



UNIVERSIDAD TÉCNICA DE COTOPAXI

DIRECCIÓN DE POSGRADO

MAESTRÍA EN ELECTRICIDAD

MODALIDAD: INFORME DE INVESTIGACIÓN

Título:

Unidades Recurrentes Cerradas (GRU) vs Redes Neuronales Artificiales en la predicción de la generación Eléctrica de la Central Hidroeléctrica Illuchi.

Trabajo de titulación previo a la obtención del título de Magíster en Electricidad
mención Sistemas Eléctricos de Potencia

Autor:

Ing. Fernando Santiago Bustamante Freire

Tutora:

Ing. MSc. Jessica Nataly Castillo Fiallos

LATACUNGA - ECUADOR

2023

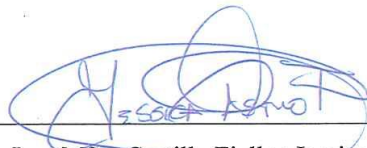
APROBACIÓN DEL TUTOR

En mi calidad de Tutor del Trabajo de Titulación “Unidades Recurrentes Cerradas (GRU) vs Redes Neuronales Artificiales en la predicción de la generación eléctrica de la Central Hidroeléctrica Illuchi” presentado por Ing. Bustamante Freire Fernando Santiago, para optar por el título magíster en Electricidad mención Sistemas Eléctricos de Potencia.

CERTIFICO

Que dicho trabajo de investigación ha sido revisado en todas sus partes y se considera que reúne los requisitos y méritos suficientes para ser sometido a la presentación para la valoración por parte del Tribunal de Lectores que se designe y su exposición y defensa pública.

Latacunga, julio, 20, 2023



Ing. MSc. Castillo Fiallos Jessica Nataly

C.C. 0604590216



APROBACIÓN TRIBUNAL

El trabajo de Titulación: “Unidades Recurrentes Cerradas (GRU) vs Redes Neuronales Artificiales en la predicción de la generación eléctrica de la Central Hidroeléctrica Illuchi”, ha sido revisado, aprobado y autorizada su impresión y empastado, previo a la obtención del título de Magíster en Electricidad mención Sistemas Eléctricos de Potencia; el presente trabajo reúne los requisitos de fondo y forma para que el estudiante pueda presentarse a la exposición y defensa.

Latacunga, julio, 25, 2023

.....
Ing. MSc. Luigi Orlando Freire Martínez
CC.: 0502529589
Presidente del tribunal

.....
Ing. MSc. Byron Paul Corrales Bastidas
CC.: 0502347768
Lector 2

.....
Ing. MSc. Jaime Daniel Nasimba Quinatoa
CC.: 1803832227
Lector 3

DEDICATORIA

Dedico con todo mi corazón este trabajo de titulación a mi madre, pues sin ella no lo habría logrado.

Tu bendición a diario a lo largo de mi vida me has protegido y por ello como ofrenda por tu paciencia y amor incondicional te regalo mi trabajo.

Fernando Santiago

AGRADECIMIENTO

Agradezco a Dios todopoderoso, porque ha estado conmigo en el trayecto de mi vida, por darme amor, salud, sabiduría y por su inmensa misericordia. A mi querida familia, pilar fundamental de mi vida, mi gran inspiración para ser mejor cada día, gracias amada familia por su amor, por su entrega, por su lucha diaria, por acompañarme en mis noches de desvelos, por ser mi apoyo incondicional.

A mi tutora de Tesis la Ing.MSc. Jessica Castillo que con sus sabios consejos y experiencia aportó de la mejor manera, para presentar un trabajo de calidad.

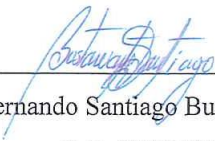
A la Universidad Técnica de Cotopaxi, por abrirme las puertas y desarrollar mi estudio de posgrado. También un agradecimiento a todos los docentes que, gracias a su esfuerzo y compromiso, contribuyeron de manera extraordinaria en mi formación profesional.

Fernando Santiago

RESPONSABILIDAD DE AUTORÍA

Quien suscribe, declara que asume la autoría de los contenidos y los resultados obtenidos en el presente Trabajo de Titulación.

Latacunga, julio, 20, 2023



Ing. Fernando Santiago Bustamante Freire
C.C. 0502985005

RENUNCIA DE DERECHOS

Quien suscribe, cede los derechos de autoría intelectual total y/o parcial del presente trabajo de titulación a la Universidad Técnica de Cotopaxi.

Latacunga, julio, 20, 2023



Ing. Fernando Santiago Bustamante Freire

C.C. 050298500-5

AVAL DEL PRESIDENTE

Quien suscribe, declara que el presente Trabajo de Titulación: **Unidades Recurrentes Cerradas (GRU) vs Redes Neuronales Artificiales en la predicción de la generación Eléctrica de la Central Hidroeléctrica Illuchi**, contiene las correcciones a las observaciones realizadas por los miembros del tribunal en la predefensa.

Latacunga, julio, 20, 2023



Ing. MSc. Luigi Orlando Freire Martínez
C.C. 0502529589

**DIRECCIÓN DE POSGRADO
MAESTRÍA EN ELECTRICIDAD MENCIÓN SISTEMAS
ELÉCTRICOS DE POTENCIA**

Título: Unidades Recurrentes Cerradas (GRU) vs Redes Neuronales Artificiales en la predicción de la generación Eléctrica de la Central Hidroeléctrica Illuchi.

Autor: Ing. Fernando Santiago Bustamante Freire

Tutor: Ing. MSc. Jessica Nataly Castillo Fiallos

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.

Palabras clave: ADAM, Python, GRU, predicción, redes neuronales artificiales

UNIVERSIDAD TÉCNICA DE COTOPAXI
DIRECCIÓN DE POSGRADO

MAESTRÍA EN ELECTRICIDAD MENCIÓN SISTEMAS ELÉCTRICOS
DE POTENCIA

Title: Closed Recurrent Units (GRU) vs Artificial Neural Networks in the prediction of the electric generation of the Illuchi Hydroelectric Power Plant.

Author: Ing. Fernando Santiago Bustamante Freire

Tutor: Ing. MSc. Jessica Nataly Castillo Fiallos

ABSTRACT

The prediction of events has been since ancient times, a phenomenon capable of generating curiosity in the human being, however, to achieve a projection of a future event, a detailed analysis of data is required to predict subsequent events, with this idea, the objective of the research was to develop two prediction systems applying artificial neural networks and GRU to determine the forecast electricity generation in the ILLUCHI HYDROELECTRIC POWER PLANT. The data used for this study was collected from the operators of ELEPCO S.A. based on the years 2008 to 2020. The input variables were the date and the energy generated to elaborate different cases with different conditions in order to reach a successful Recurrent Neural Network model (Long Short Term Memory) possible. Once the model variables were understood, the data was divided into two groups: training 80% and validation 20% respectively. For the corresponding training, the ADAM algorithm and the libraries provided by Python were used.

Keywords: ADAM, Python, GRU, prediction, neural networks.

Yo, **Lcda. Elvia Geanneth Oña Ninasunta** con cédula de identidad número 0503209587, Licenciada en Ciencia de la Educación especialización Inglés con número de registro de la SENESCYT 1020-12-1168999; **CERTIFICO** haber revisado y aprobado la traducción al idioma inglés del resumen del trabajo de investigación con el título: **Unidades Recurrentes Cerradas (GRU) vs Redes Neuronales Artificiales en la predicción de la generación Eléctrica de la Central Hidroeléctrica Illuchi de Ing. Fernando Santiago Bustamante Freire** aspirante a magister en Electricidad mención Sistemas Eléctricos de Potencia.

Latacunga julio 27del 2023



.....
Lcda. Elvia Geanneth Oña Ninasunta

0503209587

ÍNDICE DE CONTENIDOS

1. INFORMACIÓN GENERAL.....	1
2. INTRODUCCIÓN.....	1
3. MATERIALES Y MÉTODOS.....	5
3.1 Generación de Energía eléctrica.....	5
3.2 Unidades recurrentes cerradas.....	5
3.3 Redes neuronales Recurrentes.....	7
4. METODOLOGÍA.....	8
4.1 GRU.....	8
4.2 LSTM.....	9
5. RESULTADOS Y DISCUSIÓN.....	13
6. CONCLUSIONES.....	19
7. REFERENCIAS Y BIBLIOGRAFIA.....	21

ÍNDICE DE TABLAS

Tabla 1: Selección preliminar de las variables para la predicción de generación eléctrica	11
--	----

ÍNDICE DE FIGURAS

Figura 1: Estructura del sistema GRU	6
Figura 2: Estructura del sistema LSTM	7
Figura 3: Representación de la celda GRU y sus operaciones internas	9
Figura 4: Comportamiento de la generación eléctrica procedente a una base de datos	10
Figura 5: Validación y procesamiento de la información procedente de una base de datos	11
Figura 6: Flujograma del algoritmo utilizado para la predicción de la generación eléctrica	12
Figura 7: Partición de los datos en subconjunto para la predicción de la demanda eléctrica	13
Figura 8: Análisis de la generación eléctrica por un periodo de un año	14
Figura 9: Análisis de la generación eléctrica mensual por un periodo de 5 años	15
Figura 10: Comportamiento de la generación eléctrica en el generador 1	16
Figura 11: Comportamiento de la generación eléctrica en el generador 2	16
Figura 12: Mapa de calor para verificar la correlación entre las variables de entrada	17
Figura 13: Predicción con GRU	17
Figura 14: Predicción con LSTM	18
Figura 15: Predicción con redes neuronales artificiales	18

1. INFORMACIÓN GENERAL

Título del proyecto:	Unidades recurrentes cerradas (GRU) vs redes neuronales artificiales en la predicción de la generación Eléctrica de la Central Hidroeléctrica Illuchi
Línea de investigación:	Energías alternativas y renovables, eficiencia Energética y Protección ambiental
Proyecto de investigación asociado:	Desarrollo de sistemas eficientes para el abastecimiento y uso de energía eléctrica a nivel local, regional y nacional
Grupo de investigación:	Sistemas eléctricos de potencia
Red nacional o internacional:	Instituto de ingenieros Eléctricos y Electrónicos IEEE

2. INTRODUCCIÓN

La generación de energía eléctrica es de gran importancia, y eso se refleja en la variedad de estudios relacionados al trabajo de investigación, si bien es conocido que la generación tiene una característica no lineal, debido a su comportamiento variado, esto incita a más investigadores a cambiar su metodología y de esta forma conseguir mejores resultados [1]. Existen modelos de predicción relacionado con la producción de energía eléctrica mediante la aplicación de técnicas de aprendizajes computacionales, mejorando el aprovechamiento del recurso hídrico proveniente de los ríos.

Se identifica el uso de técnicas y modelos basados en Machine Learning característicos por la aplicación de modelos de redes neuronales artificiales, para obtener mejores resultados en comparación a diferentes técnicas tradicionales como: Regresión lineal, ARIMA, etc. Aplicando en la predicción de generación y otros fenómenos estocásticos. La importancia de utilizar Machine Learning [2] recae en las predicciones, los rangos de error y los valores finales, esto debido al comportamiento en la selección de variables, cuando mencionamos Machine

Learning se hace referencia a un modelo de análisis de datos que automatiza la construcción de modelos analíticos, además, es una rama de la inteligencia artificial basada en los aprendizajes por datos, esta se determina por identificar patrones típicos y tomar decisiones con respecto a variables sin la intervención de humanos [3].

Al aplicar un modelo de predicción en la generación lograremos identificar curvas típicas de comportamiento en los generadores 1 y 2 de la Central Hidroeléctrica ILLUCHI, además estos valores y gráficos permitirán realizar recomendaciones de uso o identificar problemas en la generación. Por lo que se plantea realizar una comparación de comportamiento en la generación establecida la primera por una unidad recurrente cerrada y la otra una LSTM, las mismas que serán evaluadas a través de sus resultados en gráficos y el manejo y selección de variables y datos.

Las redes neuronales artificiales como GRU y los LSTM utilizan diferentes enfoques para controlar la información a fin de evitar el problema del gradiente de desaparición. Estos son los puntos principales de comparación entre los dos métodos [4]. 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).

Para el manejo de datos se realiza la verificación de la red neuronal artificial, mediante un conjunto de datos denominados datos de validación. La verificación del funcionamiento de la red neuronal artificial se la realiza al predecir la generación eléctrica con nuevos datos que no han sido utilizados en los entrenamientos anteriores para luego compararlos con datos reales. Los datos de entrenamiento se ajustan a los parámetros de la red neuronal, como por ejemplo los pesos que interconectan las neuronas en las diferentes capas. Para ello se utiliza algún método de entrenamiento supervisado, para intentar predecir la salida a partir

de los datos de entrada. Habitualmente este conjunto de datos representa alrededor del 70 % de toda la base de datos.

Una vez analizado las variables del modelo, los datos se dividen en tres grupos: entrenamiento, prueba y validación. Se utilizan los porcentajes 80 % y 20 %, donde el 80 % es el entrenamiento de los valores recolectados y el 20 % es la validación final de modelo planteado, como se ha manifestado, las GRUs o unidades de corrientes cerradas son una variación del diseño de las RNN, estas a su vez utilizan un proceso de compuerta para gestionar y controlar el flujo de automatización entre las células de la red neuronal. Las GRUs pueden facilitar la captación de dependencia sin ignorar la información pasada de fragmentos masivos de datos secuenciales [5][12].

Todo esto se realiza a base de compuertas, las mismas que ayudan a resolver los problemas de gradiente de desaparición que se encuentran a menudo en las redes neuronales registradas tradicionalmente. Estas puertas son útiles para controlar la información que se debe mantener o descartar en cada depuración.

Además, se debe tomar en cuenta que las unidades recurrentes con compuertas hacen uso de las compuertas de reinicio y actualización. La diferencia clave 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 (a saber, puertas de entrada, salida y olvido) [6]. Las GRU y los LSTM utilizan diferentes enfoques para controlar la información a fin de evitar el problema del gradiente de desaparición. Estos son los puntos principales que comparan los dos:

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.

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). Por esa razón, estamos viendo que se usa cada vez más.

Este proyecto de investigación revela la situación del sistema de generación mediante la utilización de redes neuronales artificiales para la predicción de generación de energía y su comportamiento en la CENTRAL HIDROELECTRICA ILLUCHI.

Para descomponer las características o rasgos de la situación de estudio en sus diversas características para lograr alcanzar un mejor entendimiento técnico, se utilizara una investigación descriptiva y aplicativa con la finalidad de reconocer hechos e ideas y definir en comportamiento de la generación en la CENTRAL HIDROELECTRICA ILLUCHI2, adquiriendo una base de datos históricos con valores de corriente, potencia de energía eléctrica adicionalmente se crea una vista previa de funcionamiento de la central. En esta parte de la investigación se pondrá en práctica todos los conocimientos técnicos y científicos que se han adquirido, mediante uso del programa computacional Python que ayuda a desarrollar los análisis necesarios y la programación de un algoritmo que permita realizar el pronóstico de la demanda de energía eléctrica para obtener resultados suficientemente aproximados a los valores reales.

Este método inductivo. Deductivo examina de forma descriptiva todos los temas y subtemas que se emplearon en el desarrollo del presente trabajo de investigación, este procedimiento ayuda a formular las conclusiones y recomendaciones que surgieron a través de todo el proceso de investigación. Con relación a los métodos aplicados se analizó cada una de las metodologías existentes para el pronóstico de la generación eléctrica, a partir del análisis de investigaciones desarrolladas en diferentes áreas, se desarrolló la implementación de un algoritmo que permitió obtener los datos pronosticados, de esta forma elaborando propios criterios para recomendar trabajos futuros que pueden ser elaborados y hasta mejorarlos en este tipo de investigaciones.

3. MATERIALES Y MÉTODOS

3.1 Generación de Energía eléctrica

La generación de energía eléctrica consiste en transformar alguna clase de energía (química, cinética, térmica, lumínica, nuclear, solar entre otras), en energía eléctrica. Para la generación industrial se recurre a instalaciones denominadas centrales eléctricas, que ejecutan alguna de las transformaciones citadas. Estas constituyen el primer escalón del sistema de suministro eléctrico [7]. La generación eléctrica se realiza, básicamente, mediante un generador eléctrico; si bien estos no difieren entre sí en cuanto a su principio de funcionamiento, varían en función a la forma en que se accionan.

Una central hidroeléctrica es aquella que se utiliza para la generación de energía eléctrica mediante el aprovechamiento de la energía potencial del agua embalsada en una presa situada a más alto nivel que la central. El agua se lleva por una tubería de descarga a la sala de máquinas de la central, donde mediante enormes turbinas hidráulicas se produce la electricidad en alternadores y el agua regresa a su cauce natural tras la salida de las turbinas [8]. Las dos características principales de una central hidroeléctrica, desde el punto de vista de su capacidad de generación de electricidad son:

La potencia, que es función del desnivel existente entre el nivel medio del embalse y el nivel medio de las aguas debajo de la central, y del caudal máximo turbinable, además de las características de la turbina y del generador, la energía garantizada en un lapso determinado, generalmente un año, que está en función del volumen útil del embalse, de la pluviometría anual y de la potencia instalada [13].

3.2 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 [9].

Una red recurrente básica tiene 2 entradas: el dato actual y el estado oculto anterior esto proporciona 2 salidas la predicción y el valor actualizado del estado oculto la idea es que esta red recurrente está en la capacidad de analizar una secuencia de datos de XY producir una predicción y para esto debemos recordar que primero la red tome el estado oculto anterior, así como la entrada y genera un nuevo estado oculto usando una transformación lineal [11].

Las Unidades Recurrentes Avanzadas GRU, son una variación avanzada de las SRRN (REDES NEURONALES RECURENTES ESTANDAR).

Las GRUs utilizan la puerta de actualización y la puerta de reinicio para resolver el problema del gradiente de fuga de una RRN estándar [10][12]. Esta se trata esencialmente de 2 vectores que deciden el tipo de información que se pasa a la salida. Lo que hace que estos vectores sean especiales es que los programadores pueden entrenarlos para almacenar información, especialmente de hace mucho tiempo.

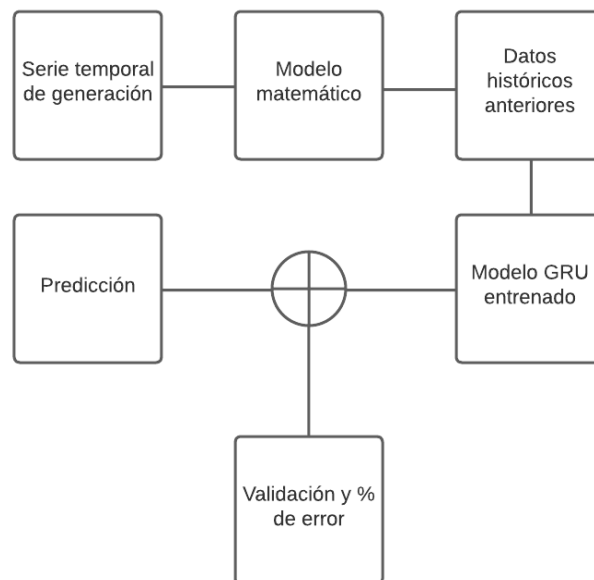


Figura 1: Estructura del sistema GRU

3.3 Redes neuronales Recurrentes

Una red LSTM es capaz de recordar un dato relevante en la secuencia y de preservarlo por varios instantes de tiempo por tanto puede tener una memoria tanto de corto plazo como las redes recurrentes básicas como también de largo plazo.

Funciona de forma similar a como nuestro cerebro analiza la secuencia si por ejemplo deseamos comprar un par de audífonos y le damos alguna valoración hecha por un comprador para tomar la decisión no nos enfocamos en la totalidad en lugar de ellos nos enfocamos únicamente en las palabras que consideramos relevantes las redes LSTM funcionan de manera similar y están en capacidad de añadir o eliminar la información que consideran relevantes para el procesamiento de la secuencia [14][15]

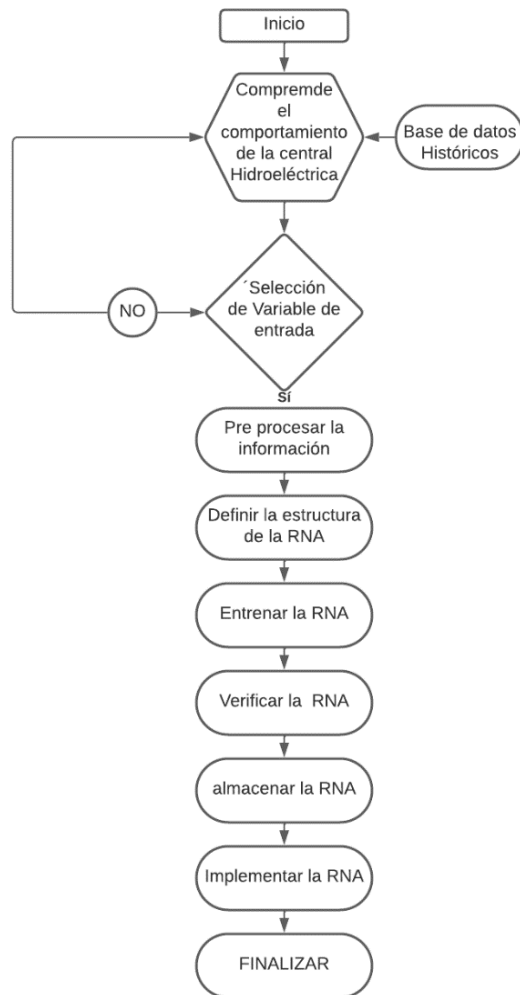


Figura 2: Estructura del sistema LSTM

4. METODOLOGÍA

El proyecto se basa en generar dos modelos de predicción para mini centrales hidroeléctricas en el Ecuador, para esto se ha tomado como referencia la mini central eléctrica de Illuchi 2 ubicada en la provincia de Cotopaxi en el cantón Latacunga, esto se realiza mediante la utilización de modelos matemáticos y entrenamiento de redes neuronales a través de un registro datos históricos de potencia desde año 2018-2023, estos son tomados diariamente debido a permite tener un registro preciso de la cantidad de agua que pasa por la central en un período de tiempo, para cumplir con requisitos legales de la normativa INEN 59:2012 y asegurar una operación adecuada, sostenible de la central y a su vez validar su efectividad con los datos reales obtenidos y su respectivo porcentaje de error.

4.1 GRU

Se utilizo este modelo por la profundidad de procesamiento ya que son capaces de 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 desea manejar pueden llegar a tener vacíos en su secuencia con el modelo mencionado los errores son minimizados ya que puede predecir lagunas de datos.

Se considera una variante avanzada de LSTM debido a sus diseños similares y a sus excelentes resultados ya que tiene una combinación de las compuertas de olvidar información y la de entrada en una única actualización. La mención a esta red neuronal en este documento no es caprichosa, se ha demostrado que GRU es mejor en algunas aplicaciones en comparación con la versión básica de LSTM; además, GRU surge como optimización de LSTM en cuanto a número de parámetros ya que como veremos a continuación, GRU no tiene una unidad de memoria como tal.

La ecuación para la update gate es la siguiente:

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

la de la reset gate:

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

dicha reset gate se va a combinar con el estado anterior h_{t-1} y se aplica la función \tanh para determinar qué información se va a reiniciar:

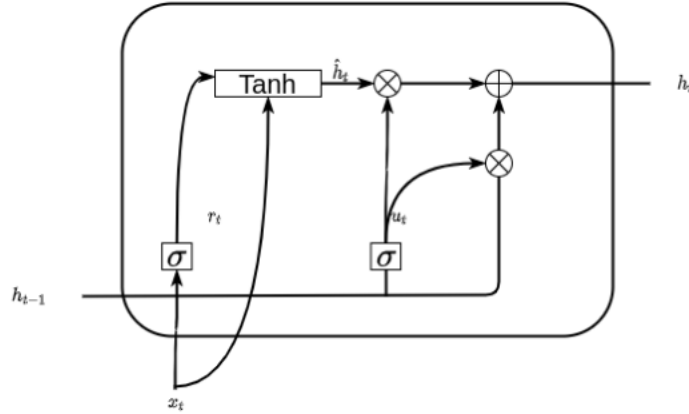


Figura 3: Representación de la celda GRU y sus operaciones internas

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

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

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

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.

4.2 LSTM

Al haber indagado toda la información fundamental se plantea elaborar el procedimiento para predecir la generación eléctrica mediante redes neuronales artificiales, presentándose de la siguiente forma.

Paso 1.- En primer lugar, se plantea comprender el comportamiento la variación de generación eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2 este paso está relacionado a buscar toda la información que permita conocer de correcta

manera la operación de la central (análisis de las curvas de generación eléctrica, hora, día, mes, año). El resultado final de este paso permite comprender toda la base de datos históricos.

Es necesario obtener una base de datos previa, de esta forma hacer una estimación de una posible técnica de predicción que se pretende utilizar. Un punto de partida que se propone emplear es visualizando el comportamiento de la generación máxima utilizando el 100% del total de nuestra base de datos, (año 2018 hasta el año 2023).




Figura 4: Comportamiento de la generación eléctrica procedente a una base de datos

Paso 2.- Seleccionar las variables de entrada de la base de datos acorde a la aplicación. En base a los datos adquiridos en el paso 1, se plantea seleccionar las variables de entrada que influyan en la variación de la generación eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

La selección de las variables de entrada que se presenta en la tabla, utilizados para la predicción de generación eléctrica se desarrolla previo a una base de datos que está compuesta por varios documentos en Excel, estos datos fueron recogidas por los operadores de la CENTRAL HIDROELÉCTRICA ILLUCHI 2, desde el año del 2018 hasta el año del 2023.

Tabla 1: Selección preliminar de las variables para la predicción de generación eléctrica

Variable	Descripción	Unidad de medida
Año	Tiempo de generación eléctrica	Año
Mes	Tiempo de generación eléctrica	Mes
Día	Tiempo de generación eléctrica	Día
Hora	Tiempo de generación eléctrica	Hora
Potencia total	Potencia total generada en Kilovatios	KW

Paso 3.- El tercer paso se encuentra la validación y preprocesamiento de los datos seleccionados como variables de entrada. La red neuronal artificial debe aprender y predecir en función de los datos históricos de las variables antes mencionadas. Se eliminarán la mayoría de los datos erróneos que existieron, para luego preprocesarlos mediante el lenguaje de programación denominado “Python” tal como se muestra en la figura

```
# rango = q75 - q25
rango = maximo - minimo
print('Rango = {}'.format(rango))
media = np.mean(data_pred_gru)
print('Media = {}'.format(media))
mediana = data_pred_gru.median()
print('Mediana = {}'.format(mediana))
varianza = data_pred_gru.var()
print('Varianza = {}'.format(varianza))
std = np.std(data_pred_gru)
print('Desviación Estándar = {}'.format(std))
coef_var = np.std(data_pred_gru) / np.mean(data_pred_gru) * 100
print('Coeficiente de variación = {}'.format(coef_var))
# lim_max, lim_min = np.percentile((data_pred_febr), [75, 25])
lim_max = media + 1 * std
lim_min = media - 1 * std
print('Límite máximo = {}'.format(lim_max))
print('Límite mínimo = {}'.format(lim_min))

data_pred_gru.describe()
```

```
.. Máximo = GENERACIÓN KW      110400.0000
   PREDICCIÓN KW      103651.8125
   dtype: float64
   Mínimo = GENERACIÓN KW      19200.000000
   PREDICCIÓN KW      31249.796875
   dtype: float64
   Rango = GENERACIÓN KW      91200.000000
   PREDICCIÓN KW      72402.015625
```

Figura 5: Validación y procesamiento de la información procedente de una base de datos

Paso 4.- Como cuarto paso se encuentra la definición la red neuronal artificial es decir la arquitectura de la red. Este paso es el más importante debido a que dependerá de una gran cantidad de entrenamientos y conseguir experiencias de las

predicciones, es necesario comparar entre diferentes estructuras de la red para encontrar el que mejor se ajuste a nuestras necesidades. En la figura 6 se presenta el diagrama de flujo necesario para la aplicación del algoritmo de predicción planteado.

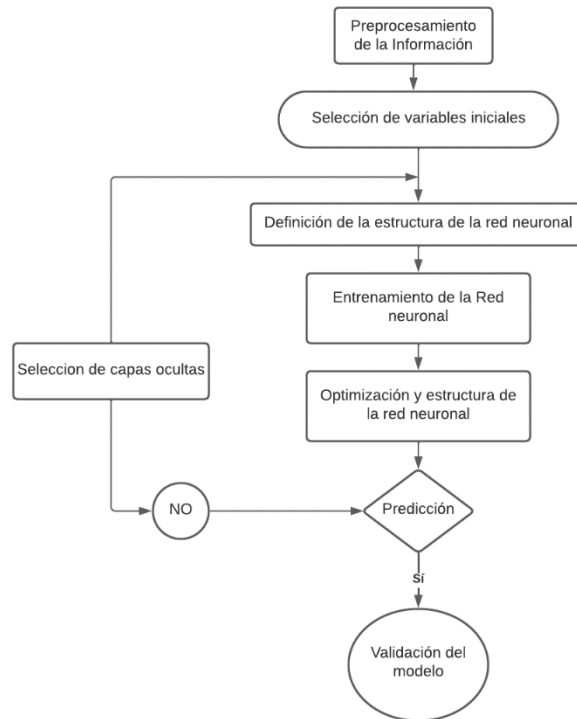


Figura 6: Flujograma del algoritmo utilizado para la predicción de la generación eléctrica

Paso 5.- Este paso se centra en el entrenamiento de la red neuronal artificial, para ello se debe tener en consideración los criterios de aprendizaje, el número de iteraciones, la aplicación de un conjunto de datos de entrenamiento. Al aplicar este paso se deberán asignar los valores finales, tanto en el número de retrasos y el algoritmo de entrenamiento a emplear para minimizar la función de coste aplicando el valor del criterio para la validación de los resultados.

Paso 6.- Como siguiente paso se encuentra la verificación de la red neuronal artificial, mediante un conjunto de datos denominados datos de validación. La verificación del funcionamiento de la red neuronal artificial se la realiza al predecir la generación eléctrica con nuevos datos que no han sido utilizados en los entrenamientos anteriores para luego compararlos con datos reales.

Conjunto de testeo: estos datos se utilizan para realizar una evaluación final del modelo. Habitualmente se representa un 20 % de los datos.

Una vez analizado las variables del modelo, los datos se dividen en tres grupos: entrenamiento, prueba y validación. Se utilizan los porcentajes 80 % y 20 % respectivamente tal como se presenta en la figura 5, estos porcentajes se modificarán al menos que los responsables lo crean necesario.



Figura 7: Partición de los datos en subconjunto para la predicción de la demanda eléctrica

Paso 7.- Como penúltimo paso se encuentra el almacenamiento de los parámetros de la red neuronal artificial una vez verificada. Es necesario almacenar los entrenamientos de la red neuronal artificial para aplicarlos en un futuro estudio, este paso ayuda a no tener la necesidad de repetir los dos últimos pasos, al menos que los responsables de este estudio lo crean necesario.

Paso 8.- Finalmente se debe implementar la red neuronal artificial para la predicción de la generación eléctrica.

5. RESULTADOS Y DISCUSIÓN

En esta sección se presentan los resultados del entrenamiento y validación de nuestra comparación entre GRU Y LSTM propuesta y creada a través del lenguaje de programación Python. Para el aprendizaje y validación de la RNA se utiliza datos diarios. Además, se compara la predicción de la generación eléctrica utilizando redes neuronales artificiales con la que existe actualmente en ELEPCO S.A. la cual es regresión lineal simple, esto para evidenciar la bondad de la RNA para la aplicación y finalmente se presenta los resultados de la predicción de la generación eléctrica.

Análisis de la Central Hidroeléctrica ILLUCHI 2

Una vez que se analizó el comportamiento de la generación utilizando el total de nuestra base de datos. Se procede a utilizar el 50 % de nuestra base de datos que están comprendidos entre el 2018 hasta el 2023 escogiendo los valores máximos para representar la variación de la generación eléctrica. En la figura 6, los meses de enero, abril, julio, agosto y octubre, noviembre y diciembre son los meses que se genera energía eléctrica, lo que no pasa en junio y septiembre que son los meses con menor generación en comparación a los demás meses del año.




Figura 8: Análisis de la generación eléctrica por un periodo de un año

Como se puede visualizar en la figura 6, existe un consumo mínimo en los meses de junio y septiembre, una de las razones por la cuales existe una disminución en el consumo de energía es debido a que en la provincia de Latacunga entra en una etapa de festividades tradicionales que se celebran cada año y en consecuencia el sector industrial, residencial realizan menos actividades, otra de las razones está relacionada con los estudiantes universitarios que estudian en la provincia y se encuentran en vacaciones, estos estudiantes toman la decisión de regresar a su provincia de origen. Los meses que siguen a continuación, progresivamente aumentan la generación debido a que varios sectores como el sector comercial y residencial requieren de mayor energía eléctrica, este es el caso de diciembre y enero, al ser las fechas que se utilizan una gran variedad de iluminación como las luces navideñas y en consecuencia aumenta la generación eléctrica.

De la misma manera que el caso anterior se utilizó la información de la generación máxima de cada mes para mostrar la variación que está sujeta a los elementos que consumen la energía eléctrica en la central hidroeléctrica. Tal como se muestra en la figura 7, donde la generación máxima se mantiene constante durante los primeros 28 días, formándose una variación durante los últimos días del mes




Figura 9: Análisis de la generación eléctrica mensual por un periodo de 5 años

Una de las razones por las cuales la generación varía en los últimos tres días del mes planteado es debido a que todos los meses no tienen exactamente 31 días, un claro ejemplo es febrero las cuales tienen 28 o 29 días cuando es año bisiesto, noviembre también tiene 30 días. Son factores que afecta en la variación de la generación.

Las figuras 8 y 9, ayudan a comprender el comportamiento de la generación máxima de cada uno de los grupos generadores que está compuesto la CENTRAL HIDROELÉCTRICA ILLUCHI 2.

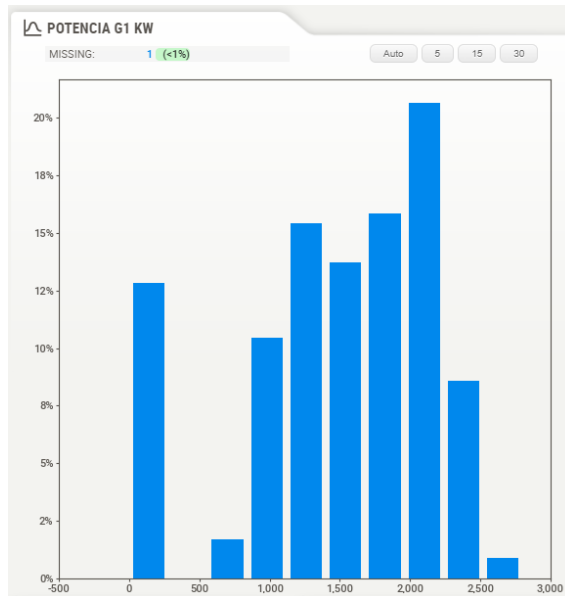


Figura 10: Comportamiento de la generación eléctrica en el generador 1

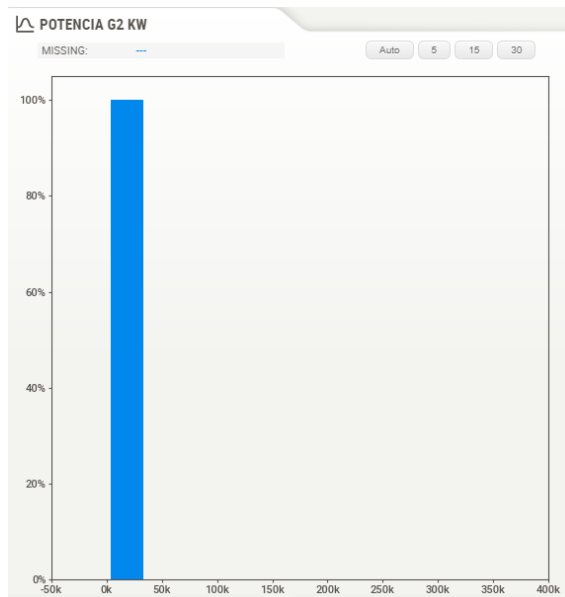


Figura 11: Comportamiento de la generación eléctrica en el generador 2

Correlación de información de la Central Hidroeléctrica ILLUCHI 2

El mapa de calor muestra las relaciones entre múltiples variables. Las áreas que están marcadas de color verde permiten entender que están perfectamente relacionadas, esta es una de las razones principales por las cuales se han seleccionado las variables que ayudarán a realizar la predicción, además con el mapa de calor se puede analizar los grupos generados con respecto al

comportamiento de la generación eléctrica, como el generador 1 en la cual se observó que el grupo generador que está consumiendo gran parte de energía eléctrica total que genera la CENTRAL HIDROELÉCTRICA ILLUCHI 2, una de las razones por las cuales tiene este efecto es que el generador 1 lleva más tiempo en funcionamiento en comparación que el generador 2. Otra razón está relacionada con el mantenimiento de cada grupo generador, es decir cuando el generador 1, sufra daños o deje de funcionar el generador 2 lo apoya e inmediatamente entra en funcionamiento, de esta forma la central mantiene su funcionamiento.




Figura 12: Mapa de calor para verificar la correlación entre las variables de entrada

Modelo para predicción GRU




Figura 13: Predicción con GRU

Modelo de aprendizaje LSTM

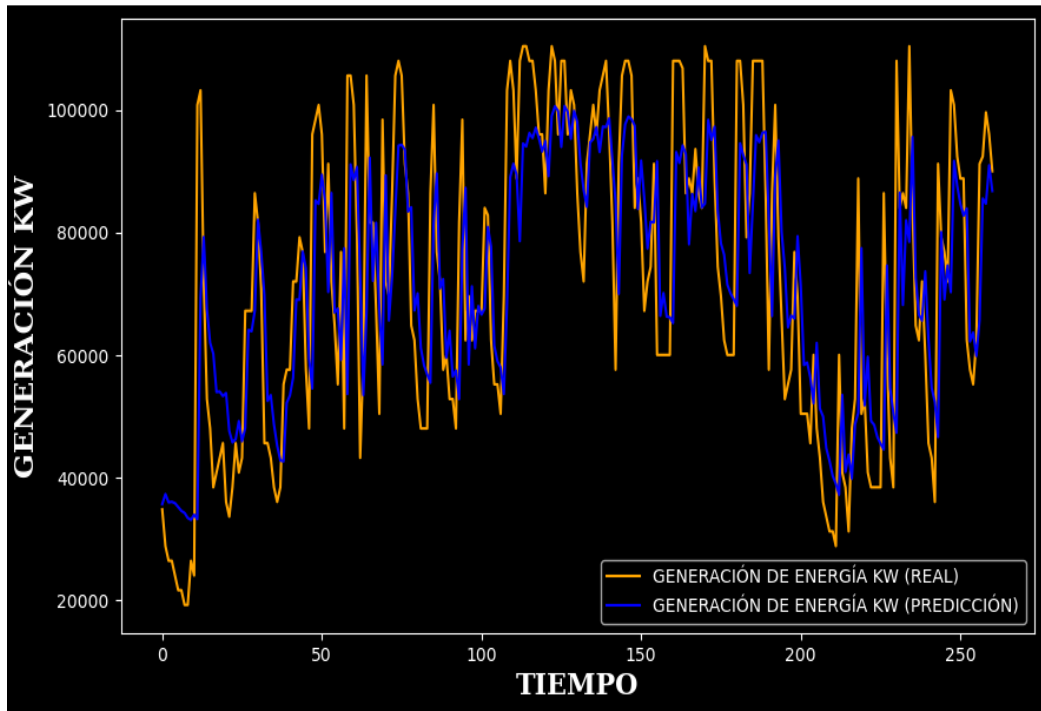


Figura 14: Predicción con LSTM

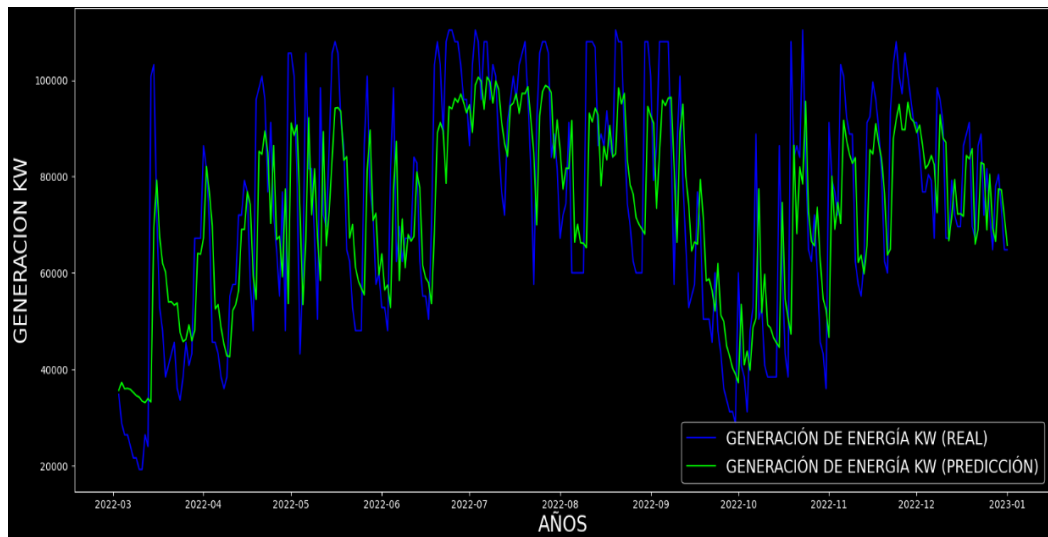


Figura 15: Predicción con redes neuronales artificiales

6. CONCLUSIONES

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 LSTM 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.

Al realizar el estudio investigativo con la ayuda de varias referencias bibliográficas relacionadas con la predicción de la generación eléctrica, se desarrolló completamente un programa computacional en base al lenguaje de programación Python que ayudaron en la predicción de la generación eléctrica basado en las redes neuronales recurrentes.

Al desarrollar un análisis completo de toda la base de datos de la CENTRAL HIDROELÉCTRICA ILLUCHI 2, se identificó las variables de entradas mediante la formación de un mapa de calor verificando la correlación que existe entre estas, con esta idea se define la aplicación e implementación de la red neuronal artificial aplicando diferentes librerías que proporciona Python.

El diseño del algoritmo para la predicción de la generación eléctrica en la CENTRAL HIDROELÉCTRICA ILLUCHI 2 se ha aplicado series de tiempo con Tensorflow para la conexión de los datos de entrada y Keras en el entrenamiento del algoritmo, se ha creado una red secuencial con la LSTM, la estructura de la RNA está formado por 10 neuronas de entrada, dos capas ocultas las cuales están compuestas por 2 capas dropout para evitar la memorización de datos y una salida para la predicción de la generación eléctrica.

Para el entrenamiento es necesario que los datos sean escalados para que no se alteren los diferentes valores. Utilizando la red neuronal artificial, mediante el manejo del optimizador de entrenamiento RMSprop, con 10 números de retrasos, 10 neuronas, el 80 % de datos de entrenamiento, 20 % datos de validación, para obtener resultados pronosticados, de esta forma proporcionando un acercamiento a

los datos reales. Con este modelo se logró confirmar la hipótesis planteada en el trabajo de investigación.

La precisión y exactitud del modelo de red neuronal artificial recurrente está ligado a la configuración de la red y el tiempo de entrenamiento, en la actualidad no existen algoritmos exactos para lograr encontrar la mejor configuración, reducir el tiempo de entrenamiento, además del recurso computacional limitado que se posee, esto trae como consecuencia, realizar varias iteraciones para conseguir el menor error posible.

Es necesario considerar que no siempre el error disminuye a un mayor tiempo de entrenamiento. Con el acceso de una supercomputadora que permita desarrollar varios modelos, es indudable que los resultados serían óptimos de esta forma se podrá lograr una disminución considerable en el error entre los datos reales y los pronosticados.

7. REFERENCIAS Y BIBLIOGRAFIA

- [1] M. A. Aguilar Paredes, «“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”», 2018, Accedido: 12 de diciembre de 2021. [En línea]. Disponible en: <http://repositorio.puce.edu.ec:80/xmlui/handle/22000/15074>
- [2] Z. Ti, X. W. Deng, y M. Zhang, «Artificial Neural Networks based wake model for power prediction of wind farm», *Renewable Energy*, vol. 172, pp. 618-631, jul. 2021, doi:10.1016/j.renene.2021.03.030.
- [3] P. Bunnoon, «Mid-Term Load Forecasting Based on Neural Network Algorithm: a Comparison of Models», *IJCEE*, pp. 600-605, 2011, doi: 10.7763/IJCEE.2011.V3.388.
- [4] A. T. Eseye, M. Lehtonen, T. Tukia, S. Uimonen, y R. John Millar, «Machine Learning Based Integrated Feature Selection Approach for Improved Electricity Demand Forecasting in Decentralized Energy Systems», *IEEE Access*, vol. 7, pp. 91463-91475, 2019, doi: 10.1109/ACCESS.2019.2924685.
- [5] J. M. Illidge-Araujo, J. L. Chacon-Velasco, A. J. Chacon-Velasco, y C. Romero-Piehadraita, «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*, vol. 19, n.º 1, Art. n.º 1, ene. 2020, doi: 10.18273/revuin.v19n1- 2020015.
- [6] A. M. Ariza Ramírez, «Métodos utilizados para el pronóstico de generación eléctrica en sistemas de distribución», 2013, Accedido: 6 de diciembre de 2021.
- [7] D. Julian y B. Baka, *Python Data Structures and Algorithm*. Birmingham: Packt Publishing, Limited, 2017. Accedido: 14 de diciembre de 2021. [En línea]. Disponible en: <https://proquest.safaribooksonline.com/9781786467355>
- [8] O. Caja García, «Librería Python para el aprendizaje y la implementación de redes neuronales», Proyecto/Trabajo fin de carrera/grado, Universitat Politècnica de València, 2020. Accedido: 16 de diciembre de 2021. [En línea]. Disponible en: <https://riunet.upv.es/handle/10251/152226>

- [9] Carrera, I. (2020). *Generación de Energía*. Obtenido de <https://www.haimec.cl/generacion-de-energia/>
- [10] Castillo, J., Carrillo, G., Freire, L., & Corrales, B. (2022). Modelado y Simulación energética de un edificio para realizar análisis de sensibilidad del consumo energético. *Energy Reports*. doi:10.1016/j.egy.2022.10.197
- [11] Castillo, J., Resabala, V., Luigi, F., & Corrales, B. (2022). Modelización y análisis de sensibilidad del consumo energético de los edificios mediante el método Monte Carlo. *Energy Reports*, 518-524. doi:10.1016/j.egy.2022.10.198
- [12] Del Canto, Ä. (2019). *IArtificial.net*. Obtenido de <https://www.iartificial.net/gradiente-descendiente-para-aprendizaje-automatico/>
- [13] GreenLux. (2021). *Paneles Solares*. Obtenido de <https://www.greenlux.com.mx/wiki/generacion-de-energia-electrica/>
- [14] 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.
- [15] Sahagún, P. (2018). *Aplicación de redes neuronales convolucionales y recurrentes al diagnóstico*. Obtenido de https://oa.upm.es/50400/1/TFG_PABLO_RODRIGUEZ_SAHAGUN_ALE_SANCO.pdf

ANEXO
ARTÍCULO
ACADÉMICO