



UNIVERSIDAD TÉCNICA DE COTOPAXI

DIRECCIÓN DE POSGRADO

MAESTRÍA EN ELECTRICIDAD

MODALIDAD: INFORME DE INVESTIGACIÓN

Título:

Modelos de predicción de caudales para una mini central hidroeléctrica

Trabajo de titulación previo a la obtención del título de magister en Electricidad
mención sistemas eléctricos de potencia

Autor:

Ing. Bonilla Correa Brayan Alexander

Tutor:

Freire Martínez Luigi Orlando MSc.

LATACUNGA –ECUADOR

2023


APROBACIÓN DEL TUTOR

En mi calidad de Tutor del Trabajo de Titulación “**Modelos de predicción de caudales para una mini central hidroeléctrica**” presentado por el **Ing. Bonilla Correa Brayan Alexander**, 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, noviembre, 20, 2023



.....


Luigi Orlando Freire Martínez MSc.

CC: 0502529589

APROBACIÓN TRIBUNAL

El trabajo de Titulación: “**Modelos de predicción de caudales para una mini central hidroeléctrica.**”, ha sido revisado, aprobado y autorizado 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, noviembre, 20, 2023



.....
Carlos Iván Quinatoa Caiza MSc.

C.I: 0503287864


Presidente del tribunal



.....
Toaza Iza Jimmy Xavier MSc.

C.I: 1717621062

Lector 2



.....
Arias Átiaja Fernando Rafael MSc.

C.I: 0502556251

Lector 3

DEDICATORIA

Les dedico este artículo a mis queridos padres, familiares, amigos con todo mi agradecimiento y cariño. Este logro no sería posible sin su apoyo incondicional que continúa animándome y enseñándome el valor del trabajo duro y la perseverancia.

Gracias por creer siempre en mí y ser mi pilar de apoyo en cada paso del camino. Su apoyo y aliento me dan una base sólida para afrontar cualquier desafío.

Este artículo no es sólo un testimonio de mi dedicación y perseverancia, sino también de su ayuda incondicional y apoyo constante. Gracias por estar ahí para mí y creer en mí cuando más lo necesitaba. Su presencia en mi vida es un regalo invaluable por el cual siempre estaré agradecido.

Brayan Bonilla

AGRADECIMIENTO

Agradezco a Dios de todo corazón por haberme dado esta oportunidad de existir, a mi madre por toda la paciencia, esfuerzo y sacrificios que ha hecho por mí, dándome ánimos de forma incondicional y sin titubear para llegar a este día.

Agradecer a toda mi familia con la que siempre conté de manera incondicional en todos los aspectos de mi vida y de manera especial a mi tía, que la considero como mi segunda madre su apoyo moral ha sido fundamental en esta etapa tan esperada; ya que es una de las personas más importantes de mi vida.

Como no mencionar a todos aquellos profesionales que conocí a lo largo de mi formación que me supieron transmitir sus conocimientos y las estrategias para culminar con éxito mi carrera, a mi tutor Ing. MSc. Luigi Freire mi más profunda consideración y gratitud

Brayan Alexander Bonilla Correa

RESPONSABILIDAD DE AUTORÍA

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

Latacunga, noviembre, 20, 2023



.....
Bonilla Correa Brayan Alexander

C.I. 0503944225

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, noviembre, 20, 2023

A handwritten signature in blue ink, consisting of several loops and strokes, positioned above a horizontal dotted line.

Bonilla Correa Brayan Alexander

C.I. 0503944225

AVAL DEL PRESIDENTE

Quien suscribe, declara que el presente Trabajo de Titulación: “**Modelos de predicción de caudales para una mini central hidroeléctrica.**” contiene las correcciones a las observaciones realizadas por los lectores en sesión científica del tribunal.

Latacunga, noviembre, 20, 2023



.....
Carlos Iván Quinatoa Caiza MSc.

C.I: 0503287864

**UNIVERSIDAD TÉCNICA DE COTOPAXI
DIRECCIÓN DE POSGRADO**

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

Título: Modelos de predicción de caudales para una mini central hidroeléctrica.

Autor: Bonilla Correa Brayan Alexander

Tutor: Freire Martínez Luigi Orlando MSc.

RESUMEN

En este artículo, se presenta una comparación entre dos sistemas implementados en Jupyter Notebook con el núcleo de cálculo de Python. Estos utilizan machine learning para predecir el caudal. Los modelos se entrenaron y evaluaron utilizando datos del año 2022. El primer sistema utiliza el método ARIMA y muestra un error del 4,55% en la predicción del caudal. Se observa una alta similitud entre las curvas del caudal real y pronosticado en cada mes. El segundo sistema utiliza el método RNA-GRU y presenta un error MAPE del 4,62% en la predicción del caudal. Al igual que con ARIMA, se observa un parecido significativo entre las curvas del caudal real y pronosticado en cada mes. Se generaron gráficos de barras que representan la dispersión de los valores pronosticados en comparación con los valores esperados. Estos gráficos permiten evaluar los errores promedio de los pronósticos. En este caso, se evidencia que el método ARIMA tiene un error inferior en comparación con el método GRU. Este artículo demuestra la capacidad de ambos sistemas implementados en Jupyter Notebook para predecir el caudal.

PALABRAS CLAVE: *Jupyter Notebook, Python, Caudal.*

UNIVERSIDAD TECNICA DE COTOPAXI
DIRECCION DE POSGRADO
MAESTRÍA EN ELECTRICIDAD
MENCIÓN SISTEMAS ELÉCTRICOS DE POTENCIA

Title: FLOW PREDICTION MODELS FOR A MINI HYDROELECTRIC POWER STATION.

Author: Bonilla Correa Brayan Alexander
Tutor: Freire Martínez Luigi Orlando MSc.

ABSTRACT

In this paper, a comparison between two systems implemented in Jupyter Notebook with the Python computation kernel is presented. They use machine learning to predict the flow rate. The models were trained and evaluated using data from the year 2022. The first system uses the ARIMA method and shows an error of 4.55% in flow prediction. A high similarity is observed between the actual and predicted flow curves for each month. The second system uses the RNA-GRU method and shows a MAPE error of 4.62% in the flow prediction. As with ARIMA, there is a significant resemblance between the actual and predicted flow curves for each month. Bar graphs were generated representing the dispersion of the predicted values compared to the expected values. These graphs allow us to evaluate the average errors of the forecasts. In this case, it is evident that the ARIMA method has a lower error compared to the GRU method. This paper demonstrates the ability of both systems implemented in Jupyter Notebook to predict the flow rate.

KEYWORD: *Jupyter Notebook, Python, Flow rate.*

TACO GUAMANI KLEBER FABIAN con cédula de identidad número: 0550231195 Licenciado en: CIENCIAS DE LA EDUCACIÓN ESPECIALIDAD INGLÉS con número de registro de la SENESCYT: 1020-2023-2649324 ; **CERTIFICO** haber revisado y aprobado la traducción al idioma inglés del resumen del trabajo de investigación con el título: “**Modelos de predicción de caudales para una mini central hidroeléctrica.**” de Bonilla Correa Brayan Alexander, aspirante a magister en Electricidad mención sistemas eléctricos de potencia



Kleber Fabian Taco Guamani

C.I: 0550231195

Latacunga, noviembre, 20, 2023

ÍNDICE DE CONTENIDO

1.	INFORMACIÓN GENERAL	1
2.	INTRODUCCIÓN	1
3.	MATERIALES Y MÉTODOS	3
3.1.	Problemática.....	3
3.2.	Modelos de predicción	5
3.3.	Desarrollo	9
4.	RESULTADOS Y DISCUSIÓN	9
4.1.	Resultado	9
4.2.	Discusión	14
5.	CONCLUSIONES	15
6.	REFERENCIAS BIBLIOGRÁFICAS	16

ÍNDICE DE IMÁGENES

Fig. 1.	Estructura del proyecto	5
Fig. 2.	Estructura del Sistema ARIMA	6
Fig. 3.	Representación de la celda GRU y sus operaciones internas. [15].....	8
Fig. 4.	Estructura del Sistema GRU	9
Fig. 5.	Pasos para el procesamiento de información.....	9
Fig. 6.	Comportamiento de caudal REAL-ARIMA	10
Fig. 7.	Comportamiento de caudal REAL-GRU	12
Fig. 8.	Comportamiento de caudal REAL-GRU	13
Fig. 9.	Comportamiento de la demanda de caudal predicha y comparada con su demanda real.	14

ÍNDICE DE TABLAS

Tabla. 1.	Pronóstico del Caudal para la generación de energía modelo ARIMA.....	10
Tabla. 2.	Pronóstico del Caudal para la generación de energía modelo RNA-GRU.....	11

1. INFORMACIÓN GENERAL

Título del Proyecto:	Modelos de predicción de caudales para una mini central hidroeléctrica
Línea de investigación:	Energías alternativas y renovables, eficiencia energética y protección ambiental
Proyecto de investigación asociado:	Modelación de sistemas
Grupo de Investigación:	Inteligencia artificial y modelación de sistemas
Red nacional o internacional:	Red Nacional

2. INTRODUCCIÓN

La generación hidroeléctrica en Ecuador y la necesidad de modelos de previsión para la operación eficiente de centrales hidroeléctricas dado el comportamiento estocástico de los caudales afluentes, logra que se describan diferentes modelos estadísticos que se han propuesto, pero se destaca la utilidad de los modelos de pronóstico basados en Inteligencia Artificial, como redes neuronales donde se utilizan algoritmos evolutivos para pronosticar la demanda y que muestra resultados satisfactorios. [1] La afluencia de volumen de los ríos, puede determinarse mediante métodos de hidrograma y regresión múltiple, su modelo matemático se obtiene para la relación entre el volumen de agua y el volumen total, de tal manera que se puede predecir la parada de las maquinas, así como su encendido, lo que permite predecir fácilmente futuros paros con un acierto superior dependiendo del tipo de predicción realizada. [2]

Los modelos para predecir caudales mensuales se han dado desde el análisis de los registros históricos los cuales fueron ajustados y evaluados desde el desempeño de los mismos, los resultados fueron apropiados para mostrar y estimar caudales afluentes, la regulación de estos permite una mayor producción de energía en una operación coordinada. [3] La base de registro histórico se toma directamente de la empresa eléctrica de Colombia, de tal manera que se utilizarán técnicas estadísticas para crear una base de datos confiable del caudal mensual del valle del río Cauca,

desarrollando modelos de predicción de caudales medios mensuales utilizando métodos de estadísticos y enfoques lineales y no lineales. [4] Los datos históricos obtenidos pertenecen a cada día en 5 años anteriores a la predicción por lo cual para realizar los modelos estadísticos se obtiene un caudal básico mensual de cada mes para no tener una distorsión agua de la curva luego se examinan estos modelos y herramientas para evaluar su validez en la estimación. [5]

En Ecuador, donde se utilizan redes neuronales para predecir el nivel del caudal y el nivel de embalse de agua en plantas hidroeléctricas solo tienen menos del 50% de casos exitosos debido al alto ruido de la señal que este remite, se necesitan modelos de predicción únicos de acuerdo a su ubicación geográfica. [6] La utilización de varios algoritmos para predecir diferentes aspectos en hidroeléctricas es bastante utilizada ya que se evalúa la influencia de los entrenamientos RNAs en la predicción de embalse de una represa hidroeléctrica, indicando así que puede realizar proyecciones de hasta 48 horas y mejorar una planificación de producción energética. [7] De tal manera, se puede decir que existen varios modelos que se utilizan para la producción de caudales, los más utilizados según criterio de varios artículos son: Redes Neuronales Artificiales, Redes Adaptativas Neuro-Difusas, Análisis Espectral Singular, Modelo Estructural y Modelo Físico los modelos se pueden aplicar en ventanas de tiempo de uno, tres, seis y hasta 12 meses en donde los diferentes tipos de software permite la inclusión de variables macro climáticas que existan en dichos terrenos. [8]

Enfocar el modelo de predicción mediante algoritmos y control de variables ya sea de un sistema virtual o sistema físico debe centrarse en la precisión de la predicción del caudal para mantener un nivel adecuado del uso del sistema de control. [9] La predicción de variables utilizando método ARIMA son muy utilizadas últimamente ya que es un modelo autorregresivo que se puede incluir en varios sistemas en este caso son variables relacionadas con el agua de tal forma como lo es su caudal o indirectamente a través de variables meteorológicas. [10] Por lo tanto el modelado de predicción de caudales la implementación y la especificación está dada por diferentes métodos como puede ser ARIMA, RNAs, ya que presentan un perceptrón multicapa que ayuda a resolver problemas que no son lineales y puede estar

conectado totalmente conectados o tan solo localmente y son funcionales para este propósito.[11]

Aunque en otros modelos de predicción se menciona que se han construido utilizando técnicas estocásticas y neuronales, no se proporciona formación detallada sobre la procedencia y representatividad de estos datos, una evaluación detallada de la efectividad de cada uno. No se muestra cómo se compararon los resultados de las técnicas estocásticas y las redes neuronales, ni se presentan métricas de desempeño específicas para respaldar la afirmación de que ambos enfoques son alternativas factibles. También se utilizan datos reales de caudales mensuales, pero no se proporciona información detallada sobre las características de estas series hidrológicas. Un análisis más profundo de las series hidrológicas, considerando aspectos como la estacionalidad, la tendencia o la presencia de valores atípicos, habría proporcionado un contexto más sólido para la interpretación de los resultados.[12]

El objetivo de este estudio es comparar y evaluar el desempeño de modelos de predicción para estimar los caudales hídricos utilizados en la generación de energía eléctrica. Para ello, se implementarán los algoritmos GRU (Unidades Recurrentes de Gated) y ARIMA (AutoRegressive Integrated Moving Average) en la mini central hidroeléctrica Illuchi 2. Estos algoritmos serán validados y contrastados utilizando datos históricos, con el fin de determinar su efectividad. El análisis de patrones y tendencias identificados junto con las predicciones generadas, proporcionará información valiosa para la gestión eficiente de la mini central hidroeléctrica Illuchi 2.

3. MATERIALES Y MÉTODOS

3.1. Problemática

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 caudal desde año 2018-2021 que da un total de 1400 datos, que 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 en el año 2022 y su respectivo porcentaje de error.

El modelo ARIMA se asocia a los requisitos de este proyecto ya que determina los órdenes de diferenciación, autorregresión y media móvil. Donde se utilizó herramientas como la función de autocorrelación (ACF) y la función de autocorrelación parcial (PACF) para identificar las órdenes apropiadas, se utilizaron datos históricos de caudales para obtener tendencias lineales y estacionarias, de tal forma se ajusta el modelo a los datos de entrenamiento y lograr generar pronósticos de caudales, con los residuos que presenta el modelo ARIMA se puede representar las diferencias entre los datos observados y los valores predichos.

El modelo GRU se vincula debido a que organiza datos históricos de los caudales en una secuencia temporal donde divide los datos en conjuntos de entrenamiento, validación y prueba, la estructura incluye una cantidad de capas y unidades de GRU en cada capa se configura con los siguientes valores (MSE), (MAE) y el (SGE) ya que una vez entrenado se puede utilizar como una secuencia temporal de entrada y los caudales reales correspondientes como salida, este modelo puede aprender de patrones no lineales e indicar dependencias más complejas.

Una vez realizado los pronósticos de los dos modelos se procede a una validación combinada de los dos modelos mediante el error MAPE y así obtener el modelo más factible para el uso en mini centrales hidroeléctricas.

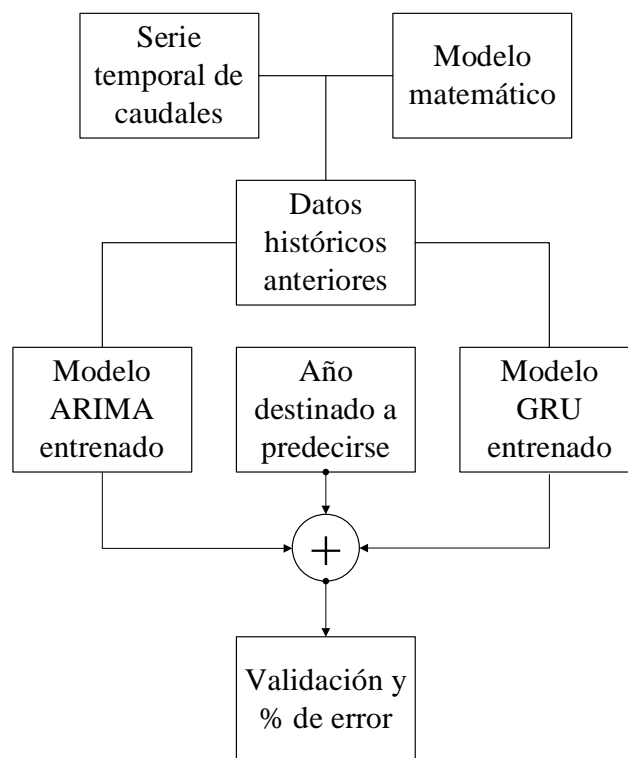


Fig. 1. Estructura del proyecto

3.2. Modelos de predicción

ARIMA

Se utilizó este modelo debido a que se tiene datos históricos de caudales que exhiben patrones lineales y estacionales, los cuales son proporcionados por la empresa eléctrica ELEPCO S.A. ARIMA está especialmente diseñado para capturar tendencias lineales y componentes estacionales.

Con lo mencionado se dispone que la serie de tiempo de caudales no muestra patrones no lineales o dependencias complejas. De tal manera que ARIMA es un modelo lineal que se ajusta mejor con relaciones lineales y se tiene suficientes datos históricos para estimar los parámetros del modelo, ya que se requiere una cantidad significativa de cifras pasadas para realizar estimaciones precisas.

Para mejorar la flexibilidad y el ajuste en las series temporales, nacen los procesos ARIMA (p,q), una combinación de las dos estructuras (autorregresiva y de media móvil) donde la observación actual de la variable de interés se explica a través de

las observaciones anteriores, las innovaciones anteriores y la innovación en ese instante.

Un proceso ARIMA (p,q) se expresa:

$$\tilde{z}_t = \phi_1 \tilde{z}_{t-1} + \phi_2 \tilde{z}_{t-2} + \dots + \phi_p \tilde{z}_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (1)$$

La expresión se puede reducir utilizando el operador de retardos:

$$(1 - \phi_1 B - \dots - \phi_p B^p) \tilde{z}_t = (1 - \theta_1 B - \dots - \theta_q B^q) a_t \quad (2)$$

$$\phi_p(B) \tilde{z}_t = \theta_q(B) a_t \quad (3)$$

Donde las raíces de $\phi_p(B) = 0$ están fuera del círculo unidad para que el proceso sea estacionario y el proceso será invertible si lo están las de $\theta_q(B) = 0$. Además, se debe cumplir que $\phi_p(B)$ y $\theta_q(B)$ no tengan raíces comunes. Si no se cumple esta condición resulta que $z_t = a_t$ y el proceso sería ruido blanco.

Los procesos ARIMA son una combinación de la diferenciación con los procesos autorregresivos y los de media móvil estudiados anteriormente.

Un método realizado para combatir el comportamiento no estacionario de algunas series temporales. Consiste en suponer que la tendencia evoluciona con el tiempo y si restamos cada valor de la serie con el valor anterior se librerá a esta de la tendencia. [13] [14]

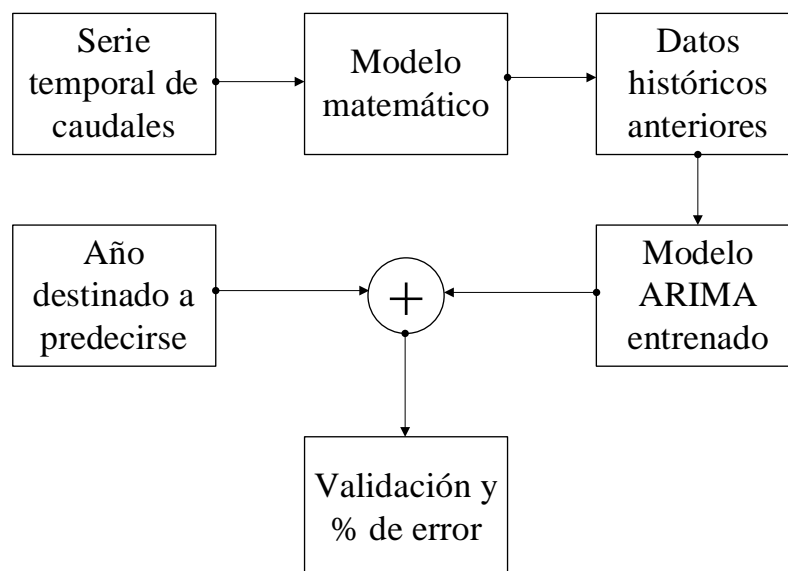


Fig. 2. Estructura del Sistema ARIMA

Gated recurrent Unit (GRU)

Se utilizó 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:

$$u_t = \sigma(W_u h_{t-1} + W_u x_t + b_u) \quad (4)$$

la de la reset gate:

$$r_t = \sigma(W_r h_{t-1} + W_r x_t + b_r) \quad (5)$$

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:




Fig. 3. Representación de la celda GRU y sus operaciones internas. [15]

$$\hat{h}_t = \tanh(W_h h_{t-1} + W_h x_t + b_h) \quad r_t = \sigma(r_t + W_r h_{t-1} + W_r x_t) \quad (6)$$

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

$$h_t = u_t \hat{h}_t + (1 - u_t) h_{t-1} \quad (7)$$

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. En la Fig. 3. podemos ver la representación visual de las operaciones sobre una única celda. [15]




Fig. 4. Estructura del Sistema GRU

3.3.Desarrollo

La Fig. 5. Muestra los pasos seguidos para el seguimiento del proyecto en general.

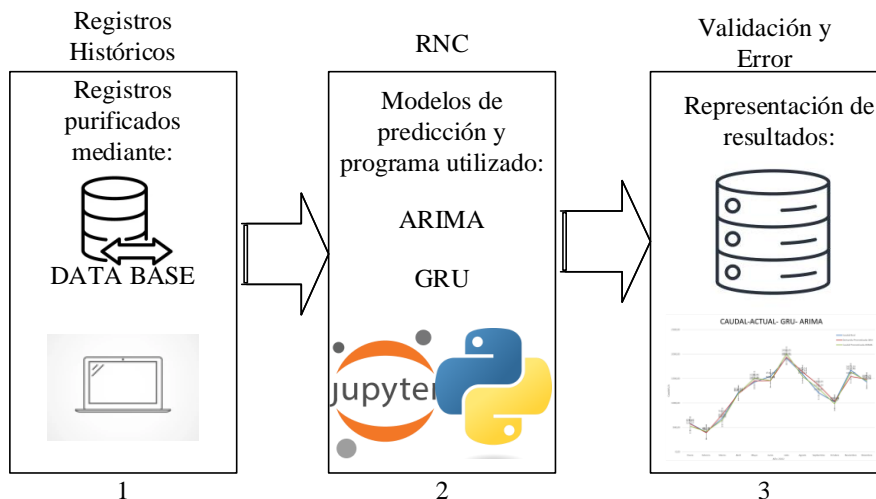


Fig. 5. Pasos para el procesamiento de información

4. RESULTADOS Y DISCUSIÓN

4.1.Resultado

En la Tabla 1. Se realizó el pronóstico mediante el método ARIMA y se calculó sus respectivos errores para conocer el comportamiento de la demanda de caudal en el año 2022, en donde se observa que el modelo es factible ya que se encuentra con un error del 4,55%.

Tabla. 1. Pronóstico del Caudal para la generación de energía modelo ARIMA

PRONOSTICO DEL CAUDAL PARA LA GENERACIÓN DE ENERGÍA MEDIANTE ARIMA										
n	MES	Caudal Real	Caudal Pronosticado ARIMA	Error Abs.	Error % Abs.	Σ Error Abs.	MAD	Error Nor.	Σ Error Nor.	TS
1	Enero	578,47	521,37	57,09981	9,87%	57,099812	57,1	57,09981	57,099812	1
2	Febrero	403,36	417,77	14,41061	3,57%	71,51042	35,8	-14,41061	42,689204	1,2
3	Marzo	691,18	650,89	40,29442	5,83%	111,80484	37,3	40,29442	82,983621	2,2
4	Abril	1219,64	1197,33	22,3042	1,83%	134,10904	33,5	22,3042	105,28782	3,1
5	Mayo	1427,80	1506,96	79,16282	5,54%	213,27186	42,7	-79,16282	26,124998	0,6
6	Junio	1546,68	1460,34	86,33988	5,58%	299,61174	49,9	86,33988	112,46487	2,3
7	Julio	1917,73	2007,05	89,32245	4,66%	388,93418	55,6	-89,32245	23,142426	0,4
8	Agosto	1592,61	1545,63	46,98155	2,95%	435,91573	54,5	46,98155	70,123976	1,3
9	Septiembre	1206,95	1291,34	84,38708	6,99%	520,30281	57,8	-84,38708	-14,263103	-0,2
10	Octubre	1019,81	984,27	35,54144	3,49%	555,84425	55,6	35,54144	21,278338	0,4
11	Noviembre	1673,20	1629,48	43,71936	2,61%	599,56361	54,5	43,71936	64,997697	1,2
12	Diciembre	1430,08	1454,82	24,73657	1,73%	624,30018	52,0	-24,73657	40,26113	0,8

SUMA %	54,66%
n	12
MAPE	4,55%

A continuación, en la Fig. 6. Se muestra el comportamiento de las curvas del caudal real y con el caudal pronosticado con el modelo ARIMA, donde se puede apreciar de mejor manera una similitud alta entre las curvas y su distorsión en cada mes del año 2022.




Fig. 6. Comportamiento de caudal REAL-ARIMA

En la tabla 2. Se realizó el pronóstico mediante el método RNA-GRU y se calculó sus respectivos errores para conocer el comportamiento de la demanda de caudal en el año 2022, en donde se observa que es adecuada ya que se encuentra con un error MAPE del 4,62%.

Tabla. 2. Pronóstico del Caudal para la generación de energía modelo RNA-GRU

PRONOSTICO DEL CAUDAL PARA LA GENERACIÓN DE ENERGÍA MEDIANTE RNA-GRU										
n	MES	Caudal Real	Caudal Pronosticado GRU	Error Abs.	Error % Abs.	Σ Error Abs.	MAD	Error Nor.	Σ Error Nor.	TS
1	January	578,47	572,25	6,216408	1,07%	6,2164084	6,2	6,216408	6,2164084	1
2	February	403,36	388,41	14,94376	3,70%	21,16017	10,6	14,94376	21,16017	2
3	March	691,18	763,14	71,95531	10,41%	93,115477	31,0	-71,95531	-50,795137	-1,6
4	April	1219,64	1187,11	32,52755	2,67%	125,64303	31,4	32,52755	-18,267586	-0,6
5	May	1427,80	1453,38	25,58154	1,79%	151,22457	30,2	-25,58154	-43,849124	-1,5
6	June	1546,68	1456,88	89,80176	5,81%	241,02632	40,2	89,80176	45,952633	1,1
7	July	1917,73	1940,91	23,17939	1,21%	264,20571	37,7	-23,17939	22,773246	0,6
8	August	1592,61	1635,51	42,89923	2,69%	307,10494	38,4	-42,89923	-20,125983	-0,5
9	September	1206,95	1369,04	162,0861	13,43%	469,19108	52,1	-162,0861	-182,21212	-3,5
10	October	1019,81	1029,38	9,574716	0,94%	478,7658	47,9	-9,574716	-191,78684	-4
11	November	1673,20	1544,17	129,0295	7,71%	607,79533	55,3	129,0295	-62,7573	-1,1
12	December	1430,08	1486,75	56,67534	3,96%	664,47068	55,4	-56,67534	-119,43264	-2,2

SUMA %	55,40%
n	12
MAPE	4,62%

A continuación, en la Fig. 7. Se muestra el comportamiento de las curvas del caudal real y con el caudal pronosticado con el modelo RNA-GRU, donde se puede apreciar de mejor manera una similitud alta entre las curvas y su distorsión en cada mes del año 2022.

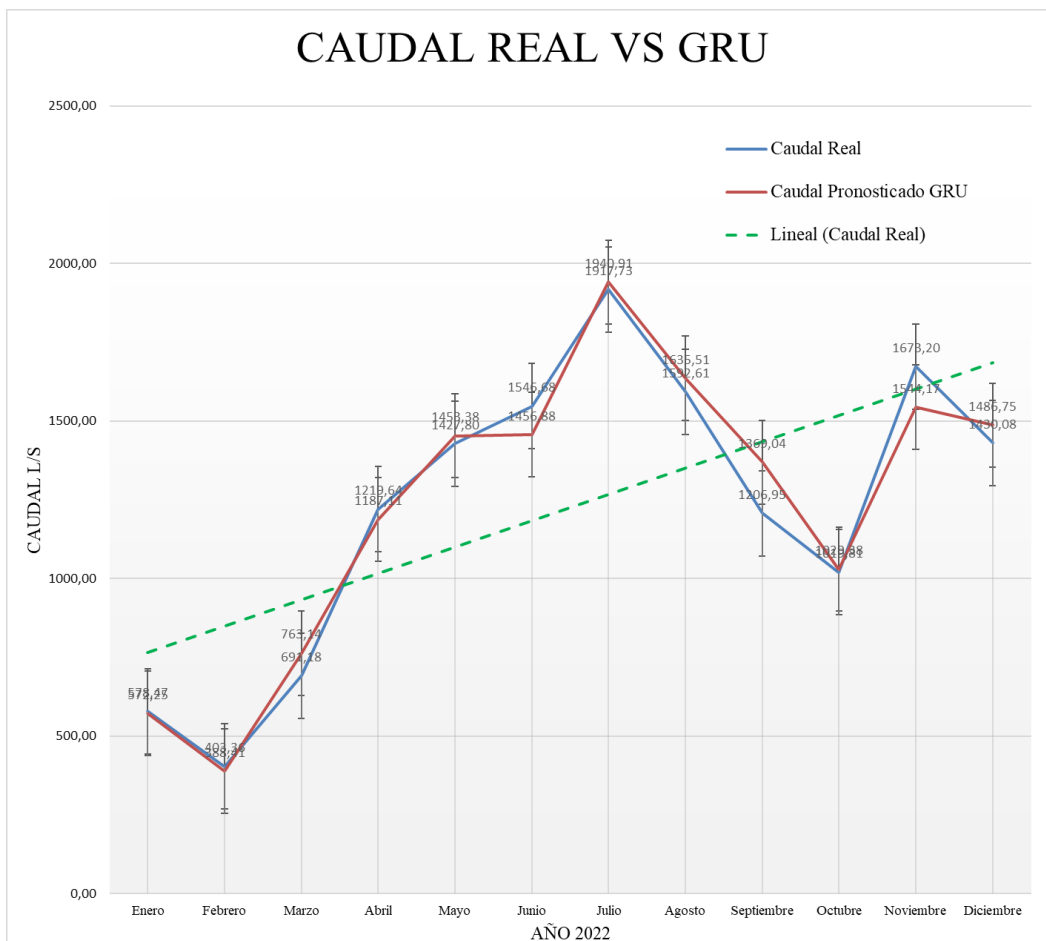


Fig. 7. Comportamiento de caudal REAL-GRU

En la Figura 8. Se puede apreciar la información recopilada en la tabla 1 y 2, se generaron dos gráficos de barras que representan el comportamiento del MAD (Desviación media absoluta). Estos gráficos sirven para evaluar la dispersión de los valores analizados en relación a los valores esperados. En esencia, proporcionan una medida de los errores promedio de los pronósticos, tal como se muestra en la figura. Es evidente que el análisis realizado el método de ARIMA presenta un error inferior en comparación con el método de GRU.

COMPORTAMIENTO DE LA DESVIACIÓN MEDIA ABSOLUTA




Fig. 8. Comportamiento de caudal REAL-GRU

Se realizó un análisis en la Fig. 9. utilizando los resultados obtenidos de las predicciones de los dos métodos empleados para validar con el caudal real. Se puede observar que la predicción más precisa se logró mediante el uso del modelo matemático ARIMA en el programa de Jupyter Notebook con Python, obteniendo un error porcentual absoluto medio del 4,55 %, a diferencia de las RNS-GRU donde se obtuvo un error del 4,62%. 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. Es posible visualizar cómo varía la curva de caudal durante el año 2022 al compararla con los datos pronosticados para los 12 meses del año. Se puede apreciar que ambas curvas presentan un comportamiento muy similar tanto en el crecimiento como en la reducción de la demanda de caudal.

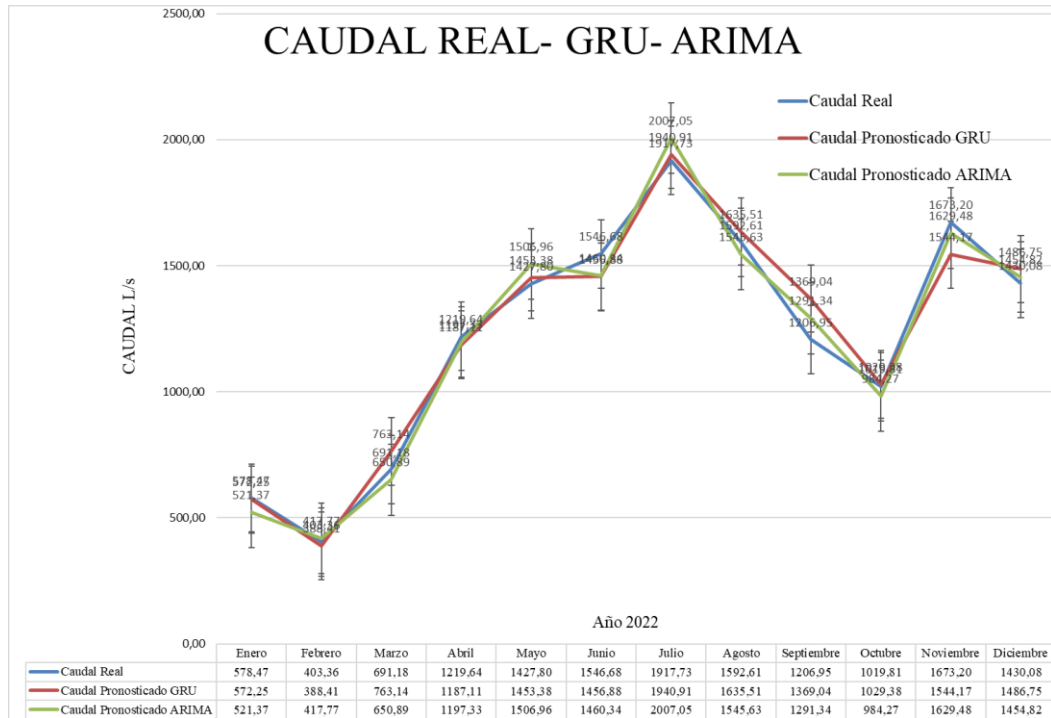


Fig. 9. Comportamiento de la demanda de caudal predicha y comparada con su demanda real.

4.2.Discusión

En cuanto a los resultados obtenidos, se realizó el pronóstico utilizando el método ARIMA y se calculó el error correspondiente para comprender el comportamiento de la demanda de caudal en el año 2022. Se observó que el modelo ARIMA es factible, ya que presenta un error del 4,55%. Se exhibió el comportamiento de las curvas del caudal real y del caudal pronosticado con ARIMA, mostrando una alta similitud entre ellas y sus variaciones en cada mes.

Además, se realizó el pronóstico utilizando el método RNA-GRU y se calculó el error MAPE correspondiente para comprender el comportamiento de la demanda de caudal en el año 2022. Se observó que el modelo RNA-GRU es adecuado, ya que presenta un error del 4,62%. Se exhibió el comportamiento de las curvas del caudal real y del caudal pronosticado con RNA-GRU, mostrando una alta similitud entre ellas y sus variaciones en cada mes.

La información recopilada se presentó en las tablas 1 y 2, y se generaron gráficos de barras que representan el comportamiento de la desviación media absoluta (MAD). Estos gráficos permiten evaluar la dispersión de los valores pronosticados en comparación con los valores esperados, proporcionando una medida de los errores promedio de los pronósticos. De manera evidente, se observa que el análisis realizado con el método ARIMA presenta un error inferior en comparación con el método GRU.

Utilizando los resultados de las predicciones de los dos métodos y validándolos con el caudal real, se observa que la predicción más precisa se logró mediante el modelo matemático ARIMA implementado en Jupyter Notebook con Python, obteniendo un error porcentual absoluto medio del 4,55%. En contraste, el modelo RNA-GRU obtuvo un error del 4,62%. Como se mencionó previamente, se considera que un valor por debajo del 5% es aceptable. Por lo tanto, se concluye que el análisis y la validación son adecuados. Además, se pudo observar cómo varía la curva de caudal a lo largo del año 2022 al compararla con los datos pronosticados para los 12 meses, demostrando un comportamiento muy similar en términos de crecimiento y reducción de la demanda de caudal.

5. CONCLUSIONES

Es esencial escalar los datos durante el entrenamiento de los modelos de caudal para evitar que afecten los diferentes valores utilizados. En nuestro enfoque, utilizando la técnica de entrenamiento RMSprop con una proporción de entrenamiento del 80% y validación del 20% en la red GRU, logramos una aproximación más cercana a los datos reales. Esto nos permitió mejorar los resultados y cuantificar oportunamente el error medio absoluto obtenido mediante optimizadores.

Tanto el modelo ARIMA como el modelo RNA-GRU demostraron ser efectivos en la predicción de caudales para mini centrales hidroeléctricas, con errores por debajo del 5% al compararlos con los valores reales medidos en el año 2022. En específico, el modelo ARIMA presentó un error del 4.55%, mientras que el modelo RNA-GRU mostró un error del 4.62%. Estos resultados cuantifican oportunamente el desempeño de los modelos y respaldan su factibilidad y menor riesgo.

La factibilidad del proyecto para la mini central hidroeléctrica Illuchi 2 depende de la selección del modelo de predicción y de la fiabilidad de los datos históricos. En nuestra investigación, hemos cuantificado oportunamente el impacto de utilizar el modelo ARIMA y el modelo RNA-GRU. Estos modelos nos permiten interpretar de manera directa los componentes de tendencia, estacionalidad y aleatoriedad en la serie de tiempo de los caudales, así como adaptarse automáticamente a diferentes patrones y características. Esto asegura resultados confiables y precisos, respaldando la gestión eficiente de la mini central hidroeléctrica Illuchi 2.

En futuros trabajos de investigación, se recomienda explorar otros modelos de predicción y técnicas avanzadas de aprendizaje automático que puedan mejorar aún más la precisión en la estimación de caudales hídricos. Además, recopilar y analizar datos en tiempo real será crucial para adaptar los modelos a cambios y eventos inesperados. Estas acciones permitirán optimizar la generación de energía eléctrica y fortalecer la gestión de la mini central hidroeléctrica Illuchi 2.

6. REFERENCIAS BIBLIOGRÁFICAS

Referencias

- [1] V. H. Hinojosa, «Cenace,» 2008. [En línea]. Available: <https://revistaenergia.cenace.gob.ec/index.php/cenace/article/view/268>. [Último acceso: 17 02 2023].
- [2] J. Alcázar Montero, «ResearchGate,» 07 2007. [En línea]. Available: https://www.researchgate.net/publication/46314616_El_Metodo_del_Caudal_Basico_para_la_terminacion_de_Caudales_de_Mantenimiento_Aplicacion_a_la_Cuenca_del_Ebro. [Último acceso: 19 02 2023].
- [3] C. A. Sugastti Medina y A. S. Arce Encína, «Universidad Nacional del Este,» 2020. [En línea]. Available: <http://servicios.fpune.edu.py:8080/jspui/handle/123456789/1062>. [Último acceso: 17 02 2023].
- [4] Y. Carvajal Escobar, G. Correa y F. Matilde Muñoz, «Redalcy,» 2007. [En línea]. Available: <https://www.redalyc.org/pdf/2311/231120826008.pdf>. [Último acceso: 18 02 2023].
- [5] H. Gonzalez, J. Piedrahita y O. Castrillón, «Scielo,» 10 2020. [En línea]. Available: https://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0718-07642020000500215. [Último acceso: 17 02 2023].

- [6] D. E. Olmedo, J. Ambato Hernandez y G. E. Asqui Santillán, «Researchgate,» 2018. [En línea]. Available: https://www.researchgate.net/publication/329440607_MODELAMIENTO_BASADO_EN_RED_ES_NEURONALES_ARTIFICIALES_PARA_LA_PREDICCION_DE_RECURSOS_HIDRICOS_EN_UNA_CENTRAL_HIDROELECTRICA. [Último acceso: 17 02 2023].
- [7] E. Chafra, G. Asqui Santillán, J. Paucar y D. Olmedo Vizueta, «Espoch,» 07 2019. [En línea]. Available: http://perspectivas.esPOCH.edu.ec:8081/index.php/RCP_ESOCH/article/view/2057. [Último acceso: 18 02 2022].
- [8] J. D. Velásquez, R. Smith, A. Cebalos, P. Correa, C. Goetz, O. Hernandez, L. F. Salazar Velasquez y E. C. Zapata, «Universidad Nacional de Colombia,» 09 2004. [En línea]. Available: https://www.researchgate.net/profile/Juan-Velasquez17/publication/255786858_Modelos_de_prediccion_de_caudales_parar_el_sector_electrico_Colombiano/links/00b7d520ae94206147000000/Modelos-de-prediccion-de-caudales-parar-el-sector-electrico-Colombiano.pdf. [Último acceso: 17 02 2023].
- [9] L. O. Freire, B. A. Bonilla, B. P. Corrales y J. L. Villarroel, «Springer,» 30 04 2023. [En línea]. Available: https://link.springer.com/chapter/10.1007/978-981-19-8493-8_47. [Último acceso: 12 05 2023].
- [10] J. G. Aguado Rodríguez, M. Castro Popoca, A. Quevedo Nolasco, R. Arteaga Ramirez, A. M. Vázquez Peña y P. B. Zamora Morales, «Scielo,» 02 2016. [En línea]. Available: https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S140531952016000100001. [Último acceso: 15 05 2023].
- [11] E. Gomez Vargas, L. Alvarez Pomar y N. Obregon Neira, «iisci,» 2012. [En línea]. Available: <https://www.iisci.org/journal/PDV/risci/pdfs/HCA987UD.pdf>. [Último acceso: 12 05 2023].
- [12] C. A. Sugasti Medina, A. S. Arce Encina y W. Panadero, «FPUNE SCIENTIFIC,» 17 05 2023. [En línea]. Available: <http://servicios.fpune.edu.py:83/fpunescientific/index.php/fpunescientific/article/view/248>. [Último acceso: 29 05 2023].
- [13] J. G. Seminario Gastelo, «Universidad de Piuá,» 05 2012. [En línea]. Available: https://pirhua.udep.edu.pe/bitstream/handle/11042/4986/ING_2106.pdf?sequence=1&isAllowed=y. [Último acceso: 30 04 2023].
- [14] M. P. González Casimiro, «Sarriko,» 14 05 2014. [En línea]. Available: <https://addi.ehu.es/handle/10810/12492>. [Último acceso: 30 04 2023].
- [15] F. J. Nanclares Rodríguez, «Uam,» 06 2021. [En línea]. Available: https://repositorio.uam.es/bitstream/handle/10486/700024/nanclares_rodriiguez_francisco_javier_tfg.pdf?sequence=1. [Último acceso: 10 05 2023].