

Modelo de predicción de caudales afluentes para centrales hidroeléctricas Yguazú y Acaray

Christian Arnaldo Sugastti Medina¹, Anastacio Sebastián Arce Encina² y Willians Panadero³

Facultad Politécnica, Universidad Nacional del Este

Ciudad del Este, Paraguay

¹cmolina9088@hotmail.com1, ²arce@fpune.edu.py, ³wpanadero@gmail.com

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, como 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 consiste en el funcionamiento de ambos aprovechamientos hidroeléctricos como centrales de pasada, y la segunda consiste en simular la operación coordinada de ambas centrales, haciendo que la Central de Yguazú utilice su embalse para proveer el volumen de agua que requiere la Central de Acaray para operar a plena carga. Los resultados muestran que la Central de Yguazú mejora significativamente la regulación de los caudales afluentes a la Central de Acaray, logrando obtener mayor producción de energía con la operación coordinada.

Descriptores: caudal afluente, central hidroeléctrica, serie temporal.

Abstract

This work is focused on the development of mathematical models for the prediction of inflows to hydroelectric power plants, covering a period of one year. For this purpose, stochastic and artificial neural techniques were comparatively evaluated and implemented using historical records of average monthly flows of the Yguazú and Acaray rivers, in the dams of the same name, respectively. The results obtained showed that the selected predictive models are appropriate, so they were used to have a projection of average flows for the 12 months of 2016. In addition, as a practical application of the forecasts obtained, simulations of the Yguazú and Acaray hydroelectric power plants energy production were carried out. Two operating rules were applied in the simulations, the first one consists of the operation of both hydroelectric plants as run-of-river plants, and the second one consists of simulating the coordinated operation of both plants, making the Yguazú plant use its reservoir to provide the volume of water required by the Acaray plant to operate at full load. The results show that the Yguazú plant significantly improves the regulation of the inflows to the Acaray plant, achieving higher energy production with the coordinated operation.

Keywords: influent flow, hydroelectric power plant, time series.

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 terminan en la presa de la Central Hidro-

eléctrica de Acaray, conforme se puede apreciar en la figura 1.



Figura 1. Presas sobre el río Yguazú, y de la Central de Acaray sobre el río epónimo.

El embalse de la presa del Acaray tiene una capacidad aproximada de 250 Hm^3 , contenida entre las cotas de 185 y 178 metros. La presa del Yguasu 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^3 entre las cotas de 223 y 214 metros. La presa del Yguasu futuramente será equipada con unidades generadoras, con el objeto de aprovechar su potencial hidro energético, cuya función actual es solo regular los caudales afluentes a la Central de Acaray [13]. Por otro lado, la central hidroeléctrica de Acaray posee en sus instalaciones unidades generadoras que totalizan una capacidad de 200 MW. La predicción de caudales afluentes constituye una de las tareas necesarias para el planeamiento y la operación de las centrales hidroeléctricas. Contar con una estimativa de los caudales afluentes por un determinado periodo de tiempo, posibilita elaborar los programas de operación y mantenimiento de los equipos encargados de la generación de energía eléctrica, y evaluar las alternativas de comercialización de la energía que ellas producen.

1.1. 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* (en castellano: estacional), y se refiere al componente estacional. Un modelo SARIMA(p, d, q)(P, D, Q) s incluye el orden p de la estructura 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:

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

Donde

$$\begin{aligned} \theta_p(B) &= 1 - \theta_1(B) - \theta_2(B)^2 - \dots - \theta_p(B)^p \\ \Theta_P(B) &= 1 - \Theta_1(B) - \Theta_2(B)^2 - \dots - \Theta_P(B)^P \\ \phi_q(B) &= 1 - \phi_1(B) - \phi_2(B)^2 - \dots - \phi_q(B)^q \\ \Phi_Q(B) &= 1 - \Phi_1(B) - \Phi_2(B)^2 - \dots - \Phi_Q(B)^Q \end{aligned}$$

La letra B corresponde a un operador que aplicado a una serie temporal Z_t , produce la misma serie atrasada un periodo:

$$BZ_t = Z_{t-1} \quad (3)$$

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

La construcción de modelos ARIMA y SARIMA generalmente se realiza siguiendo el método propuesto por Box y Jenkins [2], 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 definida 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 [3].

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: $\theta_p, \phi_q, \Theta_P, \Phi_Q$. Los parámetros

θ_p, ϕ_q corresponden a la estructura regular del modelo mientras que Θ_P, Φ_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 obtiene una lista de modelos tentativos los cuales deben ser 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, que se define mediante:

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

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 es 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 [4]. 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 [3].

1.2. Modelos de redes neuronales artificiales

Las redes neuronales artificiales (RNA) son una herramienta concebida 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, ya sea en presencia de estacionalidad o tendencia. Estos tipos de series temporales son los que se encuentran 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 ellas consta de un número definido de neuronas que pueden estar interconectadas entre sí para intercambiar información. La distribución de las neuronas en tres tipos de capas diferentes hace que la salida

(output) de una capa sea la entrada (input) para la capa siguiente. La figura 2 extraída de [5], corresponde a una arquitectura de red neuronal llamada perceptrón. Este modelo puede tener una o varias capas ocultas además de otros parámetros que son definidos a continuación.




Figura 2. Estructura de red neuronal 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 [6]. 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:

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

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 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 posibiliten 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 [7]. Algunas de las funciones de activación 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 el otro es el que se utiliza para evitar sobre aprendizaje de la red. Esta función 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 hay un mínimo global [8]. La búsqueda del vector $w^?$ se realiza de manera iterativa, ya sea generando nuevos vectores hasta que el error se reduzca lo suficiente o mediante el establecimiento de un criterio de parada específico. En ocasiones la búsqueda puede truncarse haciendo que la función nunca llegue al mínimo global, en este caso se asume que la función quedó atrapada en un mínimo local. Hay varios algoritmos para llevar a cabo este proceso, estos varían en precisión, velocidad y cantidad de memoria computacional utilizada. El algoritmo de gradiente descendiente es el más ampliamente utilizado. Este método utiliza los valores negativos de los componentes del vector gradiente, de manera que los pesos sinápticos vayan optimizándose en la dirección de mayor decrecimiento del error mediante la siguiente ecuación:

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

Donde: si hay n pesos sinápticos w , los componentes del vector gradiente de la función $f(w)$ son

$$\nabla_1 f(w) = \frac{\partial f}{\partial w_i}; \quad i = 1, \dots, n \quad (7)$$

El parámetro η 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, se agrega otro parámetro μ 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 posibilitar que los pesos sinápticos se actualicen a pasos largos cuando la curvatura no es tan pronunciada y que ocurra lo contrario cuando la curvatura es grande, de esta manera se soluciona el problema del estancamiento en mínimos locales del proceso de aprendizaje [9]. Generalmente las redes entrenadas cuentan con 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 [10].

1.3. Antecedentes

Numerosos métodos han sido propuestos para encarar el problema de la previsión de caudales hídricos, entre los cuales se destacan por un lado los procedimientos clásicos de modelado estadístico utilizando técnicas del análisis de series temporales y por otro la aplicación de las redes neuronales artificiales. 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 [14].

Por otra parte, Sánchez en su trabajo de investigación, utilizó las redes neuronales artificiales para la predicción de caudales medios mensuales del río o Huancané, teniendo en cuenta los datos de caudales, precipitaciones y evaporación. Para el efecto, en el trabajo se desarrollaron 10 modelos con distintas arquitecturas [15].

Gomes, 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 las entradas, utilizó distintos datos de la zona como los caudales medios mensuales de periodos anteriores, las precipitaciones y la temperatura de la zona, entre otras [11].

2. Método

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. Como se puede apreciar en la figura 3, el río Yguazú intercepta al Acaray en la frontera entre los departamentos Alto Paraná y Caaguazú.



Figura 3. Confluencia de los ríos Yguazú y Acaray.

Los datos disponibles del río Acaray incorporan la influencia del Yguazú por lo tanto se optó por aislar primeramente 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 eva-

luar el desempeño de ambas técnicas y seleccionar la más adecuada. Las figuras 4 y 5 corresponden a las gráficas de las series temporales de los ríos Yguazú y Acaraymi respectivamente.

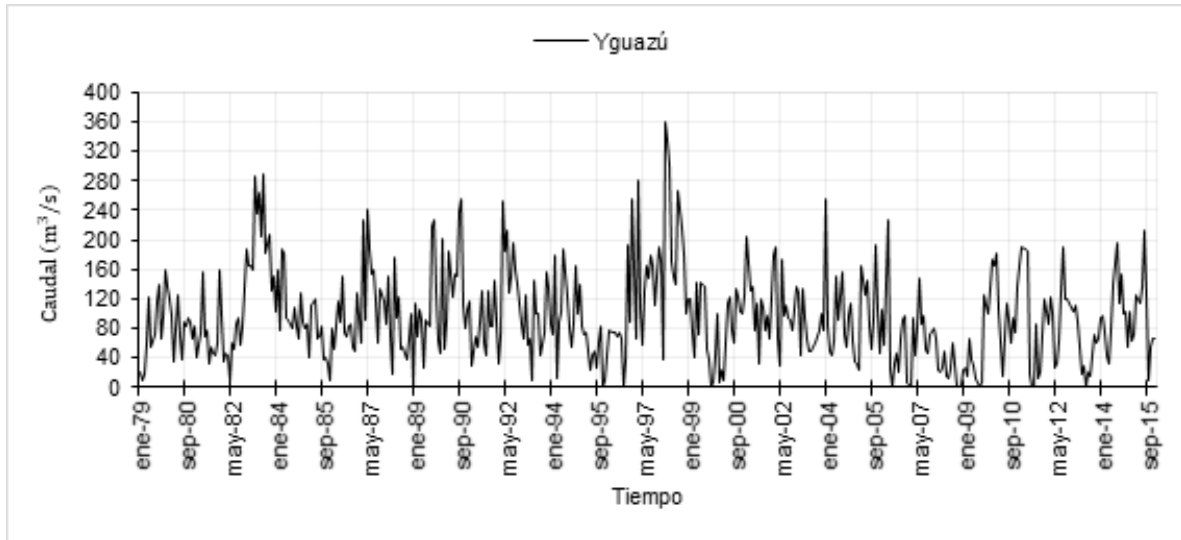


Figura 4. Serie temporal del río Yguasu.




Figura 5. Serie temporal del río Acaraymi.

Para la construcción y validación de los modelos se dividieron los datos disponibles de los ríos Yguasu y Acaray en conjuntos de entrenamiento y de prueba: el conjunto de datos para entrenamiento abarca datos desde enero de 2079 hasta diciembre de 2007, y el conjunto de datos de prueba abarca desde enero de 2008 hasta diciembre de 2015. El conjunto de entrenamiento sirvió para optimizar las redes neuronales 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.

El método utilizado para ajustar los modelos estocásticos fue una variante de la propuesta por Box y Jenkins [2], en donde primeramente se buscó obtener la estacionariedad de las series tempora-

les, si fuere necesaria. 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 [11].

En cuanto a los modelos neuronales, siguiendo una variación del método adoptado por Gomes [11] para el preprocesamiento de datos, buscando 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, se llevaron a cabo los siguientes procedimientos:

Normalización

Las series de datos fueron normalizadas con el fin de que sigan aproximadamente una distribución de probabilidad normal, con coeficiente de asimetría próximo a cero. Con esto se buscó elevar la eficiencia de las redes neuronales artificiales a la hora de captar los patrones de datos de entrada y por consecuencia, disminuir el tiempo de entrenamiento. Para la normalización de los datos se utilizaron las transformaciones cuadráticas del tipo:

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

Donde y_t es la serie temporal original y Z_t es la serie normalizada.

Tipificación

Esta operación fue aplicada a los datos normalizados con la intención de remover posibles tendencias y periodicidades en los datos que hubieran dificultado el entrenamiento de las series neuronales. Para la tipificación de los datos se utilizó la fórmula 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 σ_i es su desviación estándar.

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:

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

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.

Todas las redes fueron del tipo Perceptrón multicapa, debido a su versatilidad y facilidad de entrenamiento y modificación de sus parámetros en caso de necesidad. 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. Como se expone en la tabla 1, en total se entrenaron cinco redes neuronales para cada serie temporal, con distintas cantidades de neuronas en la capa oculta.

Tabla 1. Cantidad de neuronas en capas ocultas por cada red neuronal.

Cantidad de redes neuronales	Cantidad de neuronas en la capa oculta
2	10
3	15
4	20
	25

Para cada una de las series estudiadas, se buscó determinar el número óptimo de *inputs* para las redes neuronales mediante la inspección de las funciones de autocorrelación simple, 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 Yguasú, se utilizaron los 10 primeros retardos como *inputs* de las redes neuronales. Los parámetros de las redes durante el entrenamiento fueron fijados al valor 0,01 de tasa de aprendizaje, en combinación con el valor 0,9 de **momentum**. Las funciones de activación fueron del tipo tangente hiperbólica. El criterio de parada del entrenamiento fue un error relativo de iteración máximo de 0,02. El entrenamiento de las redes neuronales se realizó utilizando el **framework** de java Neuroph [16].

Evaluación

Para evaluar el ajuste de los modelos a los datos de entrenamiento y de prueba, se utilizaron los errores RMSE y MAE:

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

El error medio absoluto o MAE cuantifica el valor medio de los errores sin considerar si estos se producen por defecto o por exceso. Su principal ventaja es la facilidad de interpretación.

Por otra parte, la métrica del error cuadrático medio o RMSE presentado a continuación en la Ec. 13 posee la ventaja de dar 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 determinado 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 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 para los primeros 30 retardos carece de dependencia lineal ya que todos se encontraban dentro de un nivel de significancia mínimo (línea punteada), conforme se puede observar en la figura 6.




Figura 6. Función de autocorrelación simple de los residuos del modelo ARIMA (2, 0, 1).

El modelo seleccionado para la serie del río Yguasu fue SARIMA(3, 0, 3)(2, 0, 0). El análisis de los residuos mediante la función de autocorrelación simple indicó que estos no tenían correlación entre sí y por lo tanto el modelo era válido, conforme se puede observar en la figura 7.




Figura 7. Función de autocorrelación simple de los residuos del modelo SARIMA(3, 0, 3)(2, 0, 0).

3.2. Modelos de Redes Neuronales Artificiales

Con todos los modelos neuronales para la serie Acaraymi se lograron resultados similares en lo que respecta a las métricas evaluativas utilizadas: en los errores RMSE y MAE en el conjunto de entrenamiento, destacándose la red 5 con 25 neuronas en la capa oculta.

Con respecto a la serie Yguasu, la red 1 con 5 neuronas en la capa oculta fue la de mejor desempeño.

3.3. Análisis comparativo

En la tabla 2 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 de errores RMSE y MAE.

Tabla 2. Cuadro comparativo entre los modelos de red neuronal número 5 y ARIMA(2,0,1) para la serie Acaraymi.

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

En la figura 8 se puede observar el grado de precisión con que sigue la curva de simulación por el modelo SARIMA(3,0,3)(2,0,0), a la curva de datos observados para la serie Yguasu [9].

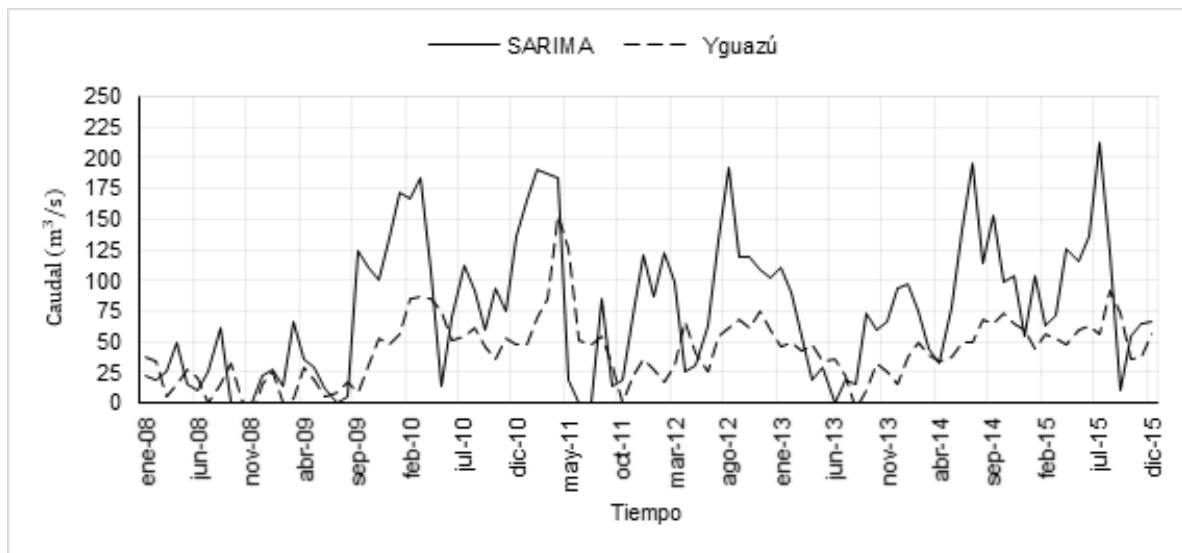


Figura 8. Curvas comparativas entre valores observados de la serie Yguazú y valores simulados por el modelo SARIMA(3,0,3)(2,0,0) [9].

Con respecto a la serie Yguasu, el cuadro comparativo de la tabla 3 entre el modelo estocástico SARIMA(3, 0, 3)(2, 0, 0) [9] y la red neuronal número 1, con 5 neuronas en la capa oculta, muestra una clara superioridad del modelo estocástico en cuanto a capacidad de predicción.

Tabla 3. Cuadro comparativo entre los modelos RNA 1 y SARIMA(3,0,3)(2,0,0) para la serie Yguasu [9].

Modelo	RMSE	MAE
red neuronal 1	65,96	50,05
SARIMA(3,0,3)(2,0,0)	59,08	46,82

En conclusión, 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 Yguasu. La figura 8 mostrada sobre estas líneas y la figura 9 mostrada a continuación corresponden a los gráficos de valores observados correspondientes a los conjuntos de prueba de cada serie temporal y los valores simulados por los modelos seleccionados.

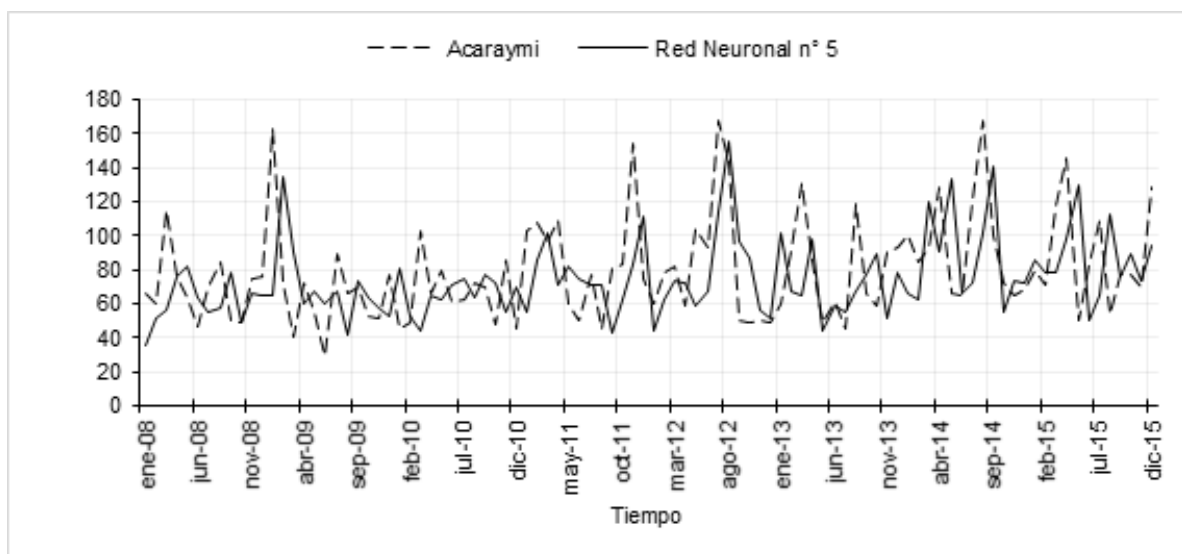


Figura 9. Curvas comparativas entre valores observados de la serie Acaraymi y valores simulados por la red neuronal número 5.

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 Yguasu y Acaraymi, los cuales se muestran en la Tabla 4. 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.

Tabla 4. Caudales medios mensuales pronosticados para los 12 meses del año 2016.

Meses	Año 2016	
	Acaray ($\frac{m^3}{s}$)	Yguasu ($\frac{m^3}{s}$)
enero	87,92	61,91
febrero	83,67	65,74
marzo	82,57	69,06
abril	81,00	56,50
mayo	66,72	77,22
junio	70,97	82,05
julio	75,14	96,05
agosto	74,95	109,63
septiembre	77,32	117,34
octubre	75,11	114,65
noviembre	71,37	127,45
diciembre	74,24	135,72

Bajo la primera regla de operación ambas centrales funcionan sin capacidad de regulación de los caudales que llegan a sus respectivos embalses y sin coordinación. Bajo la segunda regla de operación la Central Yguasu operó como reguladora de los caudales afluentes a la Central Acaray. En ambas reglas se buscó obtener la máxima producción posible. La potencia instalada adoptada para

la central Yguasu es igual a 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 de cada una de las centrales, en MW , se encuentra en la tabla 5.

Tabla 5. Caudales medios mensuales pronosticados para los 12 meses del año 2016.

	CH Acaray (MW)	CH Acaray (MW)	Producción media anual (MW)
regla 1	153,39	26,92	180,31
regla 2	200	39,74	239,74

4. Conclusión

Se ha abordado la problemática del modelado de los caudales afluentes a las represas del Yguasu 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 mostrado que tanto

las técnicas estocásticas como las redes neuronales artificiales son alternativas factibles para tratar el problema de la predicción. Con las redes neuronales se obtuvo mejor desempeño con los datos de la serie Acaraymi, mientras que con las técnicas estocásticas se han logrado mejores resultados para la serie Yguasu. Estos resultados demuestran que no hay una única técnica válida para tratar el problema de la predicción, debido a su compleji-

dad y a la cantidad de variables que inciden en el fenómeno.

Eventualmente, se podrían obtener mejores resultados modificando los métodos utilizados y realizando un análisis más profundo de las series hidrológicas que han sido estudiadas.

Referencias bibliográficas

- [1] Pliego de tarifas 21. ANDE, Asunción, Paraguay, 2017.
- [2] G. Box, G. Jenkins y G. Reinsel. Time Series Analysis: Forecasting and Control, Prentice Hall, 1994.
- [3] D. Peña. Análisis de series temporales, Alianza Editorial, 2010.
- [4] R. Hyndman y G. Athanasopoulos. Forecasting Principles and Practice, 2018, [en línea]. Obtenido de <https://otexts.com/fpp2/>
- [5] N. Mohan. Predicting Post-Procedural Complications Using Neural Networks on MIMIC-III Data. LSU Master's Theses. 4840, 2018, [en línea]. Obtenido de https://digitalcommons.lsu.edu/gradschool_theses/4840
- [6] G. Ciaburro y B. Venkateswaran. Neural network with R, Packt, 2017.
- [7] L. Fausett. Fundamentals of Neural Network Architectures, Algorithms, and Applications, Prentice Hall, 1994.
- [8] F. Caparrini. Entrenamiento de Redes Neuronales: mejorando el Gradiente Descendiente, 2017, [en línea]. Obtenido de <http://www.cs.us.es/~fsancho/?e=165>
- [9] Alex. Gradient Descent and Momentum: The Heavy Ball Method, 2020, [en línea]. Obtenido de <https://boostedml.com/2020/07/gradient-descent-and-momentum-the-heavy-ball-method.html>
- [10] N. Lewis. Neural Networks for Time Series Forecasting with R. 2020.
- [11] R. Hyndman y Y. Khandakar. Automatic time series forecasting: the forecast package for R. Journal of Statistical Software, 26, no. 3, pp. 1-22, 2008, [en línea]. Disponible en <http://www.jstatsoft.org/article/view/v0\27i03>
- [12] 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.
- [13] Administración Nacional de Electricidad. Plan Maestro de Generación de la ANDE (2016 - 2025), 2016.
- [14] 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.
- [15] M. Sánchez y W. Laqui. Predicción de caudales medios mensuales del Río Huancané utilizando Modelos de Redes Neuronales, An. Científicos, 2009.
- [16] Neuroph Team. Neuroph: A Java Neural Network Framework, 2008, [en línea]. Obtenido de <http://neuroph.sourceforge.net/>
- [17] Barrientos Mujica, L. G. y Álvarez Ferreira, L. R. Un Modelo de Planeamiento de la operación de largo y medio plazo de las usinas hidroeléctricas de Yguasú y Acaray, Universidad Nacional del Este, Paraguay. 2008.