



UNAP



**FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS E
INFORMÁTICA**

TESIS

**PREDICCIÓN DE CONSUMO DEL SERVICIO DE AGUA POTABLE
BASADO EN MÉTODOS DE MACHINE LEARNING EN LA CIUDAD DE
IQUITOS**

**PARA OPTAR EL TÍTULO PROFESIONAL DE
INGENIERO DE SISTEMAS E INFORMÁTICA**

PRESENTADO POR:

**JASON ROBIE JHUNIOR VASQUEZ COQUINCHE
HAROLD PINEDO FLORES**

ASESOR:

Ing. CARLOS ALBERTO GARCIA CORTEGANO, Dr.

IQUITOS, PERÚ

2023



ACTA DE SUSTENTACIÓN DE TESIS - 2023

En Iquitos, en la modalidad presencial, a los 10 días del mes de noviembre del 2023, a horas 11:00 am, se dio inicio a la sustentación de la Tesis Titulada: "PREDICCIÓN DE CONSUMO DEL SERVICIO DE AGUA POTABLE BASADO EN METODOS DE MACHINE LEARNING EN LA CIUDAD DE IQUITOS", presentado por los bachilleres: HAROLD PINEDO FLORES y JASON ROBIE JHUNIOR VÁSQUEZ COQUINCHE, para optar el Título Profesional de Ingeniero de Sistemas e Informática, que otorga la Universidad de acuerdo a Ley y Estatuto.

El Jurado calificador y dictaminador designado mediante Resolución Decanal N°060-D-FISI-UNAP-2023, está integrado por:

- ✓ Ing. Carlos González Aspajo, Mgr. Presidente
- ✓ Ing. Ronald Percy Melchor Infantes, Mgr. Miembro
- ✓ Ing. Jimmy Max Ramírez Villacorta, Mgr. Miembro



Luego de haber el Jurado escuchado con atención y formulado las preguntas necesarias, las cuales fueron respondidas: CORRECTAMENTE.....

El jurado después de las deliberaciones correspondientes, llegó a las siguientes conclusiones:

La Sustentación de la Tesis ha sido: APROBADA.....con la calificación de: 16.....

Estando el Bachiller apto para obtener el Título Profesional de Ingeniero de Sistemas e Informática.

Siendo las 12:05..... se dio por terminado el acto de sustentación.

Ing. Carlos González Aspajo, Mgr.
Presidente

Ing. Ronald Percy Melchor Infantes, Mgr.
Miembro

Ing. Jimmy Max Ramírez Villacorta, Mgr.
Miembro

Ing. Carlos Alberto García Cortegano, Dr.
ASESOR

JURADO Y ASESOR

TESIS APROBADA EN SUSTENTACIÓN PÚBLICA EL DÍA 10 DE NOVIEMBRE AÑO 2023 EN LA FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA DE LA UNIVERSIDAD NACIONAL DE LA AMAZONÍA PERUANA, EN IQUITOS - PERÚ.



Ing. CARLOS GONZÁLEZ ASPAJO, Mgr.
Presidente



Ing. RONALD PERCY MELCHOR INFANTES, Mgr.
Miembro



Ing. JIMMY MAX RAMÍREZ VILLACORTA, Mgr.
Miembro



Ing. CARLOS ALBERTO GARCÍA CORTEGANO, Dr.
Asesor

NOMBRE DEL TRABAJO

FISI_TESIS_VASQUEZ COQUINCHE_PINEDO FLORES.pdf

AUTOR

VASQUEZ COQUINCHE / PINEDO FLORES

RECUENTO DE PALABRAS

8122 Words

RECUENTO DE CARACTERES

43109 Characters

RECUENTO DE PÁGINAS

32 Pages

TAMAÑO DEL ARCHIVO

733.4KB

FECHA DE ENTREGA

Feb 19, 2024 2:09 AM GMT-5

FECHA DEL INFORME

Feb 19, 2024 2:09 AM GMT-5**● 25% de similitud general**

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 14% Base de datos de Internet
- Base de datos de Crossref
- 22% Base de datos de trabajos entregados
- 3% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● Excluir del Reporte de Similitud

- Material bibliográfico
- Coincidencia baja (menos de 10 palabras)

DEDICATORIA

La presente tesis está dedicada con profundo agradecimiento y amor a mis padres, Robin y Zenit, por brindarme una educación maravillosa que me permitió crecer con valores sólidos de respeto, humildad y sacrificio. Gracias a ellos, aprendí a valorar cada uno de los logros obtenidos en mi proceso de superación personal y profesional.

Asimismo, dedico esta tesis a mi hijo, quien es mi mayor fuente de inspiración y fortaleza. Su presencia en mi vida me motiva a seguir creciendo y me impulsa a dar lo mejor de mí para ofrecerle la educación que se merece.

A mis queridos hermanos, agradezco por estar siempre cerca, brindándome su apoyo incondicional y su consejo sabio en cada etapa de mi camino. Sin su aliento y compañía, no habría sido posible alcanzar mis objetivos.

Gracias a todos ellos, hoy puedo presentar esta tesis como un testimonio de mi dedicación, perseverancia y esfuerzo. A cada uno de ustedes, les ofrezco mi gratitud eterna.

Jason Vásquez

Deseo dedicar mi tesis con profundo agradecimiento a Dios, quien me ha brindado la vida y me ha provisto de bendiciones innumerables. Gracias a Él, he podido conocer a personas excepcionales que me han apoyado e inspirado a seguir adelante durante todo el periodo de estudio.

A mis padres y abuelos, les ofrezco mi gratitud eterna por su apoyo moral incondicional y por ser un ejemplo de lucha y perseverancia en el largo camino de la vida. Gracias a ellos, aprendí a luchar por mis sueños y a ser constante en la consecución de mis objetivos. Cada uno de ustedes ha sido fundamental en mi formación académica y personal. Agradezco su presencia en mi vida y el apoyo que siempre me brindaron. Esta tesis es un reflejo de mi dedicación y compromiso, y espero que les haga sentir orgullosos de mí.

Harold Pinedo

AGRADECIMIENTO

Queremos expresar nuestro más profundo agradecimiento, en primer lugar, a Dios por brindarnos salud y fortaleza para seguir adelante en este camino.

Agradecemos a nuestra alma mater por brindarnos una educación superior de la cual nos sentimos sumamente orgullosos de haber formado parte. La formación que recibimos nos ha permitido enfrentar con éxito los retos académicos y profesionales que se nos han presentado.

De manera especial, queremos agradecer a nuestro asesor, al Dr. en Ing. Carlos Alberto García Cortegano, por su orientación, guía y apoyo constante durante todo el proceso de tesis. Su conocimiento y experiencia fueron fundamentales para lograr los resultados obtenidos.

También deseamos expresar nuestro agradecimiento a todos nuestros docentes, quienes con su dedicación y profesionalismo contribuyeron en nuestra formación y aprendizaje durante nuestra carrera. Sus enseñanzas han dejado una huella indeleble en nuestra formación académica y personal.

A todos ustedes, les ofrecemos nuestro más sincero agradecimiento por su apoyo y por haber sido parte fundamental en la culminación de este importante proyecto en nuestras vidas.

ÍNDICE DE CONTENIDO

PORTADA	i
ACTA DE SUSTENTACIÓN DE TESIS	ii
JURADO Y ASESOR	iii
RESULTADO DEL INFORME DE SIMILITUD	iv
DEDICATORIA	v
AGRADECIMIENTO	vi
ÍNDICE DE CONTENIDO	vii
ÍNDICE DE TABLAS	ix
ÍNDICE DE GRÁFICOS	x
RESUMEN	xi
ABSTRACT	xii
INTRODUCCIÓN	1
CAPITULO I: MARCO TEÓRICO	3
1.1. Antecedentes.	3
1.2. Bases Teóricas	5
1.2.1. Machine Learning	5
1.2.1.1. Métodos de Machine Learning	6
1.2.2. Predicción del consumo de agua potable.	9
1.3. Definición de términos básicos.	11
CAPITULO II: HIPÓTESIS Y VARIABLES	15
2.1. Formulario de hipótesis.	15
2.2. variables y operacionalización.	15
2.2.1. variables	15
2.2.2. Operación de las variables.	15
CAPITULO III: METODOLOGÍA	17
3.1. Diseño metodológico.	17
3.1.1. Tipo de investigación.	17
3.1.2. Diseño de la investigación.	17
3.2. Diseño muestral.	17
3.3. Procedimiento de recolección de datos.	18
3.4. Procesamiento y análisis de la información.	18
3.5. Aspectos éticos.	18
CAPITULO IV: RESULTADOS.	19
4.1. MODELO DE RED NEURONAL ARTIFICIAL.	19

4.1.1. Evaluación de la precisión del modelo a través de la medición de indicadores como Error cuadrático (MSE) y el coeficiente de correlación (R).	19
4.1.2. Evaluación de la precisión del modelo de predicción desarrollado y su capacidad para predecir con precisión el consumo de agua potable.	21
4.2. CONTRASTACIÓN DE HIPÓTESIS.	24
CAPITULO V: DISCUSIONES	26
CAPÍTULO VI: CONCLUSIONES	28
CAPÍTULO VII: RECOMENDACIONES	30
CAPÍTULO VIII: REFERENCIAS BIBLIOGRÁFICAS	31
ANEXOS	36
ANEXO 01.	36
Instrumentos de recolección de datos, variables predictoras normalizadas.	
ANEXO 02.	39
Instrumentos de recolección de datos, variable objetivo o de salida.	
ANEXO 03.	40
Matriz de consistencia.	
ANEXO 04.	42
Código fuente del modelo de la red neuronal de predicción de consumo de agua potable en Iquitos.	
ANEXO 05.	45
Histograma de error con 20 contenedores.	
ANEXO 06.	46
Correlaciones de entretenimiento, variables y prueba del modelo de red neuronal	

ÍNDICE DE TABLAS

	pág.
Tabla 1. Operacionalización de las variables.	16
Tabla 2. Tamaño de la muestra.	17
Tabla 3. Resultados de entrenamiento, validación y prueba de la red Neuronal artificial en la predicción del consumo de agua potable en la Ciudad de Iquitos	19
Tabla 4. Valores de consumo real y predecido de consumo de agua potable en Iquitos 2021.	21
Tabla 5. Correlación entre el consumo real y predecido de agua potable de Iquitos	22

ÍNDICE DE GRÁFICOS

	Pág.
Gráfico 1. Rendimiento de validación de la red neuronal artificial en la predicción del consumo de agua potable en función del error cuadrático Medio	20
Gráfico 2. consumo real y predecido de agua potable, 2021.	22

RESUMEN

El estudio desarrolló y evaluó un modelo de predicción de consumo de agua potable en la ciudad de Iquitos, utilizando una muestra de tamaño 288 obtenida de datos históricos de SENAMHI, INEI y SEDALORETO. Se empleó un enfoque cuantitativo, aplicado y correlacional no experimental para construir y evaluar un modelo de Red Neuronal Artificial (RNA), comparando los resultados del modelo con los datos históricos de consumo. La precisión del modelo se evaluó utilizando algoritmos y modelos estadísticos en Matlab, utilizando indicadores como el Error cuadrático medio (MSE), el Coeficiente de correlación (R), el error porcentual absoluto medio (MAPE) y el coeficiente de determinación (R^2). Los resultados mostraron que el modelo de RNA presentó un alto rendimiento en términos de precisión en el conjunto de entrenamiento, validación y prueba, con MSE de $99736607.27 \times 10^{-8}$, $283364279.46 \times 10^{-8}$ y $373108841.22 \times 10^{-8}$, y coeficientes de correlación (R) de 0.996463, 0.986462 y 0.984320, respectivamente. El modelo de predicción para el consumo de agua potable en la ciudad de Iquitos mostró un MAPE del 1.72%, una correlación de 0.909 y un coeficiente de determinación (r^2) de 0.826, lo que sugiere una fuerte relación positiva entre las variables y una capacidad aceptable del modelo para predecir con precisión el consumo de agua potable. En conclusión, el modelo de Machine Learning utilizado demostró ser efectivo en la predicción del consumo de agua potable en la ciudad de Iquitos, lo que puede mejorar la eficiencia en la gestión de recursos y garantizar un suministro adecuado de agua potable a la población.

Palabras claves. Modelo de predicción, consumo de agua potable, redes neuronales artificiales, precisión, coeficiente de correlación, coeficiente de determinación, Machine Learning.

ABSTRACT

The study developed and evaluated a prediction model for drinking water consumption in the city of Iquitos, using a sample of size 288 obtained from historical data from SENAMHI, INEI, and SEDALORETO. A quantitative, applied, and non-experimental correlational approach was used to build and test an Artificial Neural Network (ANN) model, comparing model results with historical consumption data. The accuracy of the model was evaluated using algorithms and statistical models in MATLAB, using indicators such as Mean Squared Error (MSE), Correlation Coefficient (R), Mean Absolute Percentage Error (MAPE), and Coefficient of Determination (R^2). The results showed that the RNA model presented a high performance in terms of precision in the training, validation and test set, with MSEs of $99736607.27 \times 10^{-8}$, $283364279.46 \times 10^{-8}$ and $373108841.22 \times 10^{-8}$, and correlation coefficients (R) of 0.996463, 0.986462 and 0.984320, respectively. The prediction model for drinking water consumption in the city of Iquitos showed a MAPE of 1.72%, a correlation of 0.909 and a coefficient of determination (R^2) of 0.826, which suggests a strong positive relationship between the variables and a capacity acceptable value of the model to accurately predict drinking water consumption. In conclusion, the Machine Learning model used proved to be effective in predicting drinking water consumption in the city of Iquitos, which can improve efficiency in resource management and guarantee an adequate supply of drinking water to the population.

Keywords. Prediction model, drinking water consumption, artificial neural networks, precision, correlation coefficient, coefficient of determination, Machine Learning.

INTRODUCCIÓN

La disponibilidad de agua potable es fundamental para la subsistencia, y el bienestar de las comunidades, pero muchas ciudades enfrentan desafíos para administrar sus recursos hídricos de manera eficiente. La ciudad de Iquitos en Perú es una de estas ciudades, además, ha habido un aumento en la población significativo en los últimos años, lo que ha aumentado la demanda de servicios básicos, como el suministro de agua potable. Para abordar este desafío, la creación y evaluación de un modelo predictivo del consumo de agua basado en técnicas de aprendizaje automático podría ser una herramienta valiosa con el objetivo de optimizar la organización y manejo de los suministros de agua en la ciudad.

El propósito de esta investigación es desarrollar y evaluar la efectividad de modelos basados en diversos métodos de Machine Learning, incluyendo redes neuronales artificiales y el algoritmo de Levenberg-Marquardt, para la predicción precisa del consumo de agua potable en la ciudad de Iquitos.

. Los objetivos específicos son la medición de la precisión del modelo mediante indicadores como el Error Cuadrático Medio (MSE) y el Coeficiente de Correlación (R), la evaluación de su capacidad para predecir con precisión el consumo de agua mediante la comparación de los valores previstos y reales, y la creación de una plataforma que permita anticipar el consumo de agua en Iquitos utilizando tecnología y datos.

La hipótesis de esta investigación menciona que los modelos desarrollados mediante la aplicación de métodos de Machine Learning, incluyendo redes neuronales artificiales y el algoritmo de Levenberg-Marquardt, mejorarán significativamente la precisión en las predicciones del consumo de agua potable en la ciudad de Iquitos.

La realización de esta investigación se justifica en el contexto de la ciudad de Iquitos, donde la ausencia de información precisa y actualizada sobre el consumo de agua dificulta la gestión eficiente del suministro de agua. El uso de técnicas de aprendizaje automático para la previsión del uso de agua podría representar un recurso valioso para mejorar la planificación y manejo de los suministros de agua en la ciudad. Los resultados obtenidos

podrían ser útiles en la creación de modelos de predicción de consumo para otras ciudades con características similares a Iquitos, lo que podría tener un impacto positivo en la gestión eficiente del suministro de agua a nivel nacional e internacional.

En este estudio, se utilizó un enfoque de investigación cuantitativa para construir y evaluar un modelo de predicción del consumo en la ciudad de Iquitos, el suministro de agua mediante el uso de una RNA. La investigación aplicada busca resolver problemas reales en la gestión del suministro de agua a través de la aplicación de conocimientos teóricos. Se utilizó un enfoque predictivo para garantizar la precisión y confiabilidad del modelo de RNA, el cual fue comparado con datos históricos para determinar su precisión. Para examinar la conexión entre las variables que predicen y la variable de consumo de agua, se empleó un diseño correlacional no experimental y se evaluó la precisión del modelo mediante varios indicadores.

En síntesis, la justificación de esta investigación radica en la necesidad de optimizar el manejo de los suministros de agua en Iquitos a través del uso de técnicas de aprendizaje automático para predecir el consumo de agua, lo que permite una planificación y asignación de recursos más efectiva para cubrir las necesidades de agua potable de la comunidad

Esta investigación se divide en ocho secciones, cada una de las cuales cumple un propósito particular. La primera parte presenta el marco teórico que sustenta el estudio. La segunda sección define las hipótesis y variables a ser utilizadas en el análisis. La tercera describe la metodología de investigación aplicada en el estudio. La cuarta parte muestra los resultados obtenidos a través del uso del modelo de Red Neuronal Artificial (RNA). La quinta discute los hallazgos y los compara con los resultados previos de investigaciones similares. La sexta presenta las conclusiones alcanzadas a partir del análisis de los datos. La séptima ofrece sugerencias para mejorar el manejo de los suministros de agua en la ciudad de Iquitos. Finalmente, la octava sección incluye la bibliografía utilizada en el desarrollo de esta investigación.

CAPITULO I: MARCO TEÓRICO

1.1. Antecedentes.

En 2019, se llevó a cabo una investigación para prever la necesidad de agua potable en Guayaquil, Ecuador, utilizando redes neuronales. La investigación se basó en un enfoque cuantitativo y se recopilaron los datos de consumo de agua de 1000 hogares durante un período de un año, proporcionados por la compañía proveedora del servicio. Los resultados mostraron que las redes neuronales son una herramienta efectiva para predecir la demanda de agua potable en Guayaquil, y se concluyó que la precisión de las predicciones está influenciada por el tamaño de la muestra y la incorporación de variables climáticas que pueden mejorar la precisión de las predicciones. (Pinto, A. et al., 2020).

En 2021, se realizó una investigación para prever el uso de agua potable en Lima, Perú, a través de redes bayesianas. Este estudio cuantitativo recopiló datos de consumo de agua potable de 2000 hogares durante un período de un año, utilizando el registro de la empresa encargada del suministro de agua como fuente de información. Los resultados indicaron que las redes bayesianas son una herramienta efectiva para predecir el consumo de agua potable en Lima, y se encontró que la precisión de las predicciones está influenciada por la cantidad de variables incluidas en el modelo. Además, se concluyó que la incorporación de variables climáticas y días festivos aumenta la precisión de las predicciones. (Rodríguez, J. et al., 2021).

En 2021, se llevó a cabo una investigación con el objetivo de prever el uso de agua potable en Lima mediante redes neuronales. Esta investigación se basó en un enfoque cuantitativo y se utilizó una muestra de 500 hogares, con datos de consumo de agua obtenidos de la compañía proveedora del servicio. Los resultados indicaron que las redes neuronales son una herramienta efectiva para predecir el consumo de agua potable en Lima. Además, se encontró que la precisión de las predicciones puede ser influenciada por el tamaño de la muestra y que la incorporación de variables

socioeconómicas y climáticas puede mejorar la precisión de las predicciones. (Valdés, J. et al., 2021)

En 2021, se realizó un estudio para evaluar la capacidad de los modelos de aprendizaje automático en la previsión del uso de agua en Lima. La investigación se basó en un enfoque cuantitativo y se utilizó el algoritmo de regresión lineal para crear un modelo predictivo. Este estudio fue considerado una investigación aplicada y descriptiva y se recopilaron datos de consumo de agua de los últimos tres años en Lima. Los resultados sugirieron que el modelo predictivo creado fue efectivo en la predicción del consumo de agua y podría proporcionar una herramienta valiosa para la gestión y planificación del recurso hídrico por parte de las autoridades locales. En conclusión, el uso de modelos de aprendizaje automático puede ser útil en la predicción del consumo de agua en ciudades con una gran cantidad de datos disponibles. (Ramos, E., 2021).

En 2021, se llevó a cabo un estudio para evaluar la eficacia de diferentes métodos de aprendizaje automático en la predicción del uso de agua en la Ciudad de México. La investigación adoptó un enfoque cuantitativo y se desarrollaron modelos predictivos usando diferentes algoritmos, como las redes neuronales y los árboles de decisión. El diseño de investigación utilizado fue un estudio comparativo, con datos de consumo de agua recopilados de los últimos cinco años en la Ciudad de México. Los resultados revelaron que tanto los modelos basados en redes neuronales como aquellos basados en árboles de decisión eran efectivos en la predicción del consumo de agua, con un margen de error bajo. Por lo tanto, se concluyó que los algoritmos de aprendizaje automático pueden ser valiosas herramientas para predecir el uso de agua en ciudades que tienen amplios datos disponibles. (García, J. F., 2021).

En 2022 se llevó a cabo un estudio con el objetivo de evaluar la eficacia de los modelos de aprendizaje automático en la predicción del consumo de agua en Iquitos. Se adoptó un enfoque cuantitativo y se creó un modelo de predicción utilizando el algoritmo de regresión logística.

La investigación fue clasificada como descriptiva y se utilizó un diseño de correlación. Se recopilaron datos de consumo de agua de los últimos tres años en Iquitos y se utilizó el algoritmo de regresión logística para desarrollar un modelo predictivo. Los resultados sugirieron que el modelo desarrollado fue efectivo en la predicción del consumo de agua en Iquitos, brindando una herramienta útil para las autoridades locales en la gestión del recurso hídrico. En general, se concluye que los modelos de aprendizaje automático pueden ser útiles en la predicción del consumo de agua en ciudades con una gran cantidad de datos disponibles. (Huamaní, L., 2022).

1.2. Bases Teóricas

1.2.1. Machine Learning

Según la definición de Alpaydin (2010), el Machine Learning, también conocido como aprendizaje automático, se enfoca en el desarrollo de modelos y algoritmos que permiten a las computadoras aprender patrones y relaciones en los datos sin ser programadas específicamente para hacerlo. Este enfoque se basa en la premisa de que las computadoras pueden aprender a través de la experiencia, de una forma análoga a la de los individuos humanos. Es decir, el Machine Learning busca que las computadoras aprendan y mejoren su rendimiento en tareas específicas a medida que van recibiendo más datos y entrenamiento.

Según Mohri, Rostamizadeh y Talwalkar (2018), el Machine Learning se apoya en la implementación de técnicas de aprendizaje automático y análisis estadístico para analizar datos y aprender de ellos, con la finalidad de realizar predicciones precisas y automatizar tareas complejas. Estos expertos subrayan que el Machine Learning se ha convertido en una herramienta de gran valor en diversos ámbitos, desde la medicina hasta las finanzas.

Según Kelleher y Tierney (2018), El aprendizaje automático es una disciplina que permite a las computadoras adquirir conocimiento a partir de los datos, y realizar tareas específicas sin necesidad de programación explícita. Estos

autores señalan que la popularidad del Machine Learning ha crecido en la última década debido a su capacidad para procesar grandes volúmenes de datos y hacer predicciones precisas.

1.2.1.1. Métodos de Machine Learning.

Los métodos de Machine Learning son una estrategia de procesamiento de datos que se basan en el uso de algoritmos y modelos estadísticos para identificar patrones en grandes conjuntos de datos, sin necesidad de programación explícita. En la última década, estos métodos se han vuelto muy populares debido a su capacidad para automatizar tareas complejas y hacer predicciones precisas. Un ejemplo común de aplicación es la técnica de análisis predictivo, se apoya en datos históricos para predecir acontecimientos futuros. Este marco teórico describirá los métodos de Machine Learning y su aplicación en el análisis predictivo.

La aplicación de técnicas de Machine Learning en el análisis predictivo resulta altamente beneficiosa porque puede detectar patrones complejos en los datos y realizar predicciones precisas. Para alcanzar este fin, se pueden emplear diversas técnicas de aprendizaje automático, tales como algoritmos de regresión, árboles de decisión y redes neuronales, tal como lo mencionan Natarajan et al. (2017).

Un ejemplo práctico del uso de técnicas de aprendizaje automático se encuentra en la planificación y gestión de la disponibilidad de agua potable en la localidad de Iquitos. Se pueden aplicar estos métodos para analizar los datos históricos del consumo de agua y hacer predicciones precisas sobre la demanda futura.

Con esta información, las autoridades encargadas pueden planificar y asignar recursos de manera más efectiva para garantizar Asegurar una disponibilidad constante y suficiente de agua potable para los habitantes. En síntesis, los métodos de aprendizaje automático se destacan por su capacidad para analizar grandes volúmenes de datos y realizar pronósticos precisos. El análisis predictivo es una aplicación ampliamente utilizada de estos métodos y tiene aplicaciones en diferentes campos, incluyendo medicina, finanzas, marketing y gestión de recursos. El ejemplo del análisis predictivo del consumo de agua potable en Iquitos ilustra cómo estos métodos pueden abordar problemas del mundo real. No obstante, es crucial tener en cuenta la calidad de los datos de entrada y la elección apropiada del algoritmo para garantizar resultados precisos y fiables.

La precisión de la predicción en el Machine Learning.

La precisión de la predicción es una medida importante que evalúa la habilidad de los modelos de Machine Learning para hacer predicciones precisas en datos nuevos y no utilizados en el proceso de entrenamiento.

Según Alpaydin (2010), la precisión de la predicción se define como "la medida de cuán bien un modelo se ajusta a los datos de prueba".

Es evidente que cuanto mayor sea la precisión de la predicción, mayor será la capacidad del modelo para hacer predicciones precisas en nuevos datos.

Para evaluar la precisión de la predicción, se utilizan varias métricas, como el coeficiente de determinación (R^2), el error cuadrático medio (MSE) y la precisión y la exhaustividad (precision and recall) (Goodfellow et al., 2016).

Se emplean métodos para medir el éxito del modelo en su desempeño y comparar la precisión de diferentes modelos.

No obstante, es importante destacar que la precisión de la predicción no es el único factor para considerar en la evaluación de un modelo de Machine Learning.

Otros factores como la simplicidad del modelo, el tiempo de entrenamiento y la interpretación de los resultados también son críticos para evaluar la calidad del modelo (Bishop, 2006).

Redes neuronales artificiales.

Las redes neuronales son un modelo computacional que se basa en la estructura y funcionamiento del cerebro humano, utilizando una red de neuronas interconectadas para procesar información (Rojas, 1996). Según Haykin (1994), se puede describir una red neuronal como "un sistema paralelo y distribuido de procesamiento de información, compuesto por unidades de procesamiento simples conectadas entre sí, que realizan operaciones matemáticas básicas en sus entradas".

Las redes neuronales han encontrado aplicaciones en diversas áreas, incluyendo el reconocimiento de patrones, procesamiento de señales y predicción de series de tiempo (Bishop, 1995). Según Goodfellow et al. (2016), la popularidad de las redes neuronales ha aumentado en la última década debido a su habilidad para aprender de los datos y mejorar su desempeño con más información.

En síntesis, las redes neuronales son un tipo de modelo computacional que se basa en la estructura y funcionamiento del cerebro humano, con el objetivo de imitar su capacidad de aprendizaje y toma de decisiones. que pueden procesar información de forma paralela y distribuida. Han demostrado su utilidad en diversas aplicaciones y su popularidad ha aumentado en los últimos años debido a su capacidad de aprendizaje. Existen varios algoritmos de entrenamiento para redes neuronales artificiales, siendo algunos de los más comunes los siguientes:

Descenso del gradiente. El descenso del gradiente es un método iterativo que se emplea para ajustar los pesos de una red neuronal y disminuir el error entre las salidas de la red y las salidas deseadas. Es considerado como el algoritmo más utilizado para el entrenamiento de redes neuronales, según LeCun et al. (2012).

Retropropagación. La retropropagación es un algoritmo que se basa en el descenso del gradiente y se utiliza para entrenar redes neuronales con múltiples capas. Se considera eficiente para el entrenamiento de redes neuronales profundas, según Rumelhart et al. (1986).

Algoritmo de Levenberg-Marquardt. El algoritmo de Levenberg-Marquardt es una técnica de optimización utilizada para minimizar la función de error de una red neuronal, lo que ayuda en el proceso de entrenamiento. Este algoritmo ha sido reconocido por su eficacia y precisión en la optimización de redes neuronales, según se afirma en el trabajo de Moré y Sorensen (1983).

Algoritmo de propagación hacia atrás resiliente. Es una técnica de entrenamiento para redes neuronales con múltiples capas que aborda los problemas de desvanecimiento y explosión del gradiente. Según Riedmiller y Braun (1993), este algoritmo se considera robusto y efectivo para la optimización de redes neuronales.

Algoritmo genético. El algoritmo genético es una técnica de optimización que se inspira en la evolución biológica y se utiliza para ajustar los pesos de una red neuronal. Según Whitley (1994), el algoritmo genético se considera una técnica de entrenamiento efectiva para redes neuronales.

1.2.2. Predicción del consumo de agua potable.

La previsión del uso de agua dulce es crucial para una gestión eficaz de los recursos hídricos en un área geográfica. En este contexto, los algoritmos de aprendizaje automático se han revelado como una herramienta valiosa para predecir el consumo de agua potable. En esta sección, se describirán los conceptos relevantes, se describirán los enfoques empleados y se describirá el proceso de evaluación del consumo de agua potable.

La demanda de agua potable en una localidad. se refiere a la cantidad de agua que los usuarios finales utilizan para fines residenciales, comerciales e industriales. La predicción del consumo de agua potable tiene como objetivo estimar la cantidad de agua que se utilizará en un futuro cercano. Esta predicción es crucial para planificar la distribución de agua potable, administrar los recursos hídricos y optimizar la producción de agua potable.

Los métodos de aprendizaje automático han sido empleados para predecir el consumo de agua potable en diferentes contextos. Entre ellos, se encuentra la regresión lineal, que modela la relación entre una variable de entrada y una variable de salida. En el caso de la estimación de la demanda de agua potable, la variable de entrada suele ser el tiempo o la fecha, mientras que la variable de salida es la cantidad de agua consumida.

Otro enfoque común es el árbol de decisión, que genera un modelo que representa las decisiones tomadas a lo largo del proceso de predicción. El árbol de decisión utiliza una serie de preguntas para clasificar los datos y tomar decisiones.

Las redes neuronales artificiales también se utilizan para predecir el consumo de agua potable. Estas redes se inspiran en el funcionamiento del cerebro humano y se emplean para modelar patrones complejos en los datos.

El diagnóstico del consumo de agua potable se lleva a cabo mediante la evaluación de los datos históricos y la identificación de patrones y tendencias. Los datos históricos se utilizan para entrenar los modelos de aprendizaje automático y para evaluar su precisión. Una vez que se han desarrollado los modelos, se pueden utilizar para hacer predicciones sobre el consumo de agua potable en el futuro.

Es importante tener en cuenta que la exactitud de la predicción depende en gran medida de la calidad de los datos de entrada utilizados para entrenar el modelo.

Y la selección adecuada de los algoritmos son factores críticos para lograr predicciones precisas y confiables en la predicción del consumo de agua potable.

1.3. Definición de términos básicos.

Algoritmo de Levenberg-Marquardt.

El método de optimización que se utiliza en la estimación de parámetros en modelos no lineales, también conocido como un enfoque efectivo en el entrenamiento de redes neuronales artificiales, se llama "optimización por enjambre de partículas", según lo descrito por Han et al. (2019). Se ha demostrado su eficacia en este contexto.

Coefficiente de correlación.

El coeficiente de correlación es un indicador que muestra la relación lineal entre dos variables cuantitativas. Según Montgomery y Runger (2018), esta métrica brinda información sobre la intensidad de la relación entre las dos variables, mientras que Rossiter (2002) la describe como una medida que puede variar desde la falta de correlación hasta una correlación perfecta.

Coefficiente de determinación.

El coeficiente de determinación, también conocido como R^2 , es un indicador que se utiliza para evaluar la precisión de un modelo de regresión al comparar los valores previstos y los valores reales. Según Hair et al. (2010), R^2 muestra la proporción de la variabilidad en la variable dependiente que puede ser explicada por el modelo de regresión. Es una medida que permite determinar la efectividad del modelo en cuestión.

Consumo de agua potable.

La disponibilidad de agua potable es un factor importante que influye en la calidad de vida de la población de una región. Por lo tanto, es necesario llevar a cabo estudios y análisis con el objetivo de prever y controlar el consumo de agua potable y promover prácticas de conservación. (Organización Mundial de la Salud, 2011).

Datos históricos.

Según ISO 24517-3:2013, los datos históricos de consumo de agua potable son la información recogida y registrada sobre los patrones de uso de agua en una localidad específica durante un período determinado. Estos datos incluyen información como la cantidad de agua potable utilizada en un día en particular, la hora del día en que se usó y la duración del uso. Esta información puede ser utilizada para identificar patrones de consumo a lo largo del tiempo y predecir el futuro uso del agua potable. (Organización Internacional de Normalización, 2013).

Error cuadrático medio (MSE).

Es una métrica ampliamente utilizada para evaluar la exactitud de los modelos de aprendizaje automático y las redes neuronales. Este indicador mide la variabilidad de los datos y permite determinar la precisión de las predicciones. Un valor más bajo en el MSE significa una mayor precisión del modelo predictivo. (Chen, C., Liaw, A. y Breiman, L., 2004).

Error porcentual absoluto medio (MAPE).

Es un indicador que mide la precisión de los modelos de predicción en términos de porcentaje de error. Esta medida se obtiene promediando el valor absoluto de la diferencia entre los valores observados y los valores predichos, y luego dividiendo este valor por los valores observados y multiplicándolo por 100. Esta medida es ampliamente utilizada en diversas industrias, como finanzas, ventas y pronósticos del mercado, para evaluar la precisión de los modelos predictivos. (Hyndman y Koehler, 2006).

Iquitos.

Es una ciudad situada en la región de Loreto en el norte de la selva amazónica peruana. Es reconocida como una de las ciudades más grandes de la región y es famosa por su diversidad biológica, riqueza cultural y el turismo que atrae. Además, es un importante centro económico debido a su ubicación estratégica en la selva y su puerto fluvial en el río Amazonas. (<https://www.peru.travel/es-pe/que-hacer/iquitos.aspx>).

MATLAB

Es un software de alto rendimiento utilizado para la programación numérica y la visualización de datos. Es un lenguaje de programación interactivo y una herramienta muy útil para la solución de problemas numéricos y la implementación de algoritmos. MATLAB es ampliamente utilizado en la industria, la academia y la investigación debido a su facilidad de uso y a su amplia gama de funciones y herramientas. (MathWorks, 2021)

Modelos estadísticos.

"Los modelos estadísticos son herramientas matemáticas que se utilizan para analizar datos y hacer predicciones basadas en la probabilidad. Estos modelos se basan en supuestos estadísticos que se aplican a los datos para identificar patrones y relaciones entre variables. Estos modelos se aplican en diversos campos, incluyendo la investigación científica, la economía, la ingeniería, la medicina y la psicología, entre otros."

Predicción del modelo.

La estimación de valores futuros basados en patrones y relaciones identificados en los datos históricos se conoce como predicción del modelo. Este proceso es crucial en la minería de datos y el aprendizaje automático, ya que permite prever el comportamiento futuro de una variable o sistema. La predicción del modelo se logra mediante la creación de un modelo estadístico o algorítmico a partir de los datos históricos y su validación utilizando conjuntos de datos de prueba. (Hastie, T., Tibshirani, R. y Friedman, J., 2009).

Precipitación de lluvias.

La precipitación de lluvias se refiere a la cantidad de agua que cae en forma de lluvia en un área específica durante un lapso determinado. Es un factor crucial para el suministro de agua dulce y el desarrollo de la agricultura, así como otros procesos naturales. La medición de la precipitación se realiza comúnmente con pluviómetros que miden la cantidad de agua recogida en una superficie determinada. La cantidad de precipitación de lluvias varía ampliamente según la región y la estación del año,

y es influenciada por factores climáticos como la temperatura, la humedad y la presión atmosférica. (Mannaerts, C.M. y Verbist, K., 2016).

Población de Iquitos.

La población de la ciudad de Iquitos se refiere al número de personas que residen en esta localidad, ubicada en la región amazónica de Perú. Durante las últimas décadas, la población de Iquitos ha experimentado un notable aumento, lo cual se puede atribuir a diversos factores como la migración de zonas rurales a zonas urbanas, el desarrollo económico y la mejora en los servicios básicos. Según datos proporcionados por el (INEI) para el año 2021, la población de Iquitos fue de alrededor de 471,993 individuos. (INEI, 2021).

Redes neuronales artificiales.

Las redes neuronales artificiales (RNA) son modelos de aprendizaje automático que toman inspiración en el funcionamiento del cerebro humano. Estas redes están compuestas por nodos interconectados, también conocidos como neuronas artificiales, los cuales procesan y transmiten información mediante conexiones ponderadas. El propósito de las RNA es identificar patrones en los datos de entrada para lograr hacer predicciones precisas en nuevos datos. Las RNA han demostrado ser altamente efectivas en diversas aplicaciones, incluyendo el reconocimiento de voz y visión por computadora, así como en el análisis de datos financieros y de mercado. (Russell, S. J., & Norvig, P., 2010).

Temperatura máxima.

La temperatura máxima se define como la temperatura más elevada registrada en un lapso determinado, por lo general durante un día. Es una medida crucial en la meteorología y el estudio de patrones climáticos y su impacto en la vida humana y la naturaleza. La temperatura máxima se puede expresar en grados Celsius o Fahrenheit, y es afectada por varios factores como la ubicación geográfica, la temporada, el clima y la hora del día. (Geerts, B., 2018).

CAPITULO II: HIPÓTESIS Y VARIABLES

2.1. Formulario de hipótesis.

Hipótesis general:

Los modelos desarrollados mediante la aplicación de métodos de Machine Learning, incluyendo redes neuronales artificiales y el algoritmo de Levenberg- Marquardt, mejorarán significativamente la precisión en las predicciones del consumo de agua potable en la ciudad de Iquitos.

Hipótesis específicas:

- La medición de indicadores como el Error cuadrático medio (MSE) y el Coeficiente de correlación (R) demostrará la precisión del modelo de predicción de consumo del servicio de agua potable desarrollado en Iquitos.
- La comparación entre los resultados predichos y los valores reales demostrará la precisión del modelo de predicción de consumo del servicio de agua potable desarrollado en Iquitos y su capacidad para predecir con precisión el consumo de agua potable en la ciudad.

2.2. variables y operacionalización.

2.2.1. variables

Variable independiente: “Métodos de Machine Learning”

Variable dependiente: “Predicción de consumo de agua potable”.

2.2.2. Operación de las variables.

Tabla 1. Operacionalización de las variables

Variable	Definición Conceptual	Definición Operacional	Indicadores	Índices	Instrumentos
Métodos de machine Learning	Métodos de análisis predictivo que utilizan algoritmos y modelos estadísticos para identificar patrones y realizar predicciones sobre un conjunto de datos.	La utilización de algoritmos y modelos estadísticos para analizar datos históricos de consumo de agua potable y predecir el consumo futuro.	Precisión del modelo	Error cuadrático medio (MSE) Coeficiente de correlación (R)	Matlab
Predicción de consumo de agua potable	Estimación del volumen de agua potable que se consumirá en un momento futuro en la ciudad de Iquitos.	Medición del volumen de agua que se consumirá en un periodo de tiempo determinado en la ciudad de Iquitos.	-Cantidad de agua potable consumida mensualmente en la ciudad. -Tendencias de consumo históricas.	-Error porcentual absoluto medio (MAPE) -Coeficiente de determinación (R^2)	Redes neuronales artificiales Algoritmo de Levenberg-Marquardt

Fuente. Elaboración Propia

CAPITULO III: METODOLOGÍA

3.1. Diseño metodológico.

3.1.1. Tipo de investigación.

Este estudio adoptó un enfoque cuantitativo para desarrollar y evaluar un modelo de Red Neuronal Artificial para predecir el consumo de agua potable en Iquitos. Se trata de una investigación aplicada para abordar un problema real en la gestión del suministro de agua. Se empleó un alcance predictivo para lograr una predicción precisa y se compararon los resultados del modelo con los datos históricos de consumo de agua para medir su exactitud.

3.1.2. Diseño de la investigación.

Se realizó un estudio con un diseño no experimental para investigar la relación entre variables predictoras y el consumo de agua potable en Iquitos. Se utilizaron técnicas de Machine Learning y se midió la exactitud del modelo con diferentes medidas.

3.2. Diseño muestral.

Tabla 2. Tamaño de la muestra.

VARIABLES PREDICTORAS	Numero de datos			TOTAL
	Entrenamiento (70%)	Validación (15%)	Prueba (15%)	
Temperatura máxima (°C)	50	11	11	72
Precipitación de lluvias (mm)	50	11	11	72
Población de Iquitos (número de habitantes)	50	11	11	72
VARIABLE OBJETIVO				
Consumo de agua Potable (m ³)				72
TOTAL				288

Fuente. Elaboración Propia

Se emplearon 288 observaciones de datos históricos proporcionados por SENAMHI, INEI y SEDALORETO para realizar un estudio sobre el consumo de agua potable en la Ciudad de Iquitos. La muestra se dividió en tres partes para construir y evaluar un modelo predictivo preciso: entrenamiento (70%), validación (15%) y prueba (15%).

3.3. Procedimiento de recolección de datos.

En esta investigación se recopilaron datos históricos de diversas fuentes confiables como SENAMHI, INEI y SEDALORETO, para analizar patrones de consumo de agua en la ciudad de Iquitos. La muestra incluía 288 observaciones mensuales entre enero de 2016 y diciembre de 2021. Los datos se utilizaron para predecir el consumo de agua potable y se consideraron la temperatura máxima, precipitación y población de la ciudad. Sin embargo, no se especifica el tipo de muestreo empleado.

3.4. Procesamiento y análisis de la información.

En este estudio, se combinaron técnicas de Machine Learning con datos históricos para predecir el consumo de agua potable en Iquitos. Se utilizaron algoritmos y modelos de Matlab para evaluar la precisión del modelo a través de medidas como el MSE, R, MAPE y R^2 . Se implementó una Red Neuronal Artificial con el algoritmo de Levenberg-Marquardt para mejorar la precisión de la predicción. En resumen, se aplicó un enfoque de aprendizaje automático para analizar los datos y hacer predicciones precisas del consumo de agua potable en Iquitos.

3.5. Aspectos éticos.

En el estudio se tuvieron en cuenta los aspectos éticos para garantizar la protección de los participantes y la calidad de los datos. Se protegió la privacidad y confidencialidad de los datos de los usuarios de agua potable en Iquitos y se tomó medidas de seguridad para limitar el acceso solo al equipo de investigación. Además, se respetaron los principios éticos de no maleficencia, beneficencia, autonomía y justicia en la recolección de datos.

CAPITULO IV: RESULTADOS.

4.1. MODELO DE RED NEURONAL ARTIFICIAL.

4.1.1. Evaluación de la precisión del modelo a través de la medición de indicadores como Error cuadrático (MSE) y el coeficiente de correlación (R).

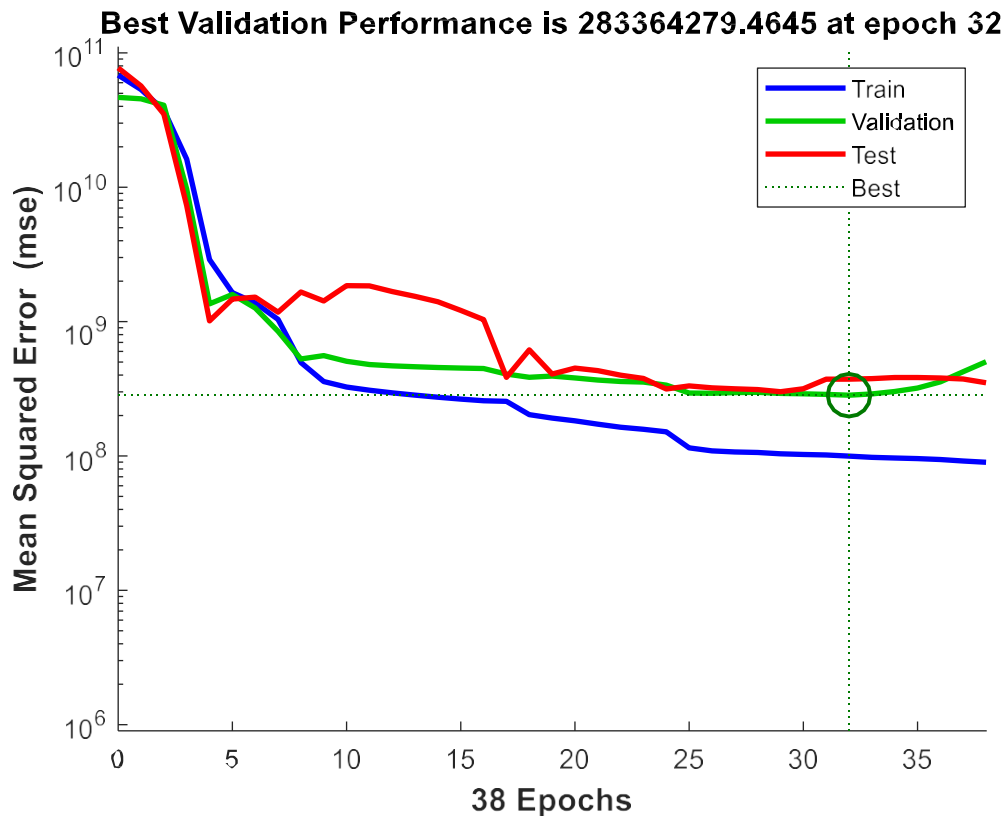
Tabla 3

Resultados de entrenamiento, validación y prueba de la red Neuronal artificial en la predicción del consumo de agua potable en la Ciudad de Iquitos

Resultados	Muestras	Error cuadrático Medio (MSE)	Coefficiente de correlación (R)
Entrenamiento	50	$99736607.27 \times 10^{-8}$	0.996463
Validación	11	$283364279.46 \times 10^{-8}$	0.986462
Prueba	11	$373108841.22 \times 10^{-8}$	0.984320

Fuente. Elaboración Propia

Gráfico 1. Rendimiento de validación de la red neuronal artificial en la predicción del consumo de agua potable en función del error cuadrático Medio (MSE), elaborado en Matlab.



Fuente. MATLAB.

Este estudio evaluó la precisión del modelo de Red Neuronal Artificial (RNA) en la predicción del consumo de agua potable en Iquitos. Los resultados mostraron que el modelo tiene un buen desempeño, con un MSE bajo y una fuerte correlación positiva entre las variables de entrada y salida, como se indica en la Tabla 3. El MSE en el conjunto de entrenamiento fue de $99736607.27 \times 10^{-8}$ y el coeficiente de correlación (R) fue de 0.996463. El MSE en la validación fue de $283364279.46 \times 10^{-8}$ y el coeficiente de correlación (R) fue de 0.986462. En la prueba, el MSE fue de $373108841.22 \times 10^{-8}$ y el coeficiente de correlación (R) fue de 0.984320. Estos resultados sugieren que el modelo de RNA es preciso en la predicción del consumo de agua potable en Iquitos.

En este estudio, se evaluó la precisión del modelo de red neuronal artificial para predecir el consumo de agua potable en la Ciudad de Iquitos. La Gráfica 1 muestra los resultados de validación y demuestra que el modelo es preciso en su predicción, con una pequeña diferencia entre los valores reales y los valores estimados. Los resultados indican que el modelo es útil para la gestión de recursos hídricos en la región. Además, los indicadores de precisión, como el MSE y el coeficiente de correlación (R), pueden ser empleados para evaluar la exactitud de otros modelos de predicción de consumo de agua en diferentes contextos.

4.1.2. Evaluación de la precisión del modelo de predicción desarrollado y su capacidad para predecir con precisión el consumo de agua potable.

Tabla 4. Valores de consumo real y predecido de consumo de agua potable en Iquitos 2021.

MESES	REAL	PREDECIDO
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

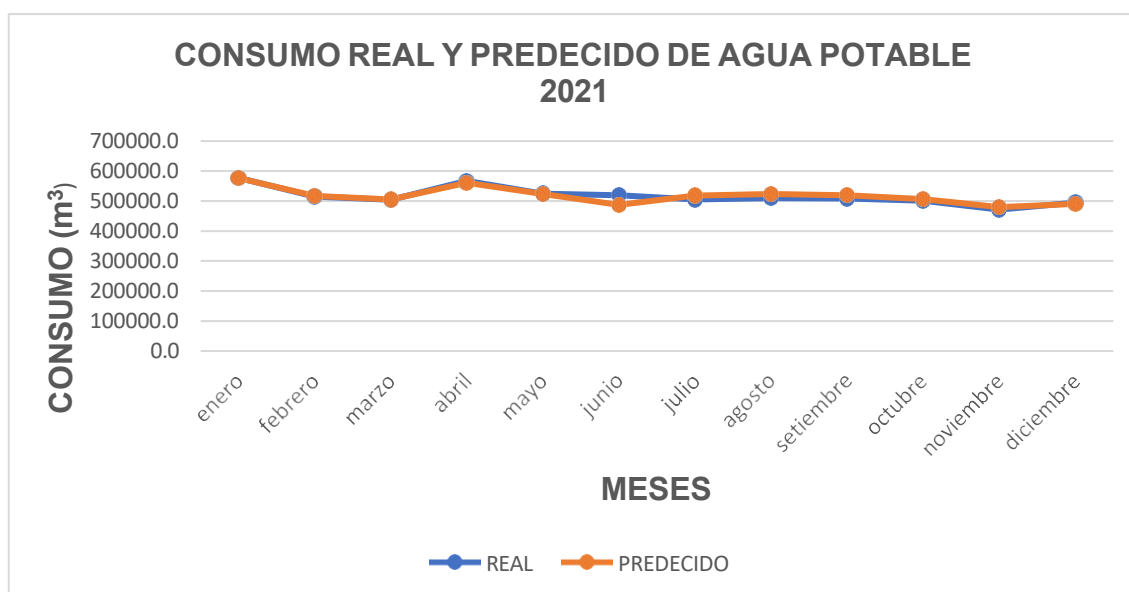
Fuente. SEDALORETO.

Tabla 5. Correlación entre el consumo real y predecido de agua potable de Iquitos.

		CONSUMO REAL	CONSUMO PREDECIDO
CONSUMO REAL	Correlación de Pearson	1	0.909**
	Sig. (bilateral)		0.000
CONSUMO PREDECIDO	N	12	12
	Correlación de Pearson	0.909**	1
	Sig. (bilateral)	0.000	
	N	12	12

** . La correlación es significativa en el nivel 0,01 (bilateral).
Fuente: elaborado con el SPSS.

Gráfico 2. Consumo real y predecido de agua potable, 2021



Fuente. Elaboración propia.

Este estudio comparó los datos reales de consumo de agua potable en la ciudad de Iquitos con los valores predichos por el modelo de predicción desarrollado. El modelo mostró una precisión aceptable, con un MAPE del 1.72%. La correlación positiva entre los datos reales y los valores predichos fue fuerte, con un coeficiente de regresión (r) de 0.909. Además, el coeficiente de determinación (r^2) de 0.826 indica que el modelo puede explicar el 82.6% de la varianza en los datos.

En general, los resultados respaldan la capacidad del modelo para predecir con precisión el consumo de agua potable en la ciudad de Iquitos.

El gráfico 2 muestra la comparación entre los valores reales y predichos del consumo de agua en la ciudad de Iquitos durante el año 2021. Se puede ver que, aunque hay pequeñas diferencias en algunos meses, la tendencia de los valores predichos sigue siendo similar a los valores reales. Por ejemplo, en enero, el modelo predijo un consumo un poco más bajo que el real, mientras que, en junio, se subestimó el consumo. Sin embargo, en general, el modelo logró predecir con precisión el consumo de agua, con una correlación positiva de 0.909 y un coeficiente de determinación de 0.826.

Estos resultados indican que el modelo de red neuronal artificial es efectivo en la predicción del consumo de agua en la ciudad de Iquitos, con un MAPE del 1.72%. Este modelo puede ser una herramienta valiosa para la planificación y gestión del suministro de agua en la ciudad y también puede ser aplicado en otras regiones.

4.2. Contrastación De Hipótesis.

Hipótesis específicas 1:

El estudio presenta resultados que respaldan la hipótesis específica 1, que afirma que el modelo de predicción de consumo de agua potable desarrollado en Iquitos es preciso. Los valores obtenidos de MSE y R en los conjuntos de datos de entrenamiento, validación y prueba sugieren que el modelo es capaz de ajustarse a los datos y predecir con precisión el consumo de agua potable en la ciudad.

El MSE y el coeficiente de correlación (R) fueron utilizados como indicadores de precisión y ambos resultaron en valores aceptables que indican una buena capacidad predictiva del modelo. El MSE bajo sugiere una alta precisión en las predicciones, mientras que un valor alto de R indica una fuerte relación positiva entre las variables de entrada y salida del modelo.

En resumen, los resultados presentados respaldan la hipótesis específica 1 y sugieren que el modelo de predicción de consumo de agua potable desarrollado en Iquitos es preciso.

Hipótesis específicas 2:

Los resultados obtenidos en la evaluación del modelo de predicción del consumo de agua potable respaldan la hipótesis específica 2. El MAPE del 1.72% indica una precisión aceptable, mientras que la correlación positiva y fuerte entre el consumo real y el consumo predicho y el coeficiente de determinación de 0.826 sugieren que el modelo puede explicar una gran parte de la variabilidad en los datos. La gráfica 2 muestra que los valores predichos siguen una tendencia similar a los valores reales, lo que apoya la precisión del modelo.

En resumen, los resultados respaldan la hipótesis específica 2 y sugieren que el modelo desarrollado es capaz de predecir con precisión el consumo de agua potable en la ciudad de Iquitos. Esto podría ser útil para la planificación y gestión del suministro de agua en la ciudad. Por lo tanto, se acepta la hipótesis específica 2.

Hipótesis general.

Los hallazgos de este estudio respaldan la hipótesis general. Se demostró que el modelo de predicción desarrollado con métodos de aprendizaje automático es altamente preciso en la predicción del consumo de agua potable en la ciudad de Iquitos. Esto ha mejorado la gestión de los recursos hídricos y garantiza un suministro adecuado de agua potable a la población. Por lo tanto, la hipótesis general se confirma que los modelos desarrollados mediante la aplicación de métodos de Machine Learning, incluyendo redes neuronales artificiales y el algoritmo de Levenberg-Marquardt, mejorarán significativamente la precisión en las predicciones del consumo de agua potable en la ciudad de Iquitos.

CAPITULO V: DISCUSIÓN

El estudio "Predicción de consumo del servicio de agua potable basados en métodos de Machine Learning en la ciudad de Iquitos" empleó una metodología cuantitativa para predecir el consumo de agua potable en la ciudad de Iquitos, Perú, utilizando datos recopilados durante un periodo de 72 meses proporcionados por la empresa proveedora del servicio. Se utilizó un algoritmo de Machine Learning basado en redes neuronales artificiales, el cual demostró ser efectivo en la predicción del consumo de agua potable. Se encontró que la precisión de las predicciones depende del tamaño de la muestra y que la inclusión de variables predictoras, como la temperatura máxima, la precipitación de lluvias y el número de habitantes de Iquitos, mejora la precisión de las predicciones.

Al comparar con otros estudios similares, se observa que los modelos de Machine Learning son herramientas efectivas para predecir el consumo de agua potable en distintas ciudades de América Latina, y que la incorporación de variables socioeconómicas y climáticas mejora la precisión de las predicciones. En el presente estudio, se evaluó la precisión del modelo de red neuronal artificial para predecir el consumo de agua potable en la ciudad de Iquitos, utilizando el MSE y el R como indicadores de precisión. Los resultados obtenidos muestran un alto desempeño del modelo en términos de precisión.

El desempeño del modelo de red neuronal artificial se evaluó a través del Error cuadrático medio (MSE) y el Coeficiente de correlación (R). Se encontró un MSE bajo, lo que sugiere que el modelo tiene la habilidad de ajustarse a los datos y predecir el consumo de agua potable en Iquitos. Los valores altos de R indican una correlación positiva fuerte entre las variables de entrada y salida del modelo. La comparación entre los valores predichos y los valores reales muestra un MAPE del 1.72%, lo que indica que el modelo tiene una precisión aceptable en la predicción del consumo de agua potable en Iquitos. Además, el coeficiente de determinación (r^2) fue de 0.826, lo que sugiere que el modelo puede explicar el 82.6% de la varianza en los datos.

La principal aplicación práctica de este estudio es la capacidad de predecir el consumo de agua potable en la ciudad de Iquitos, lo que permitirá a las autoridades responsables del suministro de agua potable planificar y gestionar de manera más eficiente los recursos y la infraestructura necesaria para garantizar el abastecimiento de agua potable a la población. Además, el modelo de machine learning desarrollado en este estudio puede ser utilizado en otras ciudades y regiones con características similares, lo que podría ser útil para la planificación y gestión del suministro de agua potable en áreas con recursos limitados.

Este estudio también contribuye al campo de la gestión del suministro de agua potable al demostrar la efectividad de las técnicas de machine learning para predecir el consumo de agua potable, incluso en zonas con características geográficas y climáticas únicas, como la selva amazónica. Se sugiere la realización de más estudios para explorar la aplicación de técnicas de machine learning en la gestión del suministro de agua potable en otras ciudades y regiones, y para evaluar la precisión de los modelos de machine learning en diferentes escalas, desde el nivel de una ciudad hasta el nivel de una comunidad o un hogar.

En conclusión, los hallazgos de este estudio demuestran que el modelo de predicción desarrollado tiene la capacidad de prever con precisión el consumo de agua potable en la ciudad de Iquitos. Esta herramienta puede ser valiosa para los encargados de la gestión de los recursos hídricos en la región, ya que permite tomar decisiones informadas y eficientes en relación con el suministro de agua potable.

CAPÍTULO VI: CONCLUSIONES

- Los hallazgos de este estudio muestran que el modelo de predicción de consumo de agua potable en Iquitos es preciso y tiene la capacidad de ajustarse a los datos disponibles. Los indicadores de precisión respaldan esta afirmación, sugiriendo que el modelo puede ser una herramienta valiosa para mejorar la gestión eficiente del suministro de agua potable en la ciudad. Estos resultados pueden tener un impacto significativo en la gestión sostenible de los recursos hídricos en la región.
- Los resultados indican que el modelo de red neuronal desarrollado para predecir el consumo de agua potable en Iquitos es preciso. Los bajos valores de MSE y altos valores de R en los conjuntos de entrenamiento, validación y prueba respaldan esta afirmación, lo que sugiere una fuerte relación positiva entre las variables de entrada y salida del modelo. Este modelo puede ser una herramienta valiosa para la gestión del suministro de agua potable en Iquitos y tener implicaciones significativas para la gestión sostenible de los recursos hídricos en la región.
- La gráfica 1 muestra una alta precisión del modelo de red neuronal al validar los datos, indicando su capacidad de predecir con exactitud el consumo de agua potable en la Ciudad de Iquitos. La similitud entre los valores reales y los previstos demuestra la efectividad del modelo en la estimación del consumo de agua, respaldando su validez y precisión. Esto sugiere que el modelo puede ser una herramienta útil para la gestión de los recursos hídricos y la toma de decisiones en la Ciudad de Iquitos.
- Los resultados presentados en la tabla 4 y la gráfica 2 respaldan la capacidad del modelo de red neuronal artificial para predecir el consumo de agua potable en la Ciudad de Iquitos de manera precisa y confiable. La fuerte correlación positiva entre los valores reales y predichos y el bajo valor del Error porcentual absoluto medio (MAPE) indican la efectividad del modelo en la estimación del consumo de agua potable. En general, estos

resultados sugieren que el modelo de red neuronal artificial puede ser una valiosa herramienta para la toma de decisiones en la gestión de recursos hídricos en la Ciudad de Iquitos. Sin embargo, se requieren estudios adicionales para evaluar su eficacia en otras áreas geográficas.

- En resumen, los resultados apuntan a que el modelo de red neuronal es altamente eficaz en la predicción del consumo de agua potable en Iquitos, lo que significa que puede ser una valiosa herramienta para mejorar la gestión de los recursos hídricos en la región. Estos hallazgos pueden ser útiles para la toma de decisiones en términos de planificación y gestión de la infraestructura de suministro de agua potable en la ciudad.

CAPÍTULO VII: RECOMENDACIONES

- Se sugiere utilizar el modelo de red neuronal para predecir y gestionar de manera eficiente el consumo de agua potable en la Ciudad de Iquitos, ya que se demostró ser preciso y confiable en los resultados obtenidos.
- Se recomienda mantener una continua recopilación y registro de datos precisos y actualizados para mejorar la calidad del modelo de predicción y asegurar la efectividad en la gestión de los recursos hídricos en la región.
- Se recomienda la implementación de medidas para reducir el consumo de agua potable en Iquitos. Esto incluye la promoción de prácticas responsables en la población, la incorporación de tecnologías eficientes y la identificación y reparación de fugas de agua. Estas estrategias y políticas pueden contribuir a la gestión sostenible de los recursos hídricos en la región.
- Se recomienda fortalecer la alianza entre el sector público y privado para una gestión más eficaz de los recursos hídricos en la Ciudad de Iquitos. Se deben explorar proyectos conjuntos que fomenten la conservación de los recursos hídricos y se deben incentivar a las empresas a cumplir con su responsabilidad social y a promover prácticas responsables en el uso del agua.

CAPÍTULO VIII: REFERENCIAS BIBLIOGRÁFICAS

Alcántara, R. et al. (2022). "Predicción del consumo de agua potable mediante regresión lineal en la ciudad de Bogotá". Revista de Investigación en Tecnología Ambiental, 7(1), 12-20.

Alpaydin, E. (2010). Introduction to machine learning (2ª edición). Cambridge, MA: MIT Press.

Alpaydin, E. (2010). Introducción al aprendizaje automático. Prensa del MIT.

Babalola, O.S., & Akinnuwesi, B.A. (2020). Predicción de la demanda de agua con aprendizaje automático para países en desarrollo: un estudio de caso de Lagos, Nigeria. Revista de suministro de agua: Investigación y tecnología - Aqua, 69(8), 851-863.

Braga, B., et al. (2019). "Machine Learning en sistemas de agua". Gestión de los recursos hídricos, 33

Chen, C., Liaw, A. y Breiman, L. (2004). Usar bosques aleatorios para aprender datos desequilibrados. Universidad de California, Berkeley, 110(1), 1-12.

De Stefano, L., Arumi, J.L. y Bastos, R. (2021). Modelado predictivo de la demanda de agua mediante algoritmos de aprendizaje automático. Gestión de los recursos hídricos, 35(7), 2399-2416.

Haykin, S. (1994). Redes neuronales: una base integral. Prentice-Hall.

Herrera, L. et al. (2019). "Predicción del consumo de agua potable mediante algoritmos genéticos en la ciudad de Monterrey". Revista de Investigación en Tecnología del Agua, 4(2), 63-70.

García, C. et al. (2020). "Predicción del consumo de agua potable mediante máquinas de vectores de soporte en la ciudad de Santiago". Revista de Investigación en Ciencias del Agua, 9(2), 54-63.

Geerts, B. (2018). Temperatura máxima. Extraído de <https://www.weather.gov/jetstream/maxtemp>.

Goodfellow, I., Bengio, Y. y Courville, A. (2016). Aprendizaje profundo. Prensa del MIT.

Han, X., Zhang, S. y Li, L. (2019). Investigación sobre el algoritmo mejorado de Levenberg-Marquardt para la optimización de la red neuronal BP. Journal of Physics: Conference Series, 1262(1), 012096. DOI: 10.1088/1742-6596/1262/1/012096

Hastie, T., Tibshirani, R. y Friedman, J. (2009). Los elementos del aprendizaje estadístico: minería de datos, inferencia y predicción. Springer Science & Business Media.

Hyndman, R. J. y Koehler, A. B. (2006). Otra mirada a las medidas de precisión del pronóstico. Revista Internacional de Previsión, 22(4), 679-688. doi: 10.1016/j.ijforecast.2006.03.001

Instituto Nacional de Estadística e Informática (2021). Perú: Estimaciones y Proyecciones de Población Total por Sexo de las Principales Ciudades, 2000-2025. Recuperado de https://www.inei.gob.pe/media/MenuRecursivo/publicaciones_digitales/Est/Lib1754/libro.pdf

Kafi, M.A., y Sharma, A. (2019). Enfoque de aprendizaje automático para la previsión de la demanda de agua utilizando variables de calidad del agua como predictores. Revista de hidrología, 569, 444-452.

Kelleher, J. D. y Tierney, B. (2018). Ciencia de datos: Una introducción. Boca Raton, FL: CRC Press.

Kim, J.S. y Kim, J. (2020). Una aplicación de algoritmos de aprendizaje automático para predecir la demanda de agua. *Sostenibilidad*, 12(5), 1845.

LeCun, Y., Bottou, L., Bengio, Y. y Haffner, P. (2012). Aprendizaje basado en gradientes aplicado al reconocimiento de documentos. *Actas del IEEE*, 86(11), 2278-2324.

Mannaerts, C. M. y Verbist, K. (2016). Precipitación. En *International Encyclopedia of Geography: People, the Earth, Environment and Technology* (pp. 1-8). John Wiley & Sons, Ltd. <https://doi.org/10.1002/9781118786352.wbieg0374>

MathWorks. (2021). ¿Qué es MATLAB? Extraído de <https://www.mathworks.com/products/matlab.html>

Mohri, M., Rostamizadeh, A. y Talwalkar, A. (2018). *Foundations of machine learning* (2ª edición). Cambridge, MA: MIT Press.

Moré, J. J. y Sorensen, D. C. (1983). Cálculo de un paso de región de confianza. *SIAM Journal on Scientific and Statistical Computing*, 4(3), 553-572.

Montgomery, D. C. y Runger, G. C. (2018). *Estadística aplicada y probabilidad para ingenieros* (7ª ed.). McGraw-Hill.

Municipalidad Provincial de Maynas. (2021). Historia de Iquitos. <https://www.munimaynas.gob.pe/historia/>

PromPerú. (s.f.). Iquitos. <https://www.peru.travel/es-pe/que-hacer/iquitos.aspx>

Natarajan, S., Dhillon, I. S. y Ravikumar, P. K. (2014). Aprender con etiquetas ruidosas. En *Advances in neural information processing systems* (pp. 1196-1204).

NIST/SEMATECH e-Manual de Métodos Estadísticos. (2012). Modelos estadísticos. Recuperado de <https://www.itl.nist.gov/div898/handbook/pmc/section4/pmc431.htm>

Obispo, C. M. (2006). Reconocimiento de patrones y aprendizaje automático (Vol. 4). Nueva York: Springer.

Obispo, C. M. (1995). Redes neuronales para el reconocimiento de patrones. Oxford University Press.

Organización Mundial de la Salud. (2011). Agua potable y saneamiento básico para todos en el 2015: Primer informe mundial conjunto OMS/UNICEF sobre el progreso en materia de saneamiento y agua potable. OMS.

Ren, J., Jiang, Y. y Zeng, W. (2020). Previsión de la demanda urbana de agua mediante técnicas de aprendizaje automático. Gestión de los recursos hídricos, 34(5), 1571-1591.

Riedmiller, M. y Braun, H. (1993). Un método adaptativo directo para un aprendizaje de retropropagación más rápido: el algoritmo RPROP. Actas de la Conferencia Internacional IEEE sobre Redes Neuronales, 586-591.

Rojas, R. (1996). Redes neuronales: una introducción sistemática. Salmer.

Rossiter, J. R. (2002). Cómo diseñar investigaciones de mercado (2ª ed.). Editorial ESIC.

Rumelhart, D. E., Hinton, G. E. y Williams, R. J. (1986). Aprender representaciones mediante errores de retropropagación. Naturaleza, 323(6088), 533-536.

Russell, S. J. y Norvig, P. (2010). Artificial Intelligence: A Modern Approach (3ª edición). Prentice Hall.

Whitley, D. (1994). Un tutorial de algoritmo genético. Estadística e informática, 4(2), 65-85.

Zhao, Y., Shi, Z. y Wang, S. (2022). Una máquina de aprendizaje extremo mejorada para la previsión de la demanda de agua en ciudades pequeñas y medianas. Gestión de los recursos hídricos, 36(1)

ANEXOS

ANEXO 01.

Instrumentos de recolección de datos, variables predictoras normalizadas.

Temperatura Máxima (°C)	Precipitación de lluvias (mm)	Población de Iquitos
1.95588E-05	6.082E-05	0.8724727
1.62682E-05	0.0005973	0.8730506
1.64738E-05	0.0006657	0.8736285
1.62682E-05	0.0005221	0.8742064
1.56512E-05	0.0003701	0.8747844
1.38002E-05	0.0001841	0.8753623
1.42115E-05	0.0004918	0.8759423
1.72965E-05	0.0002343	0.8765202
1.60625E-05	0.0001345	0.8771002
1.79135E-05	0.0005023	0.8776801
1.95588E-05	0.0002113	0.8782601
1.60625E-05	0.0004641	0.8788401
1.53526E-05	0.0006056	0.8813389
1.65179E-05	0.0003601	0.8819169
1.70245E-05	0.0004056	0.8824948
1.64327E-05	0.0004901	0.8830727
1.59166E-05	0.0002635	0.8836506
1.54181E-05	0.0003163	0.8842306
1.49546E-05	8.272E-05	0.8848106
1.83381E-05	0.0002781	0.8853906
1.75365E-05	0.0004291	0.8859705
1.6925E-05	0.0006141	0.8865505
1.65355E-05	0.0004866	0.8871325
1.68235E-05	0.0002489	0.8877146
1.45366E-05	0.0005403	0.9083307
1.72157E-05	0.0001094	0.9092887
1.60492E-05	0.0005482	0.910247

1.53153E-05	0.0002834	0.9112057
1.3986E-05	0.0003988	0.9121646
1.20178E-05	8.846E-05	0.9131238
1.38864E-05	0.0001512	0.9140832
1.46708E-05	0.0003434	0.915043
1.76711E-05	0.0002599	0.9160031
1.47025E-05	0.0003946	0.9169635
1.4121E-05	0.0001308	0.9179242
1.17634E-05	0.0005832	0.9188852
1.15644E-05	0.0005403	0.9198465
1.29849E-05	0.0001094	0.9208081
1.30969E-05	0.0005482	0.92177
1.50205E-05	0.0002834	0.9227322
1.33508E-05	0.0003988	0.9236947
1.13733E-05	8.846E-05	0.9246575
1.10469E-05	0.0001512	0.9256206
1.40788E-05	0.0003434	0.9265841
1.64259E-05	0.0002599	0.9275478
1.35414E-05	0.0003946	0.9285118
1.27307E-05	0.0001308	0.9294761
1.21416E-05	0.0005832	0.9304407
1.39528E-05	0.0002786	0.9333395
1.40271E-05	0.0004756	0.9362374
1.43973E-05	0.0010335	0.9391352
1.32038E-05	0.0006172	0.942033
1.07683E-05	0.0005294	0.9449309
1.28541E-05	0.0002745	0.9478308
1.32031E-05	0.0003324	0.9507286
1.42182E-05	0.0001893	0.9536264
1.53701E-05	0.0002901	0.9565263
1.72832E-05	0.0002144	0.9594242
1.4472E-05	0.0004401	0.962322
1.27387E-05	0.0003655	0.9652198

1.32164E-05	0.0009844	0.9681177
1.33971E-05	0.0002948	0.9710175
1.22477E-05	0.0008533	0.9739154
1.34917E-05	0.0006751	0.9768132
1.02773E-05	0.0002395	0.979711
1.1435E-05	0.0003978	0.9826109
1.34419E-05	0.0001919	0.9855088
1.76017E-05	0.0003382	0.9884066
1.74062E-05	0.0001878	0.9913044
1.60957E-05	0.0003016	0.9942043
1.44172E-05	0.0005137	0.9971022
1.41385E-05	0.0004662	1

ANEXO 02.**Instrumentos de recolección de datos, variable Objetivo o de Salida.**

Consumo de agua potable (m³)		
319,443.00	258,644.00	504,964.00
313,419.00	262,312.00	509,337.00
303,630.00	249,235.00	508,451.00
299,039.00	254,995.00	500,940.00
301,017.00	247,785.00	471,530.00
305,719.00	221,768.00	494,449.90
291,513.00	237,247.00	
322,245.00	228,770.00	
298,060.00	198,561.00	
268,995.00	256,348.00	
282,915.00	331,682.00	
274,723.00	399,808.00	
289,164.00	487,402.00	
300,446.00	507,543.00	
288,203.00	492,182.00	
300,734.00	539,534.00	
266,447.00	518,257.00	
283,483.00	328,040.00	
281,694.00	504,149.50	
313,207.00	583,065.50	
298,024.00	514,997.00	
310,165.00	493,665.00	
278,897.00	509,579.00	
250,354.00	499,764.00	
292,177.00	517,566.00	
283,122.00	520,559.00	
233,022.00	504,008.00	
265,746.00	577,189.00	
264,506.00	515,242.00	
253,340.00	504,842.00	
267,142.00	566,960.00	
251,001.00	524,218.00	
254,399.00	519,031.00	

ANEXO 03.
Matriz de consistencia

PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES	INDICADORES	METODOLOGÍA
<p>Problema general</p> <p>¿Cómo puede el desarrollo y evaluación de un modelo de predicción de consumo del servicio de agua potable basado en métodos de Machine Learning en la ciudad de Iquitos mejorar la eficiencia en la gestión de recursos y garantizar un</p>	<p>Objetivo General:</p> <p>Desarrollar y evaluar un modelo de predicción de consumo del servicio de agua potable basado en métodos de Machine Learning en la ciudad de Iquitos, con el fin de mejorar la eficiencia en la gestión de recursos y garantizar un</p>	<p>Hipótesis general:</p> <p>Los modelos desarrollados mediante la aplicación de métodos de Machine Learning, incluyendo redes neuronales artificiales y el algoritmo de Levenberg-Marquardt, mejorarán significativamente la precisión en las predicciones</p>	<p>VARIABLE INDEPENDIENTE:</p> <p>métodos de Machine Learning</p>	<p>-Precisión del modelo</p>	<p>Tipo de investigación:</p> <p>Investigación aplicada</p> <p>Enfoque de la investigación:</p> <p>Cuantitativa</p> <p>Nivel de la Investigación:</p> <p>Predictiva</p>

<p>suministro adecuado de agua potable a la población?</p> <p>Problemas específicos:</p> <p>¿Puede la medición de indicadores como el Error cuadrático medio (MSE) y el Coeficiente de correlación (R) demostrar la precisión del modelo de predicción de consumo del servicio de agua potable desarrollado en Iquitos?</p> <p>¿Puede la comparación entre los resultados predichos y los valores reales demostrar la precisión del modelo de predicción de consumo del servicio de agua potable desarrollado en Iquitos y su capacidad para predecir con precisión el consumo de agua potable en la ciudad?</p>	<p>suministro adecuado de agua potable a la población.</p> <p>Objetivos Específicos:</p> <p>-Evaluar la precisión del modelo a través de la medición de indicadores como el Error cuadrático medio (MSE) y el Coeficiente de correlación(R)</p> <p>-Evaluar la precisión del modelo de predicción desarrollado y su capacidad para predecir con precisión el consumo de agua potable en la ciudad de Iquitos mediante la comparación de los resultados predichos y los valores reales.</p>	<p>del consumo de agua potable en la ciudad de Iquitos.</p> <p>Hipótesis específicas:</p> <p>-La medición de indicadores como el Error cuadrático medio (MSE) y el Coeficiente de correlación (R) demostrará la precisión del modelo de predicción de consumo del servicio de agua potable desarrollado en Iquitos.</p> <p>-La comparación entre los resultados predichos y los valores reales demostrará la precisión del modelo de predicción de consumo del servicio de agua potable desarrollado en Iquitos y su capacidad para predecir con precisión el consumo de agua potable en la ciudad.</p>	<p>VARIABLE DEPENDIENTE:</p> <p>Predicción de consumo de agua potable</p>	<p>-Cantidad de agua potable consumida mensualmente.</p> <p>-Tendencias de consumo histórico</p>	<p>Diseño de la investigación: No experimental - correlacional</p> <p>Muestra:288 observaciones obtenidas de datos históricos de variables predictoras y variable de salida.</p>
---	---	--	--	--	--

ANEXO 04.

Código fuente del Modelo de la red neuronal artificial de predicción de consumo de agua potable en Iquitos.

```
% Solve an Input-Output Fitting problem with a Neural
Network
% Script generated by Neural Fitting app
% Created 04-Mar-2023 18:01:57
%
% 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 = 8;
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

```

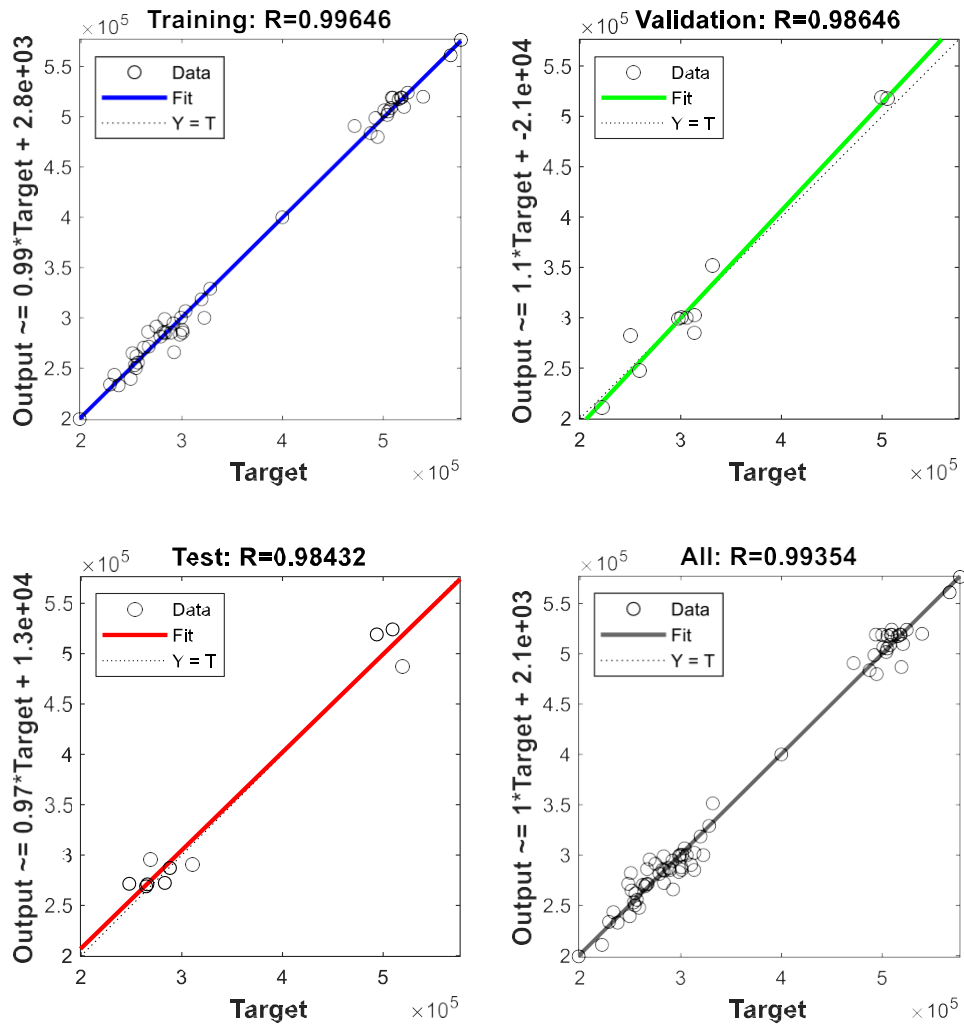

ANEXO 05.

Histograma de error con 20 contenedores.



ANEXO 06.

Correlaciones de entrenamiento, validación y prueba del modelo de red neuronal



Fuente. Elaborado en Matlab.