



UNIVERSIDAD CÉSAR VALLEJO

FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

**Propuesta de un sistema de alerta temprana de inundación
basado en inteligencia artificial para el río Catacaos – Piura; 2023**

TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE:

Ingeniero de Sistemas

AUTORES:

More Gomez, Eduardo Jose (orcid.org/0000-0002-0080-7563)

Yarleque Ramos, Pablo Junior (orcid.org/0000-0003-1996-6975)

ASESOR:

Mg. Ing. More Valencia, Ruben Alexander (orcid.org/0000-0002-7496-3702)

LÍNEA DE INVESTIGACIÓN:

Sistemas de Información y Comunicaciones

LÍNEA DE RESPONSABILIDAD SOCIAL UNIVERSITARIA:

Desarrollo sostenible y adaptación al cambio climático

PIURA – PERÚ

2023

DEDICATORIA

A Dios por darnos fuerzas para salir adelante, porque se lo debemos todo a él, ya que a pesar de nuestros errores en esta vida él siempre está con nosotros.

A nuestros padres, por apoyarnos en cada momento, por su amor, por sus consejos, y por los valores que nos brindan, y ya que gracias a ellos podemos estar en esta prestigiosa universidad y poder aportar con nuestros conocimientos.

More Gómez Eduardo José

Yarleque Ramos Pablo Junior

AGRADECIMIENTO

A Dios por brindarnos la salud en estos tiempos difíciles, por guiarnos por el buen camino, y sobre todo por nunca dejarnos solos.

A nuestro asesor porque gracias a su ayuda, paciencia y al apoyo que nos brindó, pudimos realizar esta investigación con éxito.

A la Universidad César Vallejo, por darnos la oportunidad de pertenecer a la familia Vallejiana y por brindarnos la información necesaria a través de su biblioteca virtual para el desarrollo de esta investigación.

More Gómez Eduardo José

Yarleque Ramos Pablo Junior



UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

Declaratoria de Autenticidad del Asesor

Yo, MORE VALENCIA RUBEN ALEXANDER, docente de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - PIURA, asesor de Tesis titulada: "Propuesta de un sistema de alerta temprana de inundación basado en Inteligencia Artificial para el río Catacaos – Piura; 2023", cuyos autores son MORE GÓMEZ EDUARDO JOSÉ, YARLEQUE RAMOS PABLO JUNIOR, constato que la investigación tiene un índice de similitud de 17.00%, verificable en el reporte de originalidad del programa Turnitin, el cual ha sido realizado sin filtros, ni exclusiones.

He revisado dicho reporte y concluyo que cada una de las coincidencias detectadas no constituyen plagio. A mi leal saber y entender la Tesis cumple con todas las normas para el uso de citas y referencias establecidas por la Universidad César Vallejo.

En tal sentido, asumo la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de información aportada, por lo cual me someto a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

PIURA, 09 de Diciembre del 2023

Apellidos y Nombres del Asesor:	Firma
RUBEN ALEXANDER MORE VALENCIA DNI: 02897931 ORCID: 0000-0002-7496-3702	Firmado electrónicamente por: RMOREV el 09-12- 2023 00:01:28

Código documento Trilce: TRI - 0689274





UNIVERSIDAD CÉSAR VALLEJO

**FACULTAD DE INGENIERÍA Y ARQUITECTURA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

Declaratoria de Originalidad de los Autores

Nosotros, MORE GOMEZ EDUARDO JOSE, YARLEQUE RAMOS PABLO JUNIOR estudiantes de la FACULTAD DE INGENIERÍA Y ARQUITECTURA de la escuela profesional de INGENIERÍA DE SISTEMAS de la UNIVERSIDAD CÉSAR VALLEJO SAC - PIURA, declaramos bajo juramento que todos los datos e información que acompañan la Tesis Completa titulada: "Propuesta de un sistema de alerta temprana de inundación basado en Inteligencia Artificial para el río Catacaos – Piura; 2023", es de nuestra autoría, por lo tanto, declaramos que la Tesis Completa:

1. No ha sido plagiada ni total, ni parcialmente.
2. Hemos mencionado todas las fuentes empleadas, identificando correctamente toda cita textual o de paráfrasis proveniente de otras fuentes.
3. No ha sido publicada, ni presentada anteriormente para la obtención de otro grado académico o título profesional.
4. Los datos presentados en los resultados no han sido falseados, ni duplicados, ni copiados.

En tal sentido asumimos la responsabilidad que corresponda ante cualquier falsedad, ocultamiento u omisión tanto de los documentos como de la información aportada, por lo cual nos sometemos a lo dispuesto en las normas académicas vigentes de la Universidad César Vallejo.

Nombres y Apellidos	Firma
EDUARDO JOSE MORE GOMEZ DNI: 73443519 ORCID: 0000-0002-0080-7563	Firmado electrónicamente por: EMOREGO6 el 09-12-2023 17:29:41
PABLO JUNIOR YARLEQUE RAMOS DNI: 72812378 ORCID: 0000-0003-1996-6975	Firmado electrónicamente por: PYARLEQUER el 09-12-2023 13:02:39

Código documento Trilce: TRI - 0689273



Índice de contenidos

Carátula	i
Dedicatoria	ii
Agradecimiento	iii
Declaratoria de Autenticidad del Asesor	iv
Declaratoria de Originalidad De Los Autores	v
Índice de contenidos	vi
Índice de tablas	vii
Índice de figuras	viii
RESUMEN	ix
ABSTRACT	x
I. INTRODUCCIÓN	1
II. MARCO TEÓRICO	4
III. METODOLOGÍA	1
3.1. Tipo y diseño de investigación	1
3.2. Variables y operacionalización	2
3.3. Población, muestra y muestreo	5
3.4. Técnicas e instrumentos de recolección de datos.....	6
3.5. Método de análisis de datos.....	9
3.6. Aspectos éticos	9
IV. RESULTADOS Y DISCUSIÓN	11
V. CONCLUSIONES	43
VI. RECOMENDACIONES	45
REFERENCIAS	46
ANEXOS.....	49

Índice de tablas

Tabla 01: Cantidad de afectados por inundaciones.....	11
Tabla 02: Personas afectadas por causa de inundación en Piura, en los años 2013 – 2014.	13
Tabla 03: Personas afectadas por causa de inundación en Piura, en el año 2015.	13
Tabla 04: Personas afectadas por causa de inundación en Piura, en el año 2016.	14
Tabla 05: Personas afectadas por causa de inundación en Piura, en el año 2017	15
Tabla 06: Personas afectadas por causa de inundación en Piura, en el año 2018	16
Tabla 07: Personas afectadas por causa de inundación en Piura, en el año 2019	17
Tabla 08: Personas afectadas por causa de inundación en Piura, en los años 2020 - 2022	18
Tabla 09: Personas afectadas por causa de inundación en Piura, en el año 2023	19
Tabla 10: datos Hidrometeorológicos	20
Tabla 11: datos Hidrometeorológicos normalizados	21
Tabla 12: Predicción del caudal con SARIMAX.....	23
Tabla 13: Comparación con el comportamiento real.	24
Tabla 14: métricas de evaluación.	25
Tabla 15: prueba de Dickey-Fuller para el año 2017.....	26
Tabla 16: prueba de Dickey-Fuller para el año 2018.....	27
Tabla 17: prueba de Dickey-Fuller para el año 2019.....	28
Tabla 18: prueba de Dickey-Fuller para el año 2020.....	28
Tabla 19: prueba de Dickey-Fuller para la serie temporal desde el 01/01/2017 al 02/28/2022.	29
Tabla 20: resultados de la configuración y estadísticas del modelo SARIMAX.	30
Tabla 21: resultados del análisis mediante el modelo SARIMAX.	31
Tabla 22: pruebas y métricas destinadas a evaluar la calidad y ajuste del modelo.	33

Índice de figuras

Figura 01: Predicción del caudal con SARIMAX	22
Figura 02: Comparación con el comportamiento real.....	25
Figura 03: prueba de Dickey-Fuller para el año 2017.	27
Figura 04: prueba de Dickey-Fuller para el año 2018.	27
Figura 05: prueba de Dickey-Fuller para el año 2019.	28
Figura 06: prueba de Dickey-Fuller para el año 2020.	29
Figura 07: prueba de Dickey-Fuller para la serie temporal desde el 01/01/2017 al 02/28/2022.....	30
Figura 08: la serie temporal, tendencia, estacionalidad y residuos.	34
Figura 09: autocorrelación.....	35
Figura 10: Densidad residual.....	35

RESUMEN

La presente investigación denominada “Propuesta de un sistema de alerta temprana de inundación basado en Inteligencia Artificial para el río Catacaos – Piura; 2023”. Se dio origen debido a que en el Perú se evidencia inundaciones durante los meses de verano, caracterizado por altos caudales de agua que exceden la capacidad de los ríos y desbordan sus causes, provocando inundaciones en zonas adyacentes.

Se tuvo como objetivo principal evaluar un sistema de alerta temprana para inundaciones basado en modelo de aprendizaje automático adaptado por inteligencia artificial – Catacaos – Piura; 2023. Utilizando una metodología de tipo cuantitativa y de diseño no experimental. Con una población muestral que involucra datos sobre inundaciones obtenidos de SENAMHI, de los últimos 10 años

Se concluyó que se logró que el modelo de aprendizaje automático basado en SARIMAX, utilizado demostró ser una herramienta efectiva para prever y anticipar eventos de inundación en Catacaos. La precisión del modelo, es respaldada por métricas sólidas como el MAE, MSE, y RMSE, indica una alineación estrecha entre las predicciones del modelo y los valores reales, validando así su utilidad en la predicción de patrones de inundación. La integración de este modelo inteligente como base en la implementación de un sistema de alerta temprana se muestra como un enfoque prometedor y eficiente.

Palabras clave: Alerta temprana, inundación, inteligencia artificial

ABSTRACT

The present research, titled "Proposal for an Artificial Intelligence-based Early Warning System for River Flooding in Catacaos – Piura; 2023," originated from the observation of flooding events in Peru during the summer months. These events are characterized by high water flows that exceed the rivers' capacity, leading to overflow and flooding in adjacent areas.

The main objective was to evaluate an early warning system for floods based on a machine learning model adapted by artificial intelligence in Catacaos – Piura; 2023. The research employed a quantitative methodology and a non-experimental design, with a sample population including flood data obtained from SENAMHI over the last 10 years.

It was concluded that the machine learning model based on SARIMAX proved to be an effective tool for predicting and anticipating flooding events in Catacaos. The model's accuracy, supported by robust metrics such as MAE, MSE, and RMSE, indicates a close alignment between the model predictions and actual values, validating its utility in predicting flooding patterns. The integration of this intelligent model as the foundation for implementing an early warning system emerges as a promising and efficient approach.

Keywords: Early warning, Flooding, Artificial Intelligence

I. INTRODUCCIÓN

Se conoce que los ríos son volúmenes de agua superficial más importante de las masas terrestres, estos están conformados por corrientes de agua dulce la cual circula por un cauce y desemboca en otro río o la mayoría de veces en el mar. El agua de estos ríos está relacionada con las precipitaciones, con frecuencia, pero, no obstante, los ríos reciben agua de los manantiales, esto se da porque el agua de las lluvias en general penetra el suelo, acumulándose en rocas permeables. Además de ello por la gran fuerza que tienen los ríos erosionan rocas y sedimentos, abriendo causes, estos pueden ser muy superficiales o tan profundos como el Gran Cañón que el río Colorado ha recortado en algunos lugares hasta una profundidad de 1500 m (Maza, 2019).

Esto se ha observado en Perú durante muchos años, siendo los meses de verano el período de inundaciones y con los mayores caudales de agua, y los meses de invierno la estación seca y con los menores caudales de agua. El cauce es la superficie que queda cubierta por el agua en el momento de máxima crecida del régimen fluvial, pero cuando hay un aumento puede hacer que el agua lo desborde e inunde las zonas aledañas. El calentamiento anómalo del mar cerca de las costas de estas naciones es lo que distingue a este fenómeno (Vargas, 2020).

Debido al aumento de la humedad provocado por este calentamiento, empiezan a caer fuertes lluvias, lo que provoca desbordamientos, inundaciones y derrumbes que afectan a diferentes zonas. El 2016 fue testigo de una terrible sequía que ambos países tuvieron que enfrentar ante el fenómeno. Distintas regiones del departamento de Piura fueron impactadas por este fenómeno, lo que provocó la activación de los cauces de los ríos y un aumento en el caudal de los ríos y arroyos locales que resultó en la pérdida de tierras agrícolas, caminos e infraestructura hidráulica. Por ello, en la actualidad existen lugares que podrían verse afectados por un fenómeno similar, que podría tener consecuencias nefastas, incluidas pérdidas humanas (INDECI, 2018). Años más tarde, el ciclón Yaku haría acto de presencia. Afectó principalmente a las regiones de Tumbes, Piura y Lambayeque, causando estragos en numerosas ciudades con lluvias torrenciales y desbordes de ríos.

Dado que las advertencias de peligros naturales generalmente se dan en una cantidad de tiempo y espacio limitados, la emisión de advertencias de inundaciones precisas y oportunas es un desafío constante. En esta situación, los sistemas de alerta temprana con modelos hidrológicos pueden pronosticar el caudal que conecta la lluvia y la escorrentía, entendida como el evento de una precipitación mayor a la tasa de penetración (Cárdenas, 2022).

En países como Perú, Costa Rica, Colombia y El Salvador, entre otros, se ha implementado con éxito el sistema de alerta temprana contra inundaciones. Ha brindado información a los gobiernos locales para planificar su desarrollo al reducir su vulnerabilidad a las inundaciones. Los sistemas de alerta temprana fueron creados como un medio para sostener el monitoreo de lluvias y, entre otras cosas. Además de la planificación de emergencia, los preparativos locales para inundaciones y la respuesta a inundaciones, el Volumen hidrométrico, proporciona un pronóstico de inundaciones y una alerta temprana para las comunidades cercanas. Todo esto ha permitido predecir fenómenos atmosféricos como inundaciones que pueden ocurrir en el futuro en un período de dos a seis días en naciones como España y otras regiones de Centroamérica (Pernalet, 2017).

Los sistemas de alerta temprana con IA usan algoritmos de aprendizaje automático para poder analizar datos históricos y en tiempo real y así poder identificar patrones y anomalías. Estos patrones pueden ser variaciones de datos, desviaciones de las normas establecidas o cambios en el comportamiento del usuario. Cuando se detecta un patrón, el sistema puede enviar una alerta en tiempo real a los usuarios pertinentes para que tomen medidas preventivas (Yousafzai et al, 2024).

Como justificación para la realización de este estudio, es fundamental para las regiones afectadas por el desbordamiento del cauce de los ríos, ya que el estudio y su ejecución resolverán parcialmente el problema de las inundaciones, ya que esta situación pone a los lugareños en una condición crítica y grave por las repercusiones económicas. Desde el punto de vista humano, quienes viven allí están poniendo en peligro su vida porque no hay suficiente protección contra la erosión del río, que ha llegado hasta el borde de las casas. “Los hallazgos de este estudio serán de utilidad tanto para el Gobierno Regional de Piura como para las

autoridades de los centros poblados involucrados, ya que permitirán conocer con mayor precisión las soluciones de ingeniería que se propondrán”.

El río Catacaos juega un papel distintivo como punto geográfico clave en la región de Piura, Perú, aunque la región del norte de Perú cuenta con varios ríos notables, como el río Piura y el río Chira, el río Catacaos se destaca por ser un afluente esencial del río Piura, estableciendo una conexión intrincada en la región.

Bajo este contexto, para la formulación del problema se plantea la siguiente pregunta general: ¿Cómo un modelo de aprendizaje automático adaptado por inteligencia artificial es base para un sistema de alerta temprana para inundaciones – Catacaos – Piura; 2023?; para dar respuesta a ello, se plantean como preguntas específicas, ¿Cuál es el impacto anual de las inundaciones en las personas en Catacaos – Piura; 2023?, ¿Cuál es la capacidad del sistema de alerta temprana de detectar señales físicas de amenazas de inundaciones- Catacaos – Piura; 2023?, ¿Cuál es la estacionariedad en los que se producen las inundación - Catacaos – Piura; 2023?, ¿Cómo el modelo inteligente logra comprender de manera precisa los patrones y comportamientos de las inundaciones- Catacaos - Piura; 2023?

Para dar respuesta a estas preguntas, se plantea como objetivo general: Proponer un sistema de alerta temprana para inundaciones basado en modelo de aprendizaje automático adaptado por inteligencia artificial – Catacaos – Piura; 2023. Para cumplir con este objetivo, se plantea como objetivos específicos: Identificar el número de personas afectadas por las inundaciones cada año en Catacaos - Piura; 2023, Identificar la capacidad del sistema de alerta temprana de detectar señales físicas de amenazas de inundaciones- Catacaos – Piura; 2023, Identificar la estacionariedad en los que se producen las inundaciones en Catacaos – Piura; 2023, Analizar el uso de un de un modelo inteligente para comprender de manera precisa los patrones y comportamientos de inundaciones - Catacaos – Piura; 2023.

II. MARCO TEÓRICO

Internacionales

Mora, C. y Losada, J. (2023). En su investigación titulada “Análisis de series temporales en estaciones meteorológicas para la predicción de la precipitación en la ciudad de Manizales, Colombia” tuvo como objetivo analizar diferentes series temporales utilizando modelos ARIMA, SARIMA, SARIMAX, Neural Prophet y Prophet con el fin de predecir precipitaciones en la ciudad de Manizales en Colombia, en donde como resultado obtuvo el menor valor de RMSE en el modelo Prophet en donde concluyó que en este modelo se obtiene el menor porcentaje de error.

Dorado, J (2020), en su investigación titulada “sistema de monitoreo y control de alerta temprana del desbordamiento de un río”, la cual tuvo como objetivo general Diseñar y desarrollar un sistema de información móvil para la recolección y análisis sobre el comportamiento de los ríos, menciona que el proceso de recolección de información sobre el estado de los ríos actualmente se hace de forma manual en muchos casos, para luego llevar estos datos a la gestión de riesgo y se pueden tomar medidas ante una posible inundación. Esto hace pensar que los datos no se obtienen en tiempo real tiempo, lo que dificulta determinar con exactitud cuándo el afluente es un peligro, lo que implica que no se puede ejecutar un plan de contingencia oportuno para este tipo de situaciones, lo que genera perjuicios para las personas que tienen sus viviendas en los alrededores.

Villenas, (2020), En su tesis “Predicción de caudales en la cuenca del río Chalpi Norte mediante la aplicación de redes neuronales”, la cual tuvo como objetivo principal desarrollar un modelo predictivo de caudales a escala diaria en la microcuenca mencionada. Utilizando datos de precipitación y caudal relevantes para la zona, Villenas observó que los resultados obtenidos a través de la aplicación exclusiva de un modelo de redes neuronales artificiales eran comparables a los obtenidos con modelos híbridos en microcuencas de ecosistemas de alta montaña.

En su investigación “Análisis de métodos estadísticos para evaluar el desempeño de modelos de simulación en cultivos hortícolas”, Gonzales y Soto, (2019), se propusieron analizar diversos métodos estadísticos utilizados para evaluar modelos

de simulación en agricultura. El objetivo era identificar el método más apropiado desde un punto de vista práctico. Destacaron que todas las medidas propuestas para evaluar los modelos se basan en las diferencias entre valores observados y simulados, proporcionando información del desempeño del modelo para una muestra específica. Sin embargo, señalaron la ausencia de medidas del error asociado a la generalización de los resultados a la población en su conjunto.

Del Granado, S et all (2016). En su investigación titulada, “Sistemas de Alerta Temprana para Inundaciones: Análisis Comparativo de Tres Países Latinoamericanos”, presentada en la paz - Bolivia, tuvo como objetivo comparar los Sistemas de Alerta Temprana (SATs) para inundaciones, identificar los problemas, las lecciones aprendidas y a partir de ello hacer recomendaciones, tuvo como metodología descriptiva, en la cual sus indicadores estuvieron orientados hacia sistemas de alerta temprana e inundaciones en los países de Bolivia, Republica Dominicana y Ecuador. Estudio en el cual concluyó que existe una gran brecha entre el pronóstico técnico y la comunicación efectiva para con la población, también menciona que la manera de evitar que un fenómeno natural se convierta en un desastre puede ser un SAT.

Mora, D, y Rosas, J, (2016), en su investigación titulada “Propuesta de Diseño de un Sistema de Alerta Temprana por Inundación en la Subcuenca del Río Tejalpa (SIATI-ScRT)”, la cual tuvo como objetivo realizar una propuesta de diseño de un sistema de alerta temprana por inundación en la subcuenca del río Tejalpa (SIAT-ScRT) en una plataforma web, utilizando una metodología descriptiva, dice que “el sistema de alerta temprana permite visualizar el riesgo de inundación en la subcuenca del río Tejalpa, lo que permite prevenir localidades como Colonia la Deportiva, Barrio Barbabosa, Colonia Ojuelos, Nueva Serraton, Samarrero, Barrio Santa Mara, San Juan de las Huertas y Santa Cruz Cuauhtenco, quienes presentan la mayor área de inundación, además, las principales vías del municipio de Zinacantepec—Calle 16 de Septiembre, Circuito Va Acahualco, Avenida Adolfo López Mateos y la vía a Almoloya de Juárez— son propensos a inundaciones De manera similar a como apoya a la población con mayor riesgo de inundación, este sistema tiene como objetivo garantizar que los locales estén mejor equipados para

hacer frente a tal ocurrencia y que las agencias a cargo de la prevención puedan actuar rápidamente. y decisivamente y útil durante una emergencia de inundación.

Los autores Cárdenas Sorangela, Vides Carlos y Pardo Aldo (2022), en su estudio titulado “Sistema de alerta temprana de inundaciones para el río Arauca basado en técnicas de Inteligencia Artificial” en la ciudad de Pamplona, Colombia, mencionan que al realizar un diseño de un sistema de medición y seguimiento del caudal y caudales de los ríos, la información del estudio es extraída del IDEAM y procesada, obteniendo un modelo a través de las variables que intervienen, tales como: Precipitación. Este modelo de información alimenta las tendencias lineales, de potencia y de relación potencial de tres clases de tendencias al modelo matemático para el lecho del río. El modelo de canal se compara con un observador basado en una red neuronal, que, al comparar sus salidas, crea un residuo que se encarga de proporcionar los datos proporcionados por el estado actual del nivel del río en estudio

Nacionales

Lujano, E., et all (2023). En su investigación titulada, “Modelado hidrológico basado en el algoritmo KNN: una aplicación para el pronóstico de caudales diarios del río Ramis, Perú.” Tuvo como objetivo el pronóstico de caudales de ríos aplicando el algoritmo KNN, en donde el rendimiento se midió con el error absoluto (MAPE), anomalías del coeficiente de correlación y ángulo espectral (SA), los resultados del pronóstico utilizando un modelo inteligente basado en KNN alcanzaron altos niveles en confiabilidad para predecir caudales a corto plazo.

Tello, C., (2022). En su tesis titulada “Estimación de la probabilidad de daño humano por inundación fluvial en la selva baja del Perú” presentada en la Universidad Nacional Agraria de la Selva, tuvo como objetivo el presentar un esquema de como estimar la probabilidad de daños por inundaciones para la selva baja peruana, en la metodología fue de tipo comparativa, en donde pretende estimar en número de afectados, muertos, heridos, viviendas afectadas y viviendas destruidas por inundaciones. Concluyó que la mayor cantidad de inundaciones ocurre en la selva baja, y en promedio es de 87 inundaciones por año, así como el número de viviendas afectadas es en promedio 19771.94 por año.

Pablo, k, (2019), en su investigación titulada “Sistema de Alerta Temprana de Inundaciones Aplicando un Modelamiento Hidrológico con HEC-HMS en el Río Culebras”, la cual tuvo como objetivo proponer un Sistema de Alerta Temprana contra Inundaciones utilizando un modelamiento hidrológico con HECHMS en el Río Culebras, para prevenir el peligro ante un fenómeno natural, menciona que la cuenca del río Culebras carece de datos de precipitación de la estación pluviométrica e hidrométrica para estudios hidrológicos, utilizando una metodología descriptiva. La falta de datos en las instalaciones del SENAMHI, ANA y Junta de Usuarios de Huarmey, junto con la sugerencia de estaciones hidrométricas y pluviométricas, son razones suficientes, y la cuenca del río Culebras no cuenta con estaciones dentro de su delimitación de la cuenca del río Culebras.

Gallo, K, (2021), en su investigación titulada “Propuesta de instrumentos para implementar un sistema de alerta temprana ante flujo de detritos en la quebrada Pedregal, Lurigancho Chosica, 2020”, la cual tuvo como objetivo determinar la pertinencia de la implementación de los instrumentos del Sistema de Alerta Temprana, ante la ocurrencia de flujo de detritos, instalados en la quebrada Pedregal Lurigancho – Chosica, señala que se determinó que no existen mecanismos apropiados que actualmente estén operativos para el monitoreo y/o vigilancia local de la peligrosidad de flujo de escombros en la quebrada Pedregal, utilizando una metodología analítica.

Los Sistemas de Alerta Temprana (SAT) son una colección de herramientas encargadas de predecir la probabilidad de una amenaza para una o más poblaciones. Esta anticipación se da gracias a el monitoreo de una o más señales físicas que intervienen en la amenaza. La importancia del SAT radica en su capacidad para prevenir la pérdida de vidas y la destrucción de bienes materiales fácilmente reemplazables, así como en el hecho de que puede ser utilizado para recopilar los datos necesarios para el pronóstico de eventos. y así hacer que los eventos futuros sean más fáciles de amortizar (Vargas H, 2016).

Ya se trate de un fenómeno natural o antropogénico, estos sistemas se pueden utilizar en cualquier campo donde se anticipe una amenaza para una población específica. Existen al menos dos formas diferentes de emitir alertas debido a que esta actividad se realiza a través de la observación continua de variables o

indicadores particulares en cada caso de estudio y ante la presencia de fenómenos naturales. Un EWS se puede utilizar en cualquier campo donde sea posible que una persona realice un seguimiento de los cambios en una variable natural o antropogénica (Vargas H, 2016).

El proceso para crear un sistema de alerta temprana (SAT) de tipo comunitario se divide en dos etapas. La primera etapa consiste en realizar un estudio de las áreas que pueden estar en riesgo de inundación mediante la identificación de cuerpos de agua cercanos donde se hayan registrado caudales, y luego usar simulaciones hidráulicas para determinar qué parte de la población se verá afectada y dónde se encontrarán las superficies de inundación. ser. Dado que uno de los objetivos del sistema es que pueda ser implementado por cualquier entidad o persona interesada (transferencia de tecnología fácil), la segunda fase se relaciona con el diseño e implementación del SAT comunitario (Castillo, 2020).

Inteligencia, se dice que es la capacidad de comprender, recordar, movilizar y completar de forma constructiva lo que se ha aprendido y de utilizarlo para enfrentarse a nuevas situaciones.

Artificial, se dice que es algo no natural, sino que fue hecho por la mano o arte del hombre.

La IA es uno de los campos más emocionantes y desafiantes de las ciencias de la computación porque ha tomado la inteligencia como una característica universalmente reconocida que distingue a los humanos de otros seres, ya sean vivos o no, en la creación de programas o computadoras.

Se puede decir que la inteligencia artificial es una disciplina que tiene como objetivo el estudio del comportamiento humano a través del análisis del comportamiento humano inteligente, lo que se puede denominar análisis de los procesos cognitivos, porque se enfocan en el estudio de los procesos internos, conducentes al aprendizaje.

La IA está influyendo profundamente en muchas facetas de varios campos, incluida la ciencia y la tecnología, la industria e incluso la vida cotidiana, junto con técnicas prometedoras de aprendizaje automático (ML). Es crucial tener en cuenta el

impacto del desarrollo y la aplicación de la IA en varias facetas de las ciencias básicas (González M., 2023).

La inteligencia artificial actualmente es de gran utilidad para los sistemas de alerta temprana debido a su impacto en la gestión de los recursos hídricos a través de la interpretación de imágenes de satélite y el seguimiento de variables hidrométricas (Cárdenas, 2022).

Los sistemas de alerta temprana con IA se están convirtiendo en una herramienta importante para la prevención de riesgos y las medidas preventivas en diversas industrias y sectores. Los sistemas de alerta temprana con IA ayudan a las personas y las empresas a protegerse de los riesgos potenciales, desde la detección temprana de enfermedades hasta la prevención de desastres naturales.

Los sistemas de alerta temprana basados en modelos inteligentes de aprendizaje automático analizan datos históricos y en tiempo real para buscar patrones y anomalías utilizando algoritmos de aprendizaje automático. Estos patrones pueden ser variaciones en los datos, desviaciones de los estándares aceptados o ajustes en el comportamiento del usuario. El sistema puede enviar una alerta en tiempo real a los usuarios apropiados cuando se encuentra un patrón para que puedan tomar medidas preventivas. (Yousafzai et al, 2024).

Las redes neuronales se emplearon con varios objetivos en mente, en el modelado hidrológico data de la década de 1990 y en adelante, sobre la base de redes neuronales se han logrado soluciones efectivas, entre ellas, algunos beneficios de usar estas redes incluyen su capacidad demostrada y su bajo costo, para representar conexiones intrincadas y no lineales entre la entrada, y variables de salida de un proceso hidrológico utilizando solo conjuntos. De los datos observados y aún llegar a respuestas satisfactorias; Su uso en tiempo real es posible gracias al rápido tiempo de cálculo. También sirve como una herramienta operativa potencial para ayudar a la toma de decisiones, además, para la calibración rápida independientemente de la disponibilidad de nuevos datos. Pertinente a la mejora de la compensación entre anticipo y la integración de datos de varias fuentes aumenta la precisión de las advertencias (Teixeira y Balda, 2021).

Teniendo en cuenta fuentes, como datos meteorológicos, en el diseño de la red neuronal, una imagen de un satélite meteorológico y un modelo numérico de pronóstico del tiempo, hace que las predicciones de esta sean más precisas a largo plazo en general (Teixeira y Balda, 2021).

Desde el punto de vista humano, quienes viven allí están poniendo en peligro su vida porque no hay suficiente protección contra la erosión del río, que ha llegado hasta el borde de las casas. “Los hallazgos de este estudio serán de utilidad tanto para el Gobierno Regional de Piura como para las autoridades de los centros poblados involucrados, ya que permitirán conocer con mayor precisión las soluciones de ingeniería que se propondrán”. Teniendo en cuenta que el objetivo principal del SAT es la detección temprana de amenazas potenciales a poblaciones vulnerables; la efectividad del cumplimiento de este objetivo depende del alineamiento de los procesos de toma de decisiones de las diferentes entidades que redunden en la prevención de dichas amenazas (Vargas H, et al., 2016).

Según Vargas y Giraldo (2018), existe una tendencia mundial hacia la implementación de sistemas que permitan el conocimiento directo de los niveles de los ríos, lo que puede ayudar a salvar vidas y evitar desastres. Dado que se espera que la alerta de un peligro natural llegue rápidamente, medir y monitorear el caudal y las causas de los ríos es un desafío constante. La interpretación de imágenes de satélite y el seguimiento de variables hidrométricas son dos aplicaciones actuales de la inteligencia artificial que han ayudado mucho a la gestión de los recursos hídricos (Teixeira, 2021).

Domínguez y Lozano (2014), definen un sistema de alerta temprana como una colección de herramientas, controles, capacidades de gestión y herramientas tecnológicas identificadas por instituciones clave quienes tienen a cargo la responsabilidad de comunicar información rápidamente a las comunidades en riesgo, lo que conduce a medidas de mitigación específicas buscando disminuir lo mayor posible los efectos de los desastres naturales y las consecuencias sociales y económicas resultantes, pérdidas de vida, así como lesiones (Domínguez y Lozano, 2014).

Un modelo convencional para la predicción de caudales de río puede ser validada con datos hidrometeorológicos, sirve para predicciones a corto plazo, estos modelos pueden ser utilizados por las autoridades como medida de prevención para futuras amenazas de riesgo de inundaciones (Farias, M. et al, 2020).

Para crear un sistema de alerta temprana que funcione oportunamente para satisfacer una determinada necesidad, se necesita mucho más que tecnología. Para resolver diversos tipos de dilemas, implica abarcar un marco más amplio, sobre todo, un proceso reflexivo que, en última instancia, se refiere a opciones teóricas y metodológicas, así como a cuestiones organizativas (Casanova et al, 2021).

Los sistemas de alerta temprana son un componente crucial en la mitigación de riesgos ante un desastre natural. El principal objetivo de estos es prever el peligro y con esta información evitar en su mayor medida la pérdida de vidas humanas tanto como de bienes. La población que necesita ser protegida y las autoridades gubernamentales a cargo de esta mitigación, deben funcionar en un sistema integrado, para que esta mitigación se lleve a cabo de manera óptima (Vargas H, Tovar M. y Villanueva C, 2016).

La implementación de un software para la detección de desastres ambientales ha demostrado ser fundamental y eficiente al momento de representar gráficamente los datos obtenidos, de esta manera se facilita la generación de archivos de información necesaria para tomar decisiones y emitir señales que pueden ser sonoras, como una alarma cuando se detecte algún tipo de anomalía (Solarte A y Agredo L, 2012).

Al momento de planificar y evaluar las posibles acciones que pueden tomarse para la mitigación de riesgos frente a amenazas geológicas, es indispensable disponer de la capacidad de realizar un pronóstico de las tendencias y comportamientos futuros de determinados sistemas complejos como por ejemplo litorales (C, Castedo R, Llorente M y Laín L, 2012)

Para la mitigación de los impactos catastróficos de los desastres naturales es fundamental la detección correcta y rápida, para esto, existen estudios que se centran en el monitoreo de desastres en tiempo real usando métodos de

aprendizaje profundo de la inteligencia artificial. El uso de estos modelos para la extracción de características supera a los modelos convencionales, ya que el genera una predicción con precisión en las primeras etapas del desastre (Sathishkumar V, Cho J, Subramanian M, y Naren O, 2023).

El evaluar las situaciones extremas de fenómenos inusuales y sus efectos sobre el sistema es sumamente relevante para el manejo de recursos, en este caso recursos hídricos, para la medición de caudales de ríos es importante que esta, se realicen en puntos alejados para así poder obtener valores globales que permitan promediar los efectos, la medición directa de un caudal se combina con la información de estaciones de monitorización fijas, también con la información meteorológica de las estaciones para la información sobre posibles precipitaciones de lluvias o la escases de estas, para de esta manera evaluar si el caudal es pobre o dominante (Thomas L y Marino B, 2016).

Es importante determinar el nivel de marea de tormentas asociadas a distintos periodos en que pueden presentarse en una determinada zona, en donde los datos son escasos, la información que generan estos eventos debe ser procesada para la mitigación de riesgos para cuando este se presente nuevamente. El uso de eventos sintéticos son importes para que esto, junto con la información de eventos históricos, generen una base de datos confiable para la disminución de incertidumbre en la población y permita afrontar de mejor manera dicho evento, por ello es importante el uso de datos sintéticos y datos existentes (Meza-Padilla R. et all, 2015).

Existen herramientas para la adquisición de señales ambientales que cumplen con las condiciones de obtención, procesamiento, almacenamiento y difusión de estos parámetros para la generación de alertas, estas herramientas utilizan sensores basados en diversos protocolos que permiten trabajar de manera precisa, para ellos es necesario una red robusta para la comunicación con los sensores (Guillot, J. D. et all, 2017).

Los prototipos que relacionan el uso de sensores con redes neuronales suelen ser las más robustas, el monitoreo de comportamientos ambientales es un área

bastante interesante para la aplicación de tecnologías de inteligencia artificial combinado con el campo de la electrónica (Rubio, J. et al 2016).

En un sistema de alerta temprana, la alerta debe ser rápida y precisa, por ello el enlace de transmisión utilizado para enviar los datos desde las estaciones a la instalación de procesamiento y la velocidad a la que los registradores envían los paquetes de datos son, las dos variables principales que afectan la eficacia con la que se implementa este. Para ser utilizado en SAST en el futuro. La ETH aún está trabajando en desarrollar este método e incorporarlo a SeisComp (Arregui et al., 2022).

Los sistemas de alerta temprana, también pueden predecir las precipitaciones climáticas, este tipo de sistemas son de gran ayuda para los agricultores ya que ayudan a tomar las medidas correspondientes respecto a los cultivos. En este caso se requiere información a largo plazo con respecto a los cambios de clima que influyen en el perfecto desarrollo del cultivo. El desarrollo de un sistema de este tipo permite identificar los peligros climáticos, así como la necesidad de definir acciones para adaptarse a los cambios futuros (Vargas C. et al, 2020).

La inteligencia artificial, es una herramienta que gana terreno en cuanto a medición y evaluación, esta evaluación es la que nos sirve para realizar predicciones, pero no solo se desenvuelve en este campo, pues debido a la capacidad de brindar información precisa, se usa también para la evaluación de daños, en este caso Carreño, M. Cardona, O. y Barbat, A (2011). Mencionan que el desarrollo de métodos basados en modelos de inteligencia artificial, es útil para la difícil tarea de evaluar los daños que se presenten en edificaciones después de un desastre (terremoto). De esta manera se hace una evaluación más exacta del daño, esto es una herramienta de gran ayuda para los profesionales a momento de definir la seguridad estructural. La utilización de redes neuronales artificiales es importante para calibrar este sistema inteligente a un juicio experto (Carreño M. Cardona O. y Barbat, A., 2011). Se puede decir que esta información es sumamente importante para la gestión de riesgos, ya que en razón a esta información se pueden generar medidas, guías y políticas para afrontar un posible desastre.

La aplicabilidad del algoritmo KNN para el pronóstico de los flujos diarios en los ríos, tiene gran importancia en para el enfoque de pronóstico de flujo de agua, una ventaja es que también se puede integrar para el pronóstico hidrológico dentro de un sistema de alerta temprana, El algoritmo KNN es una herramienta eficaz para el pronóstico de flujos diarios, ya que su pronóstico basado en datos, coincide estrechamente con valores reales (Lujano, E.et all., 2023).

El autor Noschang, 2020, menciona que el arima que representa un modelo con parámetros (p, d, q) , es conocido como un proceso autorregresivo compuesto de tercias móviles, representado por sus órdenes p, d y q (Noschang, 2020).

Se posibilita la descripción de las observaciones una vez que han sido sometidas a múltiples diferenciaciones con el fin de eliminar potenciales fuentes de inestabilidad, en el caso de que exista un componente igual a cero o nulo, se procede a excluir el término correspondiente de la fórmula general, contribuyendo así a una representación más precisa y depurada de los datos observados, este proceso permite mitigar posibles distorsiones y mejorar la robustez de la formulación al adaptarse de manera eficiente a las características específicas de las observaciones en cuestión, (Gallego-Nicasio, otros, 2018).

Se menciona también que los modelos arima se destacan por su beneficio, ya que su aplicación se basa en modelos que conservan una representación estacionaria, lo cual resulta altamente adecuado en la práctica, principalmente cuando se busca analizar retrospectivamente la conexión entre los valores de una serie temporal. Estos modelos, al centralizar en la estacionariedad, brindan una sólida base para explorar y percibir de manera efectiva las relaciones y patrones presentes en la evolución temporal de los datos, su aplicación proporciona herramientas valiosas para examinar de manera detallada y precisa cómo las exploraciones pasadas influyen en las tendencias actuales, permitiendo así una comprensión más profunda y significativa de la dinámica inferior en la serie temporal en consideración.

La prueba de Dickey-Fuller se maneja con el propósito de identificar de forma estadística la preexistencia de patrones de comportamiento “tendencial estocástico” en las series temporales de las variables. Este método se basa en la

realización de un contraste de hipótesis, suministrando una herramienta valiosa para evaluar la estacionariedad de los datos a lo largo del tiempo y detectar posibles predisposiciones significativas, al someter las variables a este análisis, se busca comprobar si hay evidencia suficiente para afirmar o rechazar la presencia de una tendencia en la serie temporal, lo cual es fundamental para percibir la dinámica subyacente de los datos y tomar decisiones informadas, (Calocchio, 2018).

En resumen, la prueba Dickey-Fuller constituye una herramienta decisiva en el análisis de series temporales al ofrecer un marco estadístico riguroso para evaluar la presencia de comportamientos tendenciales estocásticos en las variables estudiadas.

La prueba aumentada de Dickey-Fuller (ADF), según la explicación proporcionada por los autores (Martínez, y otros, 2023), se fundamenta en la siguiente ecuación:

$$\Delta y_t = \alpha + \theta y_{t-1} + \gamma \Delta y_{t-1} + m_i t$$

Donde la variable y_t simboliza la serie de precios bajo consideración, y $\theta = \rho - 1$.

Las hipótesis a ser evaluadas son las siguientes: $H_0: \theta = 0$, lo que involucra que la serie posee una raíz unitaria y, por ende, no es estacionaria, en contraste con $H_1: \theta < 0$, indicando que la serie es estacionaria. La descripción de esta prueba puede o no incluir un intercepto y una tendencia de tiempo lineal, dependiendo del comportamiento observado en la serie.

Con respecto a lo dicho por los autores, se puede mencionar que la ecuación ADF busca modelar la relación entre las diferencias en la serie temporal (Δy_t) y sus valores anteriores, considerando la posible aparición de una raíz unitaria que podría indicar no estacionariedad.

Scikit-learn, probablemente la biblioteca más valiosa para la ejecución de Machine Learning en entornos Python, recalca por su naturaleza de código abierto y su versatilidad, lo que la convierte en una herramienta utilizable en varios ámbitos, ya sea académico o empresarial, esta librería no solo facilita la aplicación de un amplio espectro de algoritmos de aprendizaje inspeccionado y no inspeccionado en Python, sino que también origina la reutilización de código, fomentando así un

desarrollo más eficiente y sostenible en la investigación y la industria, (Gómez, 2023).

Por otro lado, se menciona que la utilidad de Scikit-learn abarca diversas etapas del proceso, permitiéndote llevar a cabo operaciones decisivas, como el pretratamiento y el apartado de conjuntos de datos, además, suministra la preparación y la valoración de modelos en clases tan relevantes como clasificación, regresión y segmentación.

Esta librería no se limita a la ejecución básica de algoritmos, pues va más allá al suministrar funcionalidades avanzadas, como la selección de modelos a través de la búsqueda de hiperparámetros, lo que permite perfeccionar el beneficio de manera más positiva, asimismo destaca por su capacidad para evaluar modelos a través de métricas de ejercicio, facilitando una visión integral y detallada de la certeza de los modelos implementados.

(Cambroner, otros, 2023), mencionan que la estacionalidad se caracteriza por el patrón cíclico anual que surge debido a las variaciones en factores como el clima, el calendario y la sincronización de decisiones que ejercen impacto tanto directo como indirecto en las elecciones de consumo y producción de los participantes económicos, este fenómeno implica un movimiento sistemático que se manifiesta a lo largo del año, siendo influido por elementos externos que inciden en las dinámicas económicas, generando fluctuaciones periódicas en los comportamientos y acciones de los agentes económicos.

En otras palabras, la estacionalidad refleja la recurrente influencia de factores temporales en las decisiones comerciales y de consumo, creando un ciclo predecible que se repite anualmente.

En el libro de Camones, Miranda, Ordoñez y Vásquez, se menciona que las tres características fundamentales que definen el fenómeno estacional son las siguientes:

- 1) Su recurrencia anual, que se manifiesta con cierta regularidad, aunque tiene la capacidad de evolucionar con el tiempo, este patrón cíclico, que se repite

anualmente, no permanece estático y puede experimentar cambios en su intensidad o duración.

2) La posibilidad de medirlo y separarlo de otras fuerzas que afectan el movimiento de la serie. La estacionalidad puede ser cuantificada y analizada de manera independiente, permitiendo así aislar su influencia de otros factores que también inciden en la variabilidad de la serie temporal, este atributo facilita la comprensión y el estudio específico de sus efectos en el comportamiento económico.

3) Su origen principalmente vinculado a fuerzas no económicas, que son exógenas al sistema económico, estas fuerzas, que están fuera del control directo de los tomadores de decisiones económicas, desencadenan la estacionalidad y no pueden ser modificadas a corto plazo por dichos actores, esto resalta la naturaleza externa e inevitable de las influencias estacionales, las cuales provienen de factores que escapan al ámbito de control de quienes toman decisiones económicas.

Las series temporales son una recopilación de informaciones de una variable almacenada progresivamente en el tiempo, estas informaciones se suelen almacenar en intervalos de tiempo equiespaciados.

Una serie temporal se caracteriza por ser un conjunto de datos que registra observaciones de una variable específica de manera secuencial a lo largo del tiempo, por lo general, estas observaciones se obtienen en momentos temporalmente paralelas. La peculiaridad esencial de las series temporales radica en que las observaciones próximas no son independientes entre sí, lo que involucra que el análisis debe considerar el orden cíclico en el que se seleccionan dichas observaciones, este enfoque secuencial y la interdependencia temporal entre las mediciones son aspectos fundamentales que diferencian y delimitan la naturaleza única de las series temporales, y deben ser tomados en cuenta al realizar cualquier tipo de análisis o interpretación, (Meneses, 2019).

Se dice que existen dos enfoques principales al abordar la predicción mediante técnicas de series temporales, por un lado, se encuentran los métodos cualitativos, los cuales no se apoyan directamente en la información pasada para entender el fenómeno en cuestión, como es el caso de la introducción de nuevos

productos en el mercado, y por otro lado, están los métodos cuantitativos, que aprovechan al máximo la información contenida en los datos disponibles, estos métodos se basan en el análisis de patrones de comportamiento pasados para realizar proyecciones sobre el futuro, este enfoque cuantitativo implica extraer de manera exhaustiva la información histórica para anticipar tendencias y comportamientos futuros, (García, 2016).

El río Piura se origina en la cuenca del río Huancabamba, ubicada en la región del mismo nombre, su punto de inicio se encuentra a aproximadamente 3600 metros sobre el nivel del mar en la línea divisoria entre el río y la cuenca, desde allí, emprende su curso hacia el norte del país, descendiendo constantemente en altitud, drenando en una cuenca que abarca una extensión de 12.000 kilómetros cuadrados, recorriendo en el Sur-Oeste, el distrito de Catacaos, Se ubica específicamente en la vertiente del Pacífico de este país y se extiende a lo largo de 280 kilómetros, aunque su caudal es relativamente bajo, el río es altamente sensible a las lluvias estacionales, lo que ha provocado crecidas e inundaciones en determinadas ocasiones (Autoridad Nacional del Agua, n.d.).

Con respecto a lo mencionado por los autores, mientras que los métodos cualitativos se centran en fenómenos donde el pasado no proporciona una guía clara, los métodos cuantitativos buscan aprovechar al máximo la información disponible para realizar predicciones informadas sobre eventos futuros.

III. METODOLOGÍA

3.1. Tipo y diseño de investigación

La investigación fue de tipo aplicada con un enfoque cuantitativo. Según el autor Méndez, S (2020), menciona que la investigación cuantitativa se refiere a un enfoque de investigación en el cual se lleva a cabo la recopilación y análisis de información numérica que está vinculada a variables específicas, este tipo de investigación se enfoca en el estudio de las propiedades y fenómenos que pueden ser medidos y aumentados en términos cuantitativos. En el proceso de investigación cuantitativa, se utilizan diversas técnicas y herramientas de análisis para examinar de manera exhaustiva los datos recopilados, estas técnicas pueden incluir el uso de métodos estadísticos, análisis de regresión, pruebas de hipótesis, correlaciones, entre otros. El objetivo de la investigación cuantitativa es buscar patrones, establecer relaciones y realizar generalizaciones basadas en los datos numéricos recopilados. Por otro lado, se menciona que, a través de un enfoque riguroso y objetivo, se busca obtener resultados cuantificables y replicables que permitan una comprensión más precisa de los fenómenos estudiados, además de ello es importante destacar que la investigación cuantitativa se basa en la recopilación de datos de una muestra representativa de la población, lo que permite realizar inferencias sobre la población en general.

El diseño de esta investigación fue no experimental, ya que es un enfoque de investigación en el que no se manipulan deliberadamente las variables. Se basa principalmente en la observación directa de los fenómenos tal y como se presentan en su entorno natural, con el objetivo de analizarlos en detalle, en lugar de realizar intervenciones o manipulaciones controladas, el investigador se centra en la recopilación de datos a través de la observación cuidadosa y sistemática de los eventos o comportamientos en su contexto natural, esto permite capturar la realidad tal y como se manifiesta, sin alteraciones o influencias artificiales. Una vez recopilados los datos, se procede a su análisis y examen detallado, se utilizan herramientas y técnicas específicas para buscar patrones, identificar relaciones y extraer conclusiones significativas a

partir de la información obtenida, esto puede incluir la aplicación de métodos cualitativos, como el análisis de contenido o el análisis temático, así como también enfoques cuantitativos para analizar y cuantificar los datos recopilados

3.2. Variables y operacionalización

Para este estudio se tuvo como variable independiente: Sistema de alerta temprana, la cual es una variable cualitativa a la cual se le asignaran categorías numéricas a cada nivel para realizar un análisis cualitativo.

Como variable dependiente Modelo de aprendizaje automático, la cual es una variable cualitativa a la cual se le asignaran categorías numéricas a cada nivel para realizar un análisis cualitativo.

Definición conceptual:

Para la variable sistema de alerta temprana se tuvo como definición conceptual que son una colección de herramientas encargadas de predecir la probabilidad de una amenaza. La inteligencia artificial es de gran ayuda para la gestión de los recursos hidráulicos mediante el procesamiento de imágenes (Cárdenas S., et al., 2022).

Para la variable modelo de aprendizaje automático se tuvo como definición conceptual que usan algoritmos de aprendizaje automático para poder analizar datos históricos y en tiempo real y así poder identificar patrones y anomalías (Yousafzai et all, 2023).

Definición operacional:

Para la variable sistema de alerta temprana se tuvo como definición operacional:

- Recolectar datos anuales sobre el número de personas afectadas por inundaciones

$$\text{Número de Personas Afectadas} = \sum_{i=1}^n P_i$$

Donde:

- n es el número total de eventos o años considerados.
 - P_i es el número de personas afectadas en el evento o año i .
-
- Comparación de las predicciones con el Comportamiento Real. obteniendo valores estadísticos como:

- **Error Cuadrático Medio (MSE):**

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

- **Raíz de Error Cuadrático Medio (RMSE):**

$$\text{RMSE} = \sqrt{\text{MSE}}$$

- **Error Absoluto Medio (MAE)**

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- **Error Porcentual Absoluto Medio (MAPE):**

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right) \times 100\%$$

- **Coefficiente de Determinación (R^2):**

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$$

Donde:

- n es el número de observaciones
- y_i son los valores reales
- \hat{y}_i son los valores predichos.
- \bar{y}_i es la media de los valores reales.

- R^2 indica la proporción de la variabilidad en los datos que es explicada por el modelo.

Para la variable modelo de aprendizaje automático se tuvo como definición operacional:

- realizar análisis de series temporales del caudal del río a través de la prueba de Dickey-Fuller.

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \delta_1 \Delta y_{t-1} + \delta_2 \Delta y_{t-2} + \dots + \delta_{p-1} \Delta y_{t-(p-1)} + \epsilon_t$$

Donde:

- Δ es el operador de diferencia, que calcula la diferencia entre los valores sucesivos de la serie temporal.
- y_t es la serie temporal.
- t es una tendencia temporal opcional.
- α es una constante.
- β es el coeficiente asociado con la tendencia temporal.
- γ es el coeficiente que mide la dependencia de la serie en el valor rezagado.
- $\delta_1, \delta_2, \dots, \delta_{p-1}$ son coeficientes asociados con las diferencias rezagadas de la serie.
- Determinar los patrones y comportamientos de inundaciones a través de un modelo inteligente.

Indicadores:

Los indicadores para esta investigación fueron:

- Número de personas afectadas por inundaciones.
- Capacidad de detención de señales físicas de las amenazas
- Prueba de Dickey-Fuller.
- Nivel de precisión en la predicción

- **Escala de medición:**

La escala de medición seleccionada para evaluar los indicadores clave varía según la naturaleza de la información recopilada. En el caso del indicador "Número de personas afectadas por inundaciones", se empleó una escala de razón, permitiendo una medición cuantitativa precisa que puede involucrar comparaciones.

Por otro lado, para el indicador "Prueba de Dickey-Fuller", se utilizó una escala nominal, ya que esta prueba clasifica los datos en categorías sin establecer un orden específico, centrándose en la identificación de propiedades como la estacionariedad.

En cuanto a los demás indicadores, se optó por una escala ordinal. Esta elección se basa en la naturaleza cualitativa de los datos y la capacidad de interpretar su magnitud de manera relativa.

3.3. Población, muestra y muestreo

Población

La población se define como el "conjunto total de casos que cumplen con ciertas especificaciones establecidas. Es fundamental que las poblaciones estén claramente definidas en relación a sus características específicas, como el contenido, el lugar y el tiempo en el que se encuentran" Méndez, S (2020).

Para llevar a cabo la presente investigación, se recopilaron datos históricos sobre inundaciones, niveles de agua, caudales, precipitaciones, temperatura y humedad, abarcando el periodo desde 2017 hasta la fecha actual. La elección de este intervalo se justifica por la necesidad de obtener una perspectiva integral y actualizada de los eventos en Catacaos, Piura, con datos disponibles a partir de 2017. Se destaca que el año 2017 incluye el evento de mayor magnitud de la última década. Además, se consideran datos relevantes sobre el impacto en la población, como personas afectadas, damnificadas, fallecidas, así como el número de viviendas destruidas y afectadas durante los últimos 10 años. Al enfocarse en esta década, se busca proporcionar una visión precisa de la situación actual y reciente. La principal

fuentes de estos datos es el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI).

3.4. Técnicas e instrumentos de recolección de datos

Técnicas

Dentro del contexto de esta investigación, se implementó el análisis documental como técnicas fundamentales para la recolección de datos.

Según Machuca, F (2022), menciona que el análisis documental se basa en llevar a cabo una exhaustiva investigación y recopilación de información a través de la revisión de diversas fuentes documentales relevantes para el tema de estudio, esto puede incluir libros, artículos científicos, informes, registros históricos u otros documentos que contengan datos valiosos y pertinentes. La técnica de análisis documental es altamente efectiva para obtener información sustancial y precisa, ya que permite acceder a conocimientos previos, investigaciones anteriores y datos recopilados por otras personas o instituciones. Al examinar y evaluar críticamente estos documentos, es posible obtener una perspectiva más completa y profunda del fenómeno que se está investigando.

Mediante el análisis documental, se logró obtener una perspectiva más completa y equilibrada del fenómeno de investigación. La información recopilada a través de la revisión de documentos y la observación directa puede complementarse y validar mutuamente, aportando así a la rigurosidad y fiabilidad de los hallazgos obtenidos.

Por otro lado, la observación se utilizó como una técnica complementaria y valiosa para la recolección de datos, esta técnica se basa en la capacidad inherente del ser humano para analizar su entorno y el comportamiento de otras personas, mediante la observación directa, el investigador puede recopilar información de primera mano sobre los eventos, acciones y relaciones que se están estudiando. La observación puede realizarse de diferentes maneras, ya sea de forma participante, donde el investigador se integra en el entorno y participa activamente en las actividades del grupo estudiado, o de forma no participante, donde el investigador observa desde

afuera sin interferir en el contexto observado, ambos enfoques proporcionan valiosos datos cualitativos que pueden enriquecer el análisis y la interpretación de los resultados, Machuca, F (2022).

Al combinar el análisis documental y la observación, se pudo obtener una perspectiva más completa y equilibrada del fenómeno de investigación. La información recopilada a través de la revisión de documentos y la observación directa puede complementarse y validar mutuamente, lo que contribuye a la rigurosidad y fiabilidad de los hallazgos obtenidos.

Instrumentos

Como instrumento de recolección de datos para esta investigación se empleó la ficha de registro de datos.

Según Ramos (2019), menciona que la ficha de registro de datos se presenta como una herramienta de medición apropiada y efectiva, en la cual se anotan los datos observables que realmente representan los conceptos o variables que el investigador tiene en mente, este instrumento de recolección de datos descriptivos y cuantitativos resulta fundamental para capturar de manera precisa y sistemática la información relevante para la investigación.

Mediante el uso de la ficha de registro de datos, se logra una recopilación ordenada y estructurada de los datos observados, permitiendo su posterior análisis e interpretación de forma más efectiva, esta herramienta puede adaptarse a las necesidades específicas de la investigación, asegurando que los datos recopilados sean consistentes, confiables y pertinentes para los objetivos planteados, Gómez (2019).

Al utilizar la ficha de registro, el investigador puede registrar y documentar de manera sistemática los datos e información recopilados durante el proceso de recopilación de datos, esto incluye detalles relevantes, como eventos específicos, comportamientos, interacciones, características físicas o cualquier otro aspecto relevante para el objeto de estudio.

Procedimientos

En esta investigación, se utilizó la técnica de análisis documental, el modo de recolección de datos se dio a través de la recopilación de información relevante de diverso tipo de datos acerca de informes históricos de inundaciones, informes meteorológicos sobre inundaciones en el área de estudio e informes de infraestructura, información que ayudará a generar un análisis.

Para hacer posible esta recolección de datos se utilizó como instrumento la ficha de registro, la cual permitió recopilar y organizar la información obtenida de los documentos revisados, en esta ficha se registró la fecha del incidente, las principales características de la inundación como niveles de agua, caudales, precipitaciones, temperatura y humedad. Además, para el impacto en la población, se registran datos incluyendo personas afectadas, damnificadas, fallecidas, así como el número de viviendas destruidas y afectadas

Esta investigación al ser no experimental, no se manipularán variables, en cuanto al control de estas, en la selección de información, se tendrá en cuenta que los documentos relacionados sean relevantes y se ajusten a los objetivos.

para el procesamiento de los datos obtenidos se aplicaron técnicas estadísticas, como la Prueba de Dickey-Fuller, para evaluar la estacionariedad de las series temporales. Se utilizaron métricas como MAE, MSE, RMSE, MAPE y r^2 para evaluar el rendimiento de modelos inteligentes y de aprendizaje automático, estos se obtendrán haciendo uso de Python, específicamente con la librería sklearn.metrics, la cual genera métricas de manera precisa. estos datos se organizaron en tablas utilizando la herramienta Excel, en archivos .csv los cuales fueron procesados por el modelo inteligente. Para la presentación de resultados se utilizaron las tablas y gráficos estadísticos generados por el modelo inteligente como la estacionalidad, autocorrelación, residuos y densidad de residuos. En razón a esto se realizó la interpretación de los resultados relacionados a nuestras dimensiones.

3.5. Método de análisis de datos

Los datos recopilados mediante los instrumentos previamente mencionados se sometieron a un proceso de análisis utilizando el modelo inteligente desarrollado. Los resultados derivados de este análisis se organizaron en tablas utilizando la plataforma Excel. Estos datos serán fundamentales para calcular diversas métricas, tales como MAE, MSE, RMSE, MAPE y r^2 . Este cálculo se llevó a cabo utilizando Python, específicamente con la librería `sklearn.metrics`, la cual está diseñada para obtener métricas estadísticas de manera eficiente.

Según Sánchez, A (2020), menciona que el proceso de tabulación implica organizar los datos numéricos en categorías o intervalos, y luego contar la frecuencia con la que cada valor o intervalo se presenta. Estas frecuencias pueden expresarse como números absolutos o como porcentajes en relación con el total de casos. De esta manera, se obtiene una representación visual clara de cómo se distribuyen los datos y qué valores son más comunes o menos comunes en la muestra, Sáiz, M (2019).

3.6. Aspectos éticos

De acuerdo al código de ética del colegio de ingenieros del Perú (CIP), el presente trabajo de investigación se ha nutrido de una amplia gama de fuentes científicas confiables y relevantes, se ha realizado una exhaustiva revisión de artículos científicos, repositorios académicos y libros en línea que abordan el tema específico del proyecto. La utilización de estas fuentes diversificadas ha permitido obtener una visión completa y actualizada del campo de estudio, así como respaldar de manera sólida los argumentos y conclusiones presentados en el trabajo.

Es importante destacar que todas las fuentes consultadas han sido debidamente citadas y referenciadas de acuerdo con las normas bibliográficas establecidas, se ha prestado especial atención a reconocer el trabajo y las investigaciones publicadas de los autores, respetando la propiedad intelectual y dando crédito a sus contribuciones al campo de estudio, cada cita y

referencia bibliográfica ha sido cuidadosamente incluida en el trabajo, asegurando la transparencia y la integridad académica.

La inclusión de referencias bibliográficas no solo fortalece la fundamentación teórica del trabajo, sino que también permite a los lectores profundizar en los temas tratados y seguir el hilo conductor de las ideas presentadas, las referencias bibliográficas proporcionan una vía para que los lectores puedan acceder a las fuentes originales y consultar los estudios citados para obtener una comprensión más completa y detallada del tema.

La selección de fuentes científicas relevantes y confiables es esencial para garantizar la validez y la calidad del trabajo de investigación, se ha realizado una cuidadosa evaluación de la credibilidad y la autoridad de las fuentes utilizadas, asegurándose de que estén respaldadas por instituciones académicas reconocidas y que sean pertinentes para el tema en cuestión, esto ha contribuido a fortalecer la base teórica del trabajo y a generar confianza en los resultados y conclusiones presentados.

Los instrumentos de recolección de datos fueron validados por expertos antes de su aplicación.

Se siguió la investigación teniendo en cuenta los lineamientos de la universidad César Vallejo, así como los reglamentos de esta. También se garantiza que ningún documento utilizado en esta investigación será alterado de ninguna forma.

IV. RESULTADOS Y DISCUSIÓN

RESULTADOS

Objetivo: Identificar el número de personas afectadas por las inundaciones cada año en Catacaos - Piura; 2023.

La investigación se basa en la evaluación de un sistema de alerta temprana para inundaciones en la localidad de Catacaos, ubicada en la región de Piura.

Como primer indicador tenemos el número de personas afectadas por inundaciones. El análisis se centra en un periodo de 10 años, abarca tres provincias clave en el departamento de Piura: Paita, Sullana, y Piura. Los datos fueron extraídos de la fuente de datos de Senamhi, la aplicación de fichas de registro a Senamhi garantiza la fiabilidad de los datos recopilados.

Tabla 01: Cantidad de afectados por inundaciones.

Fecha	Provincia	Distrito	Afectados	Damnificados	Fallecidos	Viviendas Destruídas	Viviendas Afectadas
18/03/2015	Piura	Las lomas	0	0	0	0	490
19/03/2015	Paita	Paita	19	63	0	0	4
19/03/2015	Paita	Amotape	50	8	0	0	10
23/03/2015	Paita	Arenal	0	0	0	0	0
20/03/2015	Paita	Colán	1800	250	0	2	360
22/03/2015	Paita	Tamarindo	100	0	0	0	20
22/03/2015	Paita	Vichayal	1800	150	0	0	360
25/02/2015	Sullana	Lancones	0	0	0	0	0
27/04/2015	Sullana	Lancones	45	0	0	0	9
22/02/2016	Piura	Veintiseis de octubre	6	0	0	1	0
22/02/2016	Piura	Veintiseis de octubre	3	0	0	1	0
22/02/2016	Piura	Veintiseis de octubre	1	0	0	1	0
03/03/2016	Piura	Veintiseis de octubre	90	214	0	66	49
27/03/2017	Piura	Piura	3100	0	0	0	560

27/03/2017	Piura	Castilla	4500	12200	0	180	900
27/03/2017	Piura	Castilla	0	0	0	0	0
27/03/2017	Piura	Castilla	0	0	0	0	0
27/03/2017	Piura	Catacaos	40043	27851	8	6585	8009
27/03/2017	Piura	Cura mori	0	0	0	0	0
28/01/2017	Piura	Veintiseis de octubre	2550	208	0	33	634
16/03/2017	Piura	Veintiseis de octubre	2562	1355	0	125	642
19/03/2017	Piura	Veintiseis de octubre	6649	1461	0	63	1626
06/02/2019	Piura	Castilla	5	5	1	1	1
09/02/2019	Sullana	Lancones	85	13	0	4	26
24/04/2023	Sullana	Lancones	590	0	0	0	0
Total			63998	43778	9	7062	13700

Fuente: Ficha de registro, aplicada en el proceso de recolección de datos a Senamhi, respecto al número de personas afectadas en los años 2020, 2021 y 2022, por causa de inundación

En los eventos de inundación de 2013 - 2023, se encontró un total de afectados de 63,998 personas, total de damnificados de 43,778 personas, total de Fallecidos de 9 personas, total de viviendas destruidas de 7,062 y total de viviendas afectadas de 13,700.

Afectados en el año 2013 - 2014

Número de personas afectadas por causa de inundación en Piura, en los años 2013 – 2014

Tabla 02: Personas afectadas por causa de inundación en Piura, en los años 2013 – 2014.

<i>Año</i>	2013 - 2014
<i>Número de personas afectadas</i>	0

Fuente: Ficha de registro, aplicada en el proceso de recolección de datos a Senamhi, respecto al número de personas afectadas en los años 2013 - 2014, por causa de inundación

El número de personas afectadas fue 0, ya que no se registraron eventos por inundaciones en los años 2013 – 2014.

Afectados en el año 2015

Número de personas afectadas por causa de inundación en Catacaos – Piura, en el año 2015

Tabla 03: Personas afectadas por causa de inundación en Piura, en el año 2015.

<i>Año</i>	2015
<i>Número de personas afectadas</i>	3814

Fuente: Ficha de registro, aplicada en el proceso de recolección de datos a Senamhi, respecto al número de personas afectadas en el año 2015, por causa de inundación

El número de personas afectadas fue 3,814. Se registró un impacto significativo en la población debido a inundaciones en este año.

Afectados en el año 2016

Número de personas afectadas por causa de inundación en Catacaos – Piura, en el año 2016

Tabla 04: Personas afectadas por causa de inundación en Piura, en el año 2016.

<i>Año</i>	2016
<i>Número de personas afectadas</i>	100

Fuente: Ficha de registro, aplicada en el proceso de recolección de datos a Senamhi, respecto al número de personas afectadas en el año 2016, por causa de inundación.

El número de personas afectadas fue 100. Se reportaron personas afectadas por inundaciones en este año, pero fue un año con impacto bajo a comparación del anterior.

Afectados en el año 2017

Número de personas afectadas por causa de inundación en Catacaos – Piura, en el año 2017

Tabla 05: Personas afectadas por causa de inundación en Piura, en el año 2017

<i>Año</i>	2017
<i>Número de personas afectadas</i>	59404

Fuente: Ficha de registro, aplicada en el proceso de recolección de datos a Senamhi, respecto al número de personas afectadas en el año 2017, por causa de inundación.

El número de personas afectadas fue 59404. Se observó un significativo impacto en la población debido a inundaciones, destacando como el año con mayor número de afectados en el periodo analizado.

Afectados en el año 2018

Número de personas afectadas por causa de inundación en Catacaos – Piura, en el año 2018

Tabla 06: Personas afectadas por causa de inundación en Piura, en el año 2018

<i>Año</i>	2018
<i>Número de personas afectadas</i>	0

Fuente: Ficha de registro, aplicada en el proceso de recolección de datos a Senamhi, respecto al número de personas afectadas en el año 2018, por causa de inundación

El número de personas afectadas fue 0. No se registraron personas afectadas por inundaciones en este año, marcando un cambio drástico en comparación con el año anterior.

Afectados en el año 2019

Número de personas afectadas por causa de inundación en Catacaos – Piura, en el año 2019

Tabla 07: Personas afectadas por causa de inundación en Piura, en el año 2019

<i>Año</i>	2019
<i>Número de personas afectadas</i>	90

Fuente: Ficha de registro, aplicada en el proceso de recolección de datos a Senamhi, respecto al número de personas afectadas en el año 2019, por causa de inundación

El número de personas afectadas fue 90, Aunque inferior a 2017, se evidencia que las inundaciones continuaron afectando a la población en 2019.

Afectados en el año 2020 - 2022

Número de personas afectadas por causa de inundación en Catacaos – Piura, en los años 2020, 2021 y 2022

Tabla 08: Personas afectadas por causa de inundación en Piura, en los años 2020 - 2022

<i>Año</i>	2020- 2022
<i>Número de personas afectadas</i>	0

Fuente: Ficha de registro, aplicada en el proceso de recolección de datos a Senamhi, respecto al número de personas afectadas en los años 2020, 2021 y 2022, por causa de inundación

No se registraron personas afectadas por inundaciones en estos años, indicando una disminución significativa del impacto en comparación con el pasado.

Afectados en el año 2023

Número de personas afectadas por causa de inundación en Catacaos – Piura, en el año 2023

Tabla 09: Personas afectadas por causa de inundación en Piura, en el año 2023

<i>Año</i>	2023
<i>Número de personas afectadas</i>	590

Fuente: Ficha de registro, aplicada en el proceso de recolección de datos a Senamhi, respecto al número de personas afectadas en el año 2023, por causa de inundación

El número de personas afectadas fue 590. A pesar de la disminución respecto a 2017, se observa un aumento en comparación con los años sin afectaciones, resaltando la importancia de continuar monitoreando.

Objetivo: Identificar la capacidad del sistema de alerta temprana de detectar señales físicas de amenazas de inundaciones- Catacaos – Piura; 2023.

La capacidad de detención de señales físicas de las amenazas se realizará mediante la comparación con el comportamiento real, para ello se entrenó al modelo inteligente con datos desde 01/01/2017 hasta 28/02/2022, en la cual se obtuvo la predicción del periodo 01/03/2022 hasta 30/04/2022.

Se muestran los primeros 10 datos hidrometeorológicos utilizados para entrenar el modelo inteligente.

Tabla 10: datos Hidrometeorológicos

Fecha	Temperatura (°C)		Humedad relativa (%)	Precipitación (mm/día)	Caudal
	MAX	MIN		TOTAL	
1/01/2017	31.4	20.9	73.4	0	0
2/01/2017	35.2	20.6	73.6	0	0
3/01/2017	36	20.3	73.5	0	0
4/01/2017	35.6	20.8	70.9	0	0
5/01/2017	35.4	22.8	67.3	0	0
6/01/2017	34	22.4	67.1	0	0
7/01/2017	36.4	20.2	68.2	0	0
8/01/2017	35	23.5	69.8	0	0
9/01/2017	33.8	23.8	65.7	0	0
10/01/2017	37	22.2	65.2	0	0

Fuente: elaboración propia

Para poder utilizar los datos para el entrenamiento del modelo inteligente, es necesaria la normalización de datos, para los datos del caudal del río se utilizó la normalización Min-Max:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Donde:

- X_{norm} es el valor normalizado.
- X es el valor original de la característica.
- X_{min} es el valor mínimo de esa característica en el conjunto de datos.
- X_{max} es el valor máximo de esa característica en el conjunto de datos.

Para la normalización de todos los datos, al ser dependientes unos de otros, se utilizó la normalización z-score.

La fórmula para normalizar utilizando el z-score es la siguiente:

$$z=(x-\mu)/\sigma$$

donde:

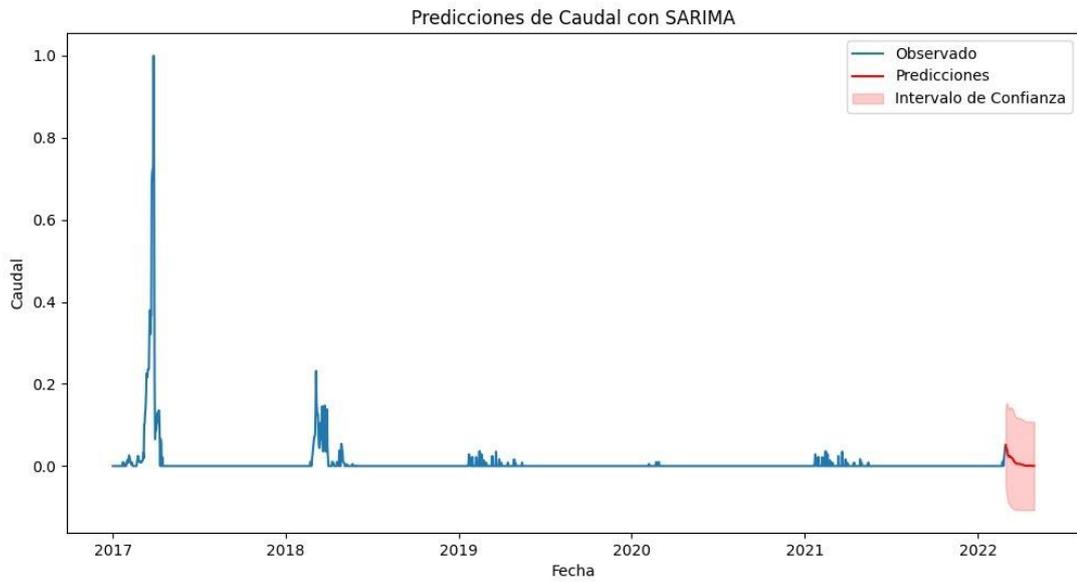
- z es el valor normalizado.
- x es el valor original de la variable.
- μ es la media de la variable.
- σ es la desviación estándar de la variable.

Tabla 11: datos Hidrometeorológicos normalizados

Fecha	Temperatura (°C)		Humedad relativa (%)	Precipitación (mm/día)	Caudal
	MAX	MIN		TOTAL	
1/01/2017	0.4488237	-1.10394364	1.2731788	0	0
2/01/2017	1.0107776	-1.14830842	1.33797161	0	0
3/01/2017	1.12908368	-1.1926732	1.3055752	0	0
4/01/2017	1.06993064	-1.1187319	0.46326862	0	0
5/01/2017	1.04035412	-0.82296669	-0.70300203	0	0
6/01/2017	0.83331847	-0.88211973	-0.76779485	0	0
7/01/2017	1.18823672	-1.20746146	-0.41143437	0	0
8/01/2017	0.98120107	-0.71944887	0.10690814	0	0
9/01/2017	0.80374195	-0.67508409	-1.22134454	0	0
10/01/2017	1.27696628	0.91169625	-1.38332658	0	0

Fuente: elaboración propia

Figura 01: Predicción del caudal con SARIMAX



Fuente: Modelo inteligente.

En el gráfico, se presenta la serie temporal utilizada para entrenar el modelo mediante una línea azul, seguida de la predicción representada por una línea roja, la cual está rodeada por una sombra roja que indica el intervalo de confianza. En este contexto, se considera únicamente el intervalo de confianza superior, dado que el caudal no puede tener valores negativos.

Tabla 12: Predicción del caudal con SARIMAX.

Fecha	Predicciones de caudal	Intervalo de confianza superior
1/03/2022	0.051503	0.087023
2/03/2022	0.046876	0.103266
3/03/2022	0.041321	0.109978
4/03/2022	0.039549	0.114324
5/03/2022	0.031611	0.114267
6/03/2022	0.026572	0.114656
7/03/2022	0.024483	0.11512
8/03/2022	0.022916	0.115085
9/03/2022	0.024514	0.118365
10/03/2022	0.024061	0.119694
11/03/2022	0.021719	0.118929
12/03/2022	0.021678	0.120195
13/03/2022	0.021204	0.121262
14/03/2022	0.019896	0.12125
15/03/2022	0.018947	0.12132
16/03/2022	0.017596	0.120999
17/03/2022	0.015646	0.120092
18/03/2022	0.013716	0.118869
19/03/2022	0.01172	0.117327
20/03/2022	0.010096	0.116062

Fuente: modelo inteligente

En la tabla 12 se muestran las 20 primeras predicciones, con los datos del caudal y el intervalo de confianza superior, estos intervalos de confianza proporcionan una medida de la incertidumbre asociada a cada predicción, mostrando el rango dentro del cual se espera que caiga el caudal con un nivel de confianza determinado.

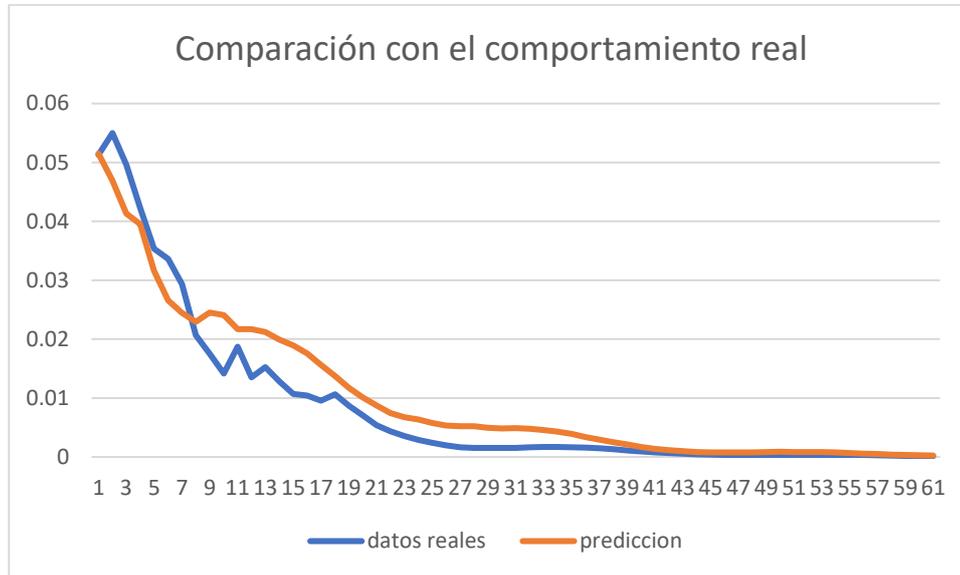
En la tabla 13, se muestran los datos reales de caudal junto con las predicciones del modelo, permitiendo una detallada comparación entre la realidad y las proyecciones del sistema, Esta recopilación de información sirve como una herramienta crucial para evaluar la precisión y el rendimiento del modelo en la anticipación del comportamiento del caudal, contribuyendo así a una mejor comprensión y gestión eficiente de los recursos hídricos.

Tabla 13: Comparación con el comportamiento real.

DATOS REALES	PREDICCIÓN		
0.051308	0.051503	0.001544	0.004871
0.054989	0.046876	0.001631	0.004782
0.049635	0.041321	0.001699	0.004545
0.042315	0.039549	0.001686	0.004283
0.035345	0.031611	0.001646	0.003891
0.033623	0.026572	0.001577	0.0034
0.029319	0.024483	0.001482	0.002921
0.020676	0.022916	0.0013	0.002528
0.017496	0.024514	0.001089	0.002131
0.014157	0.024061	0.000935	0.001706
0.018694	0.021719	0.000781	0.001392
0.01353	0.021678	0.00065	0.001164
0.015224	0.021204	0.000562	0.000966
0.0128	0.019896	0.000475	0.000839
0.010713	0.018947	0.000404	0.000778
0.010439	0.017596	0.00035	0.000768
0.009528	0.015646	0.000324	0.000768
0.010617	0.013716	0.000319	0.000784
0.008683	0.01172	0.000319	0.000828
0.007042	0.010096	0.000326	0.000861
0.0054	0.008742	0.000343	0.000855
0.004375	0.007417	0.000358	0.000837
0.003528	0.006754	0.000355	0.000807
0.002863	0.006376	0.000347	0.000761
0.002413	0.005781	0.000334	0.000668
0.001965	0.005351	0.000316	0.000559
0.001637	0.00523	0.000278	0.000481
0.00153	0.005203	0.000233	0.000403
0.00151	0.004933	0.0002	0.000337
0.00151	0.004813	0.000167	0.000292
		0.000139	0.000247

Fuente: elaboración propia

Figura 02: Comparación con el comportamiento real



Fuente: Elaboración propia

En la Figura 01, se observa que ambas líneas están muy próximas y siguen la misma tendencia, lo cual destaca la precisión en las predicciones y demuestra una notable capacidad para explicar la variabilidad en los datos.

Tabla 14: métricas de evaluación.

Error Absoluto Medio (MAE):	0.0028077377049180335
Error Cuadrático Medio (MSE):	1.4690630819672135e-05
Raíz del Error Cuadrático Medio (RMSE):	0.003832835871736766
Error Porcentual Absoluto Medio (MAPE):	95.21197421740762
Coefficiente de Determinación (r2):	0.920900148570462

Fuente: elaboración propia

Se examinaron los indicadores de rendimiento del modelo, resultando en un Error Absoluto Medio (MAE) de 0.0028077377049180335, lo que significa que, en promedio, las predicciones revelan una diferencia incondicional de 0.0028077377049180335 unidades en correlación con los datos reales, el

Error Cuadrático Medio (MSE) fue de $1.4690630819672135e-05$, mostrando el promedio de los cuadrados de las diferencias entre las predicciones y los datos reales, la Raíz del Error Cuadrático Medio (RMSE), procedente del MSE, fue de 0.003832835871736766 , facilitando una medida de la capacidad promedio de los errores en el mismo nivel que los datos reales, el Error Porcentual Absoluto Medio (MAPE) se situó en un 95.2%, revelando que, en promedio, las predicciones pueden desviarse en alrededor del 95% en comparación con los datos reales. Además, el modelo exhibió un coeficiente de determinación (r^2) de 0.97, indicando que declara el 97% de la variabilidad vista en los datos de inundaciones. Estas métricas recalcan el potencial del modelo para generar predicciones precisas y así mismo explicar la variabilidad en los sucesos de inundación, aunque el MAPE indica que las predicciones pueden tener desviaciones sustanciales.

Objetivo: Identificar la estacionariedad en los que se producen las inundaciones en Catacaos – Piura; 2023.

La evaluación de la estacionalidad en los patrones del caudal del río en Catacaos - Piura es fundamental para comprender la dinámica de los eventos de inundación. En este contexto, se utiliza como indicador la "Prueba de Dickey-Fuller sobre los patrones estacionales del caudal del río". El análisis se enfoca en datos recopilados desde 2017 hasta 2022, considerando fechas y caudales del río como variables clave. Estos datos se obtuvieron de la fuente de Senamhi, consolidando una base sólida para la evaluación de la estacionalidad en la región.

Análisis estadístico de la prueba de Dickey-Fuller para la estacionariedad, para el año 2017

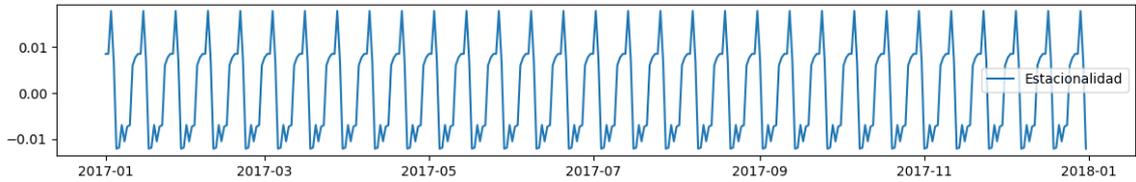
Tabla 15: prueba de Dickey-Fuller para el año 2017.

Año	ADF	p-value	Estacionariedad
2017	-3.2	0.015	Estacionaria

Fuente: Modelo inteligente.

Estos resultados indican que, en el año 2017, el valor del estadístico Dickey-Fuller fue -3.2 con un valor p de 0.015, lo que confirma la estacionariedad de la serie temporal.

Figura 03: prueba de Dickey-Fuller para el año 2017.



Fuente: Modelo inteligente.

Análisis estadístico de la prueba de Dickey-Fuller para la estacionariedad, para el año 2018

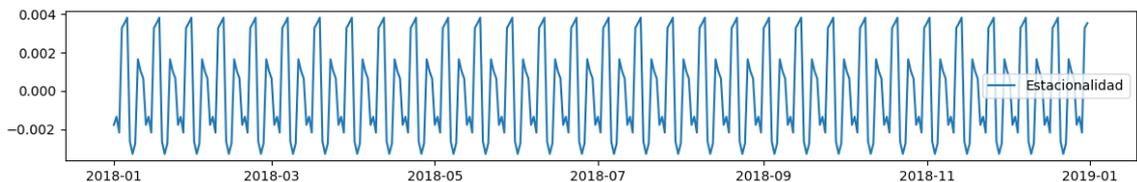
Tabla 16: prueba de Dickey-Fuller para el año 2018.

Año	ADF	p-value	Estacionariedad
2018	-2.1681454443528394	0.21800923614780832	No estacionaria

Fuente: Modelo inteligente.

En el año 2018, el valor del estadístico fue -2.1681454443528394 con un valor p de 0.21800923614780832, La no estacionariedad sugiere la ausencia de patrones temporales significativos, señalando una variabilidad en los niveles del caudal.

Figura 04: prueba de Dickey-Fuller para el año 2018.



Fuente: Modelo inteligente.

Análisis estadístico de la prueba de Dickey-Fuller para la estacionariedad, para el año 2019

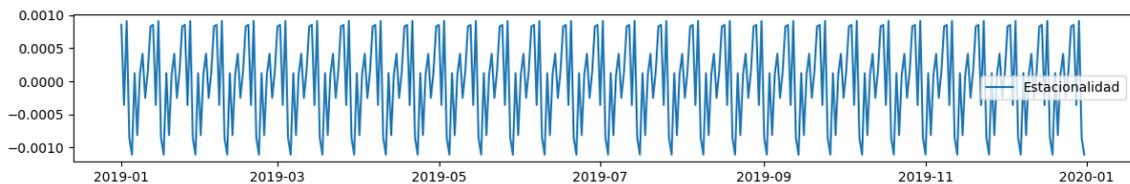
Tabla 17: prueba de Dickey-Fuller para el año 2019.

Año	ADF	p-value	Estacionariedad
2019	-2.638001478506986	0.08539469121372595	No estacionaria

Fuente: Modelo inteligente.

En el año 2019, el valor del estadístico fue -2.638001478506986 con un valor p de 0.08539469121372595, lo que sugiere que la serie no es estacionaria en este año.

Figura 05: prueba de Dickey-Fuller para el año 2019.



Fuente: Modelo inteligente.

Análisis estadístico de la prueba de Dickey-Fuller para la estacionariedad, para el año 2020

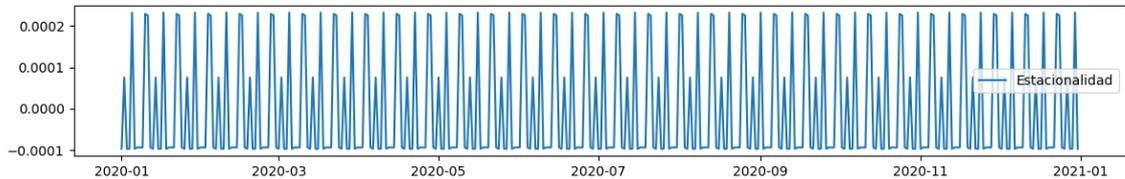
Tabla 18: prueba de Dickey-Fuller para el año 2020.

Año	ADF	p-value	Estacionariedad
2020	-3.4679237633253366	0.008850121505253904	Estacionaria

Fuente: Modelo inteligente.

En el año 2020, el valor del estadístico fue -3.4679237633253366 con un valor p de 0.008850121505253904 , lo que sugiere que la serie es estacionaria en este año.

Figura 06: prueba de Dickey-Fuller para el año 2020.



Fuente: Modelo inteligente.

Análisis estadístico de la prueba de Dickey-Fuller para la estacionariedad, para serie temporal desde el 01/01/2017 al 02/28/2022

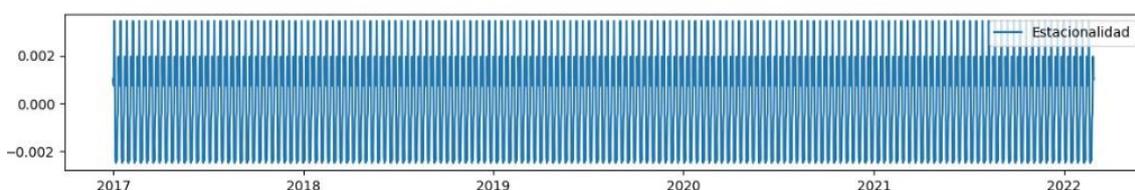
Tabla 19: prueba de Dickey-Fuller para la serie temporal desde el 01/01/2017 al 02/28/2022.

Año	ADF	p-value	Estacionariedad
2017-	-	6.013864973464078e-	Estacionaria
2022	7.44607812223471	11	

Fuente: Modelo inteligente.

Se examinó la estacionalidad de la serie temporal desde el 01/01/2017 al 02/28/2022, utilizando la estadística ADF, la cual generó un resultado de -7.44607812223471 , el valor p relacionado con esta prueba se determinó como $6.013864973464078e-11$, y los hallazgos obtenidos de la Prueba de Dickey-Fuller sugieren que la serie es estacionaria, lo que respalda la existencia de propiedades temporales consistentes en los datos que fueron objeto de análisis.

Figura 07: prueba de Dickey-Fuller para la serie temporal desde el 01/01/2017 al 02/28/2022.



Fuente: Modelo inteligente.

Objetivo: Analizar el uso de un de un modelo inteligente para comprender de manera precisa los patrones y comportamientos de inundaciones - Catacaos – Piura; 2023.

La evaluación del modelo inteligente se llevó a cabo mediante el uso del modelo SARIMAX en su estructura. En este contexto, se emplea como indicador el "Nivel de precisión en la predicción". El análisis se centra en datos recopilados desde 2017 hasta 2022, utilizados tanto para el entrenamiento del modelo inteligente como para la comparación de la predicción generada desde el 01/03/2022 hasta el 30/04/2022 con los datos reales.

Tabla 20: resultados de la configuración y estadísticas del modelo SARIMAX.

SARIMAX Results			
Dep. Variable:	caudal	No. Observations:	1885
Model:	SARIMAX(10, 0, 10)x(10, 0, 10, 12)	Log Likelihood	5.009.929
Date:	Wed, 25 oct 2023	AIC	- 9.937.859
Time:	17:38:38	BIC	- 9.710.650
Sample:	01/01/2017 - 02/28/2022	HQIC	- 9.854.182

Fuente: Modelo inteligente

Los resultados del análisis mediante el modelo SARIMAX revelan aspectos cruciales. La variable dependiente considerada es el caudal, y el modelo aplicado es SARIMAX (10, 0, 10) x (10, 0, 12), lo que implica la utilización de un modelo SARIMAX con parámetros específicos ($p = 10, d = 0, q = 10, P = 10, D = 0, Q = 10, S=12$), con la inclusión de variables exógenas identificadas por la letra X mayúscula. La muestra de datos abarca desde el 01 de enero de 2017 hasta el 28 de febrero de 2022, totalizando 1885 observaciones. El logaritmo de la probabilidad de que los datos observados se hayan generado por el modelo alcanza 5009.929. Además, se evalúan medidas de criterio informativo, donde el AIC muestra -9937.859, el BIC revela -9710.650, y el HQIC exhibe -9854.182, proporcionando así una evaluación integral de la complejidad y la bondad de ajuste del modelo.

Se presentan coeficientes para las variables AR (Auto-regresivas) y MA (Media móvil), así como los parámetros relacionados con la estacionalidad.

Tabla 21: resultados del análisis mediante el modelo SARIMAX.

Covariance Type:	opg					
	coef	std err	z	P> z	[0.025	0.975]
ar.L7	-0.2797	0.205	-1.365	0.172	-0.681	0.122
ar.L8	0.2438	0.163	1.494	0.135	-0.076	0.564
ar.L9	-0.3172	0.099	-3.189	0.001	-0.512	-0.122
ar.L10	0.2437	0.054	4.544	0	0.139	0.349
ma.L1	-0.0482	0.186	-0.259	0.795	-0.413	0.316
ma.L2	0.1006	0.136	0.741	0.459	-0.166	0.367
ma.L3	-0.3848	0.156	-2.473	0.013	-0.69	-0.08
ma.L4	0.0663	0.169	0.392	0.695	-0.265	0.398
ma.L5	-0.0021	0.161	-0.013	0.99	-0.318	0.314
ma.L6	-0.0689	0.116	-0.595	0.552	-0.296	0.158
ma.L7	0.1115	0.116	0.96	0.337	-0.116	0.339
ma.L8	-0.0473	0.119	-0.398	0.691	-0.28	0.185
ma.L9	0.4347	0.079	5.477	0	0.279	0.59
ma.L10	0.0857	0.077	1.106	0.269	-0.066	0.237
ar.S.L12	0.4969	1.571	0.316	0.752	-2.583	3.576
ar.S.L24	-0.2766	1.302	-0.212	0.832	-2.828	2.275
ar.S.L36	0.1438	4.278	0.034	0.973	-8.242	8.529
ar.S.L48	0.1043	12.914	0.008	0.994	-25.206	25.415

ar.S.L60	-0.099	8.041	-0.012	0.99	-15.859	15.661
ar.S.L72	0.0257	2.900	0.009	0.993	-5.659	5.710
ar.S.L84	0.0021	3.472	0.001	1.000	-6.804	6.808
ar.S.L96	0.0042	9.292	0	1.000	-18.208	18.216
ar.S.L108	-0.0123	10.199	-0.001	0.999	-20.003	19.978
ar.S.L120	0.0095	6.245	0.002	0.999	-12.231	12.250
ma.S.L12	-0.4938	1.571	-0.314	0.753	-3.574	2.586
ma.S.L24	0.3005	1.298	0.231	0.817	-2.244	2.845
ma.S.L36	-0.1593	4.312	-0.037	0.971	-8.611	8.292
ma.S.L48	-0.0966	12.899	-0.007	0.994	-25.378	25.184
ma.S.L60	0.0961	7.892	0.012	0.99	-15.372	15.564
ma.S.L72	-0.0253	2.679	-0.009	0.992	-5.276	5.226
ma.S.L84	-0.0121	3.480	-0.003	0.997	-6.834	6.809
ma.S.L96	0.0183	9.242	0.002	0.998	-18.095	18.132
ma.S.L108	0.001	10.192	9.52E-05	1.000	-19.975	19.977
ma.S.L120	-0.0035	6.331	-0.001	1.000	-12.412	12.405
sigma2	0.0003	2.78E-06	103.281	0	0	0

Fuente: Modelo inteligente

La tabla presenta una detallada desglose de los diversos componentes asociados a cada parámetro del modelo SARIMAX. Los identificadores "ar," "ma," y "S" corresponden a las partes autorregresivas, de medias móviles y estacionales, respectivamente, seguidos por números que indican su secuencia u orden temporal. Estos componentes incluyen el coeficiente, que representa la influencia del parámetro en la variable dependiente, donde valores positivos indican un aumento y negativos una disminución. El error estándar cuantifica la precisión en la estimación del coeficiente, y el valor z señala la significancia estadística del coeficiente. El valor p expresa la probabilidad de obtener un valor z igual o superior bajo la hipótesis nula de que el coeficiente es cero. Otros elementos, como el valor t, intervalo de confianza del 95%, y límites inferior y superior, complementan la comprensión detallada de la relación entre los parámetros y la variable dependiente. Estos resultados destacan por la significativa probabilidad asociada con los coeficientes y la calidad del ajuste del modelo.

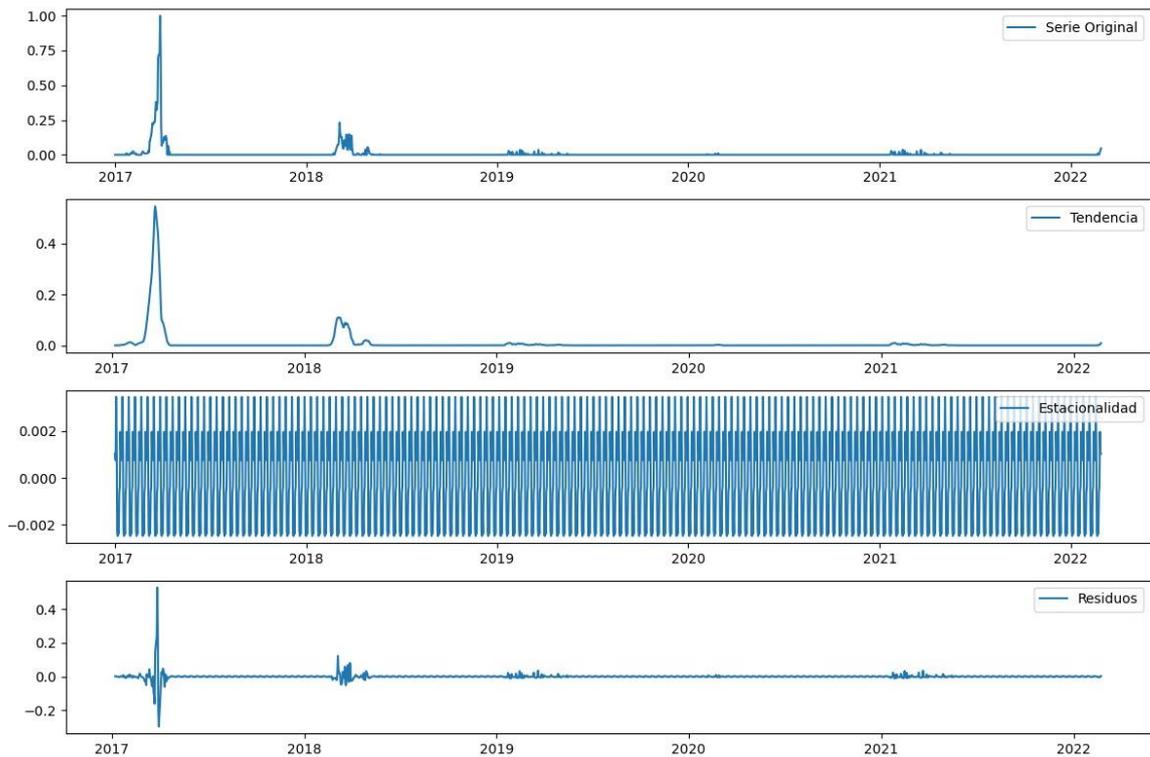
Tabla 22: pruebas y métricas destinadas a evaluar la calidad y ajuste del modelo.

Ljung-Box (L1) (Q):	0.04	Jarque-Bera (JB):	2987848.68
Prob(Q): 0.83	0.83	Prob(JB):	0
Heteroskedasticity (H):	0.05	Skew:	1.91
Prob(H) (two-sided):	0	Kurtosis:	198.01

Fuente: Modelo inteligente

La tabla muestra diversas pruebas y métricas destinadas a evaluar la calidad y ajuste del modelo. En la prueba Ljung-Box (Q), se presenta un valor de 0.04, con una probabilidad asociada (Prob(Q)) de 0.83, indicando la ausencia de autocorrelación en los residuos del modelo, respecto a la heterocedasticidad (H), se detecta un valor de 0.05, con una probabilidad bidireccional (Prob(H)) de 0.05, sugiriendo la presencia de heterocedasticidad, la prueba Jarque-Bera (JB) revela un valor notablemente elevado de 2987848.68, con la probabilidad asociada (Prob(JB)), indicando que la distribución de los residuos no sigue una distribución normal. Asimismo, se evidencia un sesgo (Skew) de 1.91 y una kurtosis (Kurtosis) de 198.01, señalando una asimetría positiva y una distribución con colas pesadas, respectivamente. Estos resultados brindan información esencial sobre la autocorrelación, heterocedasticidad y distribución de los residuos del modelo.

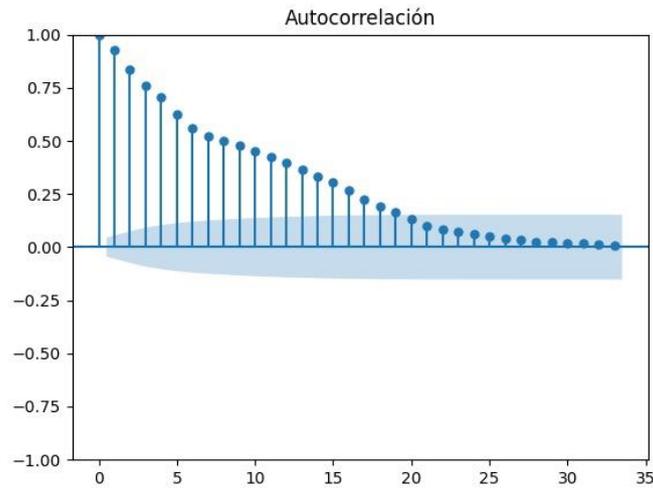
Figura 08: la serie temporal, tendencia, estacionalidad y residuos.



Fuente: Modelo inteligente

La gráfica del modelo de predicción SARIMAX muestra la serie temporal original, utilizada para entrenar el modelo. Se destaca un pico en 2017, indicando un evento significativo de inundación ese año, mientras que los picos en años posteriores son de menor magnitud. La tendencia general a lo largo del tiempo revela un leve aumento en los valores, señalando la presencia continua de inundaciones, con el pico más alto registrado en 2017. En cuanto a la estacionalidad, se observa que el caudal es más alto en ciertos meses cada año, indicando un flujo más fuerte durante esa estación. En relación con los residuos, oscilan entre -0.3 y 0.3, y la línea azul centrada alrededor de 0 sugiere una buena precisión del modelo. Sin embargo, la variación en los residuos indica que hay aspectos en los datos que el modelo no ha explicado completamente.

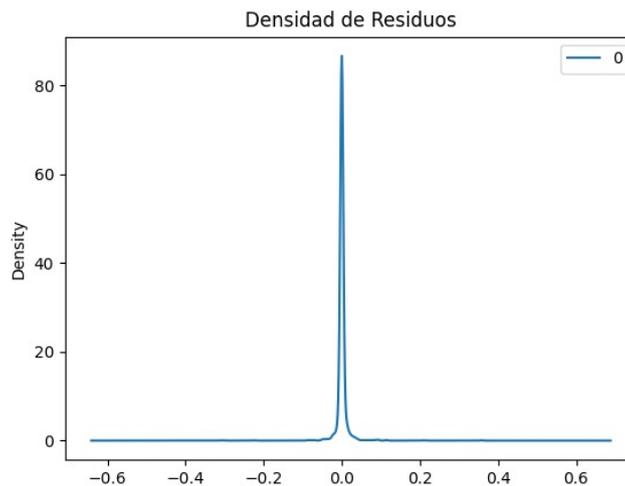
Figura 09: autocorrelación



Fuente: Modelo inteligente

El gráfico muestra la autocorrelación en función del retraso de tiempo, representando en el eje x el retraso y en el eje y el coeficiente de autocorrelación. La línea azul representa la autocorrelación, mientras que el área sombreada en gris indica el intervalo de confianza del 95%. La autocorrelación es más fuerte en un retraso de tiempo de 0 y disminuye a medida que aumenta el retraso, indicando una alta correlación en retrasos cortos y menor correlación en retrasos más largos.

Figura 10: Densidad residual



Fuente: Modelo inteligente

El ancho de la distribución indica la variabilidad de los residuos. La distribución es estrecha, los residuos tienden a variar poco alrededor de cero.

La evaluación del modelo inteligente, implementado para comprender con precisión los patrones y comportamientos de inundaciones mediante la comparación de la predicción generada (01/03/2022 al 30/04/2022) con los datos reales, arrojó los siguientes resultados:

Error Absoluto Medio (MAE): Con un valor de 0.0028077377049180335, el MAE indica una pequeña diferencia promedio entre las predicciones del modelo y los valores reales del caudal.

Error Cuadrático Medio (MSE): El MSE, con un valor de 1.4690630819672135e-05, refleja la precisión del modelo al cuantificar la media de los errores al cuadrado.

Raíz del Error Cuadrático Medio (RMSE): La RMSE, evaluada en 0.003832835871736766, proporciona una medida de la magnitud promedio de los errores en la misma escala que los datos originales.

Coefficiente de Determinación (r^2): Con un sólido r^2 de 0.920900148570462, el modelo explica el 92% de la variabilidad observada en los datos de inundaciones, indicando una capacidad significativa de predicción.

El nivel de precisión del modelo es notable, respaldado por bajos valores en MAE, MSE y RMSE, indicando que las predicciones del modelo SARIMAX están estrechamente alineadas con los valores reales. De esta manera, se puede concluir que el modelo inteligente demostró un alto nivel de precisión en la predicción de patrones.

DISCUSIÓN

La presente investigación tuvo como objetivo general proponer un sistema de alerta temprana para inundaciones basado en modelo de aprendizaje automático adaptado por inteligencia artificial – Catacaos – Piura; 2023.

Para el primer objetivo específico, identificar el número de personas afectadas por las inundaciones cada año en Catacaos - Piura; 2023, el cual tiene como dimensión, impacto de las inundaciones, la cual tiene como indicador “Número de personas afectadas por inundaciones”, se basó en el análisis detallado de los eventos de inundación en un período de 10 años. Datos obtenidos la fuente de datos de senamhi. Se utilizó el número de personas afectadas como un indicador clave para evaluar el impacto de estos eventos en la población. Los resultados proporcionan una visión completa de la variabilidad en la ocurrencia de inundaciones y su impacto en la comunidad.

En el año 2013-2014, no se registraron personas afectadas por inundaciones, indicando un período sin eventos significativos en ese año. Sin embargo, en 2015, se observó un cambio notable con 3,814 personas afectadas, señalando un impacto significativo en la población. Este evento fue seguido por otro año sin afectaciones en 2016, donde no se reportaron personas afectadas por inundaciones. El año 2017 destacó como el período con el mayor impacto, con 59404 personas afectadas. Este año fue particularmente significativo en comparación con otros años, resaltando la necesidad de un sistema de alerta temprana efectivo, para gestionar de mejor manera los riesgos. Esto concuerda con Granado et al. (2016), quienes sostienen que la población local más expuesta debe estar informada previamente sobre eventos catastróficos y riesgos para estar preparada y difundir información, siendo los Sistemas de Alerta Temprana (SAT) la opción más adecuada para lograrlo.

En 2019, se reportaron 224 personas afectadas, mostrando una disminución en comparación con 2017, pero indicando que las inundaciones continuaron afectando a la población. Los años 2020, 2021 y 2022 registraron nuevamente cero personas afectadas, sugiriendo una disminución

significativa del impacto en comparación con eventos anteriores. En el año 2023, se registraron 590 personas afectadas, indicando un aumento en comparación con los años sin afectaciones, pero una disminución con respecto a 2017. Estos resultados subrayan la importancia de continuar monitoreando.

En el periodo de 2013 a 2023, se destaca un total de 63,998 personas afectadas, implicando un impacto significativo en la vida de miles de habitantes. Además, 13,700 viviendas resultaron afectadas, comparándose con el estudio de Tello, C (2022), quien, en un periodo de 2003 a 2018, identificó la cantidad promedio anual de 19,771.94 viviendas afectadas por inundaciones en la región Omagua. Sus hallazgos también respaldan la correlación entre la cantidad de viviendas inundadas y personas afectadas por año, resaltando la importancia de abordar estas cuestiones de manera integral y considerar la planificación y la prevención a largo plazo.

En lo que concierne a la segunda dimensión, Alerta temprana, y con respecto al segundo objetivo específico de Identificar la capacidad del sistema de alerta temprana de detectar señales físicas de amenazas de inundaciones-Catacaos – Piura; 2023, se puede observar la data real del caudal junto a las predicciones del modelo inteligente, dicha recopilación de información sirve como una herramienta decisiva para evaluar la precisión y el rendimiento del modelo, en esta se examinaron los indicadores de rendimiento del modelo, resultando en un Error Absoluto Medio (MAE) de 0.0028077377049180335, el Error Cuadrático Medio (MSE) el cual fue de 1.4690630819672135e-05, la Raíz del Error Cuadrático Medio (RMSE), procedente del MSE, que fue de 0.003832835871736766, facilitando una medida de la capacidad promedio de los errores en el mismo nivel que los datos reales, por otro lado el Error Porcentual Absoluto Medio (MAPE) se situó en un 95.2%, revelando que, en promedio, las predicciones del modelo poseen un error del 95.2% en comparación con los datos reales, además, el modelo exhibió un coeficiente de determinación (r^2) de 0.92, indicando que declara el 92% de la variabilidad vista en los datos de inundaciones, y esto se puede comparar con los resultados de Villenas Quinapallo (2020), el cual menciona en su etapa de entrenamiento para su sexto modelo en el cual compara los valores del

caudal, en donde obtiene que Error Absoluto Medio es igual a 0.065 (MAE = 0.065), indicando que el modelo sobreestima el caudal con respecto a los valores medidos en el periodo de entrenamiento, así mismo que los valores manifestados por el Error Cuadrático Medio en la fase de entrenamiento muestran un error de 0.118 m³/s, por otro lado menciona que el valor de R² es igual a 0.857, además menciona que los datos proporcionados por el Error Medio Absoluto y expresados en términos porcentuales a través del Error Porcentual Medio Absoluto indican que el modelo tiende a sobreestimar el caudal en comparación con los valores medidos durante la fase de entrenamiento. Gonzales y Soto (2019) destacan la importancia de estas métricas al afirmar que son las más adecuadas para evaluar el desempeño de los modelos, así mismo compartimos plenamente la perspectiva de estos autores, ya que estas métricas constituyen herramientas esenciales para resumir y comprender las discrepancias entre las predicciones realizadas por un modelo y lo que realmente ocurre en la realidad, la elección de métricas de evaluación adecuadas es crucial para obtener una visión precisa de la capacidad predictiva y la exactitud de un modelo, y concordamos con la sugerencia de Gonzales y Soto de que las métricas mencionadas brindan una evaluación integral y significativa en este contexto, ya que al adoptar estas métricas, se facilita una comprensión más completa de las fortalezas y debilidades del modelo, lo que contribuye a un análisis más riguroso y fundamentado de su rendimiento en la predicción de caudales.

Con respecto a la tercera dimensión, Temporalidad de las inundaciones, y de acuerdo al tercer objetivo específico Identificar la estacionariedad en los que se producen las inundaciones en Catacaos – Piura; 2023, se puede observar que se analizó estadísticamente la estacionariedad para cada año desde el 2017 hasta el 2022, mediante la prueba de Dickey-Fuller, así mismo se examinó la estacionalidad general de la serie temporal desde el 01/01/2017 al 02/28/2022, la cual generó un resultado de -7.44607812223471, el valor p relacionado con esta prueba se determinó como 6.013864973464078e-11, y los hallazgos obtenidos de la Prueba de Dickey-Fuller sugieren que la serie es estacionaria, lo que respalda la existencia de propiedades temporales consistentes en los datos que fueron

objeto de análisis, estos datos los podemos comparar con los datos obtenidos por la autora Meis (2019), la cual nos menciona que tuvo en cuenta las series estacionales tanto del caudal como de distintos índices climáticos para analizar la estacionariedad de las series mediante la prueba de Dickey-Fuller la cual rechazó la hipótesis nula de no estacionariedad, con un p-valor menor a 0.05. Montalvo Molina (2019), nos menciona a cerca de la prueba de Dickey-Fuller Aumentada (ADF), la cual se presenta como una ampliación de la prueba de Dickey-Fuller original, diseñada específicamente para series temporales sin retrasos ($k=0$), su finalidad principal radica en evidenciar la presencia de al menos una raíz unitaria en la serie temporal, lo cual contribuiría a la no estacionariedad de la misma. En otras palabras, esta prueba busca identificar la persistencia de patrones que pueden generar una falta de estabilidad en la serie a lo largo del tiempo, al expandir la capacidad de la prueba Dickey-Fuller original, la ADF ofrece un enfoque más detallado y preciso para analizar la estacionariedad de las series temporales, proporcionando así información valiosa sobre la naturaleza y la evolución de los procesos subyacentes en los datos a lo largo de distintos momentos temporales. Por otro lado, Meneses, y Pérez (2019), mencionan que la prueba Dickey-Fuller fue desarrollada con el propósito de examinar la presencia de una raíz unitaria, en este contexto, se utiliza inicialmente para identificar el orden de integración de cada variable, posteriormente, se aplica (en situaciones donde todas las variables comparten el mismo orden de integración, que es mayor a cero) para contrastar la estacionariedad de los residuos de la ecuación de co-integración, llevándose a cabo así la prueba de cointegración.

Para el objetivo específico, analizar el uso de un de un modelo inteligente para comprender de manera precisa los patrones y comportamientos de inundaciones - Catacaos – Piura; 2023, el cual tiene como dimensión modelo inteligente, teniendo como indicador "Nivel de precisión en la predicción". ha proporcionado resultados detallados y significativos que generan información sobre la capacidad de este modelo para prever eventos de inundación. El análisis se centra en datos recopilados desde 2017 hasta 2022.

Los resultados de la Prueba de Dickey-Fuller sugieren que la serie es estacionaria, respaldando así la presencia de propiedades temporales consistentes en los datos analizados. Esta conclusión se compara con los hallazgos de Mora, C. y Losada, J. (2023), quienes estudiaron las precipitaciones en la ciudad de Manizales y encontraron variaciones constantes en el tiempo, indicando estacionariedad. En cuanto a la correlación, observaron una rápida disminución que tiende a cero, un patrón similar a nuestros resultados en autocorrelación.

Mora y Losada (2023) utilizaron el modelo Prophet y obtuvieron métricas con un alto error, como RMSE = 24.47890, MAE = 20.87540, MSE = 721.60857 y un AIC = 12696.14238. En contraste, al emplear el modelo SARIMAX, nosotros logramos valores notables en términos de precisión, con MAE = 0.0028077377049180335, MSE = 1.4690630819672135e-05 y RMSE = 0.003832835871736766. Estos resultados indican que las predicciones del modelo SARIMAX se ajustan estrechamente a los valores reales, demostrando un alto nivel de precisión.

La elección de implementar el modelo SARIMAX sobre la estructura del modelo se revela como apropiada para los objetivos propuestos, proporcionando una herramienta valiosa para la gestión de inundaciones en la zona.

Cabe resaltar que Lujano, E., et al. (2023). Utilizo el algoritmo KNN para realizar predicciones del caudal del río remis este enfoque particular exhibió un rendimiento notable, destacándose por valores de métricas de evaluación impresionantes, tales como ACC (Coeficiente de Correlación de Anomalías) de 0.982, NSE (Eficiencia del Modelo Nash-Sutcliffe) de 0.965, y KGE' (Eficiencia del Generador de Eventos Kling-Gupta) de 0.982. Además, se observó un bajo porcentaje de error (MAPE - Error Porcentual Absoluto Medio) de 7.403 %, indicando una alta precisión en las predicciones, además obtuvo mejores resultados luego de cambiar los datos, en el cual el que tuvo mayor precisión fue $Q_t:f(Q_{t-1}, Q_{t-2})$ en comparación a $Q_t:f(Q_{t-1})$ de entrada lo cual respalda la importancia de considerar cuidadosamente las variables de entrada y la complejidad del modelo al desarrollar pronósticos de caudales.

En nuestro contexto, hemos optado por emplear el modelo SARIMAX para analizar las inundaciones en la región. Aunque hemos elegido una metodología diferente, este antecedente resalta la diversidad de enfoques utilizados en la investigación climática.

V. CONCLUSIONES

- La Propuesta de un sistema de alerta temprana de inundación basado en Inteligencia Artificial para el río Catacaos – Piura; 2023, que tiene como objetivo general, proponer un sistema de alerta temprana para inundaciones basado en modelo de aprendizaje automático adaptado por inteligencia artificial, se concluye que se logró evaluar la viabilidad de un sistema de alerta temprana en esta localidad, ya que, los resultados obtenidos revelan que el modelo de aprendizaje automático basado en SARIMAX, utilizado demostró ser una herramienta efectiva para prever y anticipar eventos de inundación en Catacaos. La precisión del modelo, es respaldada por métricas sólidas como el MAE, MSE, y RMSE, indica una alineación estrecha entre las predicciones del modelo y los valores reales, validando así su utilidad en la predicción de patrones de inundación. La integración de este modelo inteligente como base en la implementación de un sistema de alerta temprana se muestra como un enfoque prometedor y eficiente.
- Se logró identificar el número de personas afectadas por las inundaciones anuales en Catacaos - Piura; 2023, revelando un impacto significativo y variable en la población. Aunque la frecuencia de estos eventos no es constante, se manifiestan de manera considerable en ciertos años. En particular, el año 2017 registró el mayor impacto, con un total de 27,851 personas afectadas. En el período comprendido entre 2013 y 2023, la cifra asciende a 63,998 personas afectadas, resaltando la vulnerabilidad de la población frente a eventos climáticos extremos. Estos resultados subrayan la necesidad imperativa de implementar medidas de mitigación y respuesta efectivas. La variabilidad en el número de personas afectadas destaca la importancia de un monitoreo continuo para adaptar estrategias de gestión de riesgos y planificar medidas de mitigación específicas. La información recopilada proporciona una base valiosa para mejorar la resiliencia de la comunidad ante inundaciones futuras.

- Se logró con éxito la identificación de la eficacia del sistema de alerta temprana para detectar señales físicas de amenazas de inundaciones en la localidad de Catacaos, ubicada en la región de Piura. Este logro representa un hito significativo en la evaluación y fortalecimiento de las capacidades del sistema, permitiendo una mayor comprensión de su rendimiento y precisión en anticipar eventos de inundación. La exacta recopilación de datos reales de caudal junto con las predicciones generadas por el modelo inteligente ha servido como una herramienta esencial para esta identificación, brindando una visión detallada y fidedigna de la capacidad del sistema para anticipar y alertar sobre posibles amenazas de inundaciones.
- Se ha conseguido exitosamente identificar la estacionariedad en los sucesos de inundaciones que ocurren en Catacaos - Piura, un logro fundamental en el contexto de nuestro tercer objetivo específico para el año 2023. Este proceso de identificación se llevó a cabo mediante un análisis estadístico exhaustivo, aplicando la prueba de Dickey-Fuller para cada año desde el 2017 hasta el 2022. Los resultados consistentes a lo largo de estos años respaldan de manera contundente la estacionariedad de la serie temporal, indicando propiedades temporales coherentes en los datos analizados.
- Se logró analizar el uso de un de un modelo inteligente para comprender de manera precisa los patrones y comportamientos de inundaciones - Catacaos – Piura; 2023. Ya que los resultados obtenidos indican que el modelo inteligente, basado en SARIMAX, ha demostrado un alto nivel de precisión en la predicción de eventos de inundación. La evaluación de los residuos y las pruebas de autocorrelación respaldan la calidad del ajuste del modelo, destacando su capacidad para capturar patrones complejos. La comparación entre las predicciones del modelo y los valores reales, evaluada mediante métricas como MAE, MSE, y RMSE, muestra que el modelo SARIMAX está estrechamente alineado con los datos observados, indicando una capacidad significativa de predicción, de esta manera, se respalda la elección acertada del modelo SARIMAX.

VI. RECOMENDACIONES

- Se recomienda continuar con la mejora constante del sistema de alerta temprana mediante la integración de tecnologías emergentes y la actualización regular de algoritmos. Además, es crucial mantener un flujo de comunicación claro y efectivo con las comunidades afectadas, asegurándose de que la información sea entregada de manera oportuna
- El éxito en la identificación de la estacionariedad en los sucesos de inundaciones proporciona una base sólida para la gestión y mitigación de riesgos, es por ello que se sugiere que se amplie el análisis temporal y considerar factores adicionales que puedan influir en la estacionariedad, como cambios en el uso del suelo y patrones climáticos a largo plazo.
- Establecer un mecanismo para monitorear de forma continua las condiciones de estacionariedad y actualiza periódicamente el análisis estadístico, además compartir estos hallazgos con la comunidad científica y los responsables de la toma de decisiones para contribuir a la comprensión global de los patrones temporales en eventos de inundaciones, esta información puede ser crucial para el desarrollo de estrategias de preparación y respuesta a eventos futuros.

REFERENCIAS

- Arregui S, Núñez A, Vidal J, Mendoza L, Díaz de Cossío G, Farfán F, Gálvez O, Méndez I, Orozco L, y Sánchez J. (2022). Evaluación del potencial de la red sísmológica del CICESE para su aplicación en un sistema de alerta sísmica temprana para el norte de Baja California. *Ingeniería sísmica*, (109), 28-46. Epub 17 de marzo de 2023. <https://doi.org/10.18867/ris.109.601>
- Autoridad Nacional del Agua. (n.d.). consejo de cuenca chira-piura. Retrieved December 12, 2023, from <https://www.ana.gob.pe/2019/consejo-de-cuenca/chira-piura/H>
- Calicchio, N., & Fabris, J. Validez de la paridad del poder adquisitivo en Argentina para el período 1943-2016: análisis de cointegración con sistemas parciales. http://bibliotecadigital.econ.uba.ar/download/tpos/1502-1320_CalicchioN.pdf
- Cambronero, M., Sánchez-Calderón, R., & Lobo, R. (2023). Medium and large-sized mammals in a premontane moist forest fragment, Atenas, Costa Rica. *Revista De Biología Tropical*, 71(1), e53245. <https://doi.org/10.15517/rev.biol.trop.v71i1.53245>
- Cárdenas-Rodríguez, S., Vides-Herrera, C. A., & Pardo-García, A. (2022). Sistema de alerta temprana de inundaciones para el río Arauca basado en técnicas de inteligencia artificial. *Revista de Investigación Desarrollo e Innovación*, 12(2), 315–325. <https://doi.org/10.19053/20278306.v12.n2.2022.15274>
- Carreño, M. L., Cardona, O. D., & Barbat, A. H. (2011). Evaluación de la habitabilidad de edificios afectados por sismo utilizando la teoría de conjuntos difusos y las redes neuronales artificiales. *Revista Internacional de Métodos Numéricos para Cálculo y Diseño en*
- Casanova Cruz, Daniel, Miranda Díaz, Camilo, & Yáñez Corvalán, Ana María. (2021). Sistema de alerta temprana: Centinela, una experiencia para la

retención estudiantil en la Universidad Católica de la Santísima Concepción. *Calidad en la educación*, (55), 156-174. <https://dx.doi.org/10.31619/caledu.n55.1056>

Castillo, R., & Espitia, J. C. (2020). Caracterización de zonas de riesgo por crecientes de ríos de bajo caudal, para la implementación de un sistema de alertas tempranas (SAT) con tecnología LoRa y LoRaWAN. *Información Tecnológica*, 31(2), 47–54. <https://doi.org/10.4067/S0718-07642020000200047>

Centro de Investigación y Desarrollo. (2002). *Desestacionalización de Series Económicas*. Lima. https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib0514/Libro.pdf

CIP. Código de ética del Colegio de Ingenieros del Perú. https://www.cip.org.pe/publicaciones/reglamentosCNCD2018/codigo_de_etica_del_cip.pdf

del Granado, S., Stewart, A., Borbor, M., Franco, C., Tauzer, E., & Romero, M. (2016). *Sistemas de Alerta Temprana para Inundaciones: Análisis Comparativo de Tres Países Latinoamericanos* (No. 03/2016). Development Research Working Paper Series. <https://www.inesad.edu.bo/wp-content/uploads/2016/08/Sistemas-de-Alerta-Temprana-para-Inundaciones-An%C3%A1lisis-Comparativo-de-Tres-Pa%C3%ADses-Latinoamericanos.pdf>

Domínguez-Calle, Efraín, & Lozano-Báez, Sergio. (2014). Estado del arte de los sistemas de alerta temprana en Colombia. *Revista de la Academia Colombiana de Ciencias Exactas, Físicas y Naturales*, 38(148), 321-332. Retrieved June 16, 2023, from http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0370-39082014000300007&lng=en&tlng=es.

Dorado, J. (2020). sistema de monitoreo y control de alerta temprana del desbordamiento de un río. Accedido: 8 de julio de 2023. [En línea].

Disponible en:
[http://repository.unipiloto.edu.co/bitstream/handle/20.500.12277/7475/
TESIS%20DE%20GRADO.pdf?sequence=1&isAllowed=y](http://repository.unipiloto.edu.co/bitstream/handle/20.500.12277/7475/TESIS%20DE%20GRADO.pdf?sequence=1&isAllowed=y)

Farias M, Olivares, A., Neyra, D., & Gonzalez, I. (2020). Forecast model of Piura River flows calibrated with El Niño Costero 2017 [Pronóstico de caudales del río Piura calibrado con El Niño Costero 2017]. Proceedings of the LACCEI international Multi-conference for Engineering, Education and Technology. DOI:10.18687/LACCEI2020.1.1.276

Gallego-Nicasio Moraleda, J. A., Rodríguez Aranda, A., Mínguez Novella, J., & Jiménez Perez, F. (2018). Modelos ARIMA para la predicción del gasto conjunto de oxígeno de vuelo y otros gases en el Ejército del Aire. *Sanidad Militar*, 74(4), 223-229. <https://scielo.isciii.es/pdf/sm/v74n4/1887-8571-sm-74-04-00223.pdf>

Gallo, Medina, J., 2021. Propuesta de instrumentos para implementar un sistema de alerta temprana ante flujo de detritos en la quebrada Pedregal, Lurigancho Chosica, 2020, Universidad Continental. Accedido: 8 de julio de 2023. [En línea]. Disponible en: <https://repositorio.continental.edu.pe/handle/20.500.12394/8765>

García Díaz, JC. (2016). Predicción en el dominio del tiempo. Análisis de series temporales para ingenieros. Editorial Universitat Politècnica de València. <http://hdl.handle.net/10251/72938>

Gómez, G. (2019). Instrumentos de registro. Metodología de la Investigación. investigación científica. <https://www.teseopress.com/metodologiadelainvestigacion/chapter/capitulo-6-instrumentos-de-registro/>

Gonzales., Soto. (2019). Análisis de métodos estadísticos para evaluar el desempeño de modelos de simulación en cultivos hortícolas. Universidad de Costa Rica.

- Guillot, J. D., Robles, C. A., & Callejas, J. D. (2017). Environmental signals acquisition for an early warning system. [Adquisición de señales ambientales para un sistema de alerta temprana] *Informacion Tecnologica*, 28(5), 45-54. doi:10.4067/s0718-07642017000500007
- Kunz, E. N. (2020). Análise de séries temporais: estudo estatístico sobre modelos ARIMA com uma aplicação prática em processo sazonal determinístico. <https://repositorio.ufsc.br/handle/123456789/216280>
- Lujano, E., Lujano, R., Huamani, J. C., & Lujano, A. (2023). Hydrological modeling based on the KNN algorithm: An application for the forecast of daily flows of the Ramis river, Peru. *Tecnología y Ciencias Del Agua*, 14(2), 169–203. <https://doi.org/10.24850/j-tyca-14-02-05>
- Martínez-Marcos, D., Barrios-Puente, G., Pérez-Soto, F., Ruiz-Hernández, J. A., & Lara-Reimers, E. A. (2023). Transmisión espacial de precios desde el mercado internacional al mercado mexicano de leche. *Ecosistemas Y Recursos Agropecuarios*, 10(1). <https://doi.org/10.19136/era.a10n1.3022>
- Méndez, S (2020). Metodología Cuantitativa. *Revista Científica*.
- Meneses, C. A. (2019). Análisis y predicción de series temporales provenientes de un sistema SCADA de una planta de fabricación industrial. https://repositorio.unican.es/xmlui/bitstream/handle/10902/16901/TFM_Carlos_Meneses_0719.pdf?sequence=1
- Meza-Padilla, R., Appendini, C. M., Pedrozo-Acuña, A., & González-Villarreal, F. (2015). Evaluación de la marea de tormenta en sitios con escasez de datos: río Pánuco, México. *RIBAGUA - Revista Iberoamericana del Agua*, 2(2), 61-70. <https://doi.org/10.1016/j.riba.2015.09.001>.
- Mora, C. A. P., & Losada, J. D. L. (2023). Análisis de series temporales en estaciones meteorológicas para la predicción de la precipitación en la ciudad de Manizales, Colombia. *Revista de Climatología*, 23, 59.

<https://rclimatol.eu/wp-content/uploads/2023/07/Articulo-CS23-Climatologia.pdf>

Mora, D, Rosas, J. (2016). Accedido: 8 de julio de 2023. [En línea]. Disponible en: <http://ri.uaemex.mx/bitstream/handle/20.500.11799/63871/MORA-DIANA-ROSAS-JUAN-LGI-2016.pdf?sequence=1&isAllowed=y>

Pablo, K. (2019). Sistema de Alerta Temprana de Inundaciones Aplicando un Modelamiento Hidrológico con HEC-HMS en el Río Culebras. Accedido: 8 de julio de 2023. [En línea]. Disponible en: http://repositorio.usanpedro.edu.pe/bitstream/handle/USANPEDRO/12438/Tesis_62896.pdf?sequence=1&isAllowed=y

Paredes, C., Castedo, R., Llorente, M., & Laín, L. (2012). Un modelo predictivo de la evolución en costas rocosas. *Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería*, 28(4), 243-255. <https://doi.org/10.1016/j.rimni.2012.08.002>

Pernalet, J. (2017). Gestión De Redes Informática Para El Sistema De Alerta Temprana De Inundaciones en El Municipio Maracaibo. *Revista Télématique*, 16(2), 75–99.

Ramos. (2019). Ficha de registro de datos. Página Web Educativa. [En línea]. Disponible en: <https://www.coursehero.com/file/p1o15h6/Ficha-de-observaci%C3%B3n-o-ficha-de-registro-Un-instrumento-de-medici%C3%B3n-adeecuado/>

Rubio, J. J., Hernández-Aguilar, A., Ávila-Camacho, J., Stein-Carrillo, M., & Meléndez-Ramírez, A. (2016). Sistema sensor para el monitoreo ambiental basado en redes neuronales. *Ingeniería, Investigación y Tecnología*, 17(2), 211-222. <https://doi.org/10.1016/j.riit.2016.06.006>

Sáiz, M (2019). Procesamiento de datos a través de aplicaciones informáticas. *Dianet* (Revista científica). <https://dialnet.unirioja.es/servlet/articulo?codigo=7131789>

- Sánchez, A (2020). Estadística Descriptiva. Distribución de Frecuencias. [En línea]. Disponible en: <https://aprendeconalf.es/docencia/estadistica/manual/estadistica-descriptiva/>
- Sathishkumar, V. E., Cho, J., Subramanian, M., & Naren, O. S. (2023). Forest fire and smoke detection using deep learning-based learning without forgetting. *Fire Ecology*, 19(1), 1–17. <https://doi.org/10.1186/s42408-022-00165-0>
- Singh, N. (2020). Métricas de evaluación de modelos en el aprendizaje automático. Obtenido de <https://www.datasources.ai/es/data-science-articles/metricas-de-evaluacion-de-modelos-en-el-aprendizaje-automatico>.
- Solarte, A, Varney, P. y Agredo, G. (2012). Implementación De Un Sistema De Telemetría Para La Detección Temprana De Eventos Tsunamigénicos Asociados Con La Variación Extrema Del Nivel De La Marea En La Costa Pacífica Colombiana. *Gerencia Tecnológica Informática*, 10(26), 25–34.
<https://search.ebscohost.com/login.aspx?direct=true&AuthType=ip,sso&db=fap&AN=73981718&lang=es&site=ehost-live&scope=site>
- Teixeira, G., & Balda, G. (2021). Feasibility study on operational use of neural networks in a flash flood early warning system. [Estudo de viabilidade do uso operacional de redes neurais em um sistema de alertas antecipados de enxurradas] *Revista Brasileira De Recursos Hidricos*, 26 doi:10.1590/2318-0331.262120200152
- Tello, C., (2022). Estimación de la probabilidad de daño humano por inundación fluvial en la selva baja del Perú [Universidad Nacional Agraria de la Selva]. <https://hdl.handle.net/20.500.14292/2388>
- Thomas, L. P., & Marino, B. M. (2016). Estimación del caudal a partir de la evolución del nivel del agua en un estuario con onda de marea

estacionaria. RIBAGUA - Revista Iberoamericana del Agua, 3(1), 8-17.
<https://doi.org/10.1016/j.riba.2016.01.001>

Vargas Camacho, J. C., Plata Rangel, Á. M., & Guevara, O. (2020). Diseño participativo de una alerta agroclimática temprana para el cultivo de papa criolla (*Solanum phureja*) en Subachoque, Colombia. *Acta Agronómica*, 69(3), 179-187.
<https://doi.org/10.15446/acag.v69n3.77051>

Vargas-Losada, H. F., Tovar-Rubiano, M. F., y Villanueva-Muñoz, J. C. (2016). Los SAT (Sistemas De Alertas Tempranas) . *Revista Científica*, 26, 21–28. <https://doi.org/10.14483/23448350.11087>

Villenas, Q. (2020). Predicción de caudales en la cuenca del río Chalpi Norte mediante la aplicación de redes neuronales. Facultad de ingeniería civil y ambiental. Quito – Ecuador.

Yousafzai, A., Manzoor, W., Raza, G., Mahmood, T., Rehman, F., Hadi, R., Shah, S., Amin, M., Akhtar, A., Bashir, S., Habiba, U., & Hussain, M. (2024). Forest yield prediction under different climate change scenarios using data intelligent models in Pakistan/ Previsao de producao florestal em diferentes cenarios de mudancas climaticas usando modelos inteligentes de dados no Paquistao. *Brazilian Journal of Biology*, 84, NA.
<https://link.gale.com/apps/doc/A703045044/AONE?u=univcv&sid=bookmark-AONE&xid=4f8f45be>

ANEXOS

Matriz de Operacionalización

Variable	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Escala de medición
Sistema de alerta temprana.	Son una colección de herramientas encargadas de predecir la probabilidad de una amenaza. La inteligencia artificial es de gran ayuda para la gestión de los recursos hidráulicos mediante el procesamiento de imágenes (Cárdenas S., et al., 2022).	Recolectar datos anuales sobre el número de personas afectadas por inundaciones	Impacto de las inundaciones	Número de personas afectadas por inundaciones.	Razón
		Comparación con el Comportamiento Real	Alerta temprana	Capacidad de detención de señales físicas de las amenazas	Ordinal
Modelo de aprendizaje automático	usan algoritmos de aprendizaje automático para poder analizar datos históricos y en tiempo real y así poder identificar patrones y anomalías (Yousafzai et al, 2024).	realizar análisis de series temporales del caudal del río a través de la prueba de Dickey-Fuller.	Temporalidad de las inundaciones	Patrones estacionales del caudal del río (Prueba de Dickey-Fuller).	nominal
		Determinar los patrones y comportamientos de inundaciones a través de un modelo inteligente.	Modelo inteligente	Nivel de precisión en la predicción	Ordinal

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de número de personas afectadas por las inundaciones cada año". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

1. Datos generales del juez

Nombre del juez:	Gerónimo S. Sanjinés Cabrera	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	DESARROLLADOR DE SOFTWARE	
Institución donde labora:	GEROSANCA E.I.R.L.	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	Más de 5 años (X)
Experiencia en Investigación Psicométrica:		



2. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Impacto de las inundaciones
- Objetivos de la Dimensión: obtener el número de afectados por inundaciones

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Número de personas afectadas por inundaciones.	1	4	4	4	



Gerónimo S. Sanjinés Cabrera
ING. EN PSICOLOGÍA

Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de número de personas afectadas por las inundaciones cada año". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

7. Datos generales del juez

Nombre del juez:	Jonathan Merino Farías	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	GESTIÓN PÚBLICA	
Institución donde labora:	UNIVERSIDAD CÉSAR VALLEJO	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	Más de 5 años (X)
Experiencia en Investigación Psicométrica:		



8. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Impacto de las inundaciones
- Objetivos de la Dimensión: obtener el número de afectados por inundaciones

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Número de personas afectadas por inundaciones.	1	4	4	3	



Jonathan Merino Farías
ING. DE SISTEMAS
REG. N° 124367
Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de número de personas afectadas por las inundaciones cada año". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

7. Datos generales del juez

Nombre del juez:	Manuel C. Balladares Correa	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	GESTIÓN PÚBLICA	
Institución donde labora:	DIRESA TUMBES	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	
	Más de 5 años (x)	
Experiencia en Investigación Psicométrica:		



8. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Impacto de las inundaciones
- Objetivos de la Dimensión: obtener el número de afectados por inundaciones

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Número de personas afectadas por inundaciones.	1	4	3	4	



Manuel C. Balladares Correa
 ING. DE SISTEMAS
 REG. N° 224666
 Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de datos para conocer la capacidad del sistema de alerta temprana de detectar señales físicas de amenazas de inundaciones". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

1. Datos generales del juez

Nombre del juez:	Gerónimo S. Sanjinés Cabrera	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	DESAROLLADOR DE SOFTWARE	
Institución donde labora:	GEROSANCA E.I.R.L.	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	Más de 5 años (x)
Experiencia en Investigación Psicométrica:		



2. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Alerta temprana
- Objetivos de la Dimensión: Recolectar datos para entrenar al modelo inteligente y obtener predicciones de caudal

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Capacidad de detención de señales físicas de las amenazas	1	3	3	3	



Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de datos para conocer la capacidad del sistema de alerta temprana de detectar señales físicas de amenazas de inundaciones". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

5. Datos generales del juez

Nombre del juez:	Jonathan Merino Farías	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clinica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	GESTIÓN PÚBLICA	
Institución donde labora:	UNIVERSIDAD CÉSAR VALLEJO	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	Más de 5 años (x)
Experiencia en Investigación Psicométrica:		



6. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Alerta temprana
- Objetivos de la Dimensión: Recolectar datos para entrenar el modelo inteligente y obtener predicciones de caudal

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Capacidad de detención de señales físicas de las amenazas	1	3	3	3	



Jonathan Merino Farías
ING. DE SISTEMAS
REG. N° 124367
Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de datos para conocer la capacidad del sistema de alerta temprana de detectar señales físicas de amenazas de inundaciones". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

5. Datos generales del juez

Nombre del juez:	Manuel C. Balladares Correa	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	GESTIÓN PÚBLICA	
Institución donde labora:	DIRESA TUMBES	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	
	Más de 5 años (x)	
Experiencia en Investigación Psicométrica:		



6. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Alerta temprana
- Objetivos de la Dimensión: Recolectar datos para entrenar el modelo inteligente y obtener predicciones de caudal

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Capacidad de detención de señales físicas de las amenazas	1	3	3	3	



Manuel C. Balladares Correa
ING. DE SISTEMAS
REG. N° 224666

Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de datos para conocer la estacionalidad en los que se producen las inundaciones". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

1. Datos generales del juez

Nombre del juez:	Gerónimo S. Sanjinés Cabrera	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	DESARROLLADOR DE SOFTWARE	
Institución donde labora:	GEROSANCA E.I.R.L.	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	
	Más de 5 años (x)	
Experiencia en Investigación Psicométrica:		



2. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Temporalidad de las inundaciones
- Objetivos de la Dimensión: Encontrar la estacionalidad de crecidas de caudal del río de series temporales.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Patrones estacionales del caudal del río (Prueba de Dickey-Fuller).	1	3	3	3	



Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de datos para conocer la estacionariedad en los que se producen las inundaciones". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

3. Datos generales del juez

Nombre del juez:	Jonathan Merino Farías	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	GESTIÓN PÚBLICA	
Institución donde labora:	UNIVERSIDAD CÉSAR VALLEJO	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	Más de 5 años (x)
Experiencia en Investigación Psicométrica:		



4. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Temporalidad de las inundaciones
- Objetivos de la Dimensión: Encontrar la estacionariedad de series temporales de crecidas del río.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Patrones estacionales del caudal del río (Prueba de Dickey-Fuller).	1	4	4	4	



Jonathan Merino Farías
ING. DE SISTEMAS
REG. N° 124367
Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de datos para conocer la estacionalidad en los que se producen las inundaciones". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

3. Datos generales del juez

Nombre del juez:	Manuel C. Balladares Correa	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clinica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	GESTIÓN PÚBLICA	
Institución donde labora:	DIRESA TUMBES	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	Más de 5 años (x)
Experiencia en Investigación Psicométrica:		



4. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Temporalidad de las inundaciones
- Objetivos de la Dimensión: Encontrar la estacionalidad de series temporales de crecidas del río.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Patrones estacionales del caudal del río (Prueba de Dickey-Fuller).	1	4	3	3	



Manuel C. Balladares Correa
ING. DE SISTEMAS
REG. N° 224666

Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de datos para conocer la precisión del modelo inteligente para comprender de manera precisa los patrones y comportamientos de inundaciones.". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

1. Datos generales del juez

Nombre del juez:	Gerónimo S. Sanjinés Cabrera	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	DESARROLLADOR DE SOFTWARE	
Institución donde labora:	GEROSANCA E.I.R.L.	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	Más de 5 años (x)
Experiencia en Investigación Psicométrica:		



2. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Modelo inteligente
- Objetivos de la Dimensión: obtener datos que me ayudan a encontrar la precisión en la predicción a través de la comparación con el comportamiento real.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Nivel de precisión en la predicción	1	3	3	3	



Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de datos para conocer la precisión del modelo inteligente para comprender de manera precisa los patrones y comportamientos de inundaciones.". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

1. Datos generales del juez

Nombre del juez:	Jonathan Merino Farias	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	GESTIÓN PÚBLICA	
Institución donde labora:	UNIVERSIDAD CÉSAR VALLEJO	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	
	Más de 5 años (X)	
Experiencia en Investigación Psicométrica:		



2. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Modelo inteligente
- Objetivos de la Dimensión: obtener datos que me ayudan a encontrar la precisión en la predicción a través de la comparación con el comportamiento real.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Nivel de precisión en la predicción	1	3	3	3	



Jonathan Merino Farias
ING. DE SISTEMAS
REG. N° 124367
Firma del evaluador

Evaluación por juicio de expertos

Respetado juez: Usted ha sido seleccionado para evaluar el instrumento "Ficha de registro de datos para conocer la precisión del modelo inteligente para comprender de manera precisa los patrones y comportamientos de inundaciones.". La evaluación del instrumento es de gran relevancia para lograr que sea válido y que los resultados obtenidos a partir de éste sean utilizados eficientemente; aportando al quehacer psicológico. Agradecemos su valiosa colaboración.

1. Datos generales del juez

Nombre del juez:	Manuel C. Balladares Correa	
Grado profesional:	Maestría (X)	Doctor ()
Área de formación académica:	Clínica ()	Social ()
	Educativa (X)	Organizacional ()
Áreas de experiencia profesional:	GESTIÓN PÚBLICA	
Institución donde labora:	DIRESA TUMBES	
Tiempo de experiencia profesional en el área:	2 a 4 años ()	Más de 5 años (X)
Experiencia en Investigación Psicométrica:		



2. Propósito de la evaluación:

Validar el contenido del instrumento, por juicio de expertos.

Dimensiones del instrumento:

- Primera dimensión: Modelo inteligente
- Objetivos de la Dimensión: obtener datos que me ayudan a encontrar la precisión en la predicción a través de la comparación con el comportamiento real.

Indicadores	Ítem	Claridad	Coherencia	Relevancia	Observaciones/ Recomendaciones
Nivel de precisión en la predicción	1	3	3	3	



Manuel C. Balladares Correa
ING. DE SISTEMAS
REG. N° 224666

Firma del evaluador

Registros de número de personas afectadas por las inundaciones cada año.

Investigadores a cargo:	More Gómez, Eduardo José y Yarleque Ramos Pablo Junior							
Variable	Sistema de alerta temprana.							
Dimensión	Impacto de las inundaciones							
Indicador:	Número de personas afectadas por inundaciones.							
Ubicación:	Departamento de Piura							
Periodo:	2013 - 2023							
Formula:	<p>Número de Personas Afectadas= $\sum_{i=1}^n P_i$</p> <p>Donde:</p> <ul style="list-style-type: none"> • n es el número total de eventos o años considerados. • P_i es el número de personas afectadas en el evento o año i. 							
Nº Registro	Fecha	provincia	distrito	Afectados	Damnificados	Fallecidos	Viviendas destruidas	Viviendas afectadas
01	18/03/2015	PIURA	LAS LOMAS	0	0	0	0	490
02	19/03/2015	PAITA	PAITA	19	63	0	0	4
03	19/03/2015	PAITA	AMOTAPE	50	8	0	0	10
04	23/03/2015	PAITA	ARENAL	0	0	0	0	0
05	20/03/2015	PAITA	COLÁN	1800	250	0	2	360
06	22/03/2015	PAITA	TAMARINDO	100	0	0	0	20
07	22/03/2015	PAITA	VICHAYAL	1800	150	0	0	360
08	25/02/2015	SULLANA	LANCONES	0	0	0	0	0
09	27/04/2015	SULLANA	LANCONES	45	0	0	0	9
10	22/02/2016	PIURA	VEINTISEIS DE OCTUBRE	6	0	0	1	0
11	22/02/2016	PIURA	VEINTISEIS DE OCTUBRE	3	0	0	1	0
12	22/02/2016	PIURA	VEINTISEIS DE OCTUBRE	1	0	0	1	0
13	03/03/2016	PIURA	VEINTISEIS DE OCTUBRE	90	214	0	66	49
14	27/03/2017	PIURA	PIURA	3100	0	0	0	560
15	27/03/2017	PIURA	CASTILLA	4500	12200	0	180	900
16	27/03/2017	PIURA	CASTILLA	0	0	0	0	0
17	27/03/2017	PIURA	CASTILLA	0	0	0	0	0
18	27/03/2017	PIURA	CATACAOS	40043	27851	8	6585	8009

19	27/03/2017	PIURA	CURA MORI	0	0	0	0	0
20	28/01/2017	PIURA	VEINTISEIS DE OCTUBRE	2550	208	0	33	634
21	16/03/2017	PIURA	VEINTISEIS DE OCTUBRE	2562	1355	0	125	642
22	19/03/2017	PIURA	VEINTISEIS DE OCTUBRE	6649	1461	0	63	1626
23	06/02/2019	PIURA	CASTILLA	4	5	1	1	1
24	09/02/2019	SULLANA	LANCONES	85	13	0	4	26
25	24/04/2023	SULLANA	LANCONES	590	0	0	0	0

Registro de los primeros 30 datos hidrometeorológicos para conocer la capacidad del sistema de alerta temprana de detectar señales físicas de amenazas de inundaciones

Investigadores a cargo:		More Gómez, Eduardo José y Yarleque Ramos Pablo Junior				
Variable:		Sistema de alerta temprana.				
Dimensión:		Alerta temprana				
Indicador:		Capacidad de detención de señales físicas de las amenazas				
Ubicación:		Departamento de Piura				
Periodo:		2017 - 2023				
Nº Registro	Fecha	Temperatura (°c)		Humedad relativa (%)	Precipitación (mm/día)	Caudal
		MAX	MIN		TOTAL	
01	1/01/2017	31.4	20.9	73.4	0	0
02	2/01/2017	35.2	20.6	73.6	0	0
03	3/01/2017	36	20.3	73.5	0	0
04	4/01/2017	35.6	20.8	70.9	0	0
05	5/01/2017	35.4	22.8	67.3	0	0
06	6/01/2017	34	22.4	67.1	0	0
07	7/01/2017	36.4	20.2	68.2	0	0
08	8/01/2017	35	23.5	69.8	0	0
09	9/01/2017	33.8	23.8	65.7	0	0
10	10/01/2017	37	22.2	65.2	0	0
11	11/01/2017	36.2	21	64.1	0	0
12	12/01/2017	36.5	21.2	63.8	0	0
13	13/01/2017	33.6	23.2	67.5	0	0
14	14/01/2017	35.6	23	67.6	0	0
15	15/01/2017	35.4	22.8	70.1	0	0
16	16/01/2017	36.6	23.6	66.6	0	0
17	17/01/2017	36.4	19.9	70.0	0	0
18	18/01/2017	37.4	22.2	65.8	0	0
19	19/01/2017	37	23	65.1	0	0
20	20/01/2017	35.8	22	71.6	0	0
21	21/01/2017	34.2	23.8	77.9	27	0
22	22/01/2017	34.4	22.2	76.1	0	32.84
23	23/01/2017	35	23.7	69.5	0	29.87
24	24/01/2017	36.2	23.5	71.2	0	0
25	25/01/2017	34.4	24	74.9	3.2	18.58
26	26/01/2017	34	21.9	76.1	0	0
27	27/01/2017	36.6	23	69.2	0	0
28	28/01/2017	35.2	23.5	73.6	0	0
29	29/01/2017	36.6	22.9	70.9	0	0
30	30/01/2017	36.8	24.1	71.7	53.8	32.91

Registro de datos de estacionariedad en los que se producen las inundaciones

Investigadores a cargo:		More Gómez, Eduardo José y Yarleque Ramos Pablo Junior		
Variable		Modelo de aprendizaje automático		
Dimensión		Temporalidad de las inundaciones		
Indicador:		Patrones estacionales del caudal del río (Prueba de Dickey-Fuller).		
Ubicación:		Departamento de Piura		
Periodo:		01/01/2017 - 28/02/2022		
Formula:		$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \delta_1 \Delta y_{t-1} + \delta_2 \Delta y_{t-2} + \dots + \delta_{p-1} \Delta y_{t-(p-1)} + \epsilon_t$ <p>Donde:</p> <ul style="list-style-type: none"> • Δ es el operador de diferencia, que calcula la diferencia entre los valores sucesivos de la serie temporal. • y_t es la serie temporal. • t es una tendencia temporal opcional. • α es una constante. • β es el coeficiente asociado con la tendencia temporal. • γ es el coeficiente que mide la dependencia de la serie en el valor rezagado. • $\delta_1, \delta_2, \dots, \delta_{p-1}$ son coeficientes asociados con las diferencias rezagadas de la serie. 		
Nº Registro	Año	ADF	p-value	Estacionariedad
01	2017	-3.2	0.015	Estacionaria
02	2018	-2.1681454443528394	0.21800923614780832	No estacionaria
03	2019	-2.638001478506986	0.08539469121372595	No estacionaria
04	2020	-3.4679237633253366	0.008850121505253904	Estacionaria
05	2017-2022	-7.44607812223471	6.013864973464078e-11	Estacionaria

Registro de los 30 primeros datos para conocer la precisión del modelo inteligente para comprender de manera precisa los patrones y comportamientos de inundaciones.

Investigadores a cargo:	More Gómez, Eduardo José y Yarleque Ramos Pablo Junior	
Variable	Modelo de aprendizaje automático.	
Dimensión	Modelo inteligente	
Indicador:	Nivel de precisión en la predicción	
Ubicación:	Departamento de Piura	
Periodo:	01/03/2022 – 30/04/2022	
Formula:	<ul style="list-style-type: none"> • Error Cuadrático Medio (MSE): $MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$ • Raíz de Error Cuadrático Medio (RMSE): $RMSE = \sqrt{MSE}$ • Error Absoluto Medio (MAE) $MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i$ • Error Porcentual Absoluto Medio (MAPE): $MAPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right) \times 100\%$ • Coefficiente de Determinación (R²): $R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$ <p>Donde:</p> <ul style="list-style-type: none"> ○ n es el número de observaciones ○ y_i son los valores reales ○ \hat{y}_i son los valores predichos. ○ \bar{y}_i es la media de los valores reales. ○ R^2 indica la proporción de la variabilidad en los datos que es explicada por el modelo. 	
Nº Registro	datos reales	datos generados por el modelo inteligente
01	0.051308	0.051503
02	0.054989	0.046876
03	0.049635	0.041321
04	0.042315	0.039549
05	0.035345	0.031611
06	0.033623	0.026572
07	0.029319	0.024483
08	0.020676	0.022916
09	0.017496	0.024514
10	0.014157	0.024061
11	0.018694	0.021719

12	0.01353	0.021678
13	0.015224	0.021204
14	0.0128	0.019896
15	0.010713	0.018947
16	0.010439	0.017596
17	0.009528	0.015646
18	0.010617	0.013716
19	0.008683	0.01172
20	0.007042	0.010096
21	0.0054	0.008742
22	0.004375	0.007417
23	0.003528	0.006754
24	0.002863	0.006376
25	0.002413	0.005781
26	0.001965	0.005351
27	0.001637	0.00523
28	0.00153	0.005203
29	0.00151	0.004933
30	0.00151	0.004813