



**ESCUELA UNIVERSITARIA DE POSGRADO**

**MODELO PREDICTIVO BASADO EN REDES NEURONALES ARTIFICIALES  
PARA PRONOSTICAR EL CONSUMO DE AGUA POTABLE EN LA CIUDAD DE  
IQUITOS**

**Línea de investigación:**

**Sistemas Inteligentes, Robótica y Domótica**

Tesis para optar el grado académico de Doctor en Ingeniería de Sistemas

**Autor:**

Ramirez Villacorta, Jimmy Max

**Asesor:**

Rodríguez Rodríguez, Ciro

(ORCID: ORCID- 0000-0003-2112-1349)

**Jurado:**

Petrik Azabache, Iván Carlo

Lezama Gonzales, Pedro Martín

Tejada Estrada, Gina Coral

**Lima - Perú**

**2024**



# MODELO PREDICTIVO BASADO EN REDES NEURONALES ARTIFICIALES PARA PRONOSTICAR EL CONSUMO DE AGUA POTABLE EN LA CIUDAD DE IQUITOS

## INFORME DE ORIGINALIDAD

23%

INDICE DE SIMILITUD

21%

FUENTES DE INTERNET

10%

PUBLICACIONES

9%

TRABAJOS DEL ESTUDIANTE

## FUENTES PRIMARIAS

1	<a href="https://repositorio.unapiquitos.edu.pe">repositorio.unapiquitos.edu.pe</a> Fuente de Internet	6%
2	<a href="https://hdl.handle.net">hdl.handle.net</a> Fuente de Internet	1%
3	<a href="https://dspace.esPOCH.edu.ec">dspace.esPOCH.edu.ec</a> Fuente de Internet	1%
4	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	1%
5	<a href="https://helvia.uco.es">helvia.uco.es</a> Fuente de Internet	1%
6	<a href="https://repositorio.unfv.edu.pe">repositorio.unfv.edu.pe</a> Fuente de Internet	1%
7	Submitted to Instituto Superior de Artes, Ciencias y Comunicación IACC Trabajo del estudiante	<1%
8	<a href="https://www.researchgate.net">www.researchgate.net</a>	



Universidad Nacional  
**Federico Villarreal**

**VRIN** | VICERRECTORADO  
DE INVESTIGACIÓN

## ESCUELA UNIVERSITARIA DE POSGRADO

MODELO PREDICTIVO BASADO EN REDES NEURONALES ARTIFICIALES PARA  
PRONOSTICAR EL CONSUMO DE AGUA POTABLE EN LA CIUDAD DE IQUITOS

Línea de Investigación:  
Sistemas Inteligentes, Robótica y Domótica

Tesis para optar el Grado Académico de Doctor en Ingeniería de Sistemas

Autor:

Ramirez Villacorta, Jimmy Max

Asesor:

Rodríguez Rodríguez, Ciro  
ORCID: 0000-0003-2112-1349

Jurado:

Iván Carlo Petrlik Azabache

Pedro Martín Lezama Gonzales

Gina Coral Tejada Estrada

Lima – Perú

2024

## ÍNDICE GENERAL

Dedicatoria.....	vii
Agradecimientos .....	viii
RESUMEN .....	11
ABSTRACT.....	12
<b>I. INTRODUCCIÓN.....</b>	<b>13</b>
1.1. Planteamiento del problema.....	13
1.2. Descripción del problema.....	16
1.3. Formulación del problema .....	17
1.3.1. Problema General .....	17
1.3.2. Problemas Específicos.....	17
1.4. Antecedentes .....	17
1.5. Objetivos .....	23
1.5.1. Objetivo General:.....	23
1.5.2. Objetivos Específicos:.....	23
1.6. Hipótesis.....	24
1.6.1. Hipótesis general: .....	24
1.6.2. Hipótesis específicas: .....	24
<b>II. MARCO TEÓRICO .....</b>	<b>25</b>
2.1. Marco conceptual .....	25
2.1.1. El Sistema de Agua Potable.....	25
2.1.2. Producción del Agua Potable .....	25
2.1.3. Distribución del Agua Potable .....	26
2.1.4. Facturación del Agua Potable .....	27
2.1.5. Proceso del cálculo del consumo de agua potable .....	27
2.1.6. Predicción del Consumo de agua potable.....	28
2.1.7. Redes Neuronales Artificiales.....	28
2.1.8. Red Neuronal Artificial Recurrente (RNN).....	29
2.1.9. Memoria de Largo Plazo (LSTM) .....	29

2.1.10.	Lenguaje de programación Python.....	29
2.1.11.	Plataforma de Programación MATLAB.....	30
2.1.12.	Aprendizaje automático (Machine Learning).....	30
2.1.13.	Modelo ARIMA.....	31
2.2.	Terminologías.....	32
2.3.	Estado del Arte.....	33
2.3.1.	Fase 1: Planificación.....	33
2.3.2.	Fase 2: Desarrollo.....	35
2.3.3.	Fase 3: Resultados.....	35
2.3.4.	Fase 4: Análisis.....	38
2.3.5.	Fase 5: Discusión.....	39
III.	MÉTODO.....	43
3.1.	Tipo de investigación:.....	43
3.1.1.	Tipo de Investigación:.....	43
3.1.2.	Enfoque de la Investigación.....	43
3.1.3.	Nivel.....	43
3.1.4.	Diseño.....	44
3.2.	Población y muestra.....	44
3.2.1.	Población.....	44
3.2.2.	Muestra.....	45
3.3.	Operacionalización de variables.....	47
3.4.	Instrumentos.....	49
3.5.	Procedimientos.....	49
3.6.	Análisis de datos.....	50
3.7.	Consideraciones éticas.....	51
IV.	RESULTADOS.....	52
1.1.	Respecto al objetivo específico 1:.....	52
1.2.	Respecto al Objetivo específico 2:.....	54
4.2.1.	Fase 1: Obtención de los Datos:.....	56
4.2.2.	Fase 2: Preparación y normalización de los datos.....	59
4.2.3.	Fase 3: Análisis y visualización de los datos.....	63
4.2.4.	Fase 4: Implementación del modelo de red neuronal artificial.....	68

4.2.5. Fase 5: Prueba y evaluación de las predicciones .....	69
1.3. Respecto al objetivo específico 3: .....	71
V. DISCUSIÓN DE RESULTADOS .....	75
VI. CONCLUSIONES.....	77
VII. RECOMENDACIONES .....	79
VIII. REFERENCIAS .....	81
IX. ANEXOS.....	91
Anexo A .....	91
Anexo B .....	93

## ÍNDICE DE TABLAS

<b>Tabla 01.</b> Criterios de selección de fuentes de información .....	34
<b>Tabla 02.</b> Referenciación de artículos relacionado a la tecnología que se usan para el pronóstico del consumo de agua potable .....	37
<b>Tabla 03.</b> Tamaño de la muestra .....	45
<b>Tabla 04.</b> Operacionalización de variable independiente .....	47
<b>Tabla 05.</b> Operacionalización de variable dependiente .....	48
<b>Tabla 06.</b> Técnicas e Instrumentos a usar durante el desarrollo de la investigación .....	49
<b>Tabla 07.</b> Datos históricos de consumo de agua potable de enero a diciembre del 2016 hasta enero de diciembre del 2020 .....	56
<b>Tabla 08.</b> Datos históricos de temperatura máxima y mínima de enero a diciembre del 2016 hasta enero de diciembre del 2020 .....	57
<b>Tabla 09.</b> Datos históricos de precipitación de enero a diciembre del 2016 hasta enero de diciembre del 2020 .....	57
<b>Tabla 10.</b> Datos históricos de población de la ciudad de Iquitos de enero a diciembre del 2016 hasta enero de diciembre del 2020 .....	58
<b>Tabla 11.</b> Resultado de datos normalizados de enero a diciembre del 2016 hasta enero de diciembre del 2020 .....	60
<b>Tabla 12.</b> Estadística descriptiva de temperatura mínima y máxima de enero a diciembre del 2016 hasta enero de diciembre del 2020 .....	63
<b>Tabla 13.</b> Estadística descriptiva Datos históricos precipitación de enero a diciembre del 2016 hasta enero de diciembre del 2020 .....	65
<b>Tabla 14.</b> Estadística descriptiva Datos históricos población de enero a diciembre del 2016 hasta enero de diciembre del 2020 .....	66
<b>Tabla 15.</b> Estadística descriptiva Datos históricos de consumo de agua potable de enero a diciembre del 2016 hasta enero de diciembre del 2020 .....	67
<b>Tabla 16.</b> Resultados de la prueba del modelo .....	69
<b>Tabla 17.</b> Valores real y predicho de consumo de agua potable en Iquitos en el año 2020 .....	71

## ÍNDICE DE FIGURAS

<b>Figura 01.</b> Porcentaje de documentos seleccionados según año de publicación .....	<b>33</b>
<b>Figura 02.</b> Porcentaje de documentos seleccionados según la tecnología usada.....	<b>34</b>
<b>Figura 03.</b> Fases de diseño del modelo de predicción del consumo de agua potable .....	<b>57</b>
<b>Figura 04.</b> Actividades del proceso de limpieza del modelo .....	<b>57</b>
<b>Figura 05.</b> Fórmula de normalización de los datos .....	<b>63</b>
<b>Figura 06.</b> Estadística descriptiva de temperatura mínima .....	<b>64</b>
<b>Figura 07.</b> Estadística descriptiva de temperatura máxima .....	<b>64</b>
<b>Figura 08.</b> Estadística descriptiva Datos históricos precipitación de enero a diciembre del 2016 hasta enero de diciembre del 2020.....	<b>65</b>
<b>Figura 09.</b> Estadística descriptiva Datos históricos de población de enero a diciembre del 2016 hasta enero de diciembre del 2020.....	<b>66</b>
<b>Figura 10.</b> Estadística descriptiva Datos históricos de consumo de agua potable de enero a diciembre del 2016 hasta enero de diciembre del 2020.....	<b>67</b>
<b>Figura 11.</b> Arquitectura de la red neuronal .....	<b>71</b>
<b>Figura 12.</b> Rendimiento del modelo de predicción.....	<b>72</b>

### **Dedicatoria**

A mi padre Luis que en paz descanse, quien durante su vida siempre fue mi guía y fortaleza durante este nivel de estudio.

A mi madre Mariana quien es mi inspiración de estudio.

A mis hijos quienes represento su ejemplo.

A mi esposa Flor quien siempre fue mi compañera en este camino académico.

### **Agradecimientos**

A la Universidad Nacional Federico Villarreal por ser mi alma mater en el estudio del doctorado.

A mi asesor el Dr. Ciro Rodríguez, quien con sus enseñanzas y dirección pude concluir mi tesis.

Al Dr. Carlos Alberto García Cortegano, quien fue mi asesor externo en el desarrollo de mi tesis.

## RESUMEN

Esta investigación tuvo como objetivo desarrollar un modelo de predicción basado en redes neuronales artificiales para pronosticar de manera precisa el consumo de agua potable, el método o tipo de investigación fue aplicada, porque se desarrolló una herramienta para ser usada en las empresas de saneamiento que permita mejorar la gestión del suministro de agua potable, como resultados se identificó las variables de entrada o predictoras, estos fueron la temperatura máxima y mínima, la precipitación y la población de Iquitos, la variable de salida o variable predicha fue el consumo de agua potable, el modelo de predicción obtuvo un margen de error inferior al 5%, logrando el pronóstico del consumo de agua potable preciso, el tipo de red neuronal usada es el perceptrón multicapa, el número de neuronas en la capa de entrada fueron 4, capas ocultas son 2, el número de neuronas con la capa oculta son 10, el número de neuronas con la capa de salida es 1, el algoritmo de aprendizaje y validación fue el backpropagation, como conclusión se logró identificar las variables relevantes como la temperatura máxima y mínima, la precipitación, tasa poblacional, el modelo ha sido validado con la métricas de evaluación, del coeficiente de regresión ( $r$ ), el coeficiente de determinación ( $R^2$ ) y el Error Porcentual Absoluto Medio (MAPE), logrando determinar su efectividad, y por último el modelo ha demostrado una buena capacidad de rendimiento con diferentes conjuntos de datos, incluyendo entrenamiento, validación y prueba.

***Palabras claves:*** redes neuronales artificiales, pronostico, consumo de agua potable.

## ABSTRACT

This research aimed to develop a general prediction model based on artificial neural networks to accurately forecast the consumption of drinking water. The research type was applied, as a tool was created for use in sanitation companies to enhance the management of drinking water supply. The identified input or predictor variables were the maximum and minimum temperature, precipitation, and the population of Iquitos. The output or predicted variable was the consumption of drinking water. The prediction model achieved an error margin of less than 5%, ensuring precise forecasting of drinking water consumption. The type of neural network used was the multilayer perceptron, with 4 neurons in the input layer, 2 hidden layers, 10 neurons in each hidden layer, and 1 neuron in the output layer. The learning and validation algorithm employed was backpropagation, in conclusion, this research successfully identified relevant variables such as maximum and minimum temperature, precipitation, and population rate. The model was validated using evaluation metrics, including the regression coefficient ( $r$ ), determination coefficient ( $R^2$ ), and Mean Absolute Percentage Error (MAPE), confirming its effectiveness. Finally, the model demonstrated robust performance across various datasets, including training, validation, and testing.

***Keywords:*** artificial neural networks, forecast, drinking water consumption.

## I. INTRODUCCIÓN

### 1.1. Planteamiento del problema

El agua potable y su desabastecimiento es uno de los problemas sociales más grandes que afrontan la mayor parte de ciudades en el mundo, problema que hasta ahora no se ha podido solucionar por las diferentes empresas que administran este servicio. - Desde hace años atrás se ha despertado mucho interés particular por tratar este problema, motivo por el cual se ha identificado que uno de los factores más determinantes del desabastecimiento es por la existencia de mayor consumo de agua potable en las ciudades, demanda que no son cubiertas por las empresas que producen y distribuyen este líquido vital para el ser humano, las encargadas de administrar el agua potable tanto en el proceso de extracción, producción y distribución, se denominan empresas prestadoras de servicio de saneamiento, quienes realizan procesos y las gestiones necesarias para que los pobladores de una determinada ciudad cuenten con este servicio básico de calidad, y de manera continua, si bien es cierto estas organizaciones poseen las áreas o departamento encargadas de realizar los procesos de extracción, producción y distribución, no tienen la información necesaria que permita una buena toma de decisiones para brindar el servicio con eficiencia y calidad adecuada.

El desabastecimiento de agua potable por mayor demanda del consumo, se da por factores como la falta de construcción de reservorios, quiere decir que dentro de las ciudades existe una escasa cantidad de reservorios que no abastecen la distribución del agua potable en los sectores de la ciudad, no existe información adecuada de un historial de consumo que viene teniendo los usuarios durante los años anteriores, información útil y necesaria para que los funcionarios de las empresas puedan tomar decisiones acertadas en la administración de las entidades, los problemas más comunes son la de proyección de tiempo para la adquisición adecuada de los insumos

químicos y equipamiento necesario para que el servicio de agua potable no sufra ningún interferencia y sea de calidad Huaquisto y Chambilla (2019).

La fundación AQUE en el año 2019 afirma que en Mongolia el gasto hídrico asciende a 10.000 litros por cada habitante al día, por ese motivo es considerado uno de los países que tiene mayor consumo de agua por persona del mundo, luego le sigue Nigeria, Emiratos Árabes Unidos y por ultimo Bolivia, esta información sirve como referencia para que en los demás países se tome las medidas necesarias para evitar el desabastecimiento del agua potable en los países del mundo, en el 2015 la ONU implemento una agenda que se denominó el desarrollo al 2030, que hacía referencia al desarrollo de un plan de acción que permitirá favorecer a todas los habitantes, del planeta para garantizar la disponibilidad de agua en el mundo.

En el Perú existen 49 empresas que administran el servicio de agua potable, en los procesos de extracción de agua de los ríos, la producción de agua potable y la distribución de la misma en una determinada ciudad o población, 48 son Municipales y 1 es administrada por el FONAFE, 18 de EPS están intervenidas por la Órgano Técnico de la Administración de Servicios de Saneamiento (SUNASS, 2021), esta intervención se dio a consecuencia del mal manejo que se estuvo dando a estas empresas por parte de los directorios y funcionarios, quienes por la mala toma de decisiones en su gestión fomentaban el desabastecimiento y por ende los indicadores de gestión requeridos por el estado no se lograban cumplir, llegando a genera un caos social dentro de estas ciudades.

Las posibles causas de este problema son la falta de información más precisa y el tratamiento de la misma sobre el consumo del agua potable para realizar predicciones de consumo del agua potable (Llatas y Sánchez, 2019), esto pues acarrea que no se haga una adecuada y correcta cantidad de captación de volúmenes de agua en las represas, la planificación de los

recursos, como la construcción de nuevas represas, nuevos reservorios, mejoramientos de equipos hidráulicos y para una buena distribución del agua.

Al no investigar el problema, las empresas que administran este servicio en las ciudades del Perú, no podrán contar con una herramienta tecnológica que permitan la recopilación, procesamiento y almacenamiento de información precisa sobre el consumo de agua potable que tienen sus usuarios o abonados, una de las principales dificultades que acarrea el no contar con este programa es la mala toma de decisiones en función a la proyección a futuro por parte de las áreas de gestión comercial, administrativa y operativas, respecto a los procesos de captación de los volúmenes de agua necesarios en un periodo de tiempo, la planificación de la construcción de represas y reservorios, la adquisición de equipos de macro y micro medición, equipos hidráulicos para la distribución y así evitar el desabastecimiento del agua potable en la ciudad que se encuentra ubicadas y por ende evitar el caos social que genera este tipo de problemas.

Por lo descrito, esta investigación se enfoca en desarrollar un modelo que permita a las empresas de saneamiento usar la información del consumo de agua potable para luego procesarla usando un programa que contenga un modelo de pronóstico usando la inteligencia artificial con la finalidad de predecir a futuro el consumo de agua potable de los usuarios, y así tener la información necesaria que permita implementar las gestiones necesarias para cubrir la demanda de una determinada ciudad del Perú a futuro; dados en el aporte del artículo científico de Pandolfi en el año 2018, donde indica que a través del consumo medido y registrado de agua se podrá obtener datos históricos que permitan proyectar la demanda a futuro y poder realizar toma de decisiones estratégicas que permitan evitar el desabastecimiento del agua potable de una ciudad.

## 1.2. Descripción del problema

En el Perú según el INEI en el año 2022, la población existente fue aproximadamente de 33 millones 396 mil 700 habitantes y se proyecta a crecer en un 30% en 5 años más, y eso implica o se deduce que en los demás años existirá más demanda del consumo de agua potable por parte de los habitantes del Perú, se puede resaltar o priorizar el servicio de agua potable que es considerado un elemento fundamental que necesitamos los seres humanos para vivir, ya que se utiliza para beber, cocinar, lavar, etc. Este servicio es brindado por 49 empresas de servicio de saneamiento y agua potable en las distintas regiones y ciudades del Perú algunas administradas por las Municipalidades, y otras intervenidas actualmente por el estado debido a la pésima administración que han venido teniendo durante años atrás, estas empresas constantemente evalúan el consumo que tiene los usuarios o abonados de ello se puede destacar dos tipos de consumo de agua, el consumo asignado que son las medidas de los usuarios que no tienen un medidor de agua en sus domicilios y el consumo medido es aquella medida que se toma del medidor que posee un usuario en su domicilio, de acuerdo a esos parámetros la empresa realiza la facturación y cobranza, la problemática que nos lleva en buscar la solución en esta investigación, proponer que las empresas que proporcionan o administran el servicio de saneamiento y agua potable actualmente usan métodos convencionales para predecir el consumo de agua de sus usuarios; la información predictiva obtenida con estos métodos no son muy exactos, generando el problema de no poder extraer, procesar y distribuir el agua según la necesidad temporal o el requerido en los sectores en la que las empresas tienen cobertura o instalaciones de distribución del agua potable de sus usuarios, y al mismo tiempo poder garantizar la continuidad de este servicio.

### **1.3. Formulación del problema**

#### ***1.3.1. Problema General***

¿De qué manera el desarrollo de un modelo de predicción basado en redes neuronales artificiales pronostica de manera precisa el consumo de agua potable en la ciudad de Iquitos?

#### ***1.3.2. Problemas Específicos***

- ¿Cómo se pueden identificar los patrones estacionales de consumo de agua potable en la ciudad de Iquitos mediante el análisis de los requisitos del modelo de predicción basado en redes neuronales artificiales, utilizando datos históricos y variables climáticas como inputs?
- ¿Cómo diseñar un modelo de predicción para estimar el consumo de agua potable usando redes neuronales artificiales en la ciudad de Iquitos?
- ¿Cómo se puede evaluar la precisión del modelo de predicción basado en redes neuronales artificiales al pronosticar el consumo de agua potable en la ciudad de Iquitos?

### **1.4. Antecedentes**

García-Jiménez et al. (2012), señala que la proyección del consumo de agua potable en las grandes ciudades del mundo ha sido un problema que ha sido tratado de resolver a través del tiempo bajo diferentes aspectos matemáticos y estadísticos, con la finalidad de buscar la sostenibilidad del consumo del agua potable en el tiempo, en la actualidad este proceso se ha simplificado con el uso de las TI, y una de las herramientas más usadas son los modelos predictivos utilizando la inteligencia artificial, en esta investigación se hace una recopilación de los métodos convencionales para calcular y pronosticar el consumo de agua de la zona urbana de Madrid, tomando en consideración aspectos como la evaluación de los recursos como equipos y planta que

cuenta la empresa de saneamiento, el nivel de consumo del agua potable y el crecimiento de la población, y para ello propone el desarrollo de una aplicación donde se pueda procesar y visualizar datos históricos del consumo de agua potable que ha tenido en un determinado sector de Urbano, de manera eficiente y con menos errores, la contribución de esta investigación es el desarrollo de una aplicación de método predictivos al consumo de agua potable de una zona urbana de la ciudad de Madrid en España, cuyo componentes son es realizar el pronóstico del consumo de agua potable en la ciudad de Madrid con el método ARIMA.

En la investigación de Vidaurre (2012), se describe la denominación de ciudades inteligentes que abarca varios factores y uno de los retos más fundamentales es la gestión adecuada del consumo de agua potable es por ello que es fundamental el uso de sistemas expertos o inteligentes y para ello en este trabajo se estudia las variables de relación a la demanda del consumo de agua potable considerando aspectos como las escalas espaciales y temporales, para realizar o desarrollar un modelo para realizar la predicción de consumo de agua potable urbana, tanto en corto como también el mediano plazo, en esta investigación se propone la aplicación de un algoritmo de autoaprendizaje basado en regresión lineal ya que es completamente que es adaptable a cualquier tipo de predicción de tipo temporal y espacial, en esta metodología fue fundamentada en el procesamiento de datos para pronosticar el consumo de agua, en un periodo corto de tiempo considerando la periodicidad horaria, sobre la disponibilidad lectores automáticos de medición, la contribución de esta investigación es la aplicación de la inteligencia artificial con métodos predictivos para la determinación del consumo de agua potable a futuro en una zona urbana, y los componentes de la contribución es la aplicación del algoritmo de autoaprendizaje basado en regresión lineal, para estimar o predecir consumos de agua potable en zonas urbana en un periodo corto de tiempo.

Tavera (2013), señala que dentro de los aspectos fundamentales a considerar dentro de la planificación para un sistema de agua potable es el nivel de consumo del mismo, información que debe contar todas las empresas que brindan este servicio, adicional a ello se debería contar con una herramienta que permita procesar datos temporales para obtener informes y resultados proyectados a corto, mediano y largo plazo, para predecir el consumo futuro y proponer dentro de la planificación los recursos necesarios para cubrir la demanda futura, en esta investigación dentro de su sistema denominado EPANET, incorpora un módulo que permite la predicción del consumo de agua usando las series temporales, la que le permite almacenar y procesar datos históricos del consumo de agua potable, la contribución de esta investigación es la aplicación del algoritmo de series temporales, en la estimación o predicción de consumo de agua.

Encina-Pacheco et al. (2023), señala que se debe aplicar modelos y técnicas eficientes para estimar el consumo de agua potable, en su investigación demuestra que el modelo desarrollado de tipo estocástico usando la técnica ARIMA, cuya aplicación son la base de los principales modelos que permiten predecir o estimar el consumo de agua potable, para ello se propone una metodología donde se incorpora un modelo estocástico de predicción, la contribución de esta investigación es la aplicación del modelo ARIMA, en la estimación o predicción de consumo de agua.

Pavón (2019), en su tesis señala lo importante que es el pronóstico de la demanda del consumo del agua debido al no tener una planificación adecuada, no se puede tener claro las actividades que se desarrollarán en un futuro, ocasionando que se genere un comportamiento difuso de las variables y los criterios, generando así una incertidumbre que afecta mucho a la empresa de saneamiento. Se utiliza la herramienta Neural NetWork, de Matlab, tomando también la importancia de los pronósticos en el proceso de planificación, también en el área organizacional y control de actividades o procesos. Evaluaron el horizonte temporal del pronóstico logrando

determinar las variables de entrada del modelo tanto como el volumen de consumo del agua de años posteriores. Teniendo de resultado de 4,71 en para el error cuadrático medio y en el coeficiente de correlación 0,98, lo cual indica una alta fiabilidad del pronóstico comparado a los modelos estadísticos tradicionales. Logrando un pronóstico importante para el desarrollo de la empresa y estudio técnico a futuro, la contribución de esta investigación es la aplicación del algoritmo de predicción en la herramienta MATLAB para un mejor manejo.

Miranda-Mosquera et al. (2016), señalan que los índices de calidad en cuerpos de agua superficiales en la planificación de los recursos hídricos, también explican que la planificación de recursos hídricos es fundamental para el desarrollo de una alta calidad socioeconómica por ello considera 16 factores que ejercen influencia sobre el consumo el consumo de agua que realiza la población, pensando en los factores influyentes desarrollaron una red neuronal tipo back propagation para la realización del estudio, los datos empleados para el estudio son de la provincia de China llamada Guizhou y datan del periodo entre los años 2000 a 2020 se menciona también que el estudio busca predecir el consumo de agua en los próximos 10 años, con respecto a los resultados obtenidos se ha concluido que si bien el tipo de red neuronal empleado en el estudio alcanza un mayor nivel de eficacia que otros métodos está aún ha tenido un fallo al predecir el consumo del año 2017 en donde se alejó bastante de los datos provenientes de la realidad, se cree que esto se debe, por haber empleado muchos factores de influencia puesto que esto genera masividad de datos que para ese año en concreto a afectado la capacidad de predicción del modelo, la contribución de esta investigación es la aplicación de una red neuronal back propagation para la predicción del consumo de agua en Guizhou.

En su estudio Galán (2020), señala que el desarrollo de modelos predictivos basados en redes neuronales artificiales (RNA) se ha convertido en una herramienta esencial en la gestión de

recursos especialmente en la planificación y distribución de agua potable. Los nuevos sistemas de gestión de recursos incluyendo el internet de las cosas, se orientan hacia un modelo de “Smart Cities” donde se genera una gran cantidad de datos que necesitan ser validados previamente a sus usos. en ese contexto, su estudio se centra en la estimación de consumos de agua potable de la red de abastecimiento de la empresa Municipal de Aguas de Córdoba, utilizando diferentes modelos predictivos basados en RNA, los modelos empleados son el NFIT, el NARX y el aprendizaje profundo LSTM. Se realizaron pruebas con diferentes configuraciones de arquitecturas y se evaluó el rendimiento de cada modelo mediante el cálculo de una serie de datos estadísticos. En base a los resultados muestran que el modelo RNA LSTM tuvo el mejor comportamiento en la predicción de los consumos de agua con un horizonte de una hora para todos los contadores analizados. Además, se observó que el modelo NARX presentó una mayor precisión que el NFIT en la mayoría de los casos excepto para el contador de mayor tamaño, la contribución de esta investigación es la aplicación de diferentes modelos de redes neuronales para la estimación de consumo de agua potable en la red de abastecimiento de la empresa municipal de aguas de Córdoba, la donde se realiza la evaluación de diversas arquitecturas y cálculos estadísticos para comparar el rendimiento de los modelos.

Farah y Shahrour (2017), los autores presentan una aplicación de modelos de redes neuronales artificiales que predice el consumo de agua en 2 escalas: Área de medición del Distrito (DMA) ubicada en el Campus científico de la Universidad de Lille y el usuario final que representa un restaurante dentro de este DMA. Los datos que se recopilaron fueron de Lectores de Medidores Automatizados (AMR) que midieron en tiempo casi real el consumo de agua. En su estudio los modelos se entrenaron en intervalos de tiempos diarios y horarios utilizando valores históricos y la variación entre la hora y el tipo de día. El estudio muestra que los modelos basados en RNA

pueden predecir bien el consumo de agua, incluido los valores máximos, el componente de contribución de esta investigación es la aplicación de modelos de redes neuronales artificiales para la predicción de consumo de agua en dos escalas: DMA y usuario final.

Liang-Xu et al. (2012), plantean un modelo de sistema complejo que emplea redes neuronales profundas para la gestión del agua urbana este es un artículo ampliamente relacionado con la predicción del consumo de agua puesto que comenta que para optimizar la gestión de distribución del agua en zonas urbanas es necesario conocer el consumo que estas zonas tienen. Este artículo señala que el desarrollo de las zonas urbanas, el crecimiento de las industrias y el aumento de la temperatura global son factores que han incrementado el consumo de agua en gran medida por lo que es necesario racionar y maximizar el valor del recurso hídrico pero esta es un trabajo extremadamente complejo de realizar por ello propone una arquitectura de 4 capas y analizando 15 indicadores divididos en 3 grupos que son factor socioeconómicos, factor meteorológico y factor energético para la concepción de su modelo de red neuronal de tipo LSTM, los datos usados para la experimentación provienen del boletín de recursos hídricos de Chongqing, por último concluyen que su modelo logra predecir eficazmente el consumo de agua urbana, la contribución de esta investigación es la aplicación de una red neuronal LSTM para la predicción del consumo de agua con datos obtenidos del boletín Chongqing.

## 1.5. Objetivos

### *1.5.1. Objetivo General:*

Desarrollar un modelo de predicción basado en redes neuronales artificiales para pronosticar de manera precisa el consumo de agua potable en la ciudad de Iquitos, utilizando variables históricas relevantes, y otros factores como el clima y la población.

### *1.5.2. Objetivos Específicos:*

- Analizar los Requerimientos del modelo de predicción basado en redes neuronales artificiales para pronosticar los patrones estacionales de consumo de agua potable en la ciudad de Iquitos, utilizando datos históricos y variables climáticas como inputs.
- Diseñar un modelo de predicción basado en redes neuronales artificiales para estimar de forma precisa el consumo de agua potable, empleando datos históricos de temperatura, precipitación y crecimiento poblacional.
- Validar la precisión de la predicción del modelo basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos.

## 1.6. Hipótesis

### *1.6.1. Hipótesis general:*

El desarrollo de un modelo de predicción basado en redes neuronales artificiales pronostica de manera precisa el consumo de agua potable en la ciudad de Iquitos al considerar variables históricas relevantes, así como factores ambientales como el clima y la población.

### *1.6.2. Hipótesis específicas:*

- El análisis de los Requerimientos del modelo de predicción basado en redes neuronales artificiales identifica los patrones estacionales de consumo de agua potable en la ciudad de Iquitos, utilizando datos históricos y variables climáticas como inputs.
- El diseño de un modelo de predicción basado en redes neuronales artificiales estima de forma precisa el consumo de agua potable, empleando datos históricos de temperatura, precipitación y crecimiento poblacional.
- La validación de la precisión de la predicción del modelo basado en redes neuronales artificiales contribuye al pronóstico efectivo del consumo de agua potable en la ciudad de Iquitos, mediante técnicas de cálculo del error, medio absoluto (MAE), el error cuadrático medio (MSE) y el coeficiente de determinación ( $R^2$ ).

## II. MARCO TEÓRICO

### 2.1. Marco conceptual

#### *2.1.1. El Sistema de Agua Potable*

Para Cáceres (2021), es el proceso donde el agua recibe tratamiento desde el punto donde se capta o recolecta hasta el punto de expendio llegando a este punto en condiciones aptas para el consumo humano o potabilizado. El agua potable no solo es considerada como aptas por las condiciones sanitarias de calidad, sino también por la cantidad en la que es distribuida

Vásquez (2019), señala es un conjunto de conexiones, instalaciones, tuberías, equipos y plantas que se utilizan para proporcionar agua potabilizada para que el ser humano pueda tener el servicio de manera continua y en la calidad y cantidad necesaria para satisfacer las necesidades de los usuarios.

#### *2.1.2. Producción del Agua Potable*

Para Zhou (2002), iniciar el proceso de producción del agua potable debe pasar por varios procesos empezando por el de captación o extracción de agua bruta desde una fuente de agua natural para luego llevarla hasta los reservorios donde se ejecuta el tratamiento para su potabilización, la captación del agua se realiza teniendo en consideración distintos orígenes, en la etapa producción del agua potable se realiza diferentes procesos de potabilización, donde el agua se somete a varios tratamientos filtración y de desinfección, en el proceso de producción el agua incluye etapas de retención de material grueso y fino en suspensión, aplicando tratamientos con insumos químicos.

### ***2.1.3. Distribución del Agua Potable***

Para Grandez (2019), la distribución del agua potable se realiza a través de las tuberías que llega a cada uno de los puntos o conexiones domiciliarias o industriales, estas conexiones empieza desde los reservorios donde se encuentra el agua potabilizada o tratada, aquí se encuentran las tuberías de PVC o fierro, estaciones de bombeo, válvulas, y los sistemas de transporte de agua, este sistema se encuentra sectorizado ya en caso de rupturas de tuberías emergencias se pueda controlar de manera adecuada, este proceso concluye en los dispositivos de medición de volumen de agua en los puntos donde se abastece.

Para Eytan y Dorothee (2020), el proceso de distribución del de agua potable hasta las conexiones domiciliarias de los consumidores, también se puede ejecutar a través de vehículos cisterna cuando esto no sea posible realizarlo por alimentación directa a presión mediante las redes o tuberías, la distribución por medio de los reservorios o tanques elevados de la ciudad son los más adecuados y mucho más efectivos a la hora de distribuir el agua potable ya que suelen tener mejores presión como también de las interrupciones o cortes en las tuberías, y además se encuentran en las distintas zonas urbanas de una ciudad, para facilitar su sectorización y Micro medición del Agua Potable

Laura (2012), señala que la micro medición del agua potable es el proceso que hace referencia realizar la medición, instalación y reparación de los dispositivos denominados micromedidores, esto con el objetivo de conocer de manera sistemática el volumen de agua que consumen los usuarios, también sirve para garantizar que este consumo de agua potable se realice dentro de los patrones establecidos y que el cobro de realice de manera justa y equitativa.

Según CONHYDRA (2010), el proceso de micro medición de agua potable es aquella actividad donde se realiza la medición del volumen del agua y también el control del caudal, teniendo en consideración el diámetro de alimentación y descarga estos deben estar entre 0.5 y 1 pulgadas ósea entre 15 y 25 mm, este proceso se realiza con los dispositivos llamados micro medidores que se instalan en las residencias y pequeños locales comerciales.

La Superintendencia Nacional de Servicios de Saneamiento (SUNASS, 2003), señala que el consumo del agua potable de los usuarios se determina por medición, permitiendo que estos se beneficien, pagando lo que consumen o también regular el consumo que puede pagar, ya que los sistemas de agua potable incrementan su capacidad para atención.

#### ***2.1.4. Facturación del Agua Potable***

SUNASS (2007), señala que durante el proceso de distribución en cada conexión doméstica se registra el consumo de agua potable en volumen de m<sup>3</sup>, en un periodo de tiempo o ciclo y se calcula en precio monetario de acuerdo a la tarifa reglamentaria.

#### ***2.1.5. Proceso del cálculo del consumo de agua potable***

Vidaurre (2012), señala que para realizar este proceso primero se clasifican o agrupan datos de los grupos o tipos de conexiones o usuarios para referenciarlos a su consumo, frente a la facturación promedio realizada en un periodo de tiempo para luego analizarla para estimar el cálculo del consumo de agua de los usuarios.

Para la determinación del consumo de agua potable actual, se seleccionan y estudian los grupos de consumidores de acuerdo a características homogéneas, en ello se considera el o los tipos de consumo de agua los cuales son el comercial, el residencial y el industrial, también se

debe analizar la cobertura actual de servicio y también el promedio de la facturación mensual para cada grupo definido.

### ***2.1.6. Predicción del Consumo de agua potable***

Pereda-Santos et al. (2017). Este proceso sirve para la toma de decisiones empresariales, y para se debe realizar pronósticos usando cálculos matemáticos basados en datos anteriores o series temporales de tiempo; la predicción es parte de resultado del análisis de datos o cifras obtenidas a lo largo de los años.

### ***2.1.7. Redes Neuronales Artificiales***

Herrera-Torgo et al. (2010), señala que es una herramienta matemática, con capacidad para aprender a partir de la experiencia durante cada proceso de entrenamiento, todo este proceso se almacena y procesa en un gran número de nodos donde cada uno de ellos asume funciones de procesamiento.

Tostado-Ornelas et al. (2016), señala que esta herramienta de la inteligencia artificial emular o imita la organización o función de las redes neuronales del ser humano, su objetivo es construir sistemas que permitan el procesamiento y almacenamiento de información en cada proceso de entrenamiento.

Hilera y Martínez (2000), El funcionamiento de las redes neuronales artificiales es simple, por que consiste en la recepción de valores de entradas en las neuronas colindantes para luego realizar el cálculo de un valor de salida, este resultado debe ser enviado a todas las células restantes.

### ***2.1.8. Red Neuronal Artificial Recurrente (RNN)***

Son una extensión de las redes neuronales tradicionales, estas se caracterizan por ser un modelo que posee memoria. guarda muchas similitudes con las red neuronales comunes pero a diferencia de estas en la que la información solo viaja desde la entrada de la neurona hacia la salida sin dar marcha atrás en ningún momento del proceso las redes neuronales recurrentes si cuentan con conexiones que les permiten retroceder entre las capas del modelo contando con la información de estados previos que posteriormente es tomada en cuenta para la entrega de la salida, la parte que reserva los estados de la neurona es llamada memory cell, es por esta capacidad de recordar que se emplean para realizar predicciones o analizar texto.

### ***2.1.9. Memoria de Largo Plazo (LSTM)***

Pertenece al grupo de redes conocidas en español como redes neuronales recurrentes ,LSTM es un modelo que maximiza la memoria de la neurona con el objetivo de que esta obtenga la capacidad de recordar experiencias por un largo tiempo ya que esta almacena datos en su memoria que luego decide si agregar, borrar o editar la información que tiene almacenada en función de la importancia que se le dé a esa información nueva, se cuenta con 3 tipos de puertas, input gate usada para las entradas, output gate usada para las salidas y forget gate la puerta para olvidar.

### ***2.1.10. Lenguaje de programación Python***

Es en lenguaje de programación ampliamente utilizado para labores de desarrollo informático, entre los usos más destacados en la actualidad está el emplear este lenguaje para el desarrollo de redes neuronales esto debido a la principal característica de este lenguaje es el tener

una sintaxis que facilita la lectura del código permitiendo crear código más eficiente de manera sencilla, además también cuenta con soporte para los sistemas operativos más usados y una amplia comunidad de desarrolladores que interactúan en los foros dedicados a Python.

### ***2.1.11. Plataforma de Programación MATLAB***

Es un entorno de desarrollo, además de un lenguaje de programación hecho para la realización de cálculos numéricos, análisis de datos y visualización de resultados. El nombre "MATLAB" es una abreviatura de "Matrix Laboratory", ya que el software fue originalmente diseñado para realizar operaciones con matrices. Es utilizado en una amplia variedad de campos, incluyendo ingeniería, física, matemáticas, finanzas y ciencias biológicas, entre otros. La herramienta es especialmente útil para el proceso sucesivo de señales, anteproyectos de sistemas de control y la predicción en entornos de simulación de sistemas dinámicos.

### ***2.1.12. Aprendizaje automático (Machine Learning)***

El aprendizaje automático (Machine Learning en inglés) es una parte de los sistemas de inteligencia artificial que está enfocada en el desarrollo de algoritmos y modelos estadísticos permitiendo a los sistemas informáticos aprender y mejorar su desempeño en tareas específicas a través de la experiencia. En lugar de programar explícitamente un sistema para que realice una tarea específica, el aprendizaje automático permite que un sistema aprenda de los datos y la experiencia para mejorar su desempeño en una tarea determinada. Esto se logra mediante la identificación de patrones y relaciones en los datos, y la creación de modelos estadísticos que se pueden utilizar para predecir o clasificar nuevas observaciones. El aprendizaje automático se utiliza en una amplia variedad de campos, como el pronóstico de sucesos, la identificación de spam en el correo electrónico, la recomendación de productos en línea, la clasificación de imágenes y el

reconocimiento de voz, entre otros. Con la creciente cantidad de datos que se generan en todo el mundo, el aprendizaje automático en estos días logró convertirse entre lo más importante para apoyar a las empresas y las organizaciones a analizar y aprovechar esos datos de manera efectiva.

### **2.1.13. Modelo ARIMA**

El método ARIMA (Autoregressive Integrated Moving Average) es una técnica de modelado de series de tiempo que se utiliza para predecir valores futuros en función de patrones históricos. ARIMA es un modelo estadístico que se utiliza para modelar y analizar datos de series temporales, y es muy útil para predecir valores futuros en una amplia variedad de campos. Se compone de tres componentes principales: el “AR” (modelo autoregresivo), el “MA” (modelo de media móvil) y el “I” (modelo de integración). El modelo AR para predecir los valores futuros, utiliza los valores pasados de la serie temporal, mientras que el modelo MA utiliza el error pasado para predecir los valores futuros. El modelo de integración se utiliza para transformar la serie temporal en una serie estacionaria, lo que ayuda a mejorar la precisión de las predicciones. Este método es muy flexible y puede ser personalizado para ajustarse a una amplia variedad de situaciones y conjuntos de datos. Es de las herramientas más utilizadas ya que es muy útil para el análisis y la predicción de datos de series temporales, y es ampliamente utilizado en la industria y la investigación científica.

## 2.2. Terminologías

- Agua Potable: es el agua que se consume el ser humano sin restricción alguna debido a su calidad que posee y de no representar un riesgo para la salud del ser humano.
- Pronóstico: es la acción o procedimientos de conocer lo futuro a través de ciertos indicios o datos.
- Tarifa de Agua Potable: es una herramienta regulatoria aprobada por la entidad reguladora (SUNASS) cuyo objetivo es proporcionar un costo adecuado por el uso y consumo de este líquido de los usuarios.
- Saneamiento: Consiste en la eliminación o reducción de contaminantes existentes en el agua, logrando que sean aptas para consumo humano. En el proceso del saneamiento se eliminan bacterias, virus, parásitos, productos químicos, metales pesados, sedimentos y cualquier otro contaminante que pueden llegar a ser nocivos para la salud.
- Reservoirio: Bajo el contexto de este estudio reservoirio hace referencia las estructuras de gran tamaño ubicadas en puntos estratégicos en la ciudad de Iquitos estas están conectadas con la planta de tratamiento de agua y se encargan de cargarse con gran cantidad de litros de agua para luego comenzar a distribuirlas en la zona en la que se encuentran edificadas.

## 2.3. Estado del Arte

La investigación para la búsqueda de las posibles soluciones del proyecto, se basa en el planteo de métodos donde se aplican algoritmos para el pre procesamiento, balanceo, extracción, selección de los datos para construir una red neuronal artificial, también es necesario validar el modelo para realizar el pronóstico de la demanda del consumo de agua, las alternativas presentadas son algoritmos de entrenamiento disponibles en el software MATLAB, que corresponde a la herramienta utilizada para la predicción en este trabajo.

Para la elaboración del estado del arte de la investigación se plantea las siguientes etapas:

### 2.3.1. Fase 1: Planificación

Para esta fase de la planificación del estado del arte de la investigación, formularemos las siguientes preguntas:

- Q1: ¿Qué modelos de predicción usando las redes neuronales artificiales existen para determinar el consumo de agua potable?
- Q2: ¿Qué componentes tiene los modelos para predecir el consumo de agua potable usando las redes neuronales artificiales?
- Q3: ¿Qué tipo de redes neuronales artificiales existen para predecir el consumo de agua potable?
- Q4: ¿Cómo se puede validar un modelo de predicción del consumo de agua potable usando redes neuronales artificiales?

Que serán buscado en las siguientes bases de datos de las revistas y bibliografía:

- Redalib
- Researchgate

- Scielo
- Google Scholar

La técnica de búsqueda con palabras claves (cadena de búsqueda) se tomó en consideración lo siguiente:

- Cadena de búsqueda:
- (usar en título, keywords, abstract)
- (modelo de predicción de consumo del agua potable) and (Redes neuronales artificiales)
- (Metodologías predicción AND consumo de agua potable) or (Modelos de pronóstico de consumo agua potable)
- (Drinking water consumption prediction model) and (Artificial neural networks)
- (Methodologies for prediction of drinking water consumption) or (Forecast models of drinking water)

Para los criterios de selección se plantea los siguientes criterios de selección de los artículos:

### **Tabla 1**

#### *Criterios de selección de fuentes de información*

<b>Criterios de Inclusión</b>	<b>Criterios de Exclusión</b>
<ul style="list-style-type: none"> <li>▪ Documentos que cuenten con Digital Object Identifier (DOI).</li> <li>▪ Documentos que propongan una metodología para desarrollar un modelo de predicción usando redes neuronales artificiales.</li> <li>▪ Documentos donde se explique con claridad el propósito de la investigación.</li> <li>▪ Documentos donde la metodología de la investigación esté claramente explicada.</li> </ul>	<ul style="list-style-type: none"> <li>▪ Documentos que no estén escritos en idioma inglés o español.</li> <li>▪ Documentos que no sean únicos.</li> <li>▪ Documentos con un abstract no muy relevante.</li> <li>▪ Documentos que sean mayor a 5 años de antigüedad.</li> </ul>

De la **Tabla 1**: Criterios de selección se considera la inclusión y exclusión de los documentos a considerar para estructurar el estado del arte de la investigación.

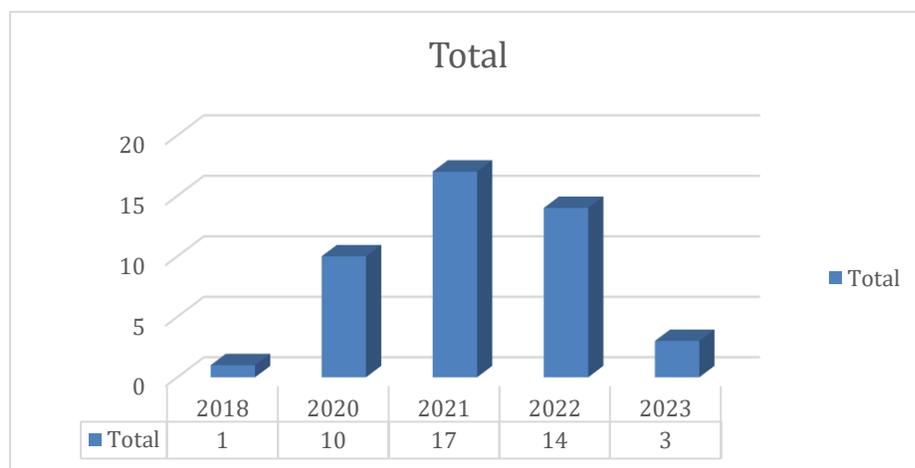
### ***2.3.2. Fase 2: Desarrollo***

Luego de la aplicación de los criterios de selección en los documentos recopilados según algunas fuentes de búsqueda mencionadas; se seleccionaron solo 10 artículos para realizar el análisis del contenido debido a que las investigaciones sobre el pronóstico del consumo de agua potable utilizando las redes neuronales artificiales durante los 3 últimos años.

### ***2.3.3. Fase 3: Resultados***

#### **Figura 1**

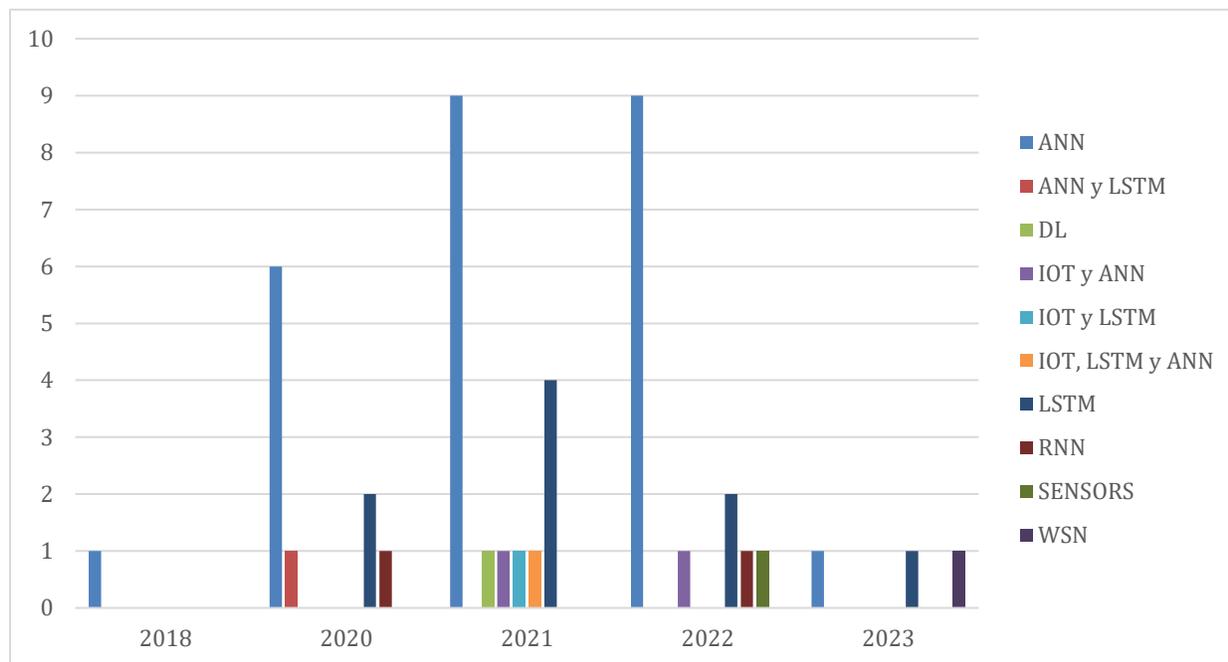
*Porcentaje de documentos seleccionados según año de publicación*



Nota. En la Figura 1, se visualiza que, en el año 2021, prepondera el número de publicaciones sobre sistemas y metodologías que utilizan las redes neuronales para realizar predicciones sobre el consumo de agua potable con un total de 17 respectivamente. Hasta el año 2023.

**Figura 2**

*Porcentaje de documentos seleccionados según la tecnología usada*



*Nota 1.* En la figura 2, se visualiza que el 50% de los artículos seleccionados, el 50% utiliza como tecnología base las Redes Neuronales, el 30% utiliza IOT, el 10% Machine Learning, el 5% Sistemas Expertos, el 5% Deep Learning.

**Tabla 2**

*Referenciación de artículos relacionado a la tecnología que se usan para el pronóstico del consumo de agua potable*

HERRAMIENTA TECNOLÓGICA	REFERENCIAS
ANN	[Zanfei, 2022] [ Zanfei, Menapace y Righetti, 2023] [ Rustam, Ishaq, Tabinda, Torre, Mazon, Rodriguez y Ashraf, 2022] [ Zanfei, Menapace y Righetti, 2021] [ Vijay y Kamaraj, 2021] [ Jin, Ynag y Fulton, 2021] [ Zanfei, Brentan, Menapace y Righetti, 2022] [ Bezuidenhout, 2018] [ Mo'tamad H. Bata , Rupp Carriveau y David S.-K. tintineo] [ T. Ibrahim, Y. Omar y FA Maghraby, 2020] [ Lenin Quiñones Huatangari, Luis Ochoa Toledo, Oscar Gamarra Torres , José Bazán Correa, Jorge Delgado Soto, Nicolás Kemper Valverde, 2020] [ Bata, M., Carriveau, R. y Ting , 2020] [ Qiang GE, Liying WANG, Weiguo ZHAO, Shixiang GU] [ Shi Chaoyang, Zhen Zhang, 2021][ M Li, LG Tian, JY Zhang y HL Duan, 2020] [ Taís Maria Nunes Carvalho, Francisco de Assis de Souza Filho, y Víctor Costa Porto, 2021] [ wenjin hao, Andrea Cominola, Andrea Castelletti, 2022] [ Rustam, F.; Ishaq, A.; Kokab, S.T.; de la Torre Diez, I.,2021] [ Louis-Gabriel Maltais, Louis Gosselin, 2021] [ Tony Salloom, Okyay Kaynak, Wei He. 2021] [ Khan SAR, Yu Z, Sharif A, 2021] [ Jing Bi, Yongze Lin,Quanxi Dong , Haitao Yuan. MengChu Zhou,2021] [ Pahont,u, B.; Chiru, C.G.; Apostol,E.-S.; Truic, C.-O.,2022]
ANN y LSTM	[Nasser, Rashad y Hussein, 2020]
DL	[Tony Salloom, Okyay Kaynak y Wei He, 2021]
IOT y ANN	[Aggarwal, Sehgal, 2022] [ Rui Zhao, 2021]
IOT y LSTM	[Gholami, Mouna y Duchesne, 2021]
IOT, LSTM y ANN	[Lopez, Haripiya, Raveendran, Bebè y Priya, 2021]

LSTM	[Aggarwal, Sehgal, 2021] [AA Nasser, MZ Rashad y SE Hussein, 2020] [Ariele Zanfei, Bruno M Brentan, andrea menapace, Mauricio Righetti y Manuel herrera, 2022] [Jun Hao Wu ; Zhaocai Wang ; Leyiping Dong, 2021] [Christian Kuehnert , Naga Mamatha Gonuguntla ,helena krieg ,Dimitri Nowaky, Jorge A. Thomas, 2021] [li-mu ; Feifei Zheng ; Ruoling Tao ; qingzhou zhang y zoran kapelan, 2020] [Ruochen Lei, Jian Yin, 2022] [Baigang Du , Qiliang Zhou , Jun Guo, Shunsheng Guo , Lei Wang , 2021] [Lixiang Wang; Huilin Dong; Yuqi Cao; Dibo Hou; Guangxin Zhang,2023]
RNN	[Zanfei, Brentan, Menapace, Righetti y Herrera, 2022] [Juntao Zhang, Ziyue Zhang, Ying Weng,Simon Gosling , 2020]
SENSORS	[Ahmed I. Taloba,2022]
WSN	[Aggarwal, Sehgal, 2022] [A. Al-Ghamdi, S. Kamel and M. Khayyat,2022]
TOTAL	45

En la Tabla 2, se visualiza que de los 45 documentos revisados las redes neuronales artificiales son las más utilizados para resolver los problemas de pronóstico del consumo de agua.

#### **2.3.4. Fase 4: Análisis**

Esta investigación se desarrollará en la E.P.S. Sedaloretto S.A. donde actualmente existe la necesidad de pronosticar del consumo de agua potable de manera efectiva que servirá para una buena toma de decisiones y que la tendencia de esta metodología y su utilización en los últimos 3 años justifica hacer una revisión exhaustiva al respecto.

Entre las fechas del 11 – 17 de Setiembre del año 2022, se alcanzó el mayor pico en búsquedas de interés correspondientes a la Predicción con un total de 100, para redes Neuronales un total de 83 y finalmente para la demanda de consumo de agua potable, un total de 0.

### ***2.3.5. Fase 5: Discusión***

En los últimos años, se han identificado recursos en preferencia que han sido utilizados para mejorar los procesos de la predicción de la demanda de agua. Las herramientas más populares y recomendadas son las Redes Neuronales Artificiales (ANN) y las Memorias a Corto Plazo (LSTM), las cuales brindan excelentes resultados en las predicciones tanto a corto como a largo plazo, con una precisión que depende del tiempo.

Estando relacionado, un artículo de Nasser-Rashad et al. (2020), en el que aplica su sistema en zonas urbanas haciendo uso de micro servicios (IoT) y redes neuronales LSTM, muestra su modelo de gestión en la que ofrece medidas cuantitativas para la reducción de la demanda de agua en horas punta, una mejor distribución de demanda de agua y menor consumo de agua. Además, de medir el efecto en el desarrollo y la expansión previstos de la cual impone la infraestructura y el rendimiento de la red de agua, llegando a reiterar que la transmisión de datos en tiempo real es fundamental para la solución del sistema en el procesamiento posterior y la posible predicción necesaria para situaciones críticas de gestión. acerca de su funcionamiento según Prabhakar y Furqan (2022), los sistemas hechos con sensores en IoT llegan a ser muy costosos por lo que se optan por un medidor dado por la empresa de agua.

Con lo que respecta, en el estudio hecho por Prabhakar y Furqan (2022), se centra tanto en la calidad y la predicción del consumo del agua, mostrando interés en el manejo significativo que tendrán estas tecnologías en los futuros años. Presenta un modelo ANN eficiente que se utiliza para proporcionar tanto una alta precisión como resultados robustos para la calidad y la predicción del consumo del agua. los experimentos que se realizaron revelan un excelente rendimiento del enfoque propuesto, obteniendo que la ANN alcanza un  $0.997 R^2$  para la predicción del consumo

del agua, siendo mejor que los enfoques existentes, observando que la arquitectura de red neuronal simple funciona bien en comparación con modelos de aprendizaje profundo complejo como CNN, LSTM y GRU.

Sin embargo, a esto, hay un estudio hecho por Shirkoohi-Doghri et al. (2021), titulado “Predicciones de la demanda de agua a corto plazo acoplado un modelo de red neuronal artificial y un algoritmo genético”, explica como haciendo uso del algoritmo genético se puede optimizar los hiperparámetros que usara el modelo ANN. Llegando a experimentar con el Modelo ARIMA, para una comparación de resultados, Teniendo como conclusión de que los modelos ANN superan los modelos clásicos de series temporales y basados en patrones, dándole la razón a la investigación de Prabhakar y Furqan (2022), pero recalcando que esto solo ocurre en casos de corto plazo, ya que muchos autores como Nasser-Rashad et al. (2020) señalaron que los modelos como ARIMA o basados en patrones dan mejores predicciones en tiempos de largo plazo.

Relacionando lo expuesto por Ibrahim-Maghraby et al. (2020), se reitera la importancia de plantear modelos de predicción para la demanda del agua ya que el contar con el recurso hídrico es determinante para la sostenibilidad del desarrollo económico y social, también hace énfasis en que la información obtenida a través de los estudios realizados apoyara activamente la toma de decisiones sobre los procesos involucrados desde la captación hasta la distribución para lograr su optimización.

Buscando un objetivo similar de prevenir la escases de agua por no conocer la predicción de la demanda Bata-Carriveau et al. (2020) en su artículo “Pronóstico de la demanda de agua a corto plazo utilizando un modelo híbrido de aprendizaje automático supervisado y no supervisado” propone la combinación de 2 métodos de aprendizaje automatizado, esto con el objetivo de obtener

una fiabilidad más alta en los resultados obtenidos y se ha conseguido demostrar que bajo el campo de realización del estudio el método combinado ha superado a métodos tradicionales como lo sería el método ARIMA.

Los autores Hao-Cominola et al. (2022) dieron por hecho que los métodos más tradicionales son superados por modelos predictivos de aprendizaje automático, por ello optaron por emplear 2 tipos de redes neuronales y comparar los resultados individuales logrando evidenciar que estos modelos consiguen un alto índice de predicción, siendo el modelo LSTM el que ha demostrado mayor rendimiento.

Predecir la demanda de agua es un desafío crítico para la gestión y planificación del suministro de agua. Muchos investigadores han utilizado redes neuronales y otros métodos de aprendizaje automático en el campo de la predicción del consumo de agua en los últimos años y han obtenido buenos resultados.

Un estudio realizado por Alghamdi-Kamel et al. (2021). señalan que la técnica tradicional ARIMA es ineficiente al tratar con grandes cantidades de datos o para predecir series temporales multivariadas. Por ello, proponen un modelo híbrido llamado PSO-ANN para pronosticar las necesidades diarias de agua, considerando las condiciones climáticas. Los resultados muestran que PSO-ANN es un modelo preciso y confiable para la previsión.

Sin embargo, Salloom-Kaynak et al. (2021), promueven una novedosa arquitectura de red neuronal de tipo profunda para la previsión de la demanda de agua en tiempo real en el año 2021, argumenta que los enfoques de aprendizaje profundo (DL) proporcionan soluciones más precisas para este propósito. Este autor propone que mediante una nueva estructura de red neuronal artificial con el objetivo de minimizar el número de parámetros entrenables mientras se mantiene un nivel

de precisión de pronóstico no inferior al informado en trabajos previos. El modelo DCGRU propuesto logra este objetivo con éxito. No obstante, el modelo se basa en el historial de demanda de agua, lo que lo hace vulnerable a anomalías en la demanda.

Zanfei-Menapace et al. (2023), en la conferencia propone que mediante una aplicación práctica de una red neuronal artificial para modelar la demanda de consumo de agua urbana en un sistema de suministro o distribución de agua potable. En su estudio, se evalúa un modelo MLP para modelar la demanda con resoluciones tanto horarias como diarias, y los resultados muestran que las métricas destacan rendimientos superiores para los modelos que reproducen la demanda con menos horas de horizonte. En conclusión, se proponen una serie de modelos a corto plazo con diferentes objetivos y se discuten estos últimos, dejando que los trabajos futuros aborden más el papel de las entradas meteorológicas en el contexto de la previsión de la demanda de agua a corto plazo.

### III. MÉTODO

#### 3.1. Tipo de investigación:

##### *3.1.1. Tipo de Investigación:*

La investigación propuesta se enmarca dentro de un tipo de investigación aplicada, ya que tiene como objetivo principal desarrollar un modelo de predicción basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos. El propósito de la investigación es aplicar este modelo en la práctica para mejorar la planificación y gestión del suministro de agua potable en la ciudad.

##### *3.1.2. Enfoque de la Investigación*

Esta investigación tendrá el enfoque de investigación cuantitativa; para Garduño (2002) este tipo de enfoque está relacionado a las ciencias exactas, el caso que nos aborda es la de realizar la predicción del consumo de agua potable de los habitantes de la ciudad de Iquitos en un periodo de tiempo, se utilizara datos numéricos que tendrán que ser calculados tanto con las fórmulas matemáticas como la estadística para realizar la prueba de hipótesis.

##### *3.1.3. Nivel*

La investigación propuesta se encuentra en el nivel de investigación descriptiva y predictiva. En cuanto a la investigación descriptiva, busca analizar y describir las relaciones entre las variables relevantes, como los factores ambientales, los datos demográficos y las tarifas de agua, y el consumo de agua potable en la ciudad de Iquitos. Esto implica recolectar datos históricos, realizar análisis estadísticos y examinar patrones y tendencias en el consumo de agua.

Por otro lado, la investigación también tiene un componente predictivo, ya que tiene como objetivo desarrollar un modelo de predicción basado en redes neuronales artificiales para pronosticar el consumo futuro de agua potable en Iquitos. Este modelo utilizará los datos históricos y las variables relevantes para generar pronósticos cuantitativos precisos sobre el consumo de agua potable en un período futuro específico.

#### ***3.1.4. Diseño***

El diseño de la investigación se basará en un enfoque longitudinal, utilizando datos históricos de consumo de agua potable en la ciudad de Iquitos. Se recopilarán datos sobre factores ambientales y datos demográficos, junto con el consumo de agua potable. Estos datos se utilizarán para entrenar y ajustar el modelo de predicción basado en redes neuronales artificiales. Se evaluará la precisión del modelo utilizando métricas como el error medio absoluto (MAE), el error cuadrático medio (MSE) y el coeficiente de determinación ( $R^2$ ). El diseño de la investigación también puede incluir análisis estadísticos para investigar las relaciones entre las variables y examinar patrones y tendencias en el consumo de agua potable en Iquitos.

### **3.2. Población y muestra**

#### ***3.2.1. Población***

La población objetivo de este proyecto está constituida por los usuarios de agua potable en la ciudad de Iquitos, incluyendo hogares, comercios e industrias que son abastecidos por la empresa Sedaloreto, se recopilarán datos históricos de consumo de agua potable durante 60 meses, así como datos de temperatura y precipitación de lluvias proporcionados por SENHAMI, datos demográficos del INEI y facturación de consumo de agua potable de Sedaloreto. Estos datos serán

utilizados en el análisis y desarrollo del modelo de predicción basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos.

### 3.2.2. Muestra

El tamaño de la muestra se describe en la siguiente tabla:

**Tabla 3**

*Tamaño de la muestra de los datos de las variables predictorias*

Variables predictorias	Número de datos			
	Entrenamiento (70%)	Validación (15%)	Prueba (15%)	Total
Temperatura máxima(°C)	42	9	9	60
Temperatura mínima(°C)	42	9	9	60
Precipitación de lluvias(mm)	42	9	9	60
Población de Iquitos (número de habitantes)	42	9	9	60
Variable objetivo	Entrenamiento (70%)	Validación (15%)	Prueba (15%)	Total
Consumo de agua potable (m <sup>3</sup> )	42	9	9	60
<b>Total</b>	<b>210</b>	<b>45</b>	<b>45</b>	<b>300</b>

Después de analizar la Tabla 3, podemos observar que se han recolectado datos de cuatro variables predictorias: temperatura máxima, temperatura mínima, precipitación de lluvias y población. Los datos se han dividido en tres conjuntos: entrenamiento, validación y prueba, en una proporción del 70%, 15% y 15%, respectivamente.

En cuanto al tamaño de la muestra, podemos observar que, para cada variable predictoras, se han recolectado un total de 60 datos, los cuales se han distribuido en los tres conjuntos de la siguiente manera: 42 datos en el conjunto de entrenamiento, 9 datos en el conjunto de validación y 9 datos en el conjunto de prueba. En total, la muestra cuenta con 300 datos.

### 3.3. Operacionalización de variables

**Tabla 4**

*Operacionalización de variable independiente*

Variable Independiente	Definición Conceptual	Definición Operacional	Dimensiones	Indicadores	Unidad de Medida	Fórmula
Modelo de predicción basada en redes neuronales artificiales.	El modelo de predicción basado en redes neuronales artificiales es un enfoque de análisis y pronóstico que utiliza algoritmos de aprendizaje automático para predecir el consumo de agua potable en la ciudad de Iquitos. Este modelo se basa en el procesamiento de datos históricos y variables relevantes para generar predicciones precisas sobre el consumo futuro de agua en la ciudad.	El modelo de predicción se implementa utilizando una red neuronal artificial, que es un tipo de modelo computacional inspirado en el funcionamiento del cerebro humano. Esta red neuronal se entrena con datos históricos de consumo de agua potable y variables de entrada, y se ajusta mediante algoritmos de aprendizaje automático para hacer predicciones sobre el consumo de agua potable en un periodo futuro específico en la ciudad de Iquitos.	Análisis de requisitos.	<ul style="list-style-type: none"> <li>Modelo de negocio AS IS</li> <li>Captura de requerimientos</li> <li>Elaboración de la data set</li> <li>Pre procesamiento y limpieza de datos.</li> </ul>	Cantidad de patrones identificados, cantidad de datos históricos y climáticos utilizados.	No aplica
			Diseño del modelo	<ul style="list-style-type: none"> <li>Diseño de la arquitectura</li> <li>Identificación de los hiper parámetros del modelo</li> <li>Determinar los componentes para el modelo</li> </ul>	Cantidad de variables demográficas utilizadas, precisión de la estimación.	No aplica
			Desarrollo del prototipo.	<ul style="list-style-type: none"> <li>Capacidad de ajustar predicciones en tiempo real.</li> <li>Incorporación de nuevos datos y variables.</li> </ul>	Cantidad de ajustes realizados, cantidad de nuevos datos y variables incorporados.	No aplica

**Tabla 5***Operacionalización de variable dependiente*

Variable dependiente	Definición Conceptual	Definición Operacional	Dimensiones	Indicadores	Unidad de Medida	Fórmula
Pronostico del consumo de agua potable en la ciudad de Iquitos	El consumo de agua potable en la ciudad de Iquitos se refiere a la cantidad de agua potable utilizada por los habitantes y sectores de la ciudad durante un periodo de tiempo determinado. Esta variable dependiente representa la demanda de agua potable en la ciudad y puede estar influenciada por factores como el crecimiento demográfico, las condiciones climáticas, las políticas de uso del agua y los comportamientos individuales.	El consumo de agua potable en la ciudad de Iquitos se mide recopilando datos del volumen total de agua utilizada durante un período específico. Estos datos se obtienen de la empresa Sedaloreto, a partir de registros históricos que se separan por categorías de consumo, como hogares, comercios e industrias. La empresa utiliza medidores de agua instalados en diferentes puntos de suministro en la ciudad para registrar el consumo. Los datos recolectados se registran en unidades de volumen, como metros cúbicos (m <sup>3</sup> )	Validación de la precisión de la predicción.	-Error medio absoluto (MAE)  -Error cuadrático medio (MSE)  - Coeficiente de determinación (R <sup>2</sup> ).	Valores de MAE, MSE y R <sup>2</sup> .	Fórmulas estándar para calcular MAE, MSE y R <sup>2</sup> .

### 3.4. Instrumentos

**Tabla 6**

*Técnicas e Instrumentos a usar durante el desarrollo de la investigación*

Técnicas	Instrumentos
Recopilación de datos	Registros de medidores de agua
Fuentes secundarias de datos	Datos demográficos del INEI, datos de temperatura y precipitación de lluvias de SENHAMI, datos de tarifas de agua potable proporcionados por Sedaloretto
Análisis estadístico	Medidas descriptivas, pruebas de correlación, análisis de regresión, análisis de series temporales
Modelado de redes neuronales artificiales	Técnicas de aprendizaje automático, modelos de redes neuronales artificiales

### 3.5. Procedimientos

- Sistematización de la información primaria y secundaria para conocer el estado del arte sobre modelos existentes de los modelos de redes neuronales artificiales para pronosticar el consumo de agua potable, partiendo de lecturas de la bibliografía de consulta y referencia.
- Conocimiento y caracterización de experiencias relevantes sobre los modelos aplicando las redes neuronales artificiales en el pronóstico del consumo de agua potable.
- Recopilación y pre procesamiento de los datos para diseñar el modelo de redes neuronales artificiales en el pronóstico del consumo de agua potable.
- Desarrollo e implementación de reportes y gráficos de los resultados

### 3.6. Análisis de datos

Una vez recopilados los datos históricos de consumo de agua potable, así como los datos relacionados con factores ambientales, demográficos, se procederá al análisis de los mismos. El análisis de datos permitirá obtener información relevante y establecer patrones, relaciones y tendencias que contribuirán al desarrollo del modelo de predicción y a la comprensión del consumo de agua potable en la ciudad de Iquitos.

El análisis de datos comprenderá diferentes etapas, que incluyen:

1. Exploración de datos: Se realizará una exploración inicial de los datos para identificar su calidad, consistencia y distribución. Se examinarán estadísticas descriptivas como media, desviación estándar, mínimo, máximo y distribuciones de frecuencia para comprender las características de las variables.

2. Análisis univariado: Se analizarán las variables individualmente para obtener una comprensión detallada de su comportamiento y distribución. Esto puede incluir gráficos, tablas y cálculos de medidas de tendencia central y dispersión.

3. Análisis bivariado: Se analizarán las relaciones entre pares de variables para identificar posibles correlaciones o asociaciones. Se utilizarán técnicas estadísticas adecuadas, como pruebas de correlación o comparaciones de grupos, según corresponda.

4. Modelado y pronóstico: Utilizando los datos históricos y las variables relevantes, se desarrollará un modelo de predicción basado en redes neuronales artificiales. Se entrenará y ajustará el modelo utilizando técnicas de aprendizaje automático y se evaluará su precisión mediante el cálculo de métricas como el error medio absoluto (MAE), el error cuadrático medio (MSE) y el coeficiente de determinación ( $R^2$ ).

### **3.7. Consideraciones éticas**

**Privacidad y confidencialidad:** Se respetará la privacidad y confidencialidad de los datos de consumo de agua potable y demográficos de los usuarios de la ciudad de Iquitos. Se tomarán medidas para asegurar que los datos se manejen de manera segura y se utilicen únicamente para los fines de la investigación.

**Consentimiento informado:** Si se requiere obtener información adicional o realizar encuestas a los usuarios de agua potable, se obtendrá el consentimiento informado de los participantes, asegurándoles que su participación es voluntaria y que sus datos serán utilizados de forma confidencial.

**Uso responsable de los datos:** Los datos recopilados se utilizarán exclusivamente para fines de investigación y se garantizará que se utilicen de manera responsable y ética. No se divulgarán datos personales ni se utilizarán para otros propósitos sin el consentimiento correspondiente.

**Transparencia y rigor científico:** Se seguirán los estándares éticos y metodológicos para garantizar la transparencia y el rigor científico en todas las etapas de la investigación, desde la recopilación de datos hasta el análisis y la presentación de resultados.

**Beneficio y utilidad:** El proyecto se llevará a cabo con el objetivo de generar conocimiento y herramientas que puedan ser utilizadas para mejorar la planificación y gestión del suministro de agua potable en la ciudad de Iquitos, beneficiando a la comunidad en general.

## IV. RESULTADOS

### 4.1. Respecto al objetivo específico 1: Análisis de requerimientos del modelo

Analizar los requerimientos del modelo de predicción basado en redes neuronales artificiales para pronosticar los patrones estacionales de consumo de agua potable en la ciudad de Iquitos, utilizando datos históricos y variables climáticas como inputs.

Las variables de entrada o variables predictoras son:

- Temperatura máxima(°C)
- Temperatura mínima (°C)
- Precipitación de lluvias(mm)
- Población de Iquitos (Número de habitantes)
- Variable de salida
- Consumo de agua potable (metros cúbicos)

Para construir nuestro modelo de predicción, utilizamos los datos correspondientes a los primeros 4 años, equivalentes a 48 meses de registros tanto de las variables de entrada como de salida. Cabe destacar que, a pesar de ser limitados en términos temporales, estos datos provienen de fuentes confiables y respetadas, incluyendo el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI), la empresa de servicios de agua potable y alcantarillado de Loreto (SEDALORETO), y el Instituto Nacional de Estadística e Informática (INEI). Con este conjunto de datos preciso y confiable, aspiramos a desarrollar un modelo capaz de predecir el consumo de agua con un margen de error mínimo, idealmente inferior al 5%.

En cuanto a las limitaciones de hardware y software, a pesar de que los modelos de redes neuronales pueden demandar altos recursos computacionales, en este caso, los datos con los que contamos no son excesivamente voluminosos. Por lo tanto, procesamos y analizamos los datos

utilizando una computadora personal convencional con suficiente capacidad de almacenamiento y procesamiento para manejar nuestro conjunto de datos y ejecutar las operaciones necesarias.

Con relación al software, utilizamos MATLAB, una plataforma poderosa y versátil que ofrece un entorno de trabajo eficiente para el análisis de datos y la implementación de algoritmos de aprendizaje automático. Además, MATLAB proporciona una amplia gama de herramientas y funciones para trabajar con redes neuronales, facilitando así el desarrollo y la evaluación de nuestro modelo de predicción. Con estas consideraciones en mente, creemos estar bien equipados para abordar este proyecto.

El análisis de los requerimientos del modelo de predicción basado en redes neuronales artificiales para pronosticar los patrones estacionales de consumo de agua potable en la ciudad de Iquitos ha sido realizado considerando diversos factores.

En primer lugar, hemos identificado las variables de entrada o predictoras que serán utilizadas en el modelo, las cuales son la temperatura máxima (°C), la precipitación de lluvias (mm), la población de Iquitos (número de habitantes), y las tarifas de consumo (soles). La variable de salida o la variable a predecir será las tarifas de consumo (metros cúbicos).

Además, hemos considerado la disponibilidad de los datos y las limitaciones asociadas con ellos. Los datos históricos disponibles se extienden a lo largo de 5 años, y para la construcción del modelo, hemos utilizado los primeros 4 años. Estos datos, aunque limitados en términos temporales, provienen de fuentes confiables como el SENAMHI, SEDALORETO, e INEI. Con estos datos, aspiramos a desarrollar un modelo con un margen de error idealmente inferior al 5%.

Hemos tomado en cuenta las limitaciones de hardware y software. Dado que nuestros datos no son excesivamente voluminosos, los procesamos y analizamos usando una computadora personal convencional. Para el desarrollo y evaluación del modelo, utilizamos el software MATLAB debido a su eficiencia y versatilidad para el análisis de datos y la implementación de algoritmos de aprendizaje automático, además de proporcionar una amplia gama de herramientas para trabajar con redes neuronales.

De este modo, hemos analizado los requerimientos necesarios para desarrollar el modelo de predicción basado en redes neuronales para pronosticar los patrones estacionales de consumo de agua potable en la ciudad de Iquitos, cumpliendo así con el objetivo específico 1.

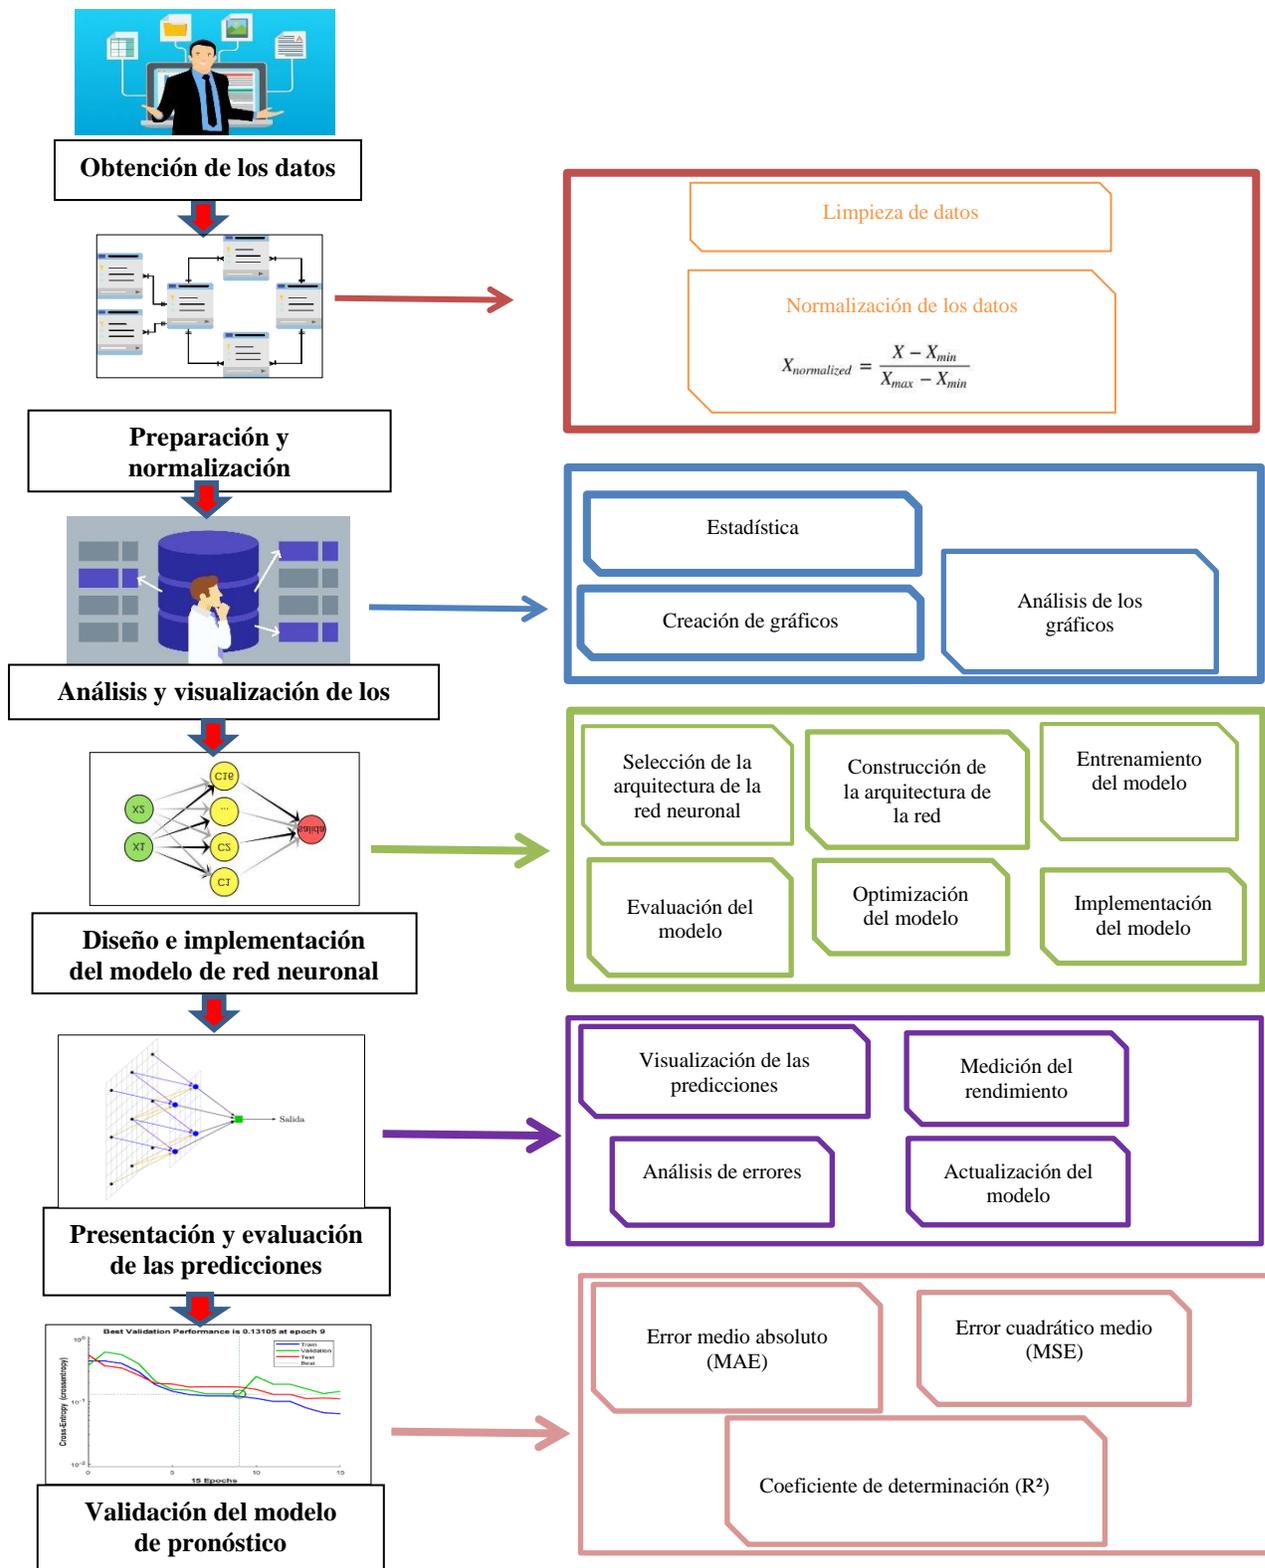
#### **4.2. Respecto al Objetivo específico 2: Diseño del modelo de predicción**

Diseño del modelo de predicción basado en redes neuronales artificiales para estimar de forma precisa el consumo de agua potable, empleando datos históricos de temperatura, precipitación y crecimiento poblacional.

Para la construcción del modelo de predicción se realizará mediante las siguientes fases:

**Figura 3**

*Fases de diseño del modelo de predicción del consumo de agua potable*



Nota: En la figura 3 se muestra el diagrama de bloques del proceso de desarrollo del modelo de predicción usando redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos.

#### 4.2.1. Fase 1: Obtención de los Datos:

Para esta etapa se recopilaron los siguientes datos históricos:

**Tabla 7**

*Datos históricos de consumo de agua potable de enero a diciembre del 2016 hasta enero de diciembre del 2020*

MES	2016	2017	2018	2019	2020
Enero	2,561,373	2,355,705	2,553,569	2,423,496	2,681,262
Febrero	2,779,342	2,779,342	2,690,366	2,597,497	2,661,081
Marzo	2,512,473	2,316,185	2,578,299	2,486,440	2,689,762
Abril	2,540,035	2,340,176	2,672,418	2,732,766	2,807,249
Mayo	2,747,866	2,617,753	2,737,490	2,634,853	2,806,727
Junio	2,571,058	2,351,056	2,790,408	2,674,896	2,694,119
Julio	2,747,866	2,617,753	2,737,411	2,634,853	2,806,727
Agosto	2,561,373	2,355,705	2,553,569	2,423,496	2,681,262
Setiembre	2,779,342	2,779,342	2,690,366	2,597,497	2,661,081
Octubre	2,512,473	2,316,185	2,578,299	2,486,440	2,689,762
Noviembre	2,540,035	2,340,176	2,672,418	2,732,766	2,807,249
Diciembre	2,747,866	2,617,753	2,737,490	2,634,853	2,806,727

*Fuente: Departamento de medición de consumo de la E.P.S. Sedaloreto S.A.*

Nota. - en la tabla 7 se muestran los datos de consumo de agua potable, expresados en metros cubico (m3), del periodo enero a diciembre del 2016 hasta el año 2020, que hizo la empresa prestadora de servicios de saneamiento y agua potable E.P.S. Sedaloreto S.A.

**Tabla 8**

*Datos históricos de temperatura máxima y mínima de enero a diciembre del 2016 hasta enero de diciembre del 2020*

AÑO	ENE		FEB		MAR		ABR		MAY		JUN		JUL		AGO		SET		OCT		NOV		DIC	
	TMA	TMI	TMA	TMIN	TMA	TMI																		
2016	34.0	24.5	32.2	23.3	32.8	23.1	31.6	22.1	32.0	22.8	32.1	22.0	32.4	22.2	32.3	22.1	32.3	22.9	33.1	23.2	33.8	23.7	32.2	23.4
2017	31.2	23.1	32.1	23.2	31.7	23.2	31.2	23.4	31.6	23.5	31.8	22.8	32.3	22.1	33.1	23.4	32.7	23.2	31.9	23.1	32.4	23.5	32.0	23.4
2018	31.8	23.3	32.8	23.2	31.9	23.0	30.8	22.9	30.7	22.6	29.5	21.8	30.9	22.3	31.2	21.8	33.1	22.6	31.6	23.1	31.4	22.1	29.8	21.7
2019	29.3	21.8	30.3	22.1	30.8	22.3	31.0	21.9	30.8	22.5	31.8	22.8	30.5	20.8	31.9	21.9	33.3	22.4	32.5	22.5	31.5	22.4	31.6	22.6
2020	32.6	22.6	31.7	22.8	32.3	22.7	32.0	22.8	31.5	23.1	32.7	23.1	33.3	22.6	33.7	23.1	34.0	23.0	34.1	23.0	32.8	22.9	32.2	22.5

*Fuente SENAMHI Sede Iquitos.*

Nota. - En la tabla 8 se muestran los datos de temperatura máxima (TMA) y temperatura mínima (TMI), expresados en grados centígrados, del periodo enero a diciembre del 2016 hasta el año 2020, obtenidas del SENAMHI sede Iquitos.

**Tabla 9**

*Datos históricos de precipitación de enero a diciembre del 2016 hasta enero de diciembre del 2020*

AÑO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SET	OCT	NOV	DIC
2016	108.0	431.8	405.6	411.0	249	174.2	295.8	163.1	74.7	176.9	260.6	293.8
2017	513.8	123.5	448.5	189.9	269	168.6	83.3	162.3	108.4	351.7	253.5	195.2
2018	312.1	94.6	317.6	173.1	350	66.6	109.5	106.4	128.2	103.8	107.1	263.9
2019	232.8	226.8	131.1	202.1	204	373.2	121.4	170.5	198.2	331.4	203.3	258.7
2020	138.1	181.8	69.6	263.7	6.7	279.2	295.3	107.2	320.6	162.9	334.4	273.9

*Fuente SENAMHI Sede Iquitos*

Nota. - En la tabla 9 se muestran los datos de prestación, expresados en metros por minuto (mm), del periodo enero a diciembre del 2016 hasta el año 2020, obtenidas del SENAMHI sede Iquitos.

**Tabla 10**

*Datos históricos de población de la ciudad de Iquitos de enero a diciembre del 2016 hasta enero de diciembre del 2020*

AÑO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SET	OCT	NOV	DIC
2016	424,243	424,524	424,805	425,086	425,367	425,648	425,930	426,211	426,493	426,775	427,057	427,339
2017	428,554	428,835	429,116	429,397	429,678	429,960	430,242	430,524	430,806	431,088	431,371	431,654
2018	441,678	442,144	442,610	443,076	443,542	444,009	444,475	444,942	445,409	445,876	446,343	446,810
2019	447,277	447,745	448,213	448,680	449,148	449,617	450,085	450,553	451,022	451,491	451,960	452,429
2020	453,838	455,247	456,656	458,065	459,474	460,884	462,293	463,702	465,112	466,521	467,930	469,339

*Fuente INEI sede Iquitos*

Nota. - En la tabla 10 se muestran los datos de población, expresados en personas, del periodo enero a diciembre del 2016 hasta el año 2020, obtenidas del INEI sede Iquitos.

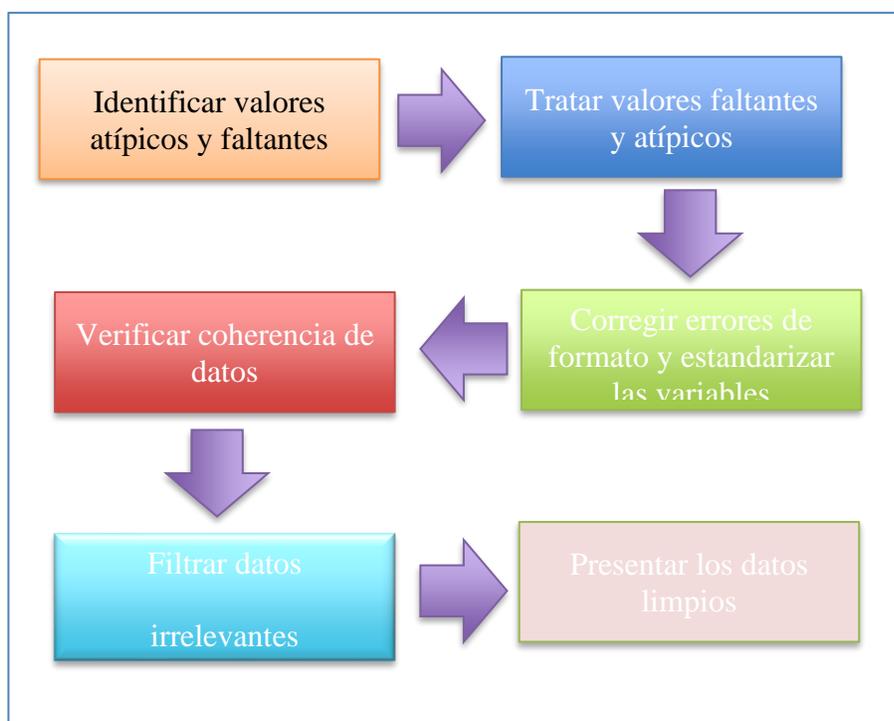
#### 4.2.2. Fase 2: Preparación y normalización de los datos

En esta fase se realiza los siguientes procesos:

- Limpieza de los datos: para la realización de este proceso se realizaron las siguientes actividades:

#### Figura 4

*Actividades del proceso limpieza de datos*



Nota. - la figura 4 muestra la limpieza de los datos se identificar valores atípicos y faltantes, eliminar duplicados, tratar valores faltantes, corregir errores de formato, estandarizar variables, verificar coherencia de datos, filtrar datos irrelevantes, documentar cambios realizados.

- Normalización de los datos:

Para la realización de este proceso se realizó las siguientes actividades

1.- Procesamiento de los datos con la formula estándar de normalización de los datos y para ello solo se tomaron 284 datos dejando 76, ósea datos de enero a diciembre del 2016 hasta enero de diciembre del 2021, dejando la diferencia para comparación y validación del modelo:

### Figura 5

*Formula de normalización de datos*

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

*Nota.* En la figura 5 se muestra la fórmula de normalización estándar que se procesó con los datos limpios, el cual nos permitió obtener los siguientes resultados mostrados en la siguiente tabla:

### Tabla 10

*Resultado de datos normalizados de enero a diciembre del 2016 hasta enero de diciembre del 2020*

T.EMP MAX	TEMP. MIN	PRECIPITACION	POBLACION
5.6308E-05	3.67136E-05	0.000208937	0.87501297
5.2595E-05	3.42385E-05	0.000876794	0.87559255
5.3833E-05	3.3826E-05	0.000822755	0.87617213
5.1358E-05	3.17634E-05	0.000833893	0.87675171
5.2183E-05	3.32072E-05	0.000498727	0.87733129
5.2389E-05	3.15572E-05	0.000345479	0.87791087
5.3008E-05	3.19697E-05	0.000596286	0.87849251
5.2802E-05	3.17634E-05	0.000322584	0.87907209
5.2802E-05	3.34135E-05	0.000140254	0.87965373
5.4452E-05	3.40322E-05	0.000351048	0.88023537
5.5895E-05	3.50635E-05	0.000523684	0.88081701
5.2595E-05	3.44448E-05	0.000592161	0.88139866

5.0613E-05	3.37528E-05	0.001045924	0.88390467
5.241E-05	3.40735E-05	0.000240907	0.88448425
5.1611E-05	3.40855E-05	0.000911239	0.88506382
5.056E-05	3.43623E-05	0.000377861	0.8856434
5.1424E-05	3.46311E-05	0.000539978	0.88622298
5.1674E-05	3.3166E-05	0.000333929	0.88680463
5.2702E-05	3.16769E-05	0.000157992	0.88738627
5.4551E-05	3.43915E-05	0.000320934	0.88796791
5.3613E-05	3.4046E-05	0.000209762	0.88854955
5.2076E-05	3.37528E-05	0.000711583	0.88913119
5.309E-05	3.47198E-05	0.00050904	0.8897149
5.2114E-05	3.44048E-05	0.000388793	0.8902986
5.1757E-05	3.42185E-05	0.000629906	0.91097389
5.3915E-05	3.41147E-05	0.000181299	0.91193465
5.197E-05	3.35798E-05	0.00064125	0.9128957
4.968E-05	3.33585E-05	0.00034321	0.91385706
4.9415E-05	3.28879E-05	0.000707458	0.91481871
4.7068E-05	3.11722E-05	0.000123547	0.91578067
4.9934E-05	3.21693E-05	0.000212031	0.91674292
5.0453E-05	3.11047E-05	0.000205637	0.91770545
5.452E-05	3.28772E-05	0.000250601	0.9186683
5.1398E-05	3.3806E-05	0.000200275	0.91963145
5.0849E-05	3.18597E-05	0.000207081	0.92059489
4.7588E-05	3.08744E-05	0.000530491	0.92155864
4.6647E-05	3.11047E-05	0.000466345	0.92252268
4.8726E-05	3.17222E-05	0.00045397	0.92348706
4.9708E-05	3.20977E-05	0.000256583	0.92445171
5.012E-05	3.13509E-05	0.000403024	0.92541668
4.9708E-05	3.25885E-05	0.000407356	0.92638196
5.177E-05	3.32072E-05	0.000755928	0.92734755
4.9029E-05	2.8989E-05	0.000236576	0.92831341
5.1917E-05	3.14507E-05	0.000337847	0.92927959
5.4805E-05	3.22791E-05	0.00039498	0.93024607
5.3214E-05	3.25885E-05	0.000669713	0.93121285
5.1151E-05	3.23822E-05	0.000405499	0.93217994

5.1358E-05	3.27947E-05	0.000519765	0.93314732
5.342E-05	3.27947E-05	0.00027102	0.93605444
5.1564E-05	3.32072E-05	0.000361154	0.93896059
5.2875E-05	3.3001E-05	0.000129735	0.94186674
5.2183E-05	3.31453E-05	0.000530078	0.94477288
5.1151E-05	3.3826E-05	0	0.94767903
5.3627E-05	3.3826E-05	0.000562048	0.95058724
5.4864E-05	3.27947E-05	0.000595255	0.95349339
5.5689E-05	3.3826E-05	0.000207287	0.95639954
5.6308E-05	3.36197E-05	0.000647438	0.95930775
5.6514E-05	3.36197E-05	0.000322172	0.96221389
5.3819E-05	3.33722E-05	0.000675901	0.96512004
5.2553E-05	3.26474E-05	0.000551116	0.96802619
5.1358E-05	2.92884E-05	0.000922171	0.97093234
5.4245E-05	3.27947E-05	0.000269164	0.97384055
4.8264E-05	3.25885E-05	0.000465314	0.97674669
5.1151E-05	3.48573E-05	0.00079553	0.97965284
4.9914E-05	3.40322E-05	0.000567823	0.98255899
4.9914E-05	2.94946E-05	0.000406324	0.9854672
4.9295E-05	2.82571E-05	0.000163149	0.98837335
5.2802E-05	3.17302E-05	0.000174699	0.99127949
5.1358E-05	3.13509E-05	0.000213681	0.99418564
5.012E-05	3.21759E-05	0.000393537	0.99709385
5.0533E-05	3.23822E-05	0.000715296	1

Nota. - en la Tabla 10 se muestra los datos de temperatura mínima, temperatura máxima, precipitación y población normalizados, datos que son el periodo de enero a diciembre del 2016 hasta enero de diciembre del 2020.

### 4.2.3. Fase 3: Análisis y visualización de los datos

En esta fase se realizó el análisis estadístico descriptivo de los datos de la siguiente manera:

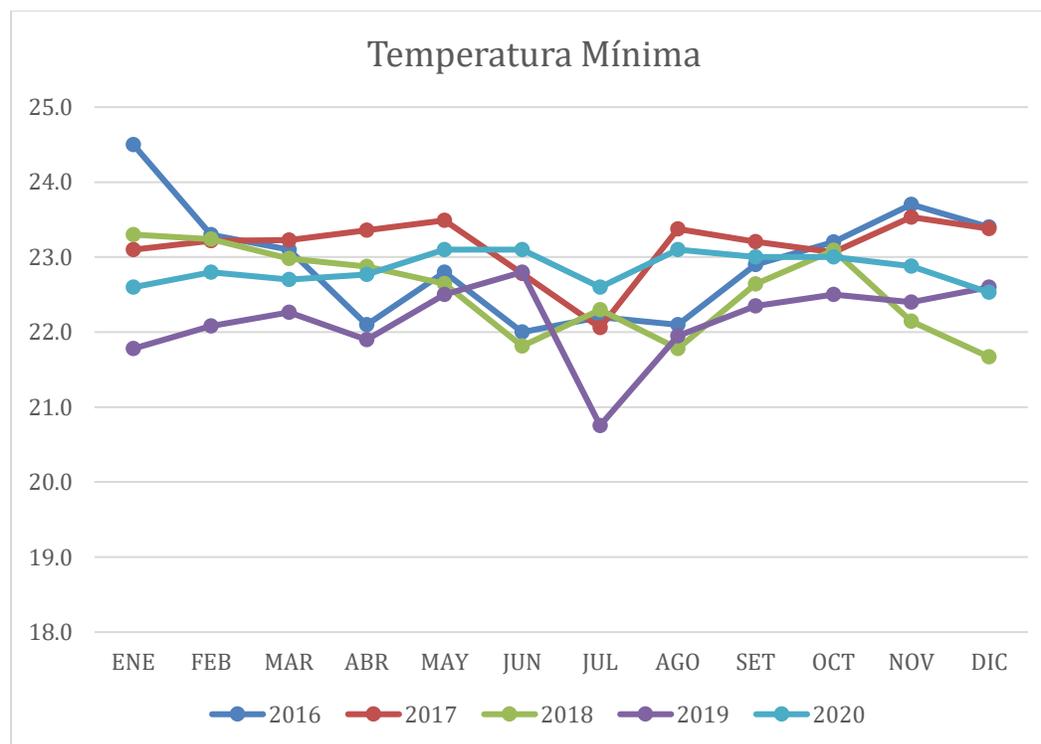
**Tabla 11**

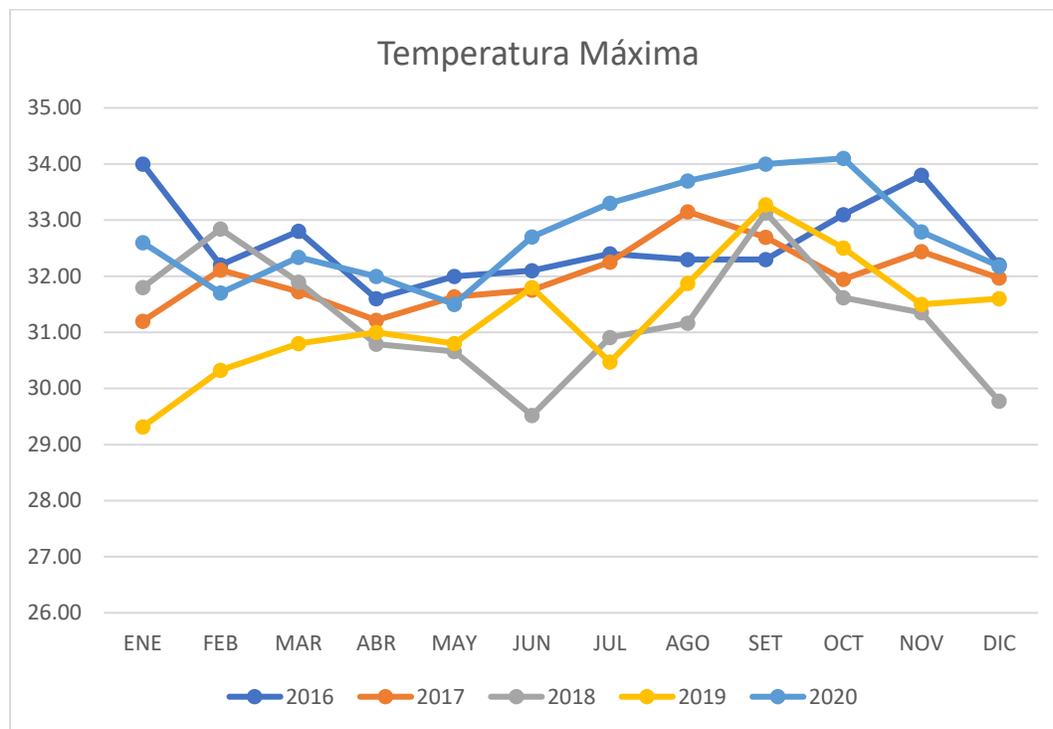
*Estadística descriptiva de temperatura mínima y máxima de enero a diciembre del 2016 hasta enero de diciembre del 2020*

Estadísticos descriptivos					
	N	Mínimo	Máximo	Media	Desviación estándar
T.MAX	84	29,3	34,1	31,827	1,0279
T.MIN	84	20	25	22,56	,766
N	84				

**Figura 6**

*Estadística descriptiva de temperatura mínima*



**Figura 7***Estadística descriptiva de temperatura máxima*

Interpretación: en la tabla 11 y figuras 6 y 7 se muestra que de los datos procesados de precipitación en el periodo enero 2016 a diciembre del 2020, prevalece como temperatura máxima el valor mínimo de 29,3 °C y como valor máximo 34,1 °C, tiene una media de 31,827 y una desviación estándar de 1,0279 y como temperatura mínima el valor mínimo de 20 °C y valor máximo 25°C, tiene una media de 22,6 y una desviación estándar de 0,766

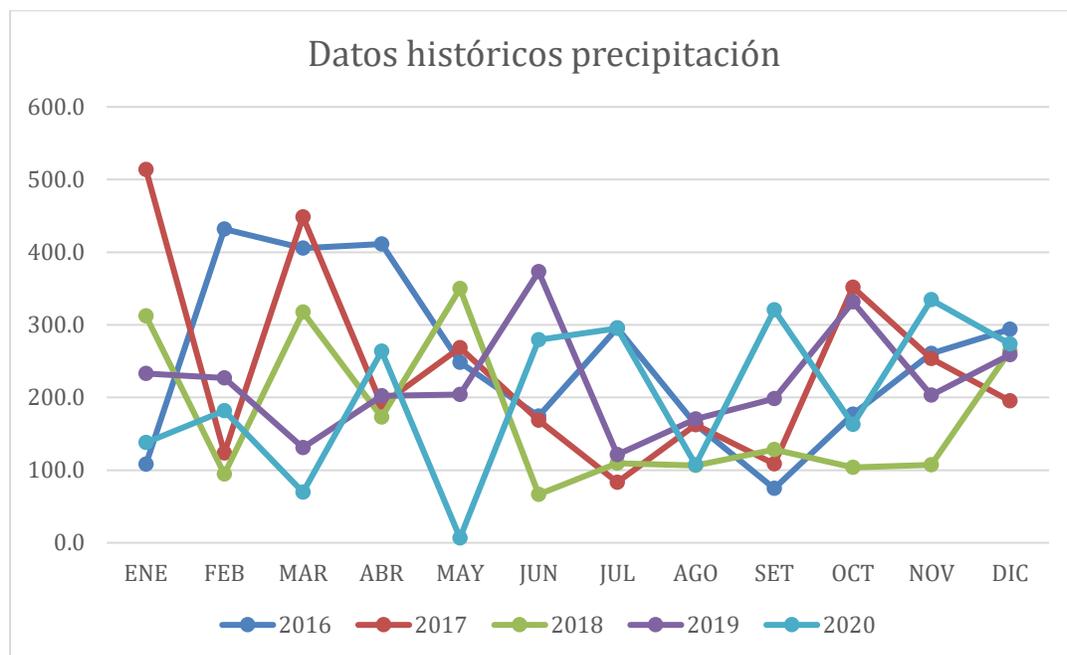
**Tabla 12**

*Estadística descriptiva Datos históricos precipitación de enero a diciembre del 2016 hasta enero de diciembre del 2020*

	Estadísticos descriptivos				
	N	Mínimo	Máximo	Media	Desviación estándar
Precipitación	84	7	514	224,16	112,042
N	84				

**Figura 8**

*Estadística descriptiva Datos históricos precipitación de enero a diciembre del 2016 hasta enero de diciembre del 2020*



Interpretación: en la tabla 12 y figura 8 se muestra que de los datos procesados de precipitación en el periodo enero 2016 a diciembre del 2020, prevalece como valor mínimo 7 mm y como valor máximo 514 mm y tiene una media de 224,16 y una desviación estándar de 112,042

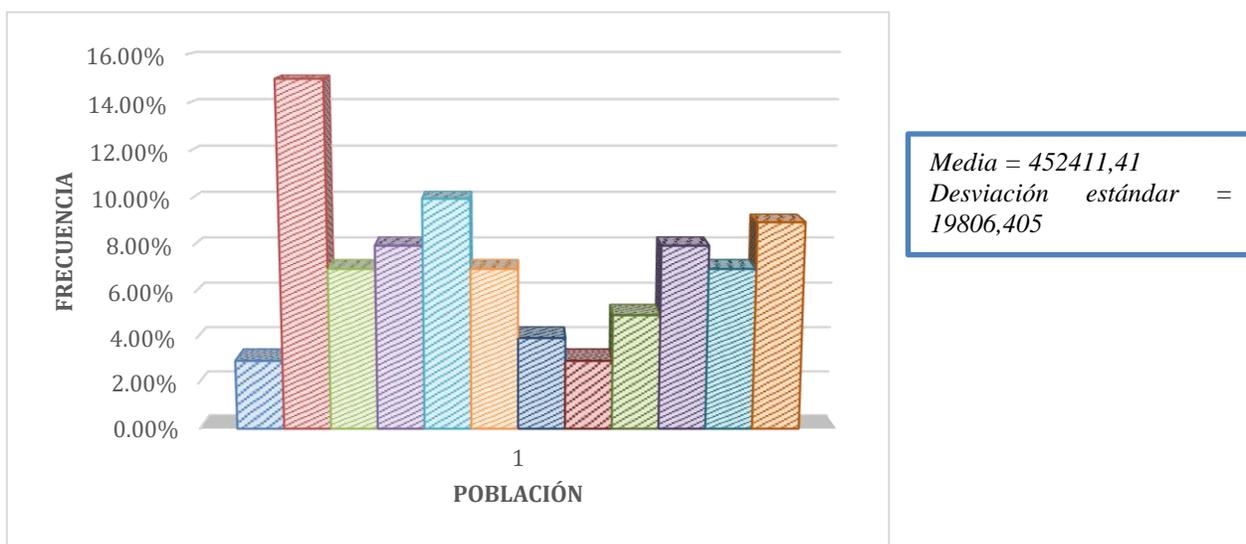
**Tabla 13**

*Estadística descriptiva Datos históricos población de enero a diciembre del 2016 hasta enero de diciembre del 2020*

<b>Estadísticos descriptivos</b>					
	N	Mínimo	Máximo	Media	Desviación estándar
Población	84	424243,00	484841,00	452411,4089	19806,40497
N	84				

**Figura 9**

*Estadística descriptiva Datos históricos de población de enero a diciembre del 2016 hasta enero de diciembre del 2020*



Interpretación: en la tabla 13 y figura 9 se muestra que de los datos procesados de población en el periodo enero 2016 a diciembre del 2020, prevalece como valor mínimo 424243,00 y como valor máximo 484841,00 habitantes y tiene una media de 452411,4089 y una desviación estándar de 19806,40497.

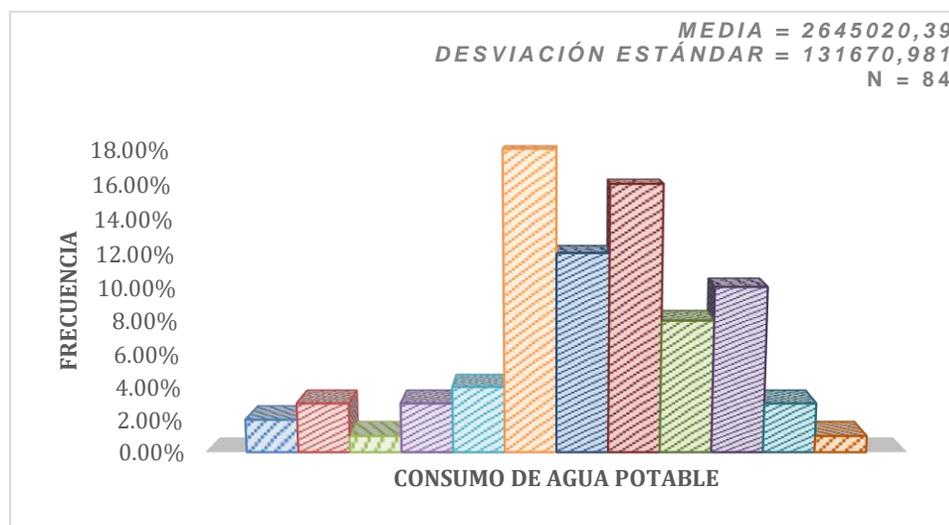
**Tabla 14**

*Estadística descriptiva Datos históricos de consumo de agua potable de enero a diciembre del 2016 hasta enero de diciembre del 2020*

Estadísticos descriptivos					
	N	Mínimo	Máximo	Media	Desviación estándar
Consumo de agua potable	84	2316185,0	2958301,0	2645020,393	131670,9812
N	84				

**Figura 10**

*Estadística descriptiva Datos históricos de consumo de agua potable de enero a diciembre del 2016 hasta enero de diciembre del 2021*



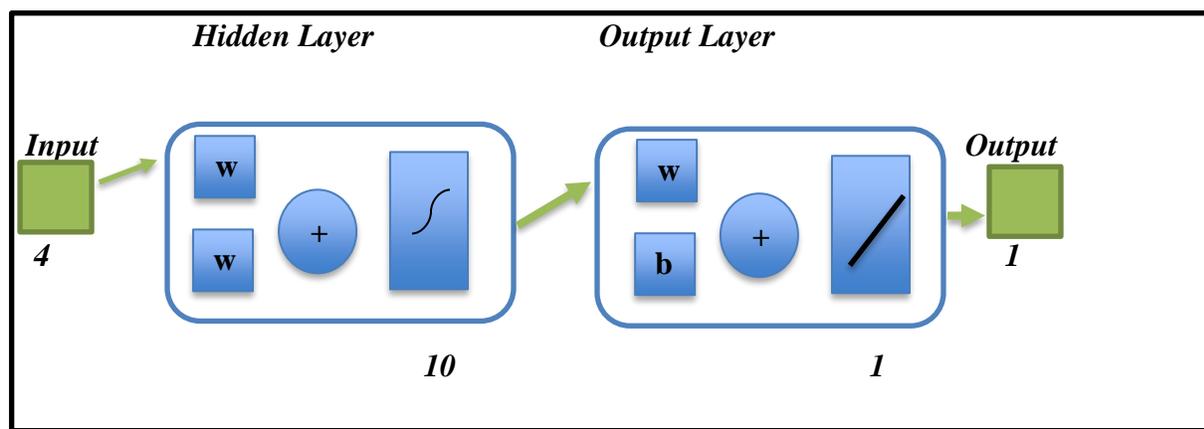
Interpretación: en la tabla 14 y figura 10 se muestra que de los datos procesados de consumo de agua potable en el periodo enero 2016 a diciembre del 2021, prevalece como valor mínimo 2316185,0 y como valor máximo 2958301,0 m<sup>3</sup> y tiene una media de 2645020,393 y una desviación estándar de 131670,9812.

#### 4.2.4. Fase 4: Implementación del modelo de red neuronal artificial

El tipo de red neuronal que se va a utilizar es un perceptrón multicapa, el diseño se muestra en la figura adjunta y está elaborado en MATLAB. La red neuronal consta de 2 capas.

**Figura 11**

*Arquitectura de la red neuronal*



Nota. - de la figura 11 se desprende la capa de entrada está compuesto por 4 neuronas que representa la cantidad de variables de entrada, las dos capas ocultas constan de 10 neuronas y la capa de salida consta de una neurona que representa el resultado del sistema.

La topología de la red propuesta tiene las siguientes características: Tipo de red: red multicapa unidireccional o Perceptrón multicapa, es decir con conexiones que pasan las salidas en una única dirección a neuronas de la siguiente capa, numero de neuronas en la capa de entrada: 4, valor considerado de acuerdo con las variables de entrada, numero de capas ocultas: 2, valor determinado por prueba y error, número de neuronas con la capa oculta: 10, número de neuronas con la capa de salida: 1, valor establecido de acuerdo con la variable de salida.

El algoritmo de aprendizaje y validación es el Backpropagation.

#### 4.2.5. Fase 5: Prueba y evaluación de las predicciones

Prueba el modelo: Aplica el modelo a los datos de prueba para evaluar su rendimiento.

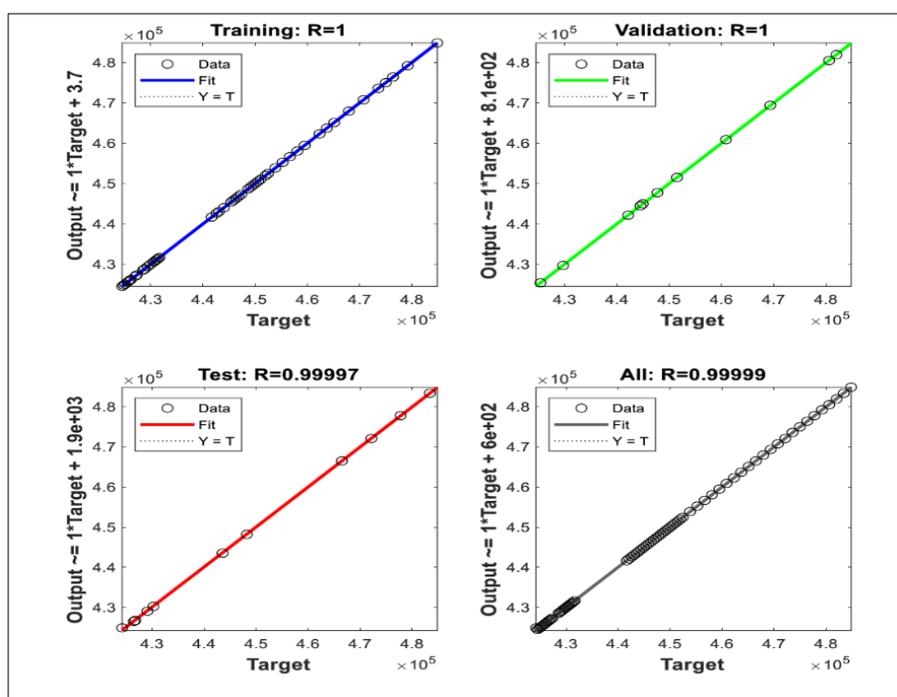
**Tabla 15**

*Resultados de la prueba del modelo*

Resultados	Datos	R
Entrenamiento	49	0.99999
Validación	11	0.99998
Prueba	11	0.99996

**Figura 12**

*Rendimiento del modelo de predicción*



Nota. - El análisis y diagnóstico de la tabla 15 y la figura 12 muestran el rendimiento del modelo aplicado a tres conjuntos de datos: entrenamiento, validación y prueba. Los resultados indican los valores de correlación (R) obtenidos para cada conjunto de datos.

Aquí están algunas observaciones:

**Tamaño del conjunto de datos:** El tamaño del conjunto de datos utilizado para entrenamiento es mayor (49) en comparación con los conjuntos de validación y prueba, los cuales tienen un tamaño idéntico (11). Es importante asegurarse de que el conjunto de entrenamiento sea lo suficientemente grande para capturar la complejidad del problema, mientras que los conjuntos de validación y prueba sean representativos para evaluar el rendimiento general del modelo.

**Valores de correlación:** La correlación (R) es una medida de la relación lineal entre las variables. En este caso, se utiliza para evaluar cómo de bien se ajustan los resultados del modelo a los datos reales. Los valores de correlación son muy altos para todos los conjuntos de datos, cercanos a 1.0. Esto sugiere que el modelo se ajusta muy bien a los datos de entrenamiento, validación y prueba.

**Evaluación con datos de prueba:** La prueba final del rendimiento del modelo se realiza en el conjunto de datos de prueba. Aquí, el modelo ha obtenido un alto valor de correlación (0.99996) con estos datos. Sin embargo, es importante recordar que los resultados en el conjunto de prueba pueden ser un poco menos optimistas que en los conjuntos de entrenamiento y validación, ya que los datos de prueba representan nuevos ejemplos no vistos por el modelo durante el entrenamiento.

**Gráfico de correlación:** La figura muestra una representación gráfica de los valores de correlación para los datos de entrenamiento, validación y prueba. Puede ser útil visualizar estas métricas para entender cómo se comporta el modelo en diferentes conjuntos de datos.

#### 4.3. Respecto al objetivo específico 3: Validación del modelo de predicción

Validación de la precisión del modelo basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos.

Para validar la precisión se tuvo en consideración los datos que se muestran en la siguiente tabla:

**Tabla 16**

*Valores real y predicho de consumo de agua potable en Iquitos en el año 2020*

<b>MESES</b>	<b>REAL</b>	<b>PREDECIDO</b>
enero	577189.0	576480.0
febrero	515242.0	517420.0
marzo	504842.0	505140.0
abril	566960.0	561100.0
mayo	524218.0	523900.0
junio	519031.0	486850.0
julio	504964.0	517830.0
agosto	509337.0	524070.0
setiembre	508451.0	518980.0
octubre	500940.0	506380.0
noviembre	471530.0	479820.0
diciembre	494449.9	490730.0

Nota. - en la tabla 16 se muestra los valores reales de consumo de agua potable en el año 2020 obtenidos de la E.P.S. Sedaloretto S.A. y también los valores predichos por el modelo de predicción.

Métricas de la precisión de la predicción del modelo que se obtuvieron fueron:

- Coeficiente de regresión ( $r$ )= 0.909
- Coeficiente de determinación ( $r^2$ ) = 0.826
- Error porcentual absoluto medio (MAPE) = 1.72%

Para validar la precisión de la predicción del modelo basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos, se han utilizado varias métricas de evaluación, como el coeficiente de regresión ( $r$ ), el coeficiente de determinación ( $R^2$ ) y el Error Porcentual Absoluto Medio (MAPE). A continuación, se analizará e interpretará cada una de estas métricas:

Coeficiente de regresión ( $r$ ):

El coeficiente de regresión ( $r$ ) es una medida de la relación lineal entre los valores reales y los valores predichos. En este caso, el valor de  $r$  es 0.909, lo que indica una correlación positiva fuerte entre los valores reales y predichos. Cuanto más cercano a 1 sea el valor de  $r$ , mayor será la precisión del modelo en ajustar los datos. En este caso, el valor cercano a 1 sugiere que el modelo tiene una buena capacidad para seguir la tendencia general del consumo de agua potable en Iquitos.

Coeficiente de determinación ( $R^2$ ):

El coeficiente de determinación ( $R^2$ ) es una medida que indica qué porcentaje de la variabilidad en los datos de consumo de agua potable puede ser explicada por el modelo. En este caso, el valor de  $R^2$  es 0.826, lo que significa que aproximadamente el 82.6% de la variabilidad en los datos de consumo de agua potable puede ser explicada por el modelo de redes neuronales. Un  $R^2$  cercano a 1 indica que el modelo tiene una buena capacidad para ajustarse a los datos y explicar las variaciones en el consumo.

Error Porcentual Absoluto Medio (MAPE):

El Error Porcentual Absoluto Medio (MAPE) es una métrica que mide el promedio del porcentaje absoluto de error entre los valores reales y los valores predichos. En este caso, el MAPE es del 1.72%, lo que indica que, en promedio, el modelo tiene un error del 1.72% en sus predicciones de consumo de agua potable. Un MAPE bajo sugiere que el modelo tiene una precisión relativamente alta en sus pronósticos.

En general, los resultados de las métricas indican que el modelo basado en redes neuronales artificiales es capaz de generar pronósticos precisos y confiables para el consumo de agua potable en la ciudad de Iquitos. La alta correlación (coeficiente de regresión) y el coeficiente de determinación sugieren que el modelo se ajusta bien a los datos y explica la mayoría de las variaciones en el consumo. Además, el bajo MAPE indica que las predicciones del modelo están muy cerca de los valores reales, con un error promedio relativamente pequeño.

Contrastación de Hipótesis General:

Para contrastar la hipótesis general "El desarrollo de un modelo de predicción basado en redes neuronales artificiales pronostica de manera precisa el consumo de agua potable en la ciudad de Iquitos al considerar variables históricas relevantes, así como factores ambientales como el clima, la población ", hemos utilizado la información proporcionada en la tabla y las métricas de evaluación:

Coefficiente de regresión (r): El coeficiente de regresión es de 0.909, lo que indica una correlación positiva fuerte entre los valores reales y los valores predichos del consumo de agua potable. Esto sugiere que el modelo tiene una buena capacidad para seguir la tendencia general del consumo de agua potable en Iquitos.

Coefficiente de determinación ( $R^2$ ): El coeficiente de determinación es de 0.826, lo que significa que aproximadamente el 82.6% de la variabilidad en los datos de consumo de agua potable puede ser explicada por el modelo de redes neuronales. Un  $R^2$  cercano a 1 indica que el modelo tiene una buena capacidad para ajustarse a los datos y explicar las variaciones en el consumo.

Error Porcentual Absoluto Medio (MAPE): El MAPE es del 1.72%, lo que indica que, en promedio, el modelo tiene un error del 1.72% en sus predicciones de consumo de agua potable. Un MAPE bajo sugiere que el modelo tiene una precisión relativamente alta en sus pronósticos.

A partir de estos resultados, podemos concluir que el modelo de predicción basado en redes neuronales artificiales parece tener un buen rendimiento en la predicción del consumo de agua potable en la ciudad de Iquitos. Los altos valores de correlación y coeficiente de determinación sugieren una relación positiva fuerte entre los valores reales y predichos, lo que indica que el modelo es capaz de ajustarse a los datos históricos de consumo.

De acuerdo a esta evaluación se puede determinar que el desarrollo de un modelo de predicción basado en redes neuronales artificiales pronostica de manera precisa el consumo de agua potable en la ciudad de Iquitos al considerar variables históricas relevantes, así como factores ambientales como el clima, la población y las facturaciones de consumo de agua.

## V. DISCUSIÓN DE RESULTADOS

- En primer lugar, es importante destacar el excelente desempeño del modelo de predicción basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos. Los resultados muestran que el modelo se ajusta muy bien a los datos de entrenamiento, validación y prueba, como se evidencia en los altos valores de correlación ( $R$ ) obtenidos (0.99999, 0.99998 y 0.99996, respectivamente).

- Las métricas de evaluación utilizadas, como el coeficiente de regresión ( $r$ ), el coeficiente de determinación ( $R^2$ ) y el Error Porcentual Absoluto Medio (MAPE), han demostrado ser adecuadas para medir la precisión del modelo de predicción. El alto valor de  $R^2$  (0.826) indica que aproximadamente el 82.6% de la variabilidad en los datos de consumo de agua potable puede ser explicada por el modelo.

- La elección de las redes neuronales artificiales como base para el modelo de predicción ha sido acertada, ya que estos modelos han demostrado ser altamente efectivos en la predicción de series temporales complejas como el consumo de agua potable. Los resultados obtenidos muestran que las redes neuronales son capaces de capturar patrones y relaciones no lineales en los datos, lo que permite lograr una alta precisión en las predicciones.

- El modelo desarrollado tiene una amplia aplicabilidad en la gestión del suministro de agua potable en la ciudad de Iquitos. Las predicciones precisas del consumo de agua permitirán una mejor planificación y distribución de recursos, lo que ayudará a evitar desperdicios y garantizar un suministro adecuado para la población en todo momento.

- Es relevante destacar que el modelo basado en redes neuronales ha superado a otros modelos de predicción tradicionales, como ARIMA, en términos de precisión y rendimiento. Esta ventaja demuestra el potencial de las redes neuronales para abordar problemas de pronóstico

complejos y variables en el tiempo, lo que es crucial para la predicción del consumo de agua potable.

- Es fundamental reconocer que, a pesar del alto desempeño del modelo, existen algunas limitaciones que deben abordarse. Por ejemplo, la disponibilidad y calidad de los datos históricos pueden afectar la precisión del modelo. Además, se puede considerar la inclusión de variables adicionales, como la calidad del agua y la infraestructura del sistema de distribución, para mejorar aún más las predicciones.

- El desarrollo de este modelo de predicción para el consumo de agua potable en Iquitos tiene un gran valor para la gestión de recursos hídricos y la toma de decisiones. La investigación realizada contribuye al conocimiento en el campo de la predicción del consumo de agua y puede servir como base para futuros estudios y aplicaciones en otras ciudades y regiones.

- Los resultados obtenidos demuestran la efectividad y precisión del modelo basado en redes neuronales para pronosticar el consumo de agua potable en Iquitos. La aplicación de métricas de evaluación y la comparación con otros modelos respaldan la validez y aplicabilidad del enfoque propuesto. No obstante, se debe tener en cuenta las limitaciones y posibles mejoras para continuar optimizando el modelo en futuras investigaciones. En general, este trabajo representa un paso importante hacia una gestión más eficiente y sostenible del recurso hídrico en la ciudad.

## VI. CONCLUSIONES

- Se ha logrado desarrollar un modelo de predicción basado en redes neuronales artificiales para pronosticar de manera precisa el consumo de agua potable en la ciudad de Iquitos. La topología de la red neuronal utilizada consiste en un perceptrón multicapa con dos capas ocultas y una capa de salida. El algoritmo de aprendizaje utilizado es el Backpropagation, que ha demostrado ser efectivo para ajustar los pesos de la red y mejorar la precisión de las predicciones.

- Se han identificado las variables relevantes para el modelo, incluyendo la temperatura máxima, la precipitación de lluvias, la población de Iquitos. Estas variables han sido utilizadas como entradas del modelo para predecir las tarifas de consumo de agua potable en la ciudad.

- El modelo ha sido validado utilizando diferentes métricas de evaluación, como el coeficiente de regresión ( $r$ ), el coeficiente de determinación ( $R^2$ ) y el Error Porcentual Absoluto Medio (MAPE). Los resultados indican que el modelo tiene una alta correlación entre los valores reales y predichos, con un coeficiente de regresión de 0.909. Además, aproximadamente el 82.6% de la variabilidad en los datos de consumo de agua potable puede ser explicada por el modelo, según el coeficiente de determinación ( $R^2$ ). El MAPE, que mide el error promedio en las predicciones, es bajo, con un valor del 1.72%.

- El modelo ha demostrado una buena capacidad de generalización al evaluar su rendimiento en diferentes conjuntos de datos, incluyendo entrenamiento, validación y prueba. Los altos valores de correlación obtenidos en los conjuntos de prueba indican que el modelo es capaz de hacer predicciones precisas incluso en datos no vistos durante el entrenamiento.

- Aunque el modelo ha mostrado un rendimiento prometedor, es importante tener en cuenta que existen limitaciones, como el tamaño limitado del conjunto de datos históricos y la necesidad de considerar otros factores ambientales adicionales. Para futuras mejoras, se recomienda utilizar un conjunto de datos más extenso y considerar variables climáticas más detalladas y otras características demográficas y económicas que puedan afectar el consumo de agua potable.

- El modelo de predicción basado en redes neuronales artificiales desarrollado ha demostrado ser efectivo para pronosticar de manera precisa el consumo de agua potable en la ciudad de Iquitos. Las métricas de evaluación muestran una alta correlación, una buena capacidad de ajuste a los datos y un bajo error promedio en las predicciones. Estos resultados sugieren que el modelo tiene un gran potencial para ser una herramienta útil en la gestión y planificación del suministro de agua potable en la ciudad, contribuyendo a una mayor eficiencia y sostenibilidad del recurso hídrico. Sin embargo, se recomienda continuar investigando y mejorando el modelo para considerar factores adicionales y aumentar su capacidad de generalización.

## VII. RECOMENDACIONES

- Para mejorar la precisión y capacidad de generalización del modelo de predicción, se recomienda ampliar el conjunto de datos históricos disponibles. Un periodo de tiempo más largo proporcionará al modelo una visión más completa de los patrones estacionales y tendencias a lo largo del tiempo, lo que permitirá realizar predicciones más sólidas y precisas.

- Considerar la inclusión de variables climáticas más detalladas, como la humedad relativa, la velocidad del viento y la radiación solar, puede proporcionar una visión más completa de los factores ambientales que afectan el consumo de agua potable. Estos datos climáticos pueden ser obtenidos de fuentes confiables, como estaciones meteorológicas locales o instituciones especializadas.

- Además de la población, es importante considerar otros factores demográficos y económicos que puedan influir en el consumo de agua potable. Variables como el crecimiento poblacional, la tasa de urbanización, el desarrollo económico y las políticas de tarifas de agua pueden tener un impacto significativo en la demanda y deben ser tomados en cuenta en el modelo.

- Para mantener la precisión del modelo en el tiempo, es fundamental realizar un monitoreo y actualización constante de los datos de entrada. La incorporación de nuevos datos a medida que estén disponibles, así como el análisis regular de la calidad y consistencia de los datos, garantizará que el modelo esté siempre basado en la información más actualizada y confiable.

- Es recomendable realizar comparaciones del modelo basado en redes neuronales con otros modelos de predicción, como modelos estadísticos o de aprendizaje automático diferentes. Esta comparación permitirá evaluar la eficacia relativa de cada enfoque y determinar cuál es el más adecuado para el pronóstico del consumo de agua potable en Iquitos.

- Para una mejor planificación y toma de decisiones, se sugiere implementar escenarios de futuro que contemplen cambios proyectados en la población, el clima y las políticas tarifarias. Estos escenarios ayudarán a evaluar cómo podría evolucionar el consumo de agua potable en diferentes condiciones y permitirán una planificación más efectiva y resiliente.

- Evaluar la sensibilidad del modelo a cambios en las variables de entrada es importante para comprender su robustez y limitaciones. Realizar análisis de sensibilidad permitirá identificar qué variables tienen un mayor impacto en las predicciones y ayudará a focalizar los esfuerzos de mejora del modelo en las áreas más críticas.

- Es esencial involucrar a los diferentes actores relevantes, como las autoridades locales, empresas de servicios públicos y la comunidad, en el proceso de desarrollo y aplicación del modelo. La comunicación efectiva y la colaboración permitirán una mejor comprensión de los resultados del modelo y una mayor aceptación y adopción de las medidas derivadas de las predicciones.

## VIII. REFERENCIAS

Aguilar, L y Obando Díaz, F. (2020) "Aprendizaje automático para la predicción de calidad de agua potable", *Ingeniare*, n.º 28, junio de 2020

<https://doi.org/10.18041/1909-2458/ingeniare.28.6215>

Al-Ghamdi, A. B., Kamel, S., y Khayyat, M. (2021). Evaluation of Artificial Neural Networks Performance Using Various Normalization Methods for Water Demand Forecasting. In *Proceedings - 2021 IEEE 4th National Computing Colleges Conference, NCCC 2021* [9428856] (Proceedings - 2021 IEEE 4th National Computing Colleges Conference, NCCC 2021). Institute of Electrical and Electronics Engineers Inc.

<https://doi.org/10.1109/NCCC49330.2021.9428856>

Amado Camargo, M. F. (2017). Determinación bacteriológica de la calidad del agua de consumo humano, regadío y bebida de animales del Distrito de Majes, Provincia de Caylloma, Departamento de Arequipa, Abril-Mayo 2017. DSpace. Tesis. Arequipa, 2018.

<http://repositorio.unsa.edu.pe/handle/UNSA/5890>

Andrés Siles, F. (2015). Desarrollo de software y diseño de un sistema automatizado para monitoreo y predicción de eventos de contaminación en sistemas de distribución de agua, utilizando inteligencia artificial. Repositorio Dspace Desarrollo de software y diseño de un sistema automatizado para monitoreo y predicción de eventos de contaminación, 1 octubre, 2019. Accedido el 16 de agosto de 2022.

[http://literatura.ciidiroaxaca.ipn.mx:8080/xmlui/handle/LITER\\_CIIDIROAX/230](http://literatura.ciidiroaxaca.ipn.mx:8080/xmlui/handle/LITER_CIIDIROAX/230)

Bata, M., Carriveau, R. & Ting, D.S.K. Short-term water demand forecasting using hybrid supervised and unsupervised machine learning model. *Smart Water* 5, 2 (2020).

<https://doi.org/10.1186/s40713-020-00020-y>

Caceres Huanuco, A., & Garcia Robles, G. G. (2021). Propuesta de mejoramiento de abastecimiento del sistema de agua potable en el Caserío de Encayoc, distrito de Ranrahirca-Yungay 2021.

<https://repositorio.ucv.edu.pe/handle/20.500.12692/76348>

Coba Louzado, A. (2022). Metodología para pronóstico de la demanda de energía eléctrica.

<http://ninive.ismm.edu.cu/handle/123456789/3931>

CONHYDRA (2010) Gestores Integrales de agua y saneamiento (CONHYDRA S.A.)

[http://catedra.conhydra.com/file.php/2/micromedicion/docs\\_referencia/sector\\_sa](http://catedra.conhydra.com/file.php/2/micromedicion/docs_referencia/sector_sa)

Cuyo Cuyo, J. (2022). Estudio de la Probabilidad de Fugas/Fallos en las redes de agua potable en el sistema de distribución de la Empresa Pública Metropolitana de Agua Potable y Saneamiento (EPMAPS) de Quito. Quito : UCE.)

<http://www.dspace.uce.edu.ec/handle/25000/27959>

Encina Dávila, A. F. M., Pacheco Hinojoza, M. A., & Vargas Martell, V. G. (2023). Técnicas de Machine Learning para la predicción del caudal efluente de la represa Condorama.

<https://hdl.handle.net/20.500.12640/3377>

Espinosa, (2018) “El agua, un reto para la salud pública: la calidad del agua y las oportunidades para la vigilancia en salud ambiental.” UNAL. Tesis. Bogotá, 2018.

<https://repositorio.unal.edu.co/handle/unal/63149>

Eytan Gur & Dorothee Spuhler (2020). Red de distribución comunitaria. Sustainable Sanitation and Water Management (SSWM)

<https://sswm.info/es/gass-perspective-es/tecnologias-de-agua-y-saneamiento/tecnologias-de-abastecimiento-de-agua/red-de-distribucion-comunitaria>

Farah, Elias, & Shahrour, Isam (2017). Leakage detection using smart water system: Combination of water balance and automated minimum night flow. *Water Resources Management*, 31, 4821-4833.

<https://doi.org/10.1007/s11269-017-1780-9>

Galán López, D. J. (2020). Desarrollo y evaluación de modelos predictivos de consumo de agua basados en redes neuronales artificiales. Aplicación en un sector específico de la red de abastecimiento de EMACSA.

<https://helvia.uco.es/xmlui/handle/10396/20068>

García, V. E. S., & Jiménez, F. J. B. (2012). El uso sostenible del agua en núcleos urbanos: las tarifas como herramienta de control del consumo. *Observatorio medioambiental*, 15, 35-59.

[https://doi.org/10.5209/rev\\_OBMD.2012.v15.40331](https://doi.org/10.5209/rev_OBMD.2012.v15.40331)

Garduño Román, S. (2002). Enfoques metodológicos en la investigación educativa. *Investigación administrativa*, 31(90), pp. 11-24. Instituto Politécnico Nacional, México.

<https://biblat.unam.mx/hevila/InvestigacionAdministrativa/2002/vol31/no90/2.pdf>

Grandez Vasquez, Jim Cliveland (2019). Mejoramiento del diseño en el sistema de abastecimiento de agua potable en el CC. NN Alfonso Ugarte, distrito de Padre Márquez, provincia de Ucayali, departamento de Loreto, año 2019.

<https://repositorio.uladech.edu.pe/handle/20.500.13032/15963>

- Hao, W., Cominola, A., and Castelletti, A.: Multi-scale Modelling of Urban Water Demand under Urban Development and Societal Uncertainties: The Case Study of Milan, Italy., EGU General Assembly 2022, Vienna, Austria, pp. 23–27 May 2022, EGU22-7292, <https://doi.org/10.5194/egusphere-egu22-7292>.
- Hernández-López, Y., Rivas-Pérez, R., & Feliu-Batlle, V. (2020). Control automático de la distribución de agua en sistemas de riego: revisión y retos. *Ingeniería Electrónica, Automática y Comunicaciones*, 41(2), 80-97.  
[http://scielo.sld.cu/scielo.php?pid=S1815-59282020000200080&script=sci\\_arttext](http://scielo.sld.cu/scielo.php?pid=S1815-59282020000200080&script=sci_arttext)
- Herrera, M., Torgo, L., Izquierdo, J., & Pérez-García, R. (2010). Predictive models for forecasting hourly urban water demand. *Journal of hydrology*, 387(1-2), 141-150.  
<https://doi.org/10.1016/j.jhydrol.2010.04.005>
- Hilera, José & Martinez Hernando, Victor. (2000). *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*.  
[https://www.researchgate.net/publication/44343683\\_Redes\\_neuronales\\_artificiales\\_fundamentos\\_modelos\\_y\\_aplicaciones\\_Jose\\_Ramon\\_Hilera\\_Gonzalez\\_Victor\\_Jose\\_Martinez\\_Hernando](https://www.researchgate.net/publication/44343683_Redes_neuronales_artificiales_fundamentos_modelos_y_aplicaciones_Jose_Ramon_Hilera_Gonzalez_Victor_Jose_Martinez_Hernando)
- Huaquisto Cáceres, Samuel, & Chambilla Flores, Isabel Griscelda. (2019). Análisis del consumo de agua potable en el centro poblado de salcedo, PUNO. *Investigación & Desarrollo*, 19(1), 133-144.  
[http://www.scielo.org.bo/scielo.php?script=sci\\_arttext&pid=S25184312019000100010&lng=es&tlng=es](http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S25184312019000100010&lng=es&tlng=es).

- Ibrahim, T., Omar, Y. & Maghraby, F. A. (2020). Water demand forecasting using machine learning and time series algorithms. 2020 International Conference on Emerging Smart Computing and Informatics (ESCI) (IEEE). pp.325-329  
[https://scholar.google.com/eg/citations?view\\_op=view\\_citation&hl=en&user=iKsi0bAAAJ&citation\\_for\\_view=iKsi0bAAAAAJ:LkGwnXOMwfcC](https://scholar.google.com/eg/citations?view_op=view_citation&hl=en&user=iKsi0bAAAJ&citation_for_view=iKsi0bAAAAAJ:LkGwnXOMwfcC)
- Idrovo, C. (2010). Optimización de la planta de tratamiento de Uchupucún [Tesis de Licenciatura, Universidad de Cuenca.  
<http://dspace.ucuenca.edu.ec/handle/123456789/2426>
- Laura, V. (2012) La medición de consumos en las empresas de agua potable.  
<https://diariooficial.elperuano.pe/pdf/0036/ley-proteccion-datos-personales.pdf>
- Liang, X. Z., Xu, M., Yuan, X., Ling, T., Choi, H. I., Zhang, F., ... & Michalakes, J. (2012). Regional climate–weather research and forecasting model. Bulletin of the American Meteorological Society, 93(9), 1363-1387.  
<https://doi.org/10.1175/BAMS-D-11-00180.1>
- Limache Sandoval, E. (2021). Modelo ARIMA sobre el consumo de agua de uso poblacional en la ciudad de Tacna. Veritas Et Scientia, 10(1), 69 - 82.  
<https://doi.org/10.47796/ves.v10i1.461>
- Llatas, A. & Sánchez, E. (2019). Factores que generan desperdicio de agua potable – ámbitos urbanos de los distritos de Uticyacu, Ninabamba y Yauyucán.  
<http://hdl.handle.net/11537/22279>
- López, A. Figueroa y J. C. Corrales, "Un mapeo sistemático sobre predicción de calidad del agua mediante técnicas de inteligencia computacional", Revista Ingenierías Universidad de

- Medellín, vol. 15, n.º 28, pp. 35–52, 2016. Accedido el 10 de agosto de 2022.  
<https://doi.org/10.22395/rium.v15n28a2>
- Mazzeo-Agustín (2020) “Revisión sistemática de literatura sobre modelos de pronósticos de consumo de energía eléctrica”. Rev. ing. univ. Medellín [online]. 2020, vol.19, n.36, pp.107-142. Epub Aug 31, 2021. ISSN 1692-3324.  
<https://doi.org/10.22395/rium.v19n36a6>.
- Miranda, J. P. R., Mosquera, J. A. S., & Céspedes, J. M. S. (2016). Índices de calidad en cuerpos de agua superficiales en la planificación de los recursos hídricos. Revista Logos, Ciencia & Tecnología, 8(1), 159-167.  
<https://www.redalyc.org/journal/5177/517752176015/517752176015.pdf>
- Nasser, A. A., Rashad, M. Z., & Hussein, S. E. (2020). A two-layer water demand prediction system in urban areas based on micro-services and LSTM neural networks. IEEE Access, 8, 147647-147661. <https://ieeexplore.ieee.org/abstract/document/9163328/>
- Olivera Mayorca, F. D. (2020). Redes neuronales artificiales en la estimación de la resistencia a la compresión del concreto para la Provincia de Huancayo.  
<http://repositorio.uncp.edu.pe/handle/20.500.12894/6139>
- Pandolfi, D., Alba, E., Villagra, A. & Leguizamón, G. (26 y 27 abril de 2018) Redes inteligentes de agua: factores y métodos para la predicción del consumo residencial de agua potable [Conferencia] XX Workshop de Investigadores en Ciencias de la Computación (WICC 2018, Universidad Nacional del Nordeste) pp. 46-49  
<http://sedici.unlp.edu.ar/handle/10915/67101>

Pavón Valencia, J. F. (2019). Modelo para el pronóstico de la demanda de agua potable de EMAPA-I aplicando redes neuronales artificiales.

<http://repositorio.utn.edu.ec/handle/123456789/9038>

Perdigón Llanes, Rudibel, & González Benítez, Neilys. (2021). Comparación y selección de técnicas de inteligencia artificial para pronosticar las producciones de leche bovina. Revista Cubana de Ciencias Informáticas, 15(2), 24-43. Epub 01 de junio de 2021.

<http://scielo.sld.cu/pdf/rcci/v15n2/2227-1899-rcci-15-02-24.pdf>

Pereda García, M., Santos Martín, J. I., & Galán Ordax, J. M. (2017). A Brief Introduction to the Use of Machine Learning Techniques in the Analysis of Agent-Based Models. En C. Hernández Iglesias (ed.), *Advances in Management Engineering* (pp. 179-186). Springer International Publishing AG.

[https://doi.org/10.1007/978-3-319-55889-9\\_11](https://doi.org/10.1007/978-3-319-55889-9_11)

Portillo Quispe, J. (2014). Modelo dinámico para la predicción del abastecimiento de agua potable, ciudad de Ayacucho, 2010 al 2020.

<http://repositorio.unsch.edu.pe/xmlui/handle/UNSCH/4551?locale-attribute=es>

Prabhakar, H., & Furqan, A. (2022). Energy consumption profiles of wireless sensor nodes in smart cities using CupCarbon (V 5.0) simulator. *International Journal of Communication Networks and Distributed Systems*, 28(6), 727-744.

<https://doi.org/10.1504/IJCNDS.2022.126223>

Quiñones Huatangari, L. Ochoa Toledo, N. Kemper Valverde, O. Gamarra Torres, J. Bazán Correa y J. Delgado Soto, "Red neuronal artificial para estimar un índice de calidad de agua",

Enfoque UTE, vol. 11, n.º 2, pp. 109–120, abril de 2020. Accedido el 11 de agosto de 2022.

<https://doi.org/10.29019/enfoque.v11n2.633>

Redes neuronales artificiales aplicadas en sistemas de predicción para la seguridad vial. Avances: Investigación En Ingeniería, 17(2).

<https://doi.org/10.18041/1794-4953/avances.2.6632>

Reyes, L., Torres, L., Jiménez, M., & Ríos, C. (2022). Predicción de la máxima demanda en un sector de la red de distribución de agua potable de la ciudad de Guanajuato, México. Tecnología y Ciencias Del Agua, 13(4), 414–446.

<https://doi.org/10.24850/j-tyca-2022-04-09>

Sánchez, C. C. (2018). Enfermedades infecciosas relacionadas con el agua en el Perú. Revista peruana de medicina experimental y salud pública, 35, 309-316.

<https://www.scielosp.org/article/rpmesp/2018.v35n2/309-316/es/>

Sandoval, E. M. L. (2021). Modelo ARIMA sobre el consumo de agua de uso poblacional en la ciudad de Tacna. Veritas Et Scientia, 10(1), 69-82.

<https://revistas.upt.edu.pe/ojs/index.php/vestsc/article/view/461>

Salloom, T., Kaynak, O., & He, W. (2021). A novel deep neural network architecture for real-time water demand forecasting. Journal of Hydrology, 599, 126353.

<https://doi.org/10.1016/j.jhydrol.2021.126353>

Serrano Pérez, B., Tendero Caballero, R., & Río Merino, M. D. (2018). Parámetros indicadores del agua potable doméstica urbana, umbrales y consecuencias para la salud.

<https://www.riarte.es/handle/20.500.12251/351>

Shirkoochi, M. G., Doghri, M., & Duchesne, S. (2021). Short-term water demand predictions coupling an artificial neural network model and a genetic algorithm. *Water Supply*, 21(5), 2374-2386.

<https://doi.org/10.2166/ws.2021.049>

SUNASS (2003). II. Sector saneamiento en el Perú- memoria 2002-2003. Disponible: [http://catedra.conhydra.com/file.php/2/micromedicacion/docs\\_referencia/sector\\_saneamiento\\_peru\\_2002-2003.pdf](http://catedra.conhydra.com/file.php/2/micromedicacion/docs_referencia/sector_saneamiento_peru_2002-2003.pdf)

SUNASS (2021) Empresas prestadoras de servicios de saneamiento. <https://www.sunass.gob.pe/prestadores/empresas-prestadoras/>

Tavera, M. (2013). Metodología para la gestión y planificación de un sistema de agua potable con suministro intermitente: Aplicación a la Ciudad de Tegucigalpa. [https://riunet.upv.es/bitstream/handle/10251/21067/TMT\\_Indice.pdf?sequence=5](https://riunet.upv.es/bitstream/handle/10251/21067/TMT_Indice.pdf?sequence=5)

Tostado Sánchez, S. E., Ornelas Rodríguez, M., Espinal Jiménez, A., & Puga Soberanes, H. J. (2016). implementación de algoritmos de inteligencia artificial para el entrenamiento de redes neuronales de segunda generación. *jóvenes en la ciencia*, 2(1), 6–10. <https://www.jovenesenlaciencia.ugto.mx/index.php/jovenesenlaciencia/article/view/715>

Urgilés, P., Inga-Ortega, J., Peralta, A., & Ortega, A. (2021). Prediction of Electricity Consumption Profiles Using Potential Polynomials of Degree One and Artificial Neural Networks in Smart Metering Infrastructure. *Revista Facultad de Ingeniería - UPTC*, 30(56), 1–16.0

<https://doi.org/10.19053/01211129.v30.n56.2021.12772>

Vásquez Cano, Sergio Alberto (2019). Elementos técnicos de diseño, construcción y operación para la supervisión de los sistemas bombeo de las edificaciones donde EPM atiende los servicios de acueducto y alcantarillado.

<https://hdl.handle.net/10495/13171>

Velásquez-Henao, J. D., Franco-Cardona, C. J., & Olaya-Morales, Y. (2012). A Review of DAN2 (Dynamic Architecture for Artificial Neural Networks) Model in Time Series Forecasting. *Ingeniería y Universidad*, 16(1), 135–146.

[https://www.researchgate.net/figure/The-DAN2-Model\\_fig3\\_256662765](https://www.researchgate.net/figure/The-DAN2-Model_fig3_256662765)

Vidaurre, Y. (2012). Aplicación de las redes neuronales artificiales para el pronóstico de la demanda de agua potable en la Empresa Epsel S.A. de la ciudad de Lambayeque [Tesis de pregrado, Universidad Católica Santo Toribio de Mogrovejo] Repositorio de la USAT.

<https://tesis.usat.edu.pe/handle/20.500.12423/525>

Yao, X. (1999). Evolving artificial neural networks. *Proceedings of the IEEE*, 87(9), 1423-1447.

<https://ieeexplore.ieee.org/abstract/document/784219>

Zanfei, A., Menapace, A., & Righetti, M. (2023). An artificial intelligence approach for managing water demand in water supply systems. In *IOP Conference Series: Earth and Environmental Science* (Vol. 1136, No. 1, p. 012004). IOP Publishing.

<https://iopscience.iop.org/article/10.1088/1755-1315/1136/1/012004/meta>

Zhou, H., Nusier, O.K. and Smith, D.W. (2002). Advanced Technologies in Water and Wastewater Treatment. *Journal of Environmental Engineering and Science*, 1, 247-264. Open Access Library Journal, Vol.1 No.5, August 11, 2014 <http://dx.doi.org/10.1139/s02-020>

## IX. ANEXOS

### Anexo A

#### *Matriz de consistencia de la investigación*

Título “Modelo predictivo basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos”

<b>Problema Principal</b>	<b>Objetivo General</b>	<b>Hipótesis</b>	<b>Variables</b>	<b>Indicador</b>	<b>Metodología</b>
<p><b>Problema General</b></p> <p>¿De qué manera el desarrollo de un modelo de predicción basado en redes neuronales artificiales pronostica de manera precisa el consumo de agua potable en la ciudad de Iquitos?</p>	<p><b>Objetivo General</b></p> <p>Desarrollar un modelo de predicción basado en redes neuronales artificiales para pronosticar de manera precisa el consumo de agua potable en la ciudad de Iquitos, utilizando variables históricas relevantes, y otros factores como el clima, la población y las facturaciones de consumo de agua.</p>	<p><b>Hipótesis general:</b></p> <p>El desarrollo de un modelo de predicción basado en redes neuronales artificiales pronostica de manera precisa el consumo de agua potable en la ciudad de Iquitos al considerar variables históricas relevantes, así como factores ambientales como el clima, la población y las facturaciones de agua.</p>	<p>Variable Independiente</p> <p>Modelo de predicción basada en redes neuronales artificiales.</p>	<ul style="list-style-type: none"> <li>• Capacidad de ajustar predicciones en tiempo real.</li> <li>• Incorporación de nuevos datos y variables.</li> </ul>	<p>El tipo de investigación es:</p> <p><b>Aplicada</b></p> <p>El nivel de investigación es:</p> <p><b>Descriptiva</b></p> <p>El diseño de la investigación se basa en un enfoque:</p>
<p><b>Problemas Específicos</b></p> <p>1. ¿Cómo se pueden identificar los patrones estacionales de consumo de agua potable en la ciudad de Iquitos mediante el análisis de los requisitos del modelo de predicción basado en redes neuronales artificiales,</p>	<p><b>Objetivos Específicos</b></p> <p>1. Analizar los Requerimientos del modelo de predicción basado en redes neuronales artificiales para pronosticar los patrones estacionales de consumo de agua potable en la ciudad de Iquitos,</p>	<p><b>Hipótesis específicas:</b></p> <p>1. El análisis de los Requerimientos del modelo de predicción basado en redes neuronales artificiales identifica los patrones estacionales de consumo de agua potable en la ciudad de Iquitos,</p>	<p>Variable dependiente</p> <p>Pronostico del consumo de agua potable en la</p>	<p>-Error medio absoluto (MAE)</p> <p>-Error cuadrático medio (MSE)</p>	<p><b>Longitudinal</b></p> <p>La población: <b>está constituida por los usuarios de agua potable en la ciudad de Iquitos</b></p>

<p>utilizando datos históricos y variables climáticas como inputs?</p> <p>2. ¿Cómo diseñar el modelo de predicción basado en redes neuronales artificiales para estimar el alcance, el crecimiento demográfico, el consumo, la demanda de agua de agua potable, empleando datos históricos de población y considerando su impacto en la demanda de agua en Iquitos?</p> <p>3. ¿Cómo se puede evaluar la precisión del modelo de predicción basado en redes neuronales artificiales al pronosticar el consumo de agua potable en la ciudad de Iquitos?</p>	<p>utilizando datos históricos y variables climáticas como inputs.</p> <p>2.Diseñar un modelo de predicción basado en redes neuronales artificiales para estimar de forma precisa el consumo de agua potable, empleando datos históricos de temperatura, precipitación y crecimiento poblacional.</p> <p>3.Validar la precisión de la predicción del modelo basado en redes neuronales artificiales para pronosticar el consumo de agua potable en la ciudad de Iquitos.</p>	<p>utilizando datos históricos y variables climáticas como inputs.</p> <p>2.El diseño de un modelo de predicción basado en redes neuronales artificiales estima de forma precisa el consumo de agua potable, empleando datos históricos de temperatura, precipitación y crecimiento poblacional.</p> <p>3.La validación de la precisión de la predicción del modelo basado en redes neuronales artificiales contribuye al pronóstico efectivo del consumo de agua potable en la ciudad de Iquitos, mediante técnicas de cálculo del error, medio absoluto (MAE), el error cuadrático medio (MSE) y el coeficiente de determinación (R<sup>2</sup>).</p>	<p>ciudad de Iquitos</p>	<p>- Coeficiente de determinación (R<sup>2</sup>).</p>	<p>Muestra: Para la investigación no se realizó muestreo y se consideró a toda la población ya que los datos son almacenados electrónicamente en la empresa de saneamiento E.P.S. Sedaloretto S.A.</p>
---	--	---	--------------------------	--	--

## Anexo B

*Código fuente en lenguaje de programación solve de Matlab del modelo de predicción de consumo de agua potable en la ciudad de Iquitos.*

```

% Solve an Input-Output Fitting problem with a Neural Network
% Script generated by Neural Fitting app
% Created 19-Jul-2023 11:15:15
%
% This script assumes these variables are defined:
%
% data - input data.
% data_1 - target data.
x = data;
t = data_1;
% Choose a Training Function
% For a list of all training functions type: help nntrain
% 'trainlm' is usually fastest.
% 'trainbr' takes longer but may be better for challenging problems.
% 'trainscg' uses less memory. Suitable in low memory situations.
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.
% Create a Fitting Network
hiddenLayerSize = 10;
net = fitnet(hiddenLayerSize,trainFcn);
% Choose Input and Output Pre/Post-Processing Functions
% For a list of all processing functions type: help nnprocess
net.input.processFcns = {'removeconstantrows','mapminmax'};
net.output.processFcns = {'removeconstantrows','mapminmax'};
% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nndivision
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;
% Choose a Performance Function
% For a list of all performance functions type: help nnperformance
net.performFcn = 'mse'; % Mean Squared Error
% Choose Plot Functions
% For a list of all plot functions type: help nnplot
net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
'plotregression', 'plotfit'};
% Train the Network
[net,tr] = train(net,x,t);

```

```

% Test the Network
y = net(x);
e = gsubtract(t,y);
performance = perform(net,t,y)
% Recalculate Training, Validation and Test Performance
trainTargets = t .* tr.trainMask{1};
valTargets = t .* tr.valMask{1};
testTargets = t .* tr.testMask{1};
trainPerformance = perform(net,trainTargets,y)
valPerformance = perform(net,valTargets,y)
testPerformance = perform(net,testTargets,y)
% View the Network
view(net)
% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, ploterrhist(e)
%figure, plotregression(t,y)
%figure, plotfit(net,x,t)
% Deployment
% Change the (false) values to (true) to enable the following code blocks.
% See the help for each generation function for more information.
if (false)
    % Generate MATLAB function for neural network for application
    % deployment in MATLAB scripts or with MATLAB Compiler and Builder
    % tools, or simply to examine the calculations your trained neural
    % network performs.
    genFunction(net,'myNeuralNetworkFunction');
    y = myNeuralNetworkFunction(x);
end
if (false)
    % Generate a matrix-only MATLAB function for neural network code
    % generation with MATLAB Coder tools.
    genFunction(net,'myNeuralNetworkFunction','MatrixOnly','yes');
    y = myNeuralNetworkFunction(x);
end
if (false)
    % Generate a Simulink diagram for simulation or deployment with.
    % Simulink Coder tools.
    gensim(net);
end

```