

## Sistema de alerta temprana de inundaciones para el río Arauca basado en técnicas de inteligencia artificial

### Early flood warning system for the Arauca river based on artificial intelligence techniques

Sorangela Cárdenas-Rodríguez<sup>1</sup>

Carlos Arturo Vides-Herrera<sup>2</sup>

Aldo Pardo-García<sup>3</sup>

**Recibido:** marzo 08 de 2022

**Aceptado:** junio 28 de 2022

#### Resumen

En este artículo se establece el diseño de un sistema de alertas tempranas de inundación en el río Arauca, municipio de Arauca, Colombia. La información del estudio se extrae del IDEAM y es procesada obteniendo un modelo a través de las variables intervinientes, como: precipitación, nivel y caudal. Este modelo de información suministra la data al modelo matemático para el cauce del río, que se obtiene a partir de tres clases de tendencias: lineal, potencia y relaciones potenciales. El modelo del cauce se compara con un observador basado en técnicas inteligentes, redes neuronales y ANFIS en este caso, que al hacer la diferencia de sus salidas genera un residuo encargado de suministrar la información que proporciona el estado actual de nivel del río bajo estudio. Esta información permite generar las alertas que son atendidas por las entidades del gobierno dedicadas a la gestión del riesgo.

**Palabras clave:** inundación, nivel de agua, modelo matemático, alerta temprana.

#### Abstract

This article establishes the design of an early warning system for flooding in the Arauca River, in the municipality of Arauca, Colombia. The information corresponding to this study is extracted from the IDEAM and is processed obtaining a model through the variables that intervene such as precipitation, level and flow. This information model supplies the data to the mathematical model corresponding to the river channel, which is obtained from three kinds of trends: linear, power and potential relationships. This model is compared with an observer based on intelligent techniques such as neural networks and ANFIS, which make the difference of their outputs and a residue is obtained that is in charge of supplying the information that provides the current state of the river level under study, which in turn generates alerts that are addressed by government entities dedicated to risk management.

**Keywords:** flood, water level, mathematical model, early warnings.

**1** Ingeniera Electrónica, Magíster en Controles Industriales, Universidad de Pamplona, Pamplona, Colombia. E-mail: sorangela.cardenas@unipamplona.edu.co

Orcid: <https://orcid.org/0000-0002-1770-2741>

**2** Ingeniero Electrónico, Magíster en Controles Industriales, Universidad de Pamplona, Pamplona, Colombia. E-mail: carlosarturvi@unipamplona.edu.co

Orcid: <https://orcid.org/0000-0001-8708-5470>

**3** Ingeniero Electricista, Doctor en Ciencias, Universidad de Pamplona, Pamplona, Colombia. E-mail: apardo13@hotmail.com

Orcid: <https://orcid.org/0000-0003-2040-9420>

## 1. Introducción

La diversidad del espacio geográfico colombiano, que incluye la presencia de volcanes, nevados y una elevada pluviosidad, hacen que sea uno de los lugares más propensos a desastres (Peña-García & García-Mendivelso, 2017). En Colombia, durante el siglo XXI han ocurrido una gran cantidad de desastres naturales, tales como: sismos (15%), deslizamientos (25%), tormentas (4%), e inundaciones con un 42% (EM-DAT, 2022). Lo anterior es preocupante ya que según el Banco Mundial y la Organización de las Naciones Unidas (ONU), Colombia es el tercer país con mayor riesgo climático en el mundo (CEPAL & BID, 2007). Esto último se refleja en que durante los últimos 30 años, han sido aproximadamente 10 millones de personas las afectadas por las inundaciones (EM-DAT, 2022).

Arauca es un departamento colombiano con gran cantidad de ríos y en época de invierno, entre los meses de mayo y agosto, es usual que estos se desborden. Las inundaciones generan emergencias para los habitantes de las riberas con afectaciones al sector ganadero, al igual que la destrucción de cultivos, como: yuca, plátano, cacao, maíz y frutales, entre otros (Gómez-Rojas & López-Ramírez, 2019). En este sentido, para los habitantes de Arauca es importante conocer el nivel de los ríos, especialmente en temporadas de invierno, para prevenir pérdidas humanas y económicas (Eslava-Zapata, 2021).

La tendencia a nivel mundial es implementar sistemas que permitan conocer directamente el nivel de los ríos, para salvar vidas y prevenir desastres (Vargas & Giraldo, 2018). Las alertas tempranas y precisas para inundaciones son un desafío constante, ya que se espera el aviso del peligro natural en espacio y tiempo cortos (Teixeira & Balda, 2021). En este caso, los modelos hidrológicos pueden predecir el caudal, que relaciona la lluvia y escorrentía, entendida como el evento de una precipitación mayor que una tasa de infiltración (Maza-Mogrobojo, 2019). Actualmente, la inteligencia artificial ha sido de gran ayuda para la gestión de recursos hídricos

a través de la interpretación de imágenes satelitales, así como del monitoreo de variables hidrométricas (Vargas et al., 2021; Vargas-Zapata et al., 2022).

En vista de lo anterior, el objetivo de la investigación fue diseñar un sistema inteligente de alerta temprana para el municipio de Arauca, que a su vez brinde la información necesaria en tiempo real con el propósito de prevenir desastres, dar mayor tiempo a desalojos y poner a salvo a la población rivereña. La metodología empleada permite la adquisición de la información de las estaciones hidro-meteorológicas a cargo del Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM), la cual es modelada matemáticamente para obtener el observador que genera la alerta de inundaciones.

## 2. Metodología

### 2.1 Adquisición y homogenización de la información

En este punto se tiene como elemento fundamental la información adquirida a través de herramientas tecnológicas y herramientas informales. Entre las primeras se menciona la información generada por las estaciones meteorológicas e hidrológicas, que están bajo la supervisión y control del IDEAM (Vargas & Giraldo, 2018). Entre las segundas está la información hidrológica de la variable nivel del río, que se obtiene a través de un protocolo de observación realizado por el cuerpo de bomberos de los municipios respectivos.

La información que se procesa en este trabajo es medida por herramientas tecnológicas o estaciones hidrométricas convencionales, que se basan en los principios de nivel y caudal, y las meteorológicas que miden: precipitación, humedad, temperatura y evaporización. Estas estaciones proporcionan una base de datos a través de días, meses y años, la cual es descargada en un archivo de Excel desde la página del IDEAM. La medida del nivel del río se efectúa por observa-

ción a través de un limnógrafo (Caina-Clavijo & Castro-Rodríguez, 2018). Luego se procede a la normalización de los datos (Rosado-Gómez & Jaimes-Fernández, 2020), con el fin de obtener la tendencia y así poder alimentar al modelo matemático que representa los parámetros que caracterizan al río Arauca.

De la estación automática "Peña los micos" del IDEAM, se obtiene la tendencia e información

del nivel promedio. En la figura 1 se observa un punto máximo de 7.5 m en el mes de julio, con una duración de día y medio de crecida, mientras que existen tres picos con frecuencia de un mes. También se observa que el comportamiento del nivel medio fue de 4 m y un nivel mínimo de 2.8 m, entre los meses de mayo y octubre. Además, la precipitación media está en un valor de 10 mm para la ventana de los 5 meses de observación.




Figura 1. Presentación de la información del IDEAM.

A continuación, se describe la metodología para la normalización de la información:

**Paso 1:** la información es descargada de la página del IDEAM, en formato .csv y se convierte a .xls. Esta tabla representa los datos de caudal de la estación y está organizada en el siguiente orden: ubicación, nombre, código, entidad, departamento, municipio y fecha.

**Paso 2:** se ordenan las variables y se adiciona una columna de tiempo que será la base para desarrollar su tendencia.

**Paso 3:** se seleccionan las columnas nivel y precipitación, que son variables en el tiempo, a las cuales se les aplica la técnica de la regresión, obteniendo un modelo matemático polinómico.

**Paso 4:** al obtener el modelo óptimo de la tendencia de información se procede a su implementación, a través de la herramienta Matlab Simulink. Cabe aclarar que existe un bloque denominado normalización, el cual ajusta la curva a valores entre 0 a 1, con el propósito de alimentar al observador diseñado con técnicas inteligentes.

## 2.2 Modelos matemáticos del río

El tratamiento de la información para desarrollar sistemas de alertas tempranas lleva consigo la aplicación de métodos de pronóstico hidrológicos, generalmente regresiones lineales (Abasov et al., 2022). Estos métodos establecen relaciones entre variables dependientes e independientes del fenómeno, a partir de variables de entrada, como precipitación y nivel, y variables de salida como el caudal (Cai & Yu, 2022).

En la actualidad, existen diversos modelos de predicción que relacionan o integran técnicas de inteligencia artificial, cuya estructura matemática es capaz de realizar relaciones complejas no lineales entre la data de entrada y la data de salida (Pacheco-Sánchez et al., 2020; Cardozo-Rueda, 2022). Una de las técnicas más aplicadas en el campo de las alertas tempranas son las redes neuronales, que simulan el funcionamiento del cerebro humano para resolver diversos problemas del mundo real (García et al., 2016). Entre estas técnicas se tiene la lógica difusa e híbrida (Béjar-Chacón et al., 2016), así como el uso de técnicas de visión artificial para predecir inundaciones de los ríos (Niño-Rondón et al., 2020).

Al hablar de modelos matemáticos se hace alusión directamente a sus tendencias equivalentes y estados de linealidad, ya que ellos buscan reflejar lo más fielmente posible el comportamiento de los procesos reales. En el caso del modelado matemático de ríos, se alude al concepto teórico sobre su funcionamiento, donde el gradiente de condiciones químicas, físicas y la existencia de subsistemas (Vannote et al., 1980), mantienen un flujo de materia y energía que varía en relación con el espacio y el tiempo (Gómez-Vargas et al., 2012).

Según Nunez (2005), los modelos matemáticos equivalen al comportamiento de un sistema, donde sus parámetros están representados por una ecuación o un conjunto de ecuaciones, expresadas en forma integro-diferencial. Otro aspecto que define un modelo matemático son las técnicas de regresión, cuyo valor principal consiste en la predicción, más allá de las rela-

ciones causales entre las variables dependiente e independientes. En este caso, se recoge la información normalizada y caracterizada de precipitación, nivel y caudal con tres opciones para su modelado, como se indica a continuación:

**Modelos lineales:** estos describen comportamientos relacionados a sus ajustes de restas, con las pendientes y constantes respectivas (ecuación 1).

$$Q(t) = B_0 + B_1 * N + B_2 * P \quad (1)$$

$$Q = \text{Caudal } \frac{m^3}{s}$$

P = Precipitación, mm

N = Nivel del río, cm

$B_0, B_1, B_2 =$  Parámetros modelo matemático

**Modelos de potencia:** estos modelos son aproximados porque abarcan índices de segundo y tercer orden que hacen que se ajusten a los valores reales del elemento a modelar (ecuación 2).

$$Q(t) = B_2 * N^{B_3} + B_1 * P^{B_4} - B_0 \quad (2)$$

**Modelo de relaciones potenciales:** estos modelos brindan el comportamiento de índices de potencia y sus variables independientes están representadas por las características del río, como nivel y precipitación, ajustadas a través de constantes multiplicativas (ecuación 3).

$$Q(t) = B_0 * N^{B_1} * P^{B_2} \quad (3)$$

Para generar el modelo matemático del río Arauca, se aplicó la siguiente metodología:

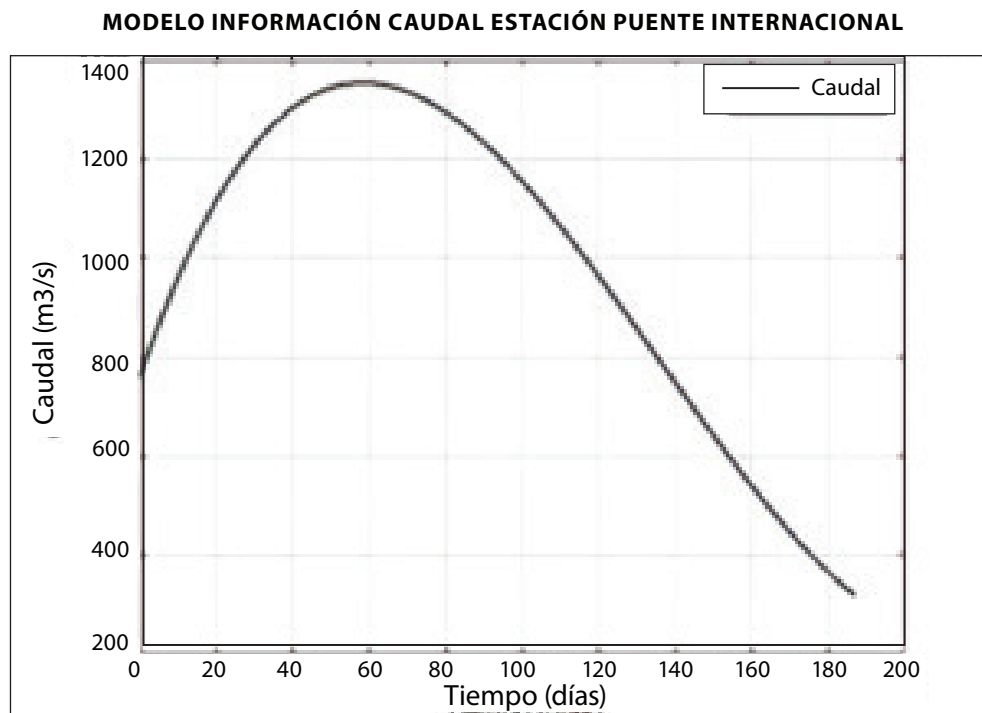
- i) Se toman los datos de las estaciones meteorológicas e hidrológicas que contienen las variables de nivel, caudal y precipitación; también se recolecta la información histórica, teniendo muy presente ventanas de tiempo en lo referente a días y meses en los que ocurrieron las crecientes del río Arauca.

- ii) Se reorganiza y normaliza la data obtenida de las estaciones meteorológicas e hidrológicas, utilizando la hoja de cálculo Excel.
- iii) Con la información organizada, se procede aplicar la técnica de regresión para obtener los modelos lineales, de potencia y de relaciones potenciales. Este último se basa en el método de convergencia para obtener las constantes multiplicativas del mismo. Luego, los modelos se comparan entre ellos y se selecciona el que presente menor error o el mejor índice de R2.
- iv) Los modelos matemáticos se implementan utilizando la herramienta Simulink de Matlab para realizar la comparación entre ellos, y determinar así la mejor versión del observador.

### 3. Resultados y discusión

#### 3.1 Modelo de información del sistema de alerta temprana

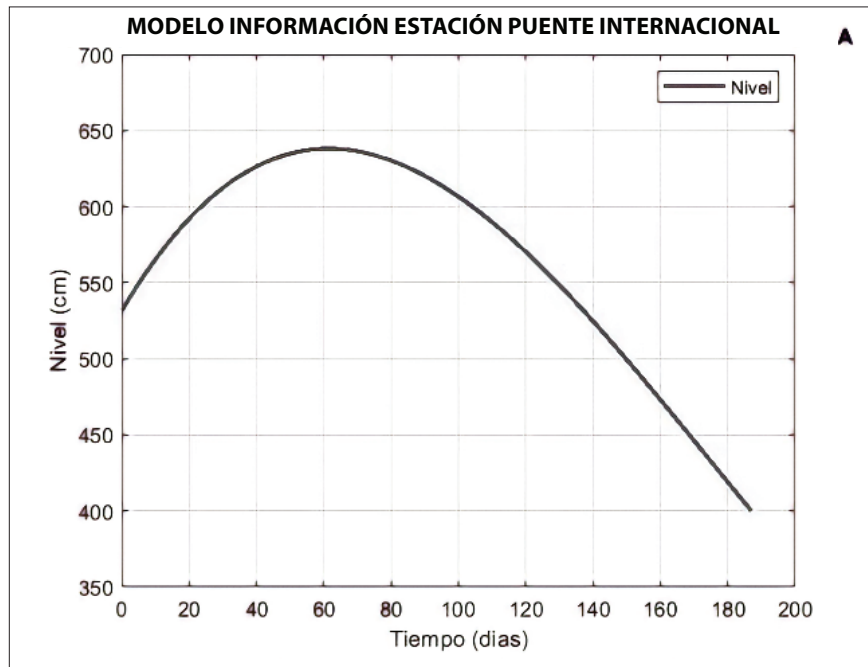
La información inicial es proporcionada por el IDEAM para el municipio de Arauca, estación "Puente Internacional, brindando los datos de precipitación y nivel, mientras que el caudal se recoge de forma manual como se indicó en la metodología. En la Figura 2 se presenta el caudal del agua del río Arauca, con un comportamiento equivalente entre 0 a 187 días, en 780 m<sup>3</sup>/días como inicio y un punto máximo de 1360 m<sup>3</sup>/días, ocurrido en 58 días. Esta trayectoria representa la creciente del cauce del río Arauca en su punto máximo, y el agotamiento, que ocurre entre 58 y 187 días transcurridos, para llegar a 320 m<sup>3</sup>/días.



**Figura 2.** Representación del modelo tendencia de caudal del río Arauca.

En la Figura 3 se presenta el nivel del agua del río Arauca, con un comportamiento equivalente entre 0 a 187 días, en 540 cm como inicio y un punto máximo de 640 cm ocurrido en 58 días.

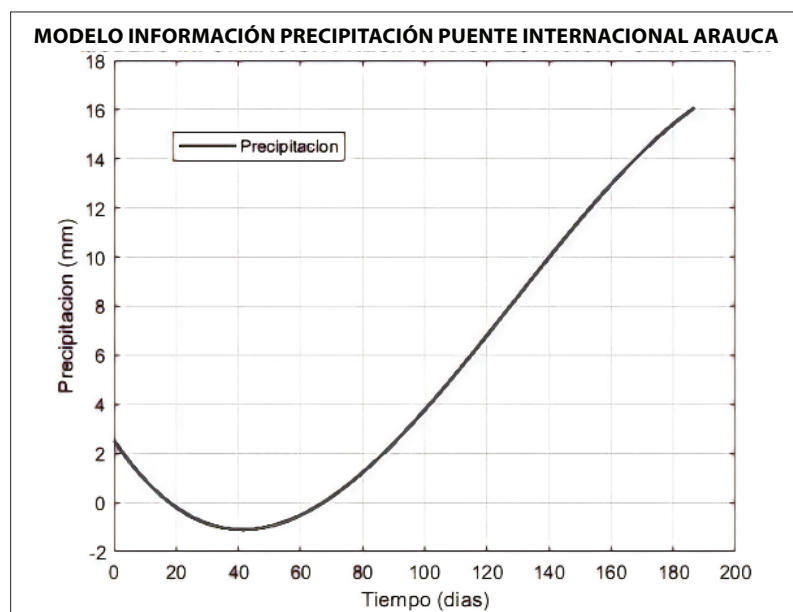
Esta trayectoria representa la creciente del cauce del río Arauca en su punto máximo, y el agotamiento, que ocurre entre 58 y 187 días, para llegar a 400 cm.



**Figura 3.** Modelo de información del nivel del río Arauca.

En la Figura 4 se presenta la precipitación en la estación Puente Internacional del municipio de Arauca, con un comportamiento equivalente

entre 0 a 187 días en 2.3% como inicio, y un punto máximo de 16%, ocurrido en 187 días.




**Figura 4.** Modelo de información estación "Puente Internacional" de Arauca.



### 3.2 Modelo matemático del cauce del río Arauca

Para obtener el modelo matemático del río en el municipio de Arauca, se utiliza la información proporcionada por el modelo de información. Teniendo en cuenta como parámetro fundamental el caudal entregado por las estaciones

meteorológicas e hidrométricas, se procede a obtener los modelos con características lineales y potencia, utilizando técnicas de regresión. Adicionalmente, se crea un modelo donde se utiliza la tendencia de relaciones potenciales o no lineal. Luego, se procede a implantar los modelos matemáticos obtenidos en la herramienta Simulink de Matlab.



**Figura 5.** Comparación de los modelos matemáticos.

La Figura 5 indica la tendencia de los modelos lineal, de potencia y Relaciones Potenciales (RP). El modelo de relaciones potenciales tiene mayor pendiente y altura de caudal en el transcurso de los 187 días, mientras que el modelo lineal y de potencia se ajusta en su tendencia en la caída

más suave. Para seleccionar el mejor modelo se recurre a la comparación entre los errores: cuadrático medio (MSE), R2 y raíz del error cuadrático medio (RMSE), respecto a los modelos de potencia, lineal y el de RP.

**Tabla 1.** Modelos lineales respecto a los errores R2, MSE y RMSE

| Modelo                 | R2     | MSE        | RMSE  |
|------------------------|--------|------------|-------|
| Potencia               | 0.9901 | 7.8355e+03 | 88.52 |
| Lineal                 | 0.9917 | 7.6513e+03 | 87.47 |
| Relaciones potenciales | 0.9989 | 265.2628   | 16.3  |

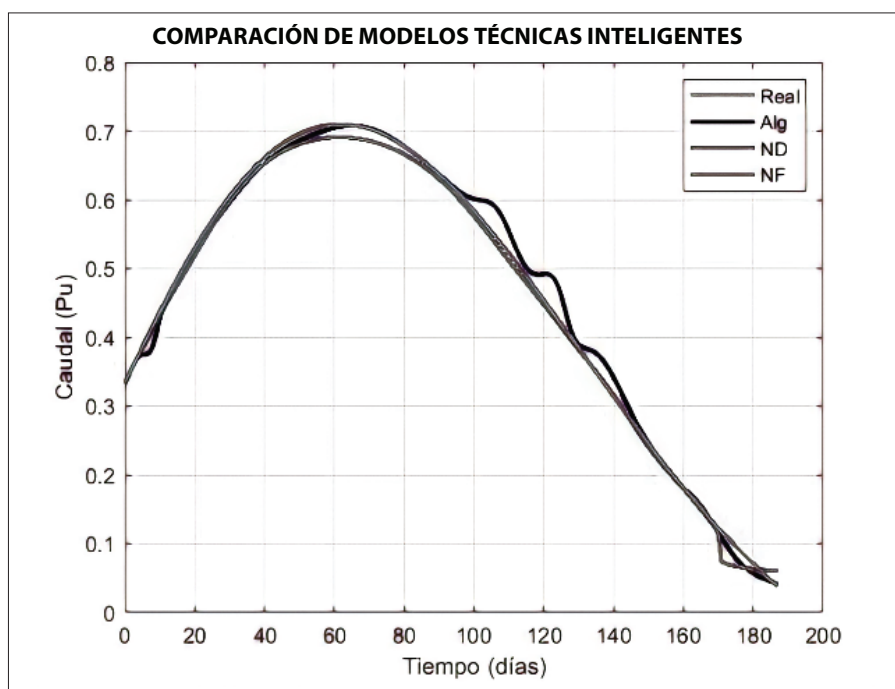
El mejor modelo referenciado con el caudal real del río Arauca según la Tabla 1, es el modelo de relaciones potenciales, donde se obtiene un

valor R2 de 0.9989, MSE de 265.26 y de RMSE equivalente a 16.3.

### 3.3 Modelo del observador con técnicas inteligentes

Con el propósito de emular y obtener una tendencia similar al modelo seleccionado, se procede a relacionar los valores de entrada o variables independientes: precipitación y nivel, con el caudal equivalente a la información real. Seguidamente, se realiza el tratamiento de normalización y a partir de los módulos estructurados, se usan técnicas inteligentes. Entre estas

técnicas se tienen las Redes Neuronales (RN) y las neuro-difusas (ANFIS), así como el Algoritmo de redes neuronales (ALG), que permite variar parámetros como: número de neuronas, número de capas, funciones de activación, distribución de datos en el entrenamiento, validación y prueba (Abasov et al., 2022). En la Figura 6 se comparan los modelos diseñados, que definen la tendencia del modelo matemático de caudal del río en el municipio de Arauca.



**Figura 6.** Comparación de las técnicas inteligentes: RN, ANFIS y Algoritmo RN.

La figura 6 se enmarca en una ventana de 0 a 187 días, donde se presentan las crecientes equivalentes al caudal por unidad de 0.35 Pu como inicial hasta un valor máximo de 0.71 Pu, y el valor final tiende a un agotamiento de 0.04 Pu. La comparación de las tres técnicas evidencia que la tendencia real del río se asemeja más al modelo neuro-difuso (NF). Cabe señalar que

en la Figura 6 se observa solapamiento entre el modelo NF y el modelo real.

La selección del mejor modelo se hace a través de la comparación de los errores que proporciona el criterio integral, tanto el valor absoluto como el error cuadrático, representados por las ecuaciones 4 y 5:



$$IAE = \int_0^t |res(t)| * dt \quad (4)$$

$$ISE = \int_0^t res(t)^2 * dt \quad (5)$$

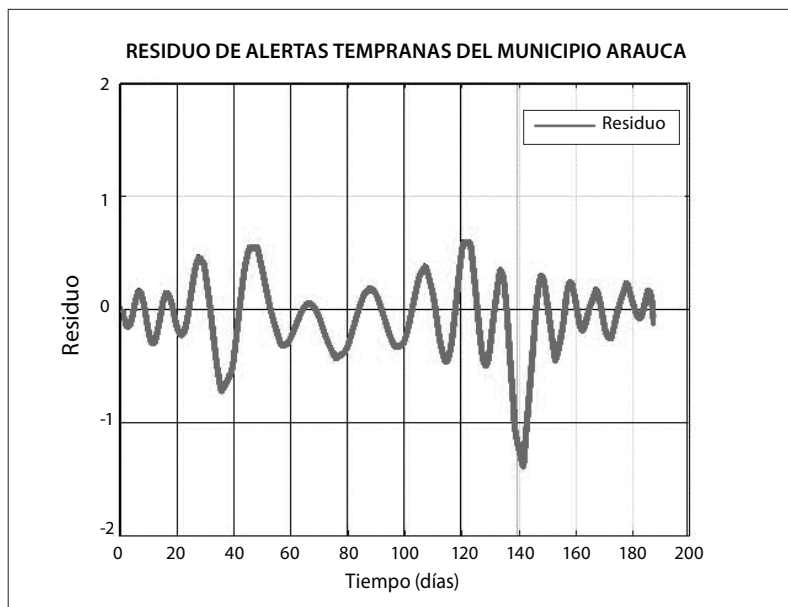
Al aplicar la relación de los modelos para el valor real del caudal por unidad, respecto a los datos que genera el modelo inteligente, se obtiene la Tabla 2, la cual contiene los errores que permiten seleccionar la mejor técnica.

**Tabla 2.** Comparación de los errores para seleccionar el modelo del río Arauca.

| Modelo | IAE    | ISE       |
|--------|--------|-----------|
| RN     | 0.1603 | 0.0001644 |
| NF     | 1.866  | 0.0282    |
| ALG    | 2.417  | 0.05977   |

La Tabla 2 muestra que el mejor modelo inteligente es el proporcionado por las redes neuronales, a través del algoritmo alternativo NFTOOL, con un valor de IAE de 0.1603 y de ISE 0.0001644. Una ventaja de las redes neuronales en aplicaciones de predicción, monitoreo y estimación de pronósticos de caudal y temperatura, es que el entrenamiento es la etapa donde se requiere de una mayor carga computacional, después su operación es rápida y brindan resultados más fiables (Adnan et al., 2012).

Para generar la alerta temprana del río Arauca se relacionó el mejor modelo del cauce del río en tiempo real normalizado, respecto al mejor modelo generado por técnicas inteligentes de redes neuronales. Lo anterior da como resultado el residuo (ver Figura 7), que representa la tendencia en el tiempo de alerta en una ventana determinada.



**Figura 7.** Residuo de la alerta temprana del municipio de Arauca.

El análisis y procesamiento de datos inicia con la carga del archivo de importación de la data del IDEAM al ambiente WorkSpace de Matlab. De allí se importa a la plataforma de Simulink, con el propósito de alimentar la información de las

variables de nivel y precipitación directamente al modelo matemático real y al sistema de observador inteligente. Lo anterior permite obtener el residuo de las dos estructuras, que a su vez proporciona la información del comportamiento

del río, donde se procesa y emite el estado para el nivel del mismo. El sistema fue diseñado para emitir la alerta en caso de que se presente un eventual incremento de nivel del río, mediante un mensaje de texto (SMS), a través de la plataforma twilio.com, a las entidades competentes, como la Unidad Nacional para la Gestión del Riesgo de Desastres.

En la revisión de literatura se encontraron dos sistemas de alerta temprana similares al aquí propuesto. Adnan et al., (2012), proponen un modelo del nivel de inundación utilizando una red neuronal Backpropagation (BPN), y además utilizan un filtro extendido de Kalman a la salida de la BPN para mejorar los valores de predicción. El filtro de Kalman extendido aporta una mejora en el rendimiento de la predicción de inundación en tiempo real a través del nivel de agua.

De otro lado, Cai y Yu (2022), presentan un modelo de inundaciones con el diseño de un sistema inteligente de predicción de inundaciones implementado en tiempo real. El modelo propuesto puede predecir con precisión las tendencias de inundación y las horas pico en el período de inundación, para lo cual utiliza una función de Kernel que permite minimizar el ruido. Además, Para la predicción emplea una red neuronal recurrente y un módulo de media móvil integrada autorregresiva multivariable.

En esta investigación se utilizaron comparaciones basadas en la obtención de modelos a partir de métodos comunes y técnicas de Inteligencia Artificial (AI), como: redes neuronales, ANFIS y algoritmo RN, en el cual se obtuvieron resultados de error de 0,9989. A nivel de predicción, este sistema tiene mayor cercanía con los resultados, en comparación con lo realizado por Adnan et al., (2012). No obstante, Cai y Yu (2022), utilizan técnicas de IA, cuyos resultados se asemejan a los presentados por nuestro modelo Neuronal.

#### 4. Conclusiones

En el trabajo reportado se probó la eficacia de tres modelos matemáticos: lineal, potencia y re-

laciones potenciales, por ser los que incorporan las mejores características reales de la cuenca en estudio. El proceso de validación permitió concluir que el mejor modelo matemático es el de relaciones potenciales, con un error R2 de 0.9989.

Lo anterior indica que los modelos basados en redes neuronales artificiales son mejores que los modelos hidrológicos convencionales, basados en modelos no lineales, y que la aplicación de este tipo de soluciones puede ser una buena alternativa para la generación de sistemas de alertas tempranas. Sin embargo, la calidad de la predicción del modelo depende de la información suministrada inicialmente. En este caso, la implementación del sistema de alerta temprana de inundación del río Arauca, en Colombia, está supeditada a la dinámica de los medios informáticos o tecnológicos que ofrece el sitio web del Instituto de Hidrología, Meteorología y Estudios Ambientales.

#### Referencias

- Abasov, N. V., Nikitin, V. M., Berezhnykh, T. V., & Osipchuk, E. N. (2022). *Monitoring and Predictive Estimations of Atmospheric Parameters in the Catchment Area of Lake Baikal*. *Atmosphere*, 13 (1). <https://doi.org/10.3390/atmos13010049>
- Adnan, R., Ruslan, F. A., & Zain, Z. M. (2012). Flood water level modelling and prediction using artificial neural network: Case study of Sungai Batu Pahat in Johor. *In 2012 IEEE Control and System Graduate Research Colloquium*, 22-25.
- Béjar-Chacón, W. E., Valeriano-Valdez, K., Ilachoque-Umasi, J. C., & Sulla-Torres, J. (2016). Predicción de caudales medios diarios en la cuenca del Amazonas aplicando redes neuronales artificiales y el modelo neurodifuso ANFIS. *Research in Computing Science*, 113 (1), 23-35. <https://doi.org/10.13053/rscs-113-1-2>
- Cai, B., & Yu, Y. (2022). Flood forecasting in urban reservoir using hybrid recurrent neural network. *Urban Climate*, 42, 101086.
- Caina-Clavijo, L. K., & Castro-Rodríguez, F. R. (2018). *Generación de Parámetros y Protocolos para un Sistema de Alerta Temprana en la Cuenca Alta de*

- Río Cauca. (Trabajo de grado). Universidad Católica de Colombia. <https://hdl.handle.net/10983/16779>
- Cardozo-Rueda, K. S. (2022). Aplicación de redes neuronales artificiales para el pronóstico de precios de café. *Revista Colombiana de Tecnologías de Avanzada*, 1(39), 113–117.
- CEPAL & BID. (2007). *Información para la gestión de riesgo de desastres*. Estudio de caso de cinco países: México.
- EM-DAT. (1 de abril de 2022). The international disaster database. <https://public.emdat.be/>
- Eslava-Zapata, R. (2021). Pasivos ambientales y métodos de valoración económica. *Infometric@ - Serie Sociales Y Humanas*, 4 (2).
- García, F., Rojas, J., Vásquez, A., Parra, D., & Castro, E. (2016). Estimating missing data in historic series of global radiation through neural network algorithms. *Sistemas y Telemática*, 14 (37), 9–22. <https://doi.org/10.18046/syt.v14i37.2239>
- Gómez-Rojas, D. F., & López-Ramírez, D. P. (2019). *Determinación de la cota de inundación del río Arauca en la vereda barrancones, municipio de Arauca mediante un modelo hidrodinámico*. (Trabajo de Grado). Universidad Católica de Colombia. <https://hdl.handle.net/10983/23392>
- Gómez-Vargas, E., Álvarez-Pomar, L., & Obregón-Neira, N. (2012). Predicción de caudales de ríos aplicando el modelo neurodifuso ANFIS y redes neuronales. *Sistemas, Cibernética e Informática*, 9 (1), 28–35.
- Maza-Mogrobejo, A. X. (2019). *Integración de un sistema de alerta temprana mediante modelación hidrodinámica y predicción de flujos con redes neuronales. Caso de estudio: río Tomebamba* (Tesis de maestría). Cuenca, Ecuador: Universidad de Cuenca. <http://dspace.ucuenca.edu.ec/handle/123456789/33595>
- Nunez, M. E. (2005). *Propuesta y Análisis de Modelos Matemáticos para la Estimación de Caudales Recesivos en la Cuenca del Río Loizntué, Estación Estero Upeo en Upeo, VII Región del Maule, Chile* (Trabajo de pregrado). Chile: Universidad de Talca.
- Niño-Rondón, C. V., Castro-Casadiego, S. A., & Medina-Delgado, B. (2020). Caracterización para la ubicación en la captura de video aplicado a técnicas de visión artificial en la detección de personas. *Revista Colombiana de Tecnologías de Avanzada*, 2(36), 83-88. <https://doi.org/10.24054/16927257.v36.n36.2020.24>
- Pacheco-Sánchez, C. A., Quintero-Bayona, B. T., Guerrero-Prado, L. T., & Moreno-Mendoza, E. F. (2020). Innovación y tecnología en el tercer sector: paradigmas y desafíos. *Revista Colombiana de Tecnologías de Avanzada*, 1(33), 62-68. <https://doi.org/10.24054/16927257.v33.n33.2019.86>
- Peña-García, K. L., & García-Mendivelso, O. A. (2017). *Diseño de un sistema de alertas tempranas para medición de caudales instantáneos en la cuenca alta y media del río Ila en el municipio de la Vega – Cundinamarca*. (Trabajo de grado). Bogotá, Colombia: Universidad Libre. <https://hdl.handle.net/10901/11172>
- Rosado-Gómez, A. A., & Jaimes-Fernández, J. C. (2020). Revisión de la incorporación de la arquitectura orientada a servicios en las organizaciones. *Revista Colombiana de Tecnologías de Avanzada*, 1 (31), 77-88. <https://doi.org/10.24054/16927257.v31.n31.2018.134>
- Teixeira, R., & Balda, G. (2021). Feasibility study on operational use of neural networks in a flash flood early warning system. *Revista Brasileira de Recursos Hídricos*, 26. <https://doi.org/10.1590/2318-0331.262120200152>
- Vannote, R. L., Wayne-Minshall, G., Cummins, K. W., Sedell, J. R., & Cushing, C. E. (1980). The river continuum concept. *Canadian Journal of Fisheries and Aquatic Sciences*, 37, 130–137.
- Vargas, N. O., & Giraldo, M. V. (2018). *Protocolo de Modelación Hidrológica e Hidráulica*. Colombia: Instituto de Hidrología, Meteorología y Estudios Ambientales.
- Vargas, C., Montes, W., Castrejón, E., & Hinojosa, M. (2021). Machine Learning como Herramienta para Determinar la Variación de los Recursos Hídricos. *Scientific Research Journal CIDI*, 1 (1), 56–69. <https://doi.org/10.53942/srjcdi.v1i1.46>
- Vargas-Zapata, M., Medina-Sierra, M., Galeano-Vasco, L. F., & Cerón-Muñoz, M. F. (2022). Algoritmos de aprendizaje de máquina para la predicción de propiedades fisicoquímicas del suelo mediante información espectral: una revisión sistemática. *Revista de Investigación, Desarrollo e Innovación*, 12 (1), 107-120. <https://doi.org/10.19053/20278306.v12.n1.2022.14212>

