

## **Modelo de Predicción de Caudales Afluentes para las Centrales Hidroeléctricas Yguazú y de Acaray**

**Christian Arnaldo Sugastti Medina, Anastacio Sebastián Arce Encina**

**Universidad Nacional del Este – Facultad Politécnica**

**Paraguay**

### ***Resumen***

Este trabajo está enfocado en el desarrollo de modelos matemáticos para predicción de caudales afluentes a centrales hidroeléctricas, cubriendo el periodo de un año. Para el efecto se evaluaron comparativamente técnicas estocásticas y neuronales artificiales que fueron implementadas utilizando los registros históricos de caudales medios mensuales de los ríos Yguazú y Acaray, en las presas del mismo nombre, respectivamente. Los resultados obtenidos demostraron que los modelos predictivos seleccionados son apropiados, por lo que se los utilizó para tener una proyección de los caudales medios para los 12 meses del año 2016. De forma complementaria y como una aplicación práctica de las previsiones obtenidas, se llevaron a cabo simulaciones de la producción energética de las centrales hidroeléctricas del Yguazú y del Acaray. Las simulaciones fueron realizadas mediante la aplicación de dos reglas operativas, la primera que consiste en el funcionamiento de ambos aprovechamientos hidroeléctricos como centrales de pasada, y la segunda se simuló la operación coordinada de ambas centrales, haciendo que la Central del Yguazú utilice su embalse para proveer el volumen de agua que requiere la Central de Acaray para operar a plena carga. Los resultados muestran la importancia de la Central de Yguazú en la regulación de los caudales afluentes a la Central de Acaray, obteniendo una mayor producción de energía en la operación coordinada.

### ***Palabras clave***

Caudales Afluentes, Centrales Hidroeléctricas, Redes Neuronales, Series Temporales.

### **1. INTRODUCCIÓN**

La cuenca del río Acaray contiene dos aprovechamientos hídricos para la generación de energía eléctrica, el primero está constituido por la presa del Yguazú, la cual forma un embalse con descarga en el río Acaray. La conjunción de los ríos Yguazú y Acaray desemboca en la presa de la Central Hidroeléctrica de Acaray, que cuenta con unidades generadoras que totalizan una capacidad de 200 MW (Megavatios) y cuyo embalse tiene una capacidad aproximada de 250 Hm<sup>3</sup> entre las cotas de 185 y 178 metros. La presa del Yguazú, que fue construida a inicio de la década del 70 con el objeto de regular los caudales afluentes a la Central de Acaray, posee una capacidad de 5.400 Hm<sup>3</sup> entre las cotas de 223 y 214 metros y futuramente será equipada con unidades generadoras, con el objeto de aprovechar su potencial hidro energético [1]. La disposición esquemática se puede apreciar en la Figura 1. La predicción de caudales afluentes es una de las tareas necesarias para el planeamiento y la operación de las centrales hidroeléctricas. Contar con una estimativa de la disponibilidad hídrica permite elaborar los programas de operación y mantenimiento de los equipos encargados de la generación de energía eléctrica y evaluar diferentes alternativas de comercialización de la energía que ellas producen, entre otros.

XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE  
23 y 24 de Junio 2022




Figura 1: Presa de Yguazú y Central de Acaray.

### 1.1. Revisión Bibliográfica.

Varios métodos han sido propuestos para tratar el problema de la predicción de caudales hídricos. Se destacan por un lado las técnicas “clásicas” o estocásticas, que se basan en el análisis de series temporales o cronológicas y se utilizan para predecir hasta cierto punto una variable aleatoria a partir de sus valores pasados.

Guevara Bello, Vega González y Guevara Pérez llevaron a cabo un análisis estocástico de la serie de tiempo de los caudales medios mensuales del río Caroní, en Venezuela. Para el efecto, utilizaron el método de eliminación de tendencia y periodicidad para la implementación de modelos lineales autorregresivos [2]. Por otro lado, la aplicación de técnicas neuronales ha ido volviéndose habitual en varios campos de la hidrología, debido en parte a la necesidad de emular patrones no lineales presentes en varios fenómenos físicos. Sánchez y Laqui, en su trabajo de investigación [3], utilizaron redes neuronales artificiales para la predicción de caudales medios mensuales del río Huanané, teniendo en cuenta los datos de caudales, precipitaciones y evaporación. Para el efecto, en el trabajo se desarrollaron 10 modelos con distintas arquitecturas. Gomes [4], realizó el modelado de una serie temporal de caudales medios mensuales utilizando la arquitectura conocida como perceptrón multicapa con distintas combinaciones de entradas y de neuronas en la capa oculta. Para la construcción de los modelos utilizó datos de la zona como los caudales medios mensuales de periodos anteriores, las precipitaciones y la temperatura de la zona, entre otras.

A continuación, se presentan las bases teóricas de las técnicas utilizadas para tratar el problema de la predicción.

### 1.2. Modelos ARIMA y SARIMA.

Los modelos autorregresivos integrados de media móvil o *Autoregressive Integrated Moving Average* (ARIMA), son el resultado de la combinación de los procesos estacionarios autorregresivos y de media móvil con los procesos integrados.

La expresión de un proceso ARIMA (p, d, q) es la siguiente:

$$\theta_p(B)(1 - B)^d z_t = \phi_q(B) a_t \quad (1)$$

En donde la letra p de la ecuación (1) es el orden de la parte autorregresiva, d es el orden de integración y q es el orden de la parte de media móvil. Los modelos SARIMA son casos especiales de los procesos autorregresivos integrados de media móvil o ARIMA, la principal diferencia es que posibilitan el modelado de componentes estacionales presentes en las series temporales, como su nombre lo indica, la letra S al inicio proviene de la palabra anglosajona Seasonal o estacional, en español. Un modelo SARIMA(p, d, q)(P, D, Q)s incluye el orden p de la estructura

**XIV SEMINARIO DEL SECTOR ELÉCTRICO PARAGUAYO - CIGRE**  
**23 y 24 de Junio 2022**

autorregresiva regular como el orden  $P$  de la estructura autorregresiva estacional. También especifica los órdenes  $q$  de la estructura de media móvil regular y  $Q$  de la estacional. Además, contiene el orden de diferenciación regular  $d$  y estacional  $D$ , así como la longitud del periodo estacional  $s$ . La expresión matemática de un proceso SARIMA que describe el valor actual  $Z_t$  de una serie temporal en función de sus valores pasados es:

$$\Theta_P(B^s)\theta_p(B)(1-B^s)^D(1-B)^d z_t = \Phi_Q(B^s)\phi_q(B) a_t \quad (2)$$

La letra  $B$  corresponde a un operador que aplicado a una serie temporal  $z_t$  que devuelve la misma serie retrasada un periodo:

$$Bz_t = z_{t-1} \quad (3)$$

Y  $a_t$  es un proceso de ruido blanco con media cero y varianza constante. Los factores  $(1 - B^s)^D$  y  $(1 - B)^d$  son los operadores estacionales y no estacionales respectivamente.

La construcción de modelos ARIMA y SARIMA generalmente se realiza siguiendo la metodología propuesta por Box y Jenkins [5], que puede estar constituida de las siguientes etapas: evaluación de la estacionariedad de la serie temporal, identificación de la estructura ARMA, estimación de los parámetros y selección de los modelos. Para la evaluación de la estacionariedad de las series temporales se pueden utilizar las funciones de autocorrelación simple (FAS) y parcial (FAP) como también realizar pruebas de raíces unitarias con el objetivo de detectar un comportamiento explosivo de las series temporales. Una vez determinada la no estacionariedad se pueden realizar diferenciaciones regulares y/o estacionales con el objetivo de alcanzar la estacionariedad. La estacionariedad de la serie temporal es una condición necesaria que debe ser alcanzada antes de ajustar un modelo ARIMA [6].

La identificación de los órdenes  $p$ ,  $q$ ,  $P$  y  $Q$  de las estructuras regular y estacional de un modelo ARIMA( $p$ ,  $d$ ,  $q$ )( $P$ ,  $D$ ,  $Q$ ) $s$  generalmente se realiza con ayuda de las funciones de autocorrelación simple y parcial, tratando de identificar los coeficientes significativos en cada correlograma.

En la ecuación (2) los parámetros del modelo son las constantes:  $\theta_p$ ,  $\phi_q$ ,  $\Theta_P$  y  $\Phi_Q$ . Los parámetros  $\theta_p$  y  $\phi_q$  corresponden a la estructura regular del modelo mientras que  $\Theta_P$  y  $\Phi_Q$  pertenecen a la estructura estacional, que puede ser mensual ( $D = 12$ ) o de cualquier otra periodicidad (trimestral, semestral, etc.). Estos parámetros se estiman de tal forma que maximicen la probabilidad de que el modelo sea capaz de reproducir los datos originales de la serie temporal.

Durante el proceso de ajuste se tendrá una lista de modelos tentativos los cuales serán evaluados antes de seleccionar al más adecuado entre todos, dicha elección puede realizarse empleando el criterio AICC para cada uno de los modelos ajustados. El criterio AICC o criterio de Akaike Corregido se define mediante:

$$AICC = -2 \log(L) + 2k + \frac{2k(k+1)}{T-k-1} \quad (4)$$

En donde  $T$  es el tamaño muestral utilizado para estimar los parámetros del modelo, en este caso, el número de observaciones de las series temporales originales,  $L$  la verosimilitud del modelo y  $k$  es el total de parámetros del modelo. Este criterio es adecuado para comparar modelos con el mismo orden de diferenciación regular o estacional, pero no se recomienda utilizarlo para comparar modelos de distinto orden de diferenciación [7].


La etapa de evaluación consiste en determinar el nivel de adecuación del modelo estimado a los datos de la serie temporal original mediante la inspección de los residuos, los cuales no deben tener ningún tipo de dependencia lineal entre sí y deben aproximarse del ruido blanco con media cero y varianza constante [6].

**XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE**  
**23 y 24 de Junio 2022**

1.3. Modelos de redes neuronales artificiales

Las redes neuronales artificiales (RNA) son herramientas concebidas dentro del campo de la inteligencia artificial para la resolución de tareas complejas. Las arquitecturas de redes neuronales se basan en la emulación del comportamiento de las neuronas físicas y se caracterizan por la utilización de combinaciones lineales de varios datos de entrada que se proveen teniendo en cuenta algunos criterios específicos. Las redes neuronales artificiales son muy útiles en el análisis de series temporales con características no estacionarias, con tendencias determinísticas muy pronunciadas, estas series son las que en la práctica se presentan más frecuentemente en el mundo real.

La mayoría de las arquitecturas de redes neuronales se basan en el principio de agrupar a las neuronas en capas de entrada, capas de salida y capas ocultas. Cada una de estas capas cuenta con un número específico de neuronas que deben estar interconectadas entre sí para intercambiar información y así entrenarse. La distribución de las neuronas en tres tipos de capas diferentes hace que la salida (output) de una determinada capa sea la entrada (input) para la capa siguiente. La Figura 2 extraída de [8] corresponde a una arquitectura de red neuronal llamada perceptrón. Este modelo puede tener una o varias capas ocultas además de otros parámetros que serán definidos a continuación.



**Figura 2: Estructura de un perceptrón.**

Los pesos sinápticos (en inglés *weights*) de una red neuronal artificial son equivalentes a la pendiente de una función lineal. El término *bias* de una red neuronal, se puede entender como un valor adicional que cumple la función de ajustar el resultado de la suma ponderada de los inputs del modelo, sería equivalente al componente de intercepción con el eje de las ordenadas en una función lineal [9]. Matemáticamente, las operaciones que se llevan a cabo dentro de las neuronas de las capas para determinar sus respectivos valores de salida tienen la siguiente forma:

$$u = \sum_{i=1}^n w_{ij}x_j + b_j \quad (5)$$

En la ecuación (5) los pesos sinápticos  $w_{ij}$  son los que se encuentran asociados a cada uno de los inputs  $x_j$  provistos en la capa de entrada junto con los valores *bias*  $b_j$ . A esta salida  $u$  de características lineales generalmente se le aplica una función de activación no lineal para limitarla dentro de un rango específico. Cabe resaltar que la función debe ser derivable, para poder aplicar técnicas de optimización que permitan entrenar a la red neuronal. La función de activación es la que introduce la propiedad de no linealidad en la red neuronal, haciendo posible la resolución de problemas complejos como el reconocimiento de patrones en imágenes o la detección y eliminación de ruido en una línea telefónica [10]. Algunas de las funciones de activaciones más utilizadas son la sigmoide y la tangente hiperbólica.

El proceso de entrenamiento de una red neuronal se lleva a cabo minimizando una función de costo  $f$ , la cual generalmente consta de dos tipos de términos: uno es el error de ajuste de la red a los datos provistos y otro que se utiliza para evitar el sobre aprendizaje de la red. Esta función

**XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE**  
**23 y 24 de Junio 2022**

depende de los pesos sinápticos y de los términos de bias, que se agrupan en un solo vector  $w$ , por lo que se puede escribir a la función de error como  $f(w)$  y el objetivo del proceso de optimización es encontrar el vector  $w'$  que posee los parámetros para los cuales existe un mínimo global [11]. La búsqueda del vector  $w'$  se realiza de manera iterativa, ya sea generando nuevos vectores hasta que el error se reduzca lo suficiente o estableciendo un criterio de parada específico. En ocasiones la búsqueda puede truncarse haciendo que la función nunca llegue al mínimo global, en este caso decimos que la función quedó atrapada en un mínimo local. Existen varios algoritmos para llevar a cabo este proceso, los cuales varían en precisión, velocidad y cantidad de memoria computacional utilizada. El algoritmo de gradiente descendiente es el más ampliamente utilizado. El método del gradiente descendiente utiliza los valores negativos de los componentes del vector gradiente, de manera a que los pesos sinápticos vayan optimizándose en la dirección del mayor decrecimiento del error mediante la siguiente formula:

$$w^{i+1} = w^i - \frac{\partial f}{\partial w_i} \eta \quad (6)$$

En donde: Si existen  $n$  pesos sinápticos  $w$ , los componentes del vector gradiente de la función  $f(w)$  son:

$$\nabla_i f(w) = \frac{\partial f}{\partial w_i} \quad i = 1, \dots, n \quad (7)$$

El parámetro  $\eta$  es la tasa de aprendizaje, esta define la velocidad con que se lleva a cabo el proceso de aprendizaje. Generalmente este valor es muy pequeño, ralentizando el proceso, pero evitando que la función de error quede atrapada en mínimos locales. En ocasiones, a la ecuación se le agrega otro parámetro  $\mu$  llamado *momento*:

$$w^{i+1} = w^i - \frac{\partial f}{\partial w_i} \eta + \mu(w^i - w^{i-1}) \quad (8)$$

Su función es permitir que los pesos sinápticos se actualicen a pasos largos cuando la curvatura no es tan pronunciada y que realice lo contrario cuando la curvatura es grande, de esta manera se soluciona el problema del estancamiento en mínimos locales del proceso de aprendizaje [12]. Generalmente las redes entrenadas cuentan un número muy elevado de neuronas, por lo que la aplicación de la ecuación (8) se debe realizar en cada uno de los nodos, exigiendo bastantes recursos computacionales. El método de entrenamiento de *Backpropagation* presenta una solución a esta problemática mediante lo que se conoce como la retro propagación del error utilizando el concepto del descenso del gradiente para optimizar los valores de los pesos sinápticos [13].

## 2. METODOS

Para el modelado del comportamiento de la afluencia, se utilizaron los datos de caudales medios mensuales (periodo 1979 - 2015) correspondientes a los ríos Yguazú y Acaray.

Los datos disponibles del río Acaray incorporaban la influencia del Yguazú por lo que se optó primeramente por aislar los aportes de cada uno de los cauces hídricos para realizar el estudio de cada serie temporal de manera individual. La serie temporal correspondiente a los aportes del río Acaray sin la influencia del Yguazú fue nombrada como Acaraymi. Fueron ajustados modelos estocásticos y neuronales a cada una de las series para luego evaluar el desempeño de ambas técnicas y seleccionar la más adecuada. Para la construcción y validación de los modelos se dividieron los datos disponibles en conjuntos de entrenamiento y de prueba de la forma como se muestra en la Tabla I. El conjunto de entrenamiento sirvió para optimizar a las redes neuronales

**XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE**  
23 y 24 de Junio 2022

y calcular los parámetros autorregresivos y de media móvil de los modelos estocásticos, mientras que el conjunto de prueba se utilizó exclusivamente para evaluar el desempeño en la predicción de cada uno de los modelos. La metodología utilizada para el ajuste de los modelos estocásticos fue una variante de la propuesta por Box y Jenkins [5], en donde primeramente se buscó obtener la estacionariedad de las series temporales. Para la estimación de los parámetros y la selección de los modelos se utilizaron las funciones contenidas dentro del paquete forecast, desarrollado por Rob J. Hyndman para el lenguaje de programación R [14]. En cuanto a los modelos neuronales, siguiendo una variación de la metodología adoptada por Gomes [4] y Ochoa [15] para el preprocesamiento de datos, buscando elevar la eficiencia en el aprendizaje de las redes neuronales. Una vez finalizados el entrenamiento y las pruebas, los datos vuelven a transformarse para obtener los valores en la escala original se llevaron a cabo los siguientes procedimientos:

2.1. Normalización

Con esto se buscó elevar la eficiencia de las redes neuronales artificiales a la hora de captar los patrones de los datos de entrada y por consecuencia, disminuir el tiempo de entrenamiento. Para la normalización de los datos se utilizaron las transformaciones cuadráticas del tipo:

$$Z_t = \sqrt[4]{y_t} \quad (9)$$

En donde  $y_t$  es la serie temporal original y  $Z_t$  es la serie normalizada.

2.2. Tipificación

Se realizó con la intención de remover posibles componentes determinísticos presentes en los datos que hubieran dificultado el entrenamiento de las series neuronales. Para la tipificación de los datos se utilizó la formula estadística de unidad tipificada:

$$y_t = z_i - \bar{z}_i \sigma_i \quad (10)$$

En donde  $z_i$  es el valor de la serie normalizada correspondiente al mes  $i$ ,  $\bar{z}_i$  es el valor medio para el mes  $i$  y  $\sigma_i$  es su desviación estándar.

2.3. Escalamiento

Los datos utilizados fueron previamente trabajados para que se encuentren distribuidos entre determinados valores mínimos y máximos, con el objetivo de que todos los valores se encuentren en el rango de la función de activación a ser utilizada. La ecuación de escalamiento utilizada fue la siguiente:

$$Z_t = \frac{(L_s - L_i)Y_{VT} + (L_i M_z - L_s m_z)}{M_z - m_z} \quad (11)$$

En donde  $Z_T$  es la serie escalada,  $M_z$  es el valor máximo de la serie temporal  $Y_{VT}$  (serie tipificada),  $m_z$  es el valor mínimo de la serie temporal  $Y_{VT}$  (serie tipificada),  $L_s$  es el límite superior del intervalo a adoptar para escalar,  $L_i$  es el límite inferior del intervalo a adoptar para escalar.

Tabla I: División de los datos disponibles.

Serie	Conjunto de entrenamiento	Conjunto de prueba
Acaraymi	Enero de 1979 a diciembre de 2007	Enero de 2008 a diciembre de 2015
Yguazú		

#### XIV SEMINARIO DEL SECTOR ELÉCTRICO PARAGUAYO - CIGRE 23 y 24 de Junio 2022

Todas las redes fueron del tipo Perceptrón multicapa. Todos los modelos estudiados contaron con tres capas: una capa de entrada donde se encuentran los *inputs*, una capa oculta que utiliza la función de activación tangente hiperbólica y una capa de salida. En total se entrenaron 5 redes neuronales para cada serie temporal, con distintos números de neuronas en la capa oculta.

Se determinó el número óptimo de *inputs* para las redes neuronales mediante la inspección de las funciones de autocorrelación simple (FAS), identificando los retardos con coeficientes más altos. En el caso de la serie Acaraymi, se utilizaron 12 *inputs* para las redes neuronales a ser entrenadas. Estos inputs corresponden a los primeros 12 retardos de la serie original. En el caso de la serie Yguazú, se utilizaron los 10 primeros retardos como *inputs* de las redes neuronales.

Los parámetros de las redes durante el entrenamiento, se fijó la tasa de aprendizaje en 0,01. Las funciones de activación fueron del tipo tangente hiperbólica. El criterio de parada del entrenamiento fue un error de iteración máximo de 0,02. El entrenamiento de las redes neuronales se realizó utilizando el *framework* de java, Neuroph [16].

#### 2.4. Evaluación.

Para evaluar el ajuste de los modelos a los datos de entrenamiento y de prueba, se utilizaron métricas de errores. En particular, las métricas seleccionadas fueron:

El error absoluto medio o MAE

$$MAE = \frac{\sum_{i=1}^n |Q_{i,obs} - Q_{i,sim}|}{n} \quad (12)$$

El MAE cuantifica el valor medio de los errores sin considerar si estos se producen por defecto o por exceso y se lo utiliza para evaluar la precisión de los modelos matemáticos con relación a los datos observados. La métrica del error cuadrático medio o RMSE posee la ventaja de proveer el resultado en las unidades de medida originales de los datos y de ser bastante robusto. Otra ventaja de esta métrica es que posibilita penalizar con más peso a los errores elevados, haciendo que sea posible tener un panorama más general del desempeño de un modelo.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{i,obs} - Q_{i,sim})^2}{n}} \quad (13)$$

### 3. RESULTADOS

#### 3.1. Modelos ARIMA y SARIMA.

Durante el análisis de la serie temporal correspondiente al río Acaraymi no se observó un patrón sistemático en lo que respecta a una tendencia. Se detectaron correlaciones entre los valores anuales de desviación estándar y las medias anuales de la serie. El correlograma no indicó necesidad de diferenciación. El modelo estocástico seleccionado fue el ARIMA (2, 0, 1). La función de autocorrelación simple de los residuos no indicó para los primeros 30 retardos la presencia de dependencia lineal ya que todos se encontraban dentro de un nivel de significancia mínimo. En cuanto a la serie del río Yguazú, el modelo seleccionado fue el SARIMA(3, 0, 3)(2, 0, 0). El análisis de los residuos mediante la función de autocorrelación simple determinó que estos tenían una débil correlación entre sí y por lo tanto el modelo era válido.

#### 3.2. Modelos de Redes Neuronales Artificiales.

Todos los modelos neuronales para la serie Acaraymi lograron resultados similares en lo que respecta a las métricas evaluativas utilizadas: el error RMSE y el error MAE en el conjunto de entrenamiento, destacándose la red 5 con 25 neuronas en la capa oculta. Por el lado de la serie Yguazú, la red 1 con 5 neuronas en la capa oculta fue la de mejor desempeño.

**XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE**  
23 y 24 de Junio 2022

3.3. Análisis comparativo.

En la Tabla III se observa la comparación entre el modelo ARIMA (2, 0, 1) y la red neuronal 5 en el conjunto de prueba de la serie Acaraymi. Se puede apreciar que la red neuronal demostró una mejor capacidad de predicción que el modelo estocástico considerando los criterios RMSE y MAE.

Tabla III: Comparativo entre los modelos para la serie Acaraymi.

Modelo	RMSE	MAE
Red Neuronal número 5	33,17	26,05
ARIMA(2, 0, 1)	36,55	27,75

Por otro lado, en lo que respecta a la serie Yguazú el comparativo de la Tabla IV entre el modelo estocástico SARIMA(3, 0, 3)(2, 0, 0)[12] y la red neuronal número 1, con 5 neuronas en la capa oculta, demuestra una clara superioridad del modelo estocástico en cuanto a la capacidad de predicción.

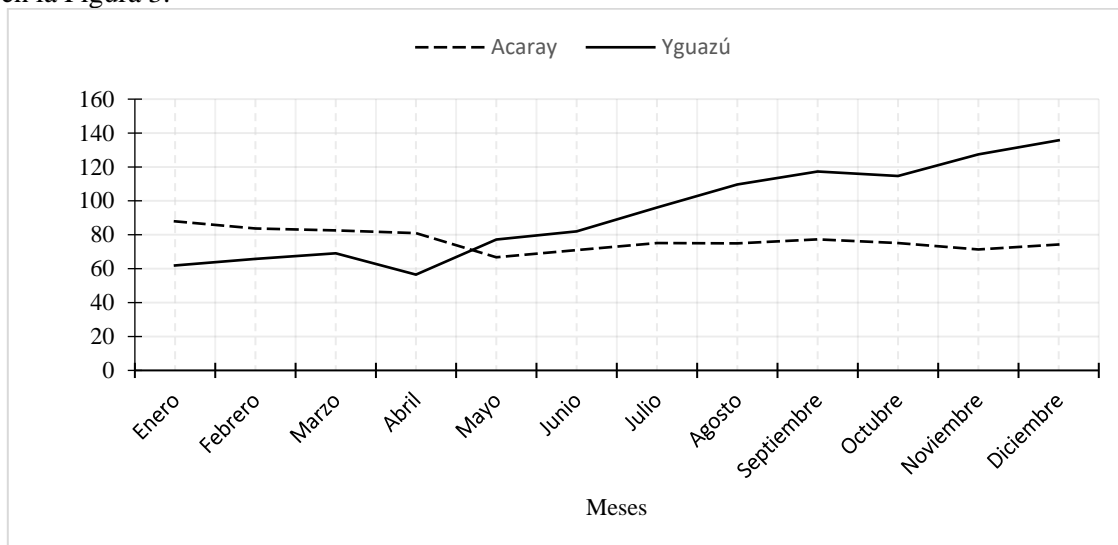
Tabla IV: Comparativo entre los modelos para la serie Yguazú.

Modelo	RMSE	MAE
Red Neuronal 1	65,96	50,05
SARIMA(3, 0, 3)(2, 0, 0)[12]	59,08	46,82

Por lo tanto, el modelo predictivo más adecuado para la serie Acaraymi resultó ser la red neuronal 5, mientras que el modelo estocástico SARIMA(3,0,3)(2,0,0) fue seleccionado para la serie Yguazú.

3.4. Aplicación práctica de los resultados obtenidos.

Con los modelos seleccionados para ambas series temporales se estimaron los caudales promedios mensuales de los 12 meses del año 2016 para los ríos Yguazú y Acaraymi, los cuales se muestran en la Figura 3.



**Figura 3: Gráfica de caudales medios mensuales pronosticados para los 12 meses del año 2016.**



**XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE**  
**23 y 24 de Junio 2022**

De manera complementaria y con la utilización de los datos de caudales obtenidos, se estimó la producción de las centrales hidroeléctricas para el año 2016, siguiendo básicamente dos reglas de operación en ambas usinas. La primera, una regla de operación en que ambas centrales operan sin capacidad de regulación de los caudales que llegan a sus respectivos embalses y sin ninguna coordinación, y una segunda regla de operación en la cual la Central del Yguazú operó como reguladora de los caudales afluentes al Acaray.

En ambas reglas se buscó obtener la máxima producción posible. La potencia instalada adoptada para la central Yguazú fue de 200 MW. Los polinomios de Cota versus Canal de fuga, Cota versus Embalse y los factores de productividad de ambas centrales, necesarios para las simulaciones fueron obtenidos del trabajo de L. G. Barrientos Mujica y L. R. Álvarez Ferreira [17]. La producción media anual para cada una de las centrales (en MWmed) se encuentra en la Tabla V.

#### 4. DISCUSION

Se ha abordado la problemática del modelado de los caudales afluentes a las represas del Yguazú y del Acaray con el objeto de realizar predicciones hasta el horizonte de un año. Para el efecto, se han utilizado datos reales de caudales medios mensuales afluentes a dichas represa y se han construido modelos predictivos utilizando técnicas estocásticas y neuronales. Se ha demostrado que tanto las técnicas estocásticas como las neuronales son alternativas factibles para tratar el problema de la predicción de caudales. Las redes neuronales tuvieron un mejor desempeño con los datos de la serie Acaraymi, mientras que las técnicas estocásticas lograron mejores resultados para la serie Yguazú. De este resultado, se puede concluir que el éxito de una u otra técnica de predicción no está garantizado en todos los casos de estudio. El preprocesamiento de los datos de entrada de las redes neuronales pudo afectar el desempeño de las mismas debido a la remoción de algunas características inherentes de las series temporales originales. Eventualmente, se podrían obtener mejores resultados modificando las metodologías utilizadas y realizando un análisis más profundo de las series hidrológicas que han sido estudiadas. En cuanto a los resultados de la simulación de operación de las centrales hidroeléctricas de Yguazú y Acaray, se demuestra la importancia de la Central de Yguazú en la regulación de los caudales afluentes a la Central de Acaray, obteniendo una mayor producción de energía en la operación coordinada.

Tabla V: Producción anual de las centrales hidroeléctricas para cada una de las dos reglas de operación utilizadas.

	CH Acaray (MWmed)	CH Yguazú (MWmed)	Producción Promedio Anual (MWmed)
Regla 1	153.39	26.92	180.31
Regla 2	200	39.74	239.74

#### 5. REFERENCIAS BIBLIOGRÁFICAS

- [1] Plan Maestro de Generación de la ANDE (2016 - 2025). Administración Nacional de Electricidad, 2016.
- [2] J. Guevara, C. Vega y E. Pérez, *Análisis estocástico de una serie cronológica de caudales mensuales. Caso de estudio: Río Caroní, Venezuela*. Rev. Ing. UC, 2010.
- [3] M. Sánchez y W. Laqui, "Predicción de caudales medios mensuales del Río Huancané utilizando Modelos de Redes Neuronales", An. Científicos, 2009.
- [4] G. Gomes Villa Trinidad, *Modelo De Predicción De Aportaciones Mensuales Utilizando Redes Neuronales Artificiales. Aplicación A La Cuenca Del Río Amambaí (Brasil)*, Trabajo Fin de Máster, Universidad Politécnica de Valencia, Nov. 2016.
- [5] G. Box, G. Jenkins and G. Reinsel, *Time Series Analysis: Forecasting and Control*. Prentice Hall, 1994.

**XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE**  
**23 y 24 de Junio 2022**

---

- [6] D. Peña, *Análisis de series temporales*. Alianza Editorial, 2010.
- [7] R. Hyndman and G. Athanasopoulos, *Forecasting Principles and Practice*. 2018. [Online]. Available: [OText.com/fpp2](http://OText.com/fpp2).
- [8] N. Mohan. “Predicting Post-Procedural Complications Using Neural Networks on MIMIC-III Data”, 2018.
- [9] G. Ciaburro and B. Venkateswaran, *Neural network with R*. Packt, 2017.
- [10] L. Fausett, “Fundamentals of Neural Network Architectures, Algorithms, and Applications”, Prentice Hall, 1994.
- [11] F. Caparrini, “Entrenamiento de Redes Neuronales: mejorando el Gradiente Descendiente”, 2017. [Online]. Available: <http://www.cs.us.es/~fsancho/?e=165>.
- [12] Alex, “Gradient Descent and Momentum: The Heavy Ball Method”, 2020. [Online]. Available: <https://boostedml.com/2020/07/gradient-descent-and-momentum-the-heavy-ball-method.html>.
- [13] N. Lewis, *Neural Networks for Time Series Forecasting with R*. Nigel D. Lewis, 2020.
- [14] R. Hyndman and Y. Khandakar, “Automatic time series forecasting: the forecast package for R”, *Journal of Statistical Software*, vol. 26, no. 3, pp. 1-22, 2008, [Online]. Available: <http://www.jstatsoft.org/article/view/v0\27i03>
- [15] C. Ochoa, “Modelo estocástico de redes neuronales para la síntesis de caudales aplicados a la gestión probabilística de sequías”, Universidad Politécnica de Valencia, 2002.
- [16] Neuroph Team, “Neuroph: A Java Neural Network Framework”, 2008. [Online]. Available: <http://neuroph.sourceforge.net/>
- [17] L. G. Barrientos Mujica y L. R. Álvarez Ferreira, “Un Modelo de Planeamiento de La Operación de Largo y Medio Plazo de Las Usinas Hidroeléctricas de Yguazú Y Acaray”, Universidad Nacional del Este, Paraguay.