mejor comportamiento en la etapa de predicción. Esto permite afirmar que la parametrización con mejores resultados en la etapa de validación, deberán ser los seleccionados para el modelo predictivo.

AGRADECIMIENTOS

Los autores del presente artículo agradecen al Instituto de Investigación Geológico y Energético, por el soporte técnico y acceso a bases de datos que fueron fundamentales para la elaboración del presente trabajo.

REFERENCIAS BIBLIOGRÁFICAS

- [1] H. Sharadga, S. Hajimirza, and R. S. Balog, "Time series forecasting of solar power generation for large-scale photovoltaic plants," *Renew. Energy*, vol. 150, pp. 797–807, 2020, doi: 10.1016/j.renene.2019.12.131.
- [2] A. Alzahrani, P. Shamsi, C. Dagli, and M. Ferdowsi, "Solar Irradiance Forecasting Using Deep Neural Networks," in *Procedia Computer Science*, 2017, vol. 114, pp. 304–313, doi: 10.1016/j.procs.2017.09.045.
- [3] G. Mahalakshmi, S. Sridevi, and S. Rajaram, "A Survey on Forecasting of Time Series Data," p. 8, 2016.
- [4] V. O. Nur Laily, B. Warsito, and D. A. I Maruddani, "Comparison of ARCH / GARCH model and Elman Recurrent Neural Network on data return of closing price stock," *J. Phys. Conf. Ser.*, vol. 1025, no. 1, 2018, doi: 10.1088/1742-6596/1025/1/012103.
- [5] M. Bettiza, "An Analysis on Wind Speed

- Forecasting Result with the Elman Recurrent Neural Network Method,” E3S Web Conf., vol. 324, p. 4, 2021, doi: 10.1051/e3sconf/202132405002.
- [6] A. A. Fierro, “Predicción de Series Temporales con Redes Neuronales,” *Fac. Informática Univ. Nac. La Plata Argentina*, p. 64, 2020.
- [7] W. M. Septiawan and S. N. Endah, “Suitable Recurrent Neural Network for Air Quality Prediction with Backpropagation Through Time,” 2018 2nd Int. Conf. Informatics Comput. Sci. ICICoS 2018, pp. 196–201, 2018, doi: 10.1109/ICICOS.2018.8621720.
- [8] T. E. Putri, A. A. Firdaus, and W. I. Sabilla, “Short-Term Forecasting of Electricity Consumption Revenue on Java-Bali Electricity System using Jordan Recurrent Neural Network,” *J. Inf. Syst. Eng. Bus. Intell.*, vol. 4, no. 2, p. 96, 2018, doi: 10.20473/jisebi.4.2.96-105.
- [9] J. Durán, “Redes Neuronales Convolucionales en R Reconocimiento de caracteres escritos a mano,” p. 78, 2018, [Online]. Available: <http://bibing.us.es/proyectos/abreproy/91338/fichero/TFG+Jaime+Durán+Suárez.pdf>.
- [10] D. D. Cervantes, “Estudio De Las Emisiones De Nox Mediante Redes Neuronales Recurrentes,” 2020.
- [11] M. Cabezón, “Implementación de redes neuronales recurrentes en Python . Miguel Cabezón Manchado Trabajo de fin de máster en Ingeniería Matemática,” p. 43, 2018, [Online]. Available: https://eprints.ucm.es/49444/1/2018-MIGUEL_CABEZON_Memoria.pdf.
- [12] F. Rodríguez, A. Fleetwood, A. Galarza, and L. Fontán, “Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control,” *Renew. Energy*, vol. 126, pp. 855–864, 2018, doi: 10.1016/j.renene.2018.03.070.
- [13] B. Kamanditya and B. Kusumoputro, “Elman Recurrent Neural Networks Based Direct Inverse Control for Quadrotor Attitude and Altitude Control,” in *Proceedings of International Conference on Intelligent Engineering and Management, ICIEM 2020*, 2020, pp. 39–43, doi: 10.1109/ICIEM48762.2020.9160191.
- [14] C. Arana, “Redes Neuronales Recurrentes: Análisis De Los Modelos Especializados En Datos Secuenciales,” *Univ. del Cema*, no. 797, pp. 4–8, 2021, [Online]. Available: <https://ucema.edu.ar/publicaciones/download/documentos/797.pdf>.
- [15] S. Alemany, J. Beltran, A. Perez, and S. Ganzfried, “Predicting hurricane trajectories using a recurrent neural network,” 33rd AAI Conf. Artif. Intell. AAI 2019, 31st Innov. Appl. Artif. Intell. Conf. IAAI 2019 9th AAI Symp. Educ. Adv. Artif. Intell. EAAI 2019, pp. 468–475, 2019, doi: 10.1609/aaai.v33i01.3301468.
- [16] M. M. Rahman et al., “Prospective methodologies in hybrid renewable energy systems for energy prediction using artificial neural networks,” *Sustain.*, vol. 13, no. 4, pp. 1–28, 2021, doi: 10.3390/su13042393.
- [17] M. Abreu and L. Villas, *Minería de datos para Series Temporales*, no. August. Universidad Central “Martha Abreu” de las Villas, 2015.
- [18] M. Christoph Bergmeir, “Neural networks using the stuttgart neural network simulator (SNNS),” pp. 1–74, 2021, [Online]. Available: <https://github.com/cbergmeir/RNNNS/issues>.
- [19] E. Andrade, “Estudio de los principales tipos de redes neuronales y las herramientas para su aplicación,” p. 152, 2013, [Online]. Available: <http://dspace.ups.edu.ec/handle/123456789/4098>.
- [20] A. Zell et al., “Stuttgart Neural Network Simulator SNNS,” *Univ. Tübingen*, pp. 1–350, 2016, [Online]. Available: papers2://publication/uuid/1C682FBB-1EEB-4D5E-AB83-EE9F7D055829.
- [21] D. M. Polo, L. P. Caballero, and E. M. Gómez, “Comparación de Redes Neuronales aplicadas a la predicción de Series de Tiempo,” *Prospectiva*, vol. 13, no. 2, pp. 88–95, 2015.
- [22] J. A. Cárdenas Garro, “Pronósticos Y Comparación De Una Serie De Tiempo Con Cambios Estructurales Mediante La Red Neuronal Artificial De Retropropagación Resiliente Y Modelos No Lineales,” *Univ. Nac. Mayor San Marcos - Fac. Ciencias Mat. Esc. Prof. Estadística*, 2015.
- [23] M. De Liu, L. Ding, and Y. L. Bai, “Application of hybrid model based on empirical mode decomposition, novel recurrent neural networks and the ARIMA to wind speed prediction,” *Energy Convers. Manag.*, vol. 233, p. 113917, 2021, doi: 10.1016/j.enconman.2021.113917.
- [24] L. Hardinata, B. Warsito, and Suparti, “Bankruptcy prediction based on financial ratios using Jordan Recurrent Neural Networks: A case study in Polish companies,” *J. Phys. Conf. Ser.*, vol. 1025, no. 1, 2018, doi: 10.1088/1742-6596/1025/1/012098.
- [25] A. F. Romero Granda, “Predicción de la potencia activa a corto plazo de un parque fotovoltaico utilizando una red neuronal artificial,” *ESCUELA POLITÉCNICA NACIONAL*, 2017.



Alejandro Cuesta. - Nació en Quito, Ecuador en 1994. Recibió su título de Ingeniero en Mecatrónica de la Universidad Tecnológica Equinoccial en 2019. Ha realizado investigaciones en el campo de energía eólica y tratamiento de bases de datos.



Diego Jijón. - Nació en Quito, Ecuador en 1984. Recibió su título de Físico en Quito en la Escuela Politécnica Nacional en 2012. Obtuvo su título de posgrado en la Escuela Politécnica Nacional en Diseño y Simulación en el año 2019. Sus campos de investigación están relacionados con Energías Renovables, Eficiencia Energética, Aplicaciones de Física de Láseres y Simulación con Elementos Finitos.



Jessica Constante. - Nació en Quito, Ecuador en 1992. Recibió su título de Ingeniera en Mecatrónica de la Universidad Tecnológica Equinoccial en 2014. Sus campos de investigación están relacionados con las Energías Renovables, el tratamiento y análisis de bases de datos, CFD y desarrollo de software.