





Unidades recurrentes cerradas (GRU) vs redes neuronales artificiales en la predicción de la generación eléctrica de la Central Hidroeléctrica Illuchi

Closed recurring units (GRU) vs artificial neural networks in the prediction of electricity generation at the Illuchi Hydroelectric Power Plant

- ¹ Fernando Santiago Bustamante Freire  <https://orcid.org/0009-0004-2404-2544>
Universidad Técnica de Cotopaxi (UTC), Ecuador
fernando.bustamante@utc.edu.ec
- ² Jessica Nataly Castillo Fiallos  <https://orcid.org/0000-0002-3120-7229>
Universidad Técnica de Cotopaxi (UTC), Ecuador
jessica.castillo@utc.edu.ec
- ³ Carlos Iván Quinatoa Caiza  <https://orcid.org/0000-0001-6369-7480>
Universidad Técnica de Cotopaxi (UTC), Ecuador
carlos.quinatoa7864@utc.edu.ec
- ⁴ Héctor Raúl Reinoso Peñaherrera  <https://orcid.org/0009-0008-4881-3920>
Universidad Técnica de Cotopaxi (UTC), Ecuador
hector.reinoso@utc.edu.ec



Artículo de Investigación Científica y Tecnológica

Enviado: 12/05/2023

Revisado: 28/06/2023

Aceptado: 28/07/2023

Publicado: 30/08/2023

DOI: <https://doi.org/10.33262/ap.v5i3.395>

Cítese:

Bustamante Freire, F. S., Castillo Fiallos, J. N., Quinatoa Caiza, C. I., & Reinoso Peñaherrera, H. R. (2023). Unidades recurrentes cerradas (GRU) vs redes neuronales artificiales en la predicción de la generación eléctrica de la Central Hidroeléctrica Illuchi. AlfaPublicaciones, 5(3), 150–166. <https://doi.org/10.33262/ap.v5i3.395>



ALFA PUBLICACIONES, es una Revista Multidisciplinar, **Trimestral**, que se publicará en soporte electrónico tiene como **misión** contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://alfapublicaciones.com>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec

Esta revista está protegida bajo una licencia Creative Commons AttributionNonCommercialNoDerivatives 4.0 International. Copia de la licencia: <http://creativecommons.org/licenses/by-nc-nd/4.0/>

Palabras

claves:

ADAM, Python,
GRU,
predicción,
redes neuronales
artificiales.

Keywords: :

ADAM,
Python, GRU,
prediction,
neural
networks.

Resumen

La predicción de eventos ha sido desde la antigüedad, un fenómeno capaz de generar curiosidad en el ser humano, sin embargo, para lograr una proyección de un evento futuro se requiere de un análisis detallado de datos para predecir eventos posteriores, con esta idea. **Objetivos:** el objetivo de la investigación fue desarrollar dos sistemas de predicción aplicando redes neuronales artificiales y GRU para determinar la generación eléctrica pronosticada en la CENTRAL HIDROELÉCTRICA ILLUCHI. **Metodología:** Los datos utilizados para este estudio fueron recopilados de los operadores de ELEPCO S.A. en base a los años 2008 - 2020. Las variables de entrada fueron la fecha y la energía generada para elaborar diferentes casos con distintas condiciones con el fin de llegar a un modelo de Red Neuronal Recurrente exitoso posible. **Resultados:** Una vez comprendidas las variables del modelo, los datos se dividieron en dos grupos: entrenamiento 70% y validación 30% respectivamente. Para el entrenamiento correspondiente se utilizó el algoritmo ADAM y las librerías proporcionadas por Python. **Área de estudio general:** Ingeniería. **Área de estudio específica:** Eléctrica.

Abstract

The prediction of events has been, since ancient times, a phenomenon capable of generating curiosity in human beings. However, to achieve a projection of a future event, a detailed analysis of data is required to predict subsequent events. **Objectives:** The objective of the research was to develop two prediction systems using artificial neural networks and GRU to determine the predicted electrical generation at the ILLUCHI HYDROELECTRIC PLANT. **Methodology:** The data used for this study were collected from ELEPCO S.A. operators based on the years 2008 to 2020. The input variables were the date and the energy generated to develop different cases with different conditions to arrive at a successful Recurrent Neural Network model. **Results:** Once the variables of the model were understood, the data was divided into two groups: training 70% and validation 30% respectively. The ADAM algorithm and libraries provided by Python were used for the corresponding training. **General area of study:** Engineering. **Specific area of study:** Electrical.

Introducción

La generación de electricidad es crucial, lo que se evidencia en la amplia gama de estudios relacionados con la investigación en este campo. Aunque se sabe que la generación de electricidad tiene un comportamiento no lineal y variable, esto motiva a los investigadores a adaptar sus metodologías para obtener mejores resultados. Hay modelos predictivos para la producción de electricidad que utilizan técnicas de aprendizaje computacional para mejorar el uso del agua de los ríos como recurso hídrico (Castillo et al., 2022a).

Se ha observado el uso de técnicas y modelos basados en aprendizaje automático, como las redes neuronales artificiales, para obtener mejores resultados en comparación con técnicas tradicionales como la regresión lineal y ARIMA (Castillo et al., 2022b). Estos modelos se aplican en la predicción de la generación de energía y otros fenómenos estocásticos. La importancia del aprendizaje automático radica en la precisión de las predicciones, los márgenes de error y los valores finales, debido a su capacidad para seleccionar variables relevantes. El aprendizaje automático es un tipo de análisis de datos que automatiza la construcción de modelos analíticos y es una rama de la inteligencia artificial basada en el aprendizaje a partir de datos. Su objetivo es identificar patrones y tomar decisiones con respecto a variables sin intervención humana (Ti et al., 2021; Bunnoon, 2011, p. 2). Al utilizar un modelo de predicción en la generación de energía, podremos identificar patrones de comportamiento en los generadores 1 y 2 de la Central Hidroeléctrica ILLUCHI. Estos valores y gráficos nos permitirán hacer recomendaciones de uso o detectar problemas en la generación. Se propone comparar el comportamiento de la generación utilizando dos modelos diferentes: una unidad recurrente cerrada y una LSTM. Estos modelos serán evaluados a través de sus resultados en gráficos y su capacidad para manejar y seleccionar variables y datos relevantes.

Lo expuesto por Eseye & Tukia (2019), las redes neuronales artificiales, como las GRU y las LSTM, utilizan enfoques diferentes para controlar la información y evitar el problema del gradiente de desaparición. Estos son los principales puntos de comparación entre estos dos métodos (Sahagún, 2018, p. 119). La unidad GRU controla el flujo de información como la unidad LSTM, pero sin tener que utilizar una unidad de memoria, simplemente expone el contenido oculto completo sin ningún control mientras que las GRU son relativamente nuevas y, según la experiencia, su rendimiento es similar al de las LSTM, pero computacionalmente más eficientes (como se señaló, tienen una estructura menos compleja) (Aguilar & Paredes, 2018; Illidge et al., 2020). Una vez que se han analizado las variables del modelo, los datos se dividen en tres grupos: entrenamiento, prueba y validación. El 80% de los valores recolectados se utilizan para el entrenamiento y el 20% restante para la validación final del modelo planteado. Las GRUs, o Unidades de Corrientes Cerradas, son una variación del diseño de las RNN y utilizan un proceso de compuerta para gestionar y controlar el flujo de automatización

entre las células de la red neuronal. Esto permite a las GRUs capturar dependencias sin ignorar la información pasada en grandes conjuntos de datos secuenciales.

Además Ramírez (2013), sostiene que la principal diferencia entre una GRU y un LSTM es que una GRU tiene dos puertas (puertas de reinicio y actualización) mientras que un LSTM tiene tres puertas (puertas de entrada, salida y olvido).

Objetivo General: Desarrollar un sistema de predicción utilizando redes neuronales artificiales y unidades recurrentes cerradas en Python para predecir la generación de energía eléctrica en la CENTRAL HIDROELECTRICA ILLUCHI.

Objetivos Específicos: Obtener información actualizada sobre el desarrollo de algoritmos utilizados en la predicción de generación eléctrica en centrales hidroeléctricas.

Determinar los parámetros necesarios para el desarrollo de algoritmos a implementar en la red neuronal recurrente (RNN) y la unidad recurrente cerrada (GRU)

Implementar la RNN y GRU sobre el software Python

Validar los resultados obtenidos de la red neuronal artificial y las unidades recurrentes cerradas.

Metodología

Esta investigación examina la situación del sistema de generación en relación con la predicción a corto plazo de la demanda de energía eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2. Se considera una gran cantidad de información sobre la demanda de energía eléctrica en diferentes momentos en que la central está en operación. Se proponen varias alternativas para analizar las variaciones en la demanda de energía eléctrica.

Para comprender mejor la situación, fenómeno u objeto de estudio, es importante descomponer sus características en sus diversos rasgos. En este caso, se realiza un reconocimiento de hechos e ideas para definir el comportamiento en la CENTRAL HIDROELÉCTRICA ILLUCHI 2. Se recopila una base de datos histórica con valores de corriente, potencia y demanda de energía eléctrica, y se crea una vista previa del funcionamiento de la central. Esto permite un mejor entendimiento técnico de la situación.

En esta parte de la investigación aplicada, se utilizarán todos los conocimientos técnicos y científicos adquiridos para desarrollar análisis y programar un algoritmo en el lenguaje de programación Python. Este algoritmo permitirá realizar el

pronóstico de la demanda de energía eléctrica y obtener resultados que se aproximen a los valores reales.

Resultados

Generación de Energía eléctrica

La producción de electricidad implica la conversión de una forma de energía, como la química, cinética, térmica, lumínica, nuclear o solar, en energía eléctrica (Eseye & Tukia, 2019, p. 18). Las centrales eléctricas son instalaciones que realizan estas transformaciones para la generación industrial de electricidad y son el primer paso en el sistema de suministro eléctrico (Carrera, 2020, p. 1). La producción de electricidad se lleva a cabo principalmente a través de un generador eléctrico. Aunque todos los generadores funcionan con el mismo principio, difieren en la forma en que se accionan (GreenLux, 2021).

Una central hidroeléctrica es una instalación que genera electricidad aprovechando la energía potencial del agua almacenada en una presa a mayor altura que la central (Aguilar & Paredes, 2018). El agua se transporta a través de una tubería hasta la sala de máquinas, donde se utiliza para mover grandes turbinas hidráulicas que generan electricidad en alternadores. Después de pasar por las turbinas, el agua regresa a su cauce natural (Caja, 2020, p. 6). Las dos características principales de una central hidroeléctrica, desde el punto de vista de su capacidad de generación de electricidad son:

La potencia de una central hidroeléctrica depende del desnivel entre el nivel medio del embalse y el nivel medio de las aguas debajo de la central, así como del caudal máximo que puede pasar por las turbinas. También influyen las características de la turbina y del generador. La energía que se puede garantizar en un período determinado, generalmente un año, depende del volumen útil del embalse, de la cantidad de lluvia anual y de la potencia instalada (Cueva, 2018, pp. 64-68).

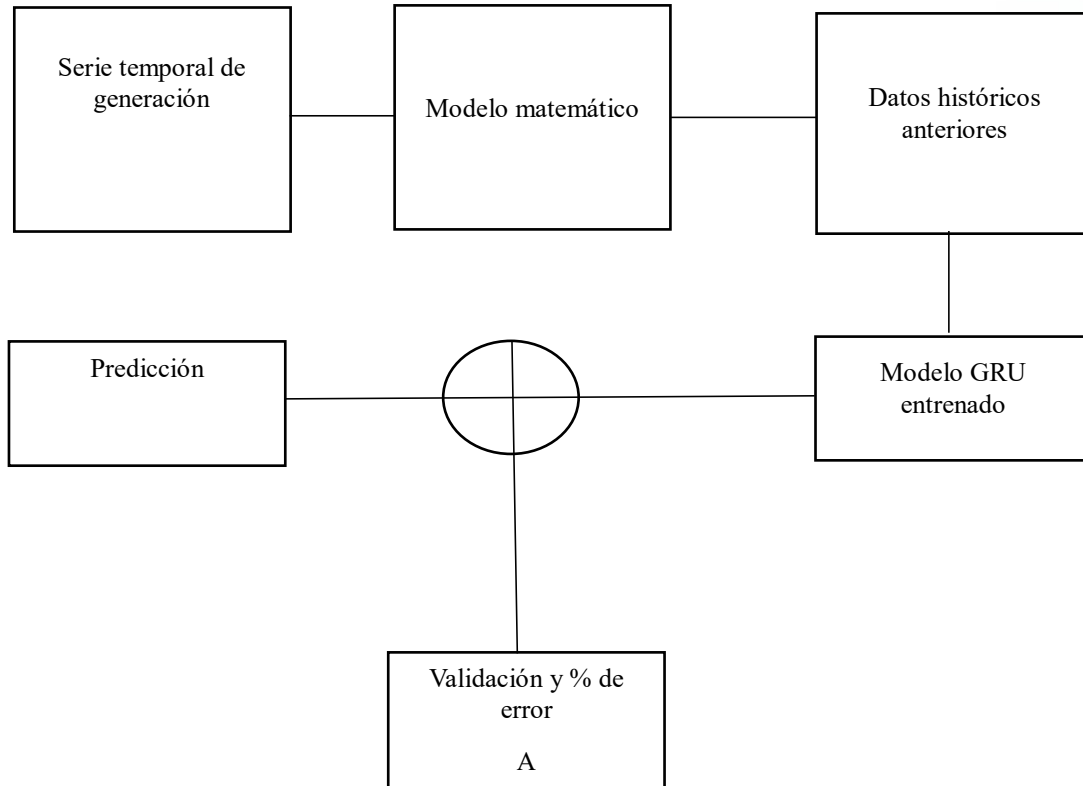
Unidades recurrentes cerradas

La GRU también conocida como “Gated Recurrent unit”, fue desarrollada para resolver problemas comunes de gradientes desvanecidos, además se considera a la GRU como una variante avanzada de la LSTM, esto debido a sus diseños similares y a sus excelentes resultados.

Las GRUs utilizan la puerta de actualización y la puerta de reinicio para resolver el problema del gradiente de fuga de una RRN estándar (Del Canto, 2019). Esencialmente, se trata de dos vectores que determinan el tipo de información que se transmite a la salida. Lo que hace que estos vectores sean especiales es que pueden ser entrenados por programadores para almacenar información, incluso información de hace mucho tiempo.

Figura 1

Estructura del sistema GRU

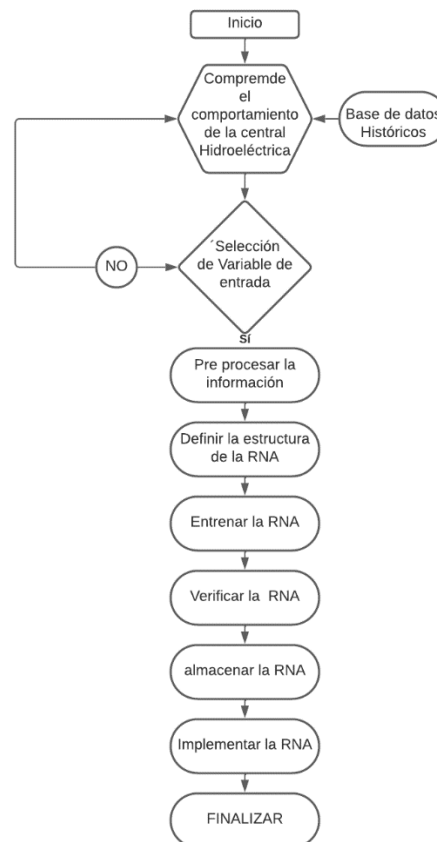


Redes neuronales Recurrentes

Una red LSTM es capaz de recordar información relevante en una secuencia y preservarla durante varios momentos en el tiempo (Nieve, 2021, p. 130). Por lo tanto, puede tener una memoria tanto a corto plazo, como las redes recurrentes básicas, como a largo plazo. Funciona de manera similar a cómo nuestro cerebro analiza una secuencia. Por ejemplo, si queremos comprar un par de audífonos y leemos una valoración hecha por un comprador para tomar la decisión, no nos enfocamos en la totalidad de la valoración, sino solo en las palabras que consideramos relevantes. Las redes LSTM funcionan de manera similar y pueden añadir o eliminar información que consideran relevante para el procesamiento de la secuencia.

Figura 2

Estructura del sistema LSTM



El proyecto tiene como objetivo desarrollar dos modelos de predicción para mini centrales hidroeléctricas en Ecuador. Para ello, se ha tomado como referencia la minicentral eléctrica Illuchi 2, ubicada en la provincia de Cotopaxi, en el cantón Latacunga. Esto se logra mediante el uso de modelos matemáticos y el entrenamiento de redes neuronales utilizando datos históricos de potencia desde 2018 hasta 2023, registrados diariamente. Esto permite tener un registro preciso de la cantidad de agua que pasa por la central en un período de tiempo, cumpliendo con los requisitos legales de la normativa INEN 59:2012 y asegurando una operación adecuada y sostenible de la central. Además, se valida su efectividad con los datos reales obtenidos y su respectivo porcentaje de error (Aguilar & Paredes, 2018, p. 12).

GRU

Este modelo se utilizó debido a su capacidad para procesar en profundidad y capturar relaciones de tendencias no lineales y patrones complejos de datos. Es recurrente en este tipo de proyectos y puede recordar información a largo plazo en los datos de caudales. Los datos históricos que se manejan pueden tener vacíos en su secuencia, pero con este

modelo, los errores son minimizados ya que puede predecir lagunas de datos. Se considera una variante avanzada de LSTM debido a sus diseños similares y excelentes resultados, ya que combina las compuertas de olvido y entrada en una única actualización. La mención a esta red neuronal en este documento no es caprichosa, ya que se ha demostrado que GRU es mejor en algunas aplicaciones en comparación con la versión básica de LSTM. Además, GRU surge como una optimización de LSTM en cuanto al número de parámetros, ya que no tiene una unidad de memoria como tal.

La ecuación para la update gate es la siguiente:

$$u_t = \sigma(W_u h_{t-1} + W_U x_t + b_u) \quad (1)$$


reset gate:

$$r_t = \sigma(W_r h_{t-1} + W_r x_t + b_r) \quad (2)$$

La compuerta de reinicio (reset gate) se combina con el estado anterior (h_{t-1}) y se aplica la función tangente hiperbólica (\tanh) para determinar qué información se va a reiniciar.

Figura 3

Representación de la celda GRU y sus operaciones internas



$$\hat{h}_t = \tanh(W_h h_{t-1} + W_h x_t + b_h) \quad r_t + W_h h_{t-1} + b_h \quad (3)$$

Por último, la utilización de una media exponencial nos permite combinar dicho resultado anterior con el estado previo:

$$h_t = u_t \hat{h}_t + (1 - u_t) h_{t-1} \quad (4)$$

GRU, al igual que LSTM tiene una matriz de pesos para cada tipo de compuerta, donde W_u son los pesos para la update gate, W_r los pesos para la reset gate y W_h los pesos de la combinación del update con la entrada actual.

Discusión

En esta sección se muestran los resultados del entrenamiento y validación de la comparación entre GRU y LSTM, propuesta y creada mediante el lenguaje de programación Python. Para el aprendizaje y validación de la RNA, se utilizan datos diarios. Además, se compara la predicción de la generación eléctrica utilizando redes neuronales artificiales con la que existe actualmente en ELEPCO S.A., que es una regresión lineal simple. Esto se hace para demostrar la eficacia de la RNA para esta aplicación. Finalmente, se presentan los resultados de la predicción de la generación eléctrica.

Análisis de correlación de la información de la centralhidroeléctrica Illuchi

Uno de los desafíos al depurar la base de datos original es determinar si las variables tienen un comportamiento similar, es decir, si están correlacionadas entre sí. Como se muestra en la tabla, las variables de año, mes, día, hora y demanda de energía eléctrica tienen un comportamiento similar, lo que indica que están correlacionadas

Tabla 1

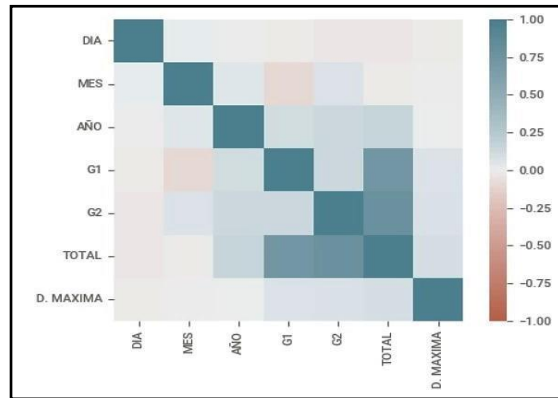
Variables usadas para la predicción de la demanda de energía Eléctrica

	DIA	MES	AÑO	G1	G2	TOTAL	D.MAXIMA
DIA	1.000.000	0,011726	-0,006109	-0,012916	-0,028274	-0,027828	-0,019256
MES	0,011726	1.000.000	0,042998	-0,100125	0,069436	-0,014784	-0,000606
AÑO	-0,006109	0,042998	1.000.000	0,114879	0,140095	0,169962	0,001297
G1	-0,012916	-0,100125	0,114879	1.000.000	0,13421	0,723899	0,062664
G2	-0,028274	0,069436	0,140095	0,13421	1.000.000	0,780818	0,076846
TOTAL	-0,027828	-0,014784	0,169962	0,723899	0,780818	1.000.000	0,093008
D.MAXIMO	-0,019256	-0,000606	0,001297	0,062664	0,076846	0,093008	1.000.000

Una forma de visualizar la correlación entre variables es mediante un mapa de calor, como se muestra en la figura 4.

Figura 4

Mapa de calor para verificar la correlación entre las variables de entrada



Un mapa de calor muestra las relaciones entre múltiples variables. Las áreas marcadas en verde indican que las variables están fuertemente relacionadas, lo que es una de las principales razones por las que se seleccionaron estas variables para realizar la predicción. Además, el mapa de calor permite analizar los grupos generados en relación con el comportamiento de la demanda de energía eléctrica. Por ejemplo, en el caso del generador 1, se observó que este grupo generador consume una gran parte de la energía eléctrica total generada por la CENTRAL HIDROELÉCTRICA ILLUCHI

En la tabla 2, se muestra la predicción de la generación de energía utilizando el método de unidades recurrentes cerradas (GRU) y se calculan los errores correspondientes. Se observa que este modelo presenta un error del 3,94% según el cálculo del error porcentual absoluto medio (MAPE).

Tabla 2

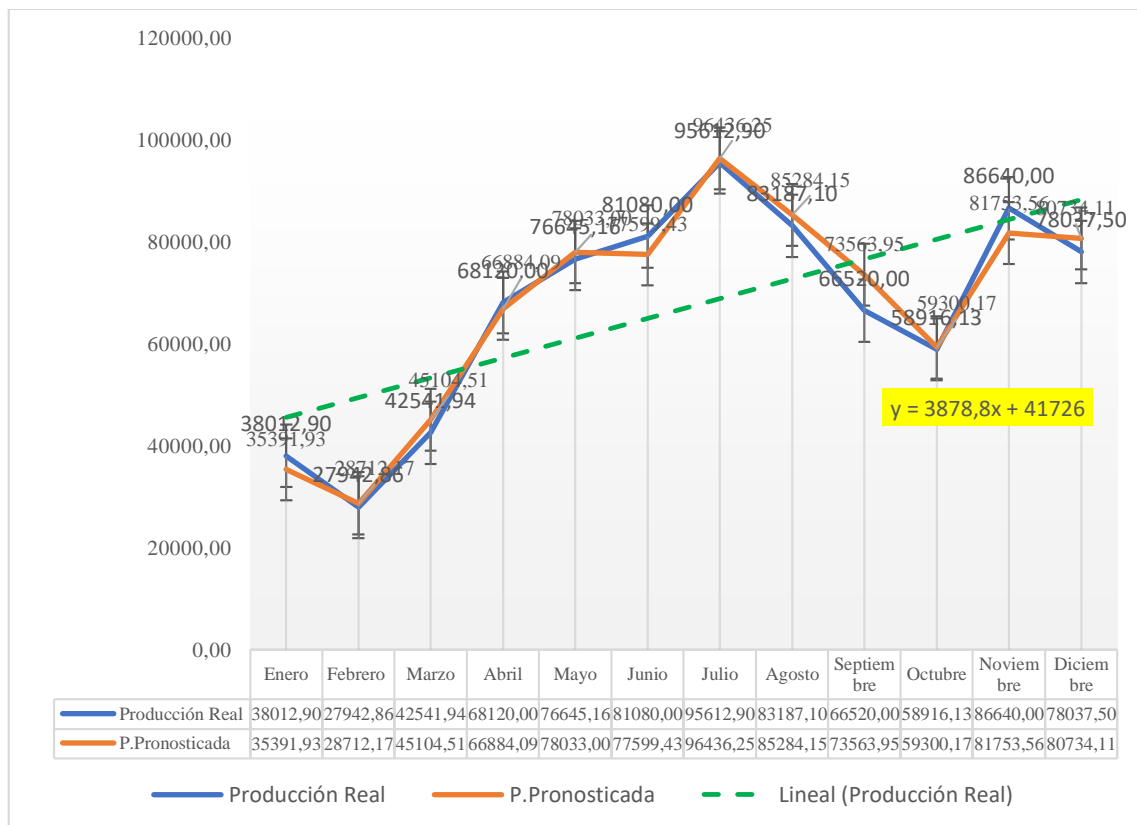
n	Mes	Producción Real	P. Pronosticada	Error Abs.	Error % Abs.	∑ Error Abs.	MAD	Error Nor.	∑ Error Nor.	TS
1	Enero	38012,90	35391,93	2620,970784	6,89%	2620,970784	2621,0	2620,970784	2620,970784	1
2	Febrero	27942,86	28712,17	769,3139497	2,75%	3390,284734	1695,1	-769,3139497	1851,656835	1,1
3	Marzo	42541,94	45104,51	2562,5742	6,02%	5952,858935	1984,3	-2562,5742	-710,9173658	-0,4
4	Abril	68120,00	66884,09	1235,909896	1,81%	7188,76883	1797,2	1235,909896	524,9925301	0,3
5	Mayo	76645,16	78033,00	1387,843498	1,81%	8576,612328	1715,3	-1387,843498	-862,8509679	-0,5
6	Junio	81080,00	77599,43	3480,573568	4,29%	12057,1859	2009,5	3480,573568	2617,7226	1,3
7	Julio	95612,90	96436,25	823,3477822	0,86%	12880,53368	1840,1	-823,3477822	1794,374818	1
8	Agosto	83187,10	85284,15	2097,05494	2,52%	14977,58862	1872,2	-2097,05494	-302,680122	-0,2
9	Septiembre	66520,00	73563,95	7043,954036	10,59%	22021,54265	2446,8	-7043,954036	-7346,634158	-3
10	Octubre	58916,13	59300,17	384,0447329	0,65%	22405,58739	2240,6	-384,0447329	-7730,678891	-3,5
11	Noviembre	86640,00	81753,56	4886,436849	5,64%	27292,02424	2481,1	4886,436849	-2844,242042	-1,1
12	Diciembre	78037,50	80734,11	2696,605469	3,46%	29988,6297	2499,1	-2696,605469	-5540,847511	-2,2
				SUMA %	47,31%					
				n	12					
				MAPE	3,94%					

Nota: Predicción de la generación de energía mediante GRU

A continuación, en la figura 5, se muestra el comportamiento de las curvas de la producción real vs la producción pronosticada en GRU, donde se puede apreciar de mejor manera una similitud alta entre las curvas y su distorsión en cada mes del año.

Figura 5

Comportamiento de la predicción real-pronosticada RGU



En la tabla 3. Se realizó la predicción de la generación mediante el método LSTM y se calculó sus respectivos errores, en donde se observa que en este modelo existe un error MAPE del 3,85%.

Tabla 3

Predicción de la generación de energía modelo RNA-LSTM

n	Mes	Producción Real	P. Pronosticada	Error Abs.	Error % Abs.	Σ Error Abs.	MAD	Error Nor.	Σ Error Nor.	TS
1	Enero	38012,90	36934,35	1078,548387	2,84%	1078,548387	1078,5	1078,548387	1078,548387	1
2	Febrero	27942,86	26793,18	1149,678571	4,11%	2228,226959	1114,1	1149,678571	2228,226959	2
3	Marzo	42541,94	46493,97	3952,033392	9,29%	6180,260351	2060,1	-3952,033392	-1723,806434	-0,8
4	Abril	68120,00	65723,87	2396,133333	3,52%	8576,393684	2144,1	2396,133333	672,3268997	0,3
5	Mayo	76645,16	75459,42	1185,740675	1,55%	9762,134359	1952,4	1185,740675	1858,067575	1
6	Junio	81080,00	75375,15	5704,851562	7,04%	15466,98592	2577,8	5704,851562	7562,919138	2,9

Tabla 3

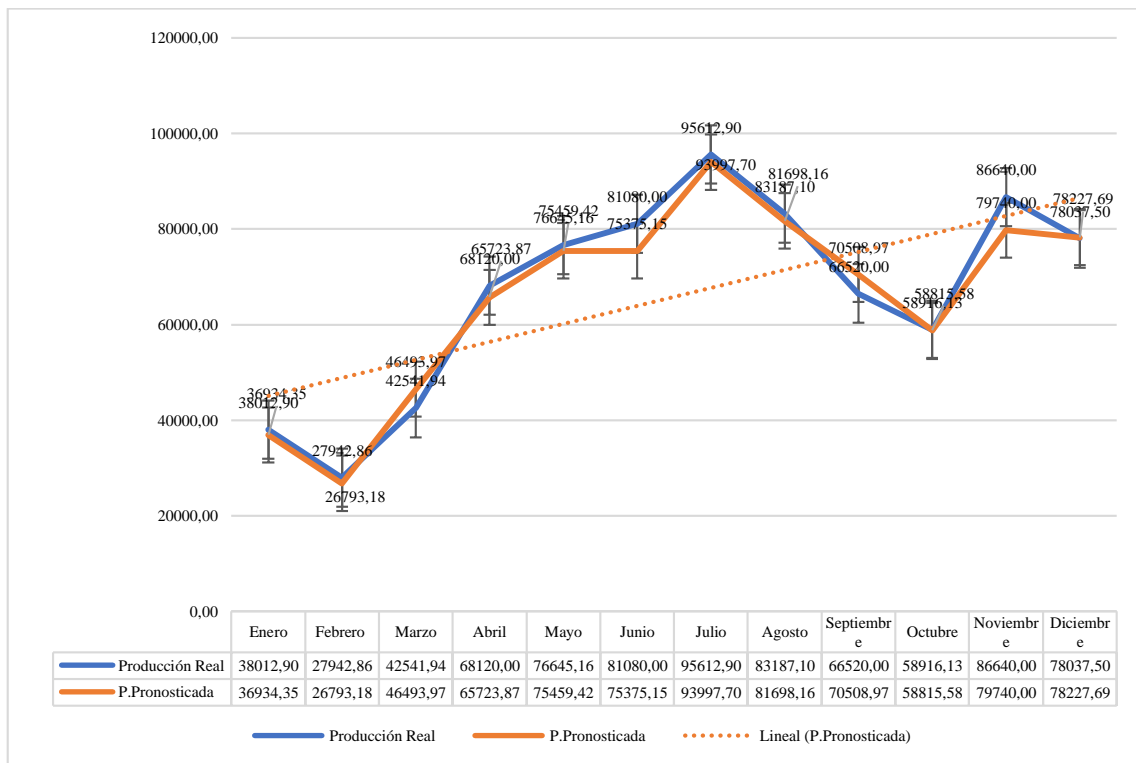
Predicción de la generación de energía modelo RNA-LSTM (continuación)

n	Mes	Producción Real	P. Pronosticada	Error Abs.	Error % Abs.	Σ Error Abs.	MAD	Error Nor.	Σ Error Nor.	TS
7	Julio	95612,90	93997,70	1615,204889	1,69%	17082,19081	2440,3	1615,204889	9178,124027	3,8
8	Agosto	83187,10	81698,16	1488,935988	1,79%	18571,1268	2321,4	1488,935988	10667,06001	4,6
9	Septiembre	66520,00	70508,97	3988,972396	6,00%	22560,09919	2506,7	-3988,972396	6678,087619	2,7
10	Octubre	58916,13	58815,58	100,5516633	0,17%	22660,65086	2266,1	100,5516633	6778,639282	3
11	Noviembre	86640,00	79740,00	6899,995182	7,96%	29560,64604	2687,3	6899,995182	13678,63446	5,1
12	Diciembre	78037,50	78227,69	190,1943359	0,24%	29750,84038	2479,2	-190,1943359	13488,44013	5,4
				SUMA %	46,20%					
				n	12					
				MAPE	3,85%					

En la figura 6 se muestra el comportamiento de las curvas de la producción real vs la producción pronosticada en LSTM, donde se puede apreciar de mejor manera una similitud alta entre las curvas y su distorsión en cada mes del año.

Figura 6

Comportamiento de la predicción real – pronosticada LSTM




Nota: Generación-Actual VS LSTM

La figura 7 muestra la información recopilada en las tablas 1 y 2, representada en dos gráficos de barras que muestran el comportamiento de la Desviación Media Absoluta (MAD). Estos gráficos permiten evaluar la dispersión de los valores analizados en relación con los valores esperados y proporcionan una medida de los errores promedio de los pronósticos. Según el análisis realizado, el método de Redes Neuronales Artificiales con memoria a largo plazo (RNA-LSTM) presenta un error inferior en comparación con el método de unidades recurrentes cerradas (GRU).

Figura 7


Comportamiento de la desviación media absoluta



Se realizó un análisis en la figura 8, utilizando los resultados obtenidos de las predicciones de los dos métodos empleados para validar la predicción de la generación de energía. Se puede observar que la predicción más precisa se logró mediante el uso del modelo matemático RNA-LSTM en el programa Python, obteniendo un error porcentual absoluto medio del 3,85%, a diferencia de las GRU donde se obtuvo un error del 3,94%. Como se mencionó previamente, este valor debe ser inferior al 5 %. Por lo tanto, se puede concluir que el análisis y la validación son adecuados.

Figura 8

Comportamiento de demanda KW para su validación



Conclusiones

- Las Redes Neuronales Artificiales (RNA) son capaces de predecir con mayor precisión que las unidades recurrentes cerradas (GRU), ya que presentan un error del 3.85% en comparación con el 3.94% de error de las GRU. Esto significa que las RNA son ligeramente más precisas en sus predicciones que las GRU. Sin embargo, es importante tener en cuenta que la elección entre RNA y GRU puede depender de otros factores, como la longitud de la secuencia de entrenamiento y la infraestructura disponible.
- Las GRU generalmente se usan cuando tiene muestras de entrenamiento de secuencia larga y desea una precisión rápida y decente y tal vez en casos donde la infraestructura es un problema. Se prefieren los RNN cuando la longitud de la secuencia es mayor y existe un buen contexto. Los LSTM, cuando se entrenan con más datos, le brindan mejores resultados que los GRU.
- Las unidades recurrentes cerradas (GRU) suelen utilizarse cuando se tienen secuencias de entrenamiento largas y se desea obtener una precisión rápida y decente, especialmente en casos donde la infraestructura es un problema. Por otro lado, las redes LSTM se prefieren cuando la longitud de la secuencia es mayor y

hay un buen contexto disponible. Cuando se entrenan con más datos, las redes LSTM pueden proporcionar mejores resultados que las GRU.

- Después de realizar un estudio investigativo y consultar varias referencias bibliográficas relacionadas con la predicción de la generación eléctrica, se desarrolló un programa computacional en el lenguaje de programación Python para predecir la generación eléctrica utilizando redes neuronales recurrentes.
- Al realizar un análisis exhaustivo de la base de datos de la CENTRAL HIDROELÉCTRICA ILLUCHI, se identificaron las variables de entrada mediante la creación de un mapa de calor que muestra la correlación entre ellas. Con esta información, se definió la aplicación e implementación de la red neuronal.

Referencias Bibliográficas

- Aguilar, M., & Paredes, A. (2018). *Incidencia de los proyectos emblemáticos de generación eléctrica ejecutados en el periodo 2007-2016 en la oferta eléctrica del país y su prospectiva al año 2030*. <http://repositorio.puce.edu.ec/handle/22000/15074>
- Bunnoon, P. (2011, August). Mid-Term Load Forecasting Based on Neural Network Algorithm: A Comparison of Models. *IJCEE*, 3(4), 600-605. doi:10.17706/IJCEE
- Caja, O. (2020). *Librería Python para el aprendizaje y la implementación de redes neuronales*. Universidad Politécnica de Valencia: <https://riunet.upv.es/handle/10251/152226>
- Carrera, I. (2020). *Generación de Energía*. <https://www.haimec.cl/generacion-de-energia/>
- Castillo, J., Carrillo, G., Freire, L., & Corrales, B. (2022a). Modelado y Simulación energética de un edificio para realizar análisis de sensibilidad del consumo energético. *Energy Reports*. doi:10.1016/j.egyr.2022.10.197
- Castillo, J., Resabala, V., Luigi, F., & Corrales, B. (2022b). Modelización y análisis de sensibilidad del consumo energético de los edificios mediante el método Monte Carlo. *Energy Reports*, 518-524. doi:10.1016/j.egyr.2022.10.198
- Cueva, J. (2018). Rediseño y construcción de un sistema de filtro de agua automático y estudio para la disminución de la velocidad del agua en el canal. 65-67. Quito, Ecuador.
- Del Canto, Ä. (2019). *IArtificial.net*. <https://www.iartificial.net/gradiente-descendiente-para-aprendizaje-automatico/>

- Eseye, A., & Tukia, T. (2019, June). Machine Learning Based Integrated Feature Selection Approach for Improved Electricity Demand Forecasting in Decentralized Energy Systems. *IEEE*, 7, 91463-91475. doi:10.1109/ACCESS.2019.2924685
- GreenLux. (2021). *Paneles Solares*. <https://www.greenlux.com.mx/wiki/generacion-de-energia-electrica/>
- Illidge, J., Chacon, J., & Chacon, A. (2020). Diseño y simulación de un sistema pico-hydro para la generación de energía eléctrica en zonas rurales, mediante un software de mecánica de fluidos computacional. *Revista UIS Ingenierías*, 19(1). <https://doi.org/10.18273/revuin.v19n1-2020015>
- Nieve, J. (2021). *Estructura Del Sistema Operativo*. <https://es.scribd.com/document/483578733/Unidad-I-Recurso-4-Estructura-del-Sistema-Operativo#>
- Ramírez, A. (2013). *Métodos utilizados para el pronóstico de generación eléctrica en sistemas de distribución*. <https://repositorio.utp.edu.co/server/api/core/bitstreams/ee2fb283-daa7-4987-b747-faa1e42e9711/content>
- Rodríguez, V. (2018). *Conceptos básicos sobre redes neuronales*. <https://vincentblog.xyz/posts/conceptos-basicos-sobre-redes-neuronales>
- Sahagún, P. (2018). *Aplicación de redes neuronales convolucionales y recurrentes al diagnóstico*. https://oa.upm.es/50400/1/TFG_PABLO_RODRIGUEZ_SAHAGUN_ALESAN_CO.pdf
- Ti, Z., Wei, X., & Mingming, Z. (2021, July). Artificial Neural Networks based wake model for power prediction of wind farm. *Renewable Energy*, 172, 618-631. <https://doi.org/10.1016/j.renene.2021.03.030>

Conflicto de intereses

No existe conflicto de intereses en relación con el artículo presentado.

El artículo que se publica es de exclusiva responsabilidad de los autores y no necesariamente reflejan el pensamiento de la **Revista Alfa Publicaciones**.



El artículo queda en propiedad de la revista y, por tanto, su publicación parcial y/o total en otro medio tiene que ser autorizado por el director de la **Revista Alfa Publicaciones**.



Indexaciones

