

**UNIVERSIDAD TÉCNICA DEL NORTE**  
**FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS**  
**CARRERA DE INGENIERÍA INDUSTRIAL**



**TEMA:**

MODELO PARA LA PREDICCIÓN Y EVALUACIÓN DE LA DEMANDA DE AGUA POTABLE MEDIANTE REDES NEURONALES ARTIFICIALES DE LA EMPRESA PÚBLICA DE AGUA POTABLE Y ALCANTARILLADO ANTONIO ANTE.

Trabajo de Grado previo a la obtención del título de Ingeniero Industrial.

**AUTOR:**

Francisco Nicolas Mena Reascos

**DIRECTOR:**

Ing. Robert Mauricio Valencia Chapi, PhD.

Ibarra, 2023



# UNIVERSIDAD TÉCNICA DEL NORTE

## BIBLIOTECA UNIVERSITARIA

### AUTORIZACIÓN DE USO Y PUBLICACIÓN

### A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

### IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
<b>CÉDULA DE IDENTIDAD:</b>	1003754775		
<b>APELLIDOS Y NOMBRES:</b>	MENA REASCOS FRANCISCO NICOLAS		
<b>DIRECCIÓN:</b>	AV. EL RETORNO Y RIO TIPUTINI. CONDOMINIOS JARDINES DEL RETORNO. CASA #35		
<b>EMAIL:</b>	<a href="mailto:fnmenar@utn.edu.ec">fnmenar@utn.edu.ec</a>		
<b>TELÉFONO FIJO:</b>	2953-772	<b>TELÉFONO MÓVIL:</b>	0994243022

DATOS DE LA OBRA	
<b>TÍTULO:</b>	MODELO PARA LA PREDICCIÓN Y EVALUACIÓN DE LA DEMANDA DE AGUA POTABLE MEDIANTE REDES NEURONALES ARTIFICIALES DE LA EMPRESA PÚBLICA DE AGUA POTABLE Y ALCANTARILLADO ANTONIO ANTE
<b>AUTOR (ES):</b>	MENA REASCOS FRANCISCO NICOLAS
<b>FECHA DE APROBACIÓN: DD/MM/AAAA</b>	05-09-2023
<b>PROGRAMA:</b>	<input checked="" type="checkbox"/> <b>PREGRADO</b> <input type="checkbox"/> <b>POSGRADO</b>
<b>TITULO POR EL QUE OPTA:</b>	INGENIERÍA INDUSTRIAL
<b>ASESOR /DIRECTOR:</b>	PhD. ROBERT MAURICIO VALENCIA CHAPI

## CONSTANCIAS

El autor manifiesta que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es el titular de los derechos patrimoniales, por lo que asume la responsabilidad sobre el contenido de la misma y saldrá en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 05 días del mes de septiembre de 2023

### EL AUTOR:



Mena Reascos Francisco Nicolas

C.I. 1003754775



UNIVERSIDAD TÉCNICA DEL NORTE  
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS  
CARRERA DE INGENIERÍA INDUSTRIAL

**CERTIFICACIÓN DEL TUTOR**

Yo Ing. Robert Valencia Chapi, PhD. Director del trabajo de grado desarrollado por el señor estudiante: **FRANCISCO NICOLAS MENA REASCOS** para la obtención del título de Ingeniero Industrial.

**CERTIFICA**

Que, el Proyecto de Trabajo de Grado titulado: “**MODELO PARA LA PREDICCIÓN Y EVALUACIÓN DE LA DEMANDA DE AGUA POTABLE MEDIANTE REDES NEURONALES ARTIFICIALES DE EMPRESA PÚBLICA DE AGUA POTABLE Y ALCANTARILLADO ANTONIO ANTE**”, ha sido elaborado en su totalidad por el señor estudiante Francisco Nicolas Mena Reascos, bajo mi dirección, para la obtención del título de Ingeniero Industrial. Luego de ser revisado, considerando que se encuentra concluido y cumple con las exigencias y requisitos académico de la Facultad de Ingeniería en Ciencias Aplicadas, Carrera de Ingeniería Industrial, autoriza la presentación y defensa para que pueda ser juzgado por el tribunal correspondiente.

Ibarra, 05 de septiembre de 2023.

---

Ing. Robert Valencia Chapi, PhD  
DIRECTOR DE TRABAJO DE GRADO

## DEDICATORIA

A mi querida familia, cuyo amor inquebrantable y apoyo constante han sido mi soporte durante este arduo viaje académico. Sin ustedes, nada de esto habría sido posible.

A mis valiosos amigos, quienes han compartido risas, consejos y motivación en cada paso del camino. Su amistad ha sido mi inspiración.

A mis profesores, a quienes agradezco por su orientación, paciencia y sabiduría. Sus enseñanzas han iluminado mi camino hacia el conocimiento.

A mi universidad, por brindarme las herramientas y oportunidades para crecer como estudiante y como persona.

Este trabajo de tesis es un reflejo de todos ustedes y de cómo sus contribuciones han enriquecido mi vida. Gracias por ser parte de este logro que compartimos juntos.

## AGRADECIMIENTO

Quiero expresar mi profundo agradecimiento a la Empresa Pública de Agua Potable y Alcantarillado de Antonio Antes y a todos sus colaboradores por su apoyo inquebrantable durante el desarrollo de esta tesis. Su generosa disposición para proporcionar datos, recursos y orientación fue fundamental para el éxito de este proyecto.

Agradezco sinceramente a mi tutor, el PhD. Robert Valencia, por su mentoría, paciencia y sabiduría. Sus valiosos consejos y dirección han sido una fuente constante de inspiración.

Asimismo, agradezco a mi asesor, el MSc. Víctor Erazo, por su guía y dedicación a lo largo de este proceso. Su apoyo fue esencial para superar los desafíos que surgieron.

No puedo dejar de mencionar a mi universidad por proporcionarme la educación y las oportunidades necesarias para llevar a cabo este proyecto.

Finalmente, quiero dedicar un agradecimiento especial a mis queridos padres y abuelitos, cuyo amor incondicional y apoyo constante me han sostenido en cada etapa de mi vida académica. Su influencia y aliento han sido un faro de luz en mi camino.

Este logro no habría sido posible sin la contribución de cada uno de ustedes. Estoy profundamente agradecido por su apoyo y confianza en mí. ¡Gracias!

## INDICE

RESUMEN .....	12
ABSTRACT.....	13
1. Capítulo I GENERALIDADES .....	14
1.1. Tema.....	14
1.2. Problema.....	14
1.3. Objetivos .....	15
1.3.1. Objetivo general.....	15
1.3.2. Objetivos específicos .....	15
1.4. Alcance.....	15
1.5. Justificación.....	16
1.6. Metodología .....	17
1.6.1. Métodos de investigación .....	17
1.6.2. Técnica de investigación.....	18
1.6.3. Instrumentos.....	18
2. Capítulo II FUNDAMENTACIÓN TEÓRICA .....	19
2.1. Pronósticos .....	19
2.1.1. Clasificación de los pronósticos.....	20
2.1.2. Patrones de tiempo.....	20
2.1.3. Precisión de los pronósticos.....	25
2.2. Redes neuronales.....	29

2.2.1.	Historia de las redes neuronales.....	30
2.2.2.	Principios de las redes neuronales .....	33
2.2.3.	Modelo de una red neuronal .....	34
2.3.	Regresión Lineal .....	37
2.3.1.	Análisis de regresión.....	38
2.3.2.	Modelo de Regresión Lineal Simple.....	40
2.3.3.	Hipótesis de la regresión lineal .....	41
2.4.	Modelo SARIMA.....	42
2.4.1.	Diferenciación.....	44
2.4.2.	El modelo .....	47
3.	Capítulo III SITUACIÓN ACTUAL .....	49
3.1.	Descripción de la organización .....	49
3.2.	Localización de la empresa .....	49
3.3.	Misión.....	50
3.4.	Visión .....	50
3.5.	Valores .....	50
3.6.	Objetivos estratégicos .....	51
3.7.	Productos.....	51
3.8.	Estructura organizacional.....	51
3.9.	Descripción del proceso productivo.....	53



3.9.1.	Captación .....	53
3.9.2.	Estación de bombeo .....	53
3.9.3.	Planta de tratamiento.....	54
3.10.	Producción de la empresa y consumo anual .....	56
3.11.	Datos de la población .....	57
3.12.	Volumen de almacenamiento .....	58
3.13.	Capacidad de las plantas de tratamiento.....	59
3.14.	Análisis de autocorrelación .....	59
3.14.1.	Análisis de autocorrelación de la demanda mensual de agua potable.....	59
3.14.2.	Análisis de autocorrelación de los clientes .....	61
3.15.	Análisis de estacionalidad de la serie de tiempo .....	62
3.15.1.	Análisis de estacionalidad de la demanda mensual de agua potable.....	62
3.15.2.	Análisis de estacionalidad de los clientes mensuales.....	63
4.	Capítulo IV MODELO DE PRONÓSTICO .....	64
4.1.	Selección de variable.....	64
4.2.	Obtención de datos .....	64
4.3.	Estructura de los modelos .....	65
4.4.	Análisis de tendencia y estacionalidad.....	66
4.5.	Pronóstico de la red neuronal .....	68
4.6.	Estructura de la red neuronal MLP .....	70

4.7.	Pronóstico con la mejora del entrenamiento de la red .....	71
4.8.	Modelo SARIMA (2,0,2) (1,0,1).....	72
4.9.	Regresión lineal.....	72
4.10.	Resultados de los modelos de pronóstico .....	73
4.11.	Comportamiento de la demanda.....	74
4.12.	Comparación de modelos .....	75
5.	CONCLUSIONES .....	78
6.	RECOMENDACIONES.....	81
7.	BIBLIOGRAFÍA .....	82
8.	ANEXOS .....	92

## INDICE DE TABLAS

<b>Tabla 1</b> Principios de las redes neuronales artificiales. ....	34
<b>Tabla 2</b> Captaciones de agua cruda.....	53
<b>Tabla 3</b> Características de los sistemas de bombeo .....	54
<b>Tabla 4</b> Producción y consumo ( <i>m</i> 3) mensual del cantón Antonio Ante. ....	56
<b>Tabla 5</b> Proyección poblacional del cantón Antonio Ante. ....	57
<b>Tabla 6</b> Volumen de almacenamiento de los tanques de reserva.....	58
<b>Tabla 7</b> Capacidad de las plantas de tratamiento .....	59
<b>Tabla 8</b> Clientes mensuales del año 2020 al 2022. ....	64
<b>Tabla 9</b> Pronóstico de la demanda de agua potable de los diferentes modelos. ....	77

## INDICE DE FIGURAS

<b>Figura 1</b> Clasificación de los pronósticos .....	20
<b>Figura 2</b> Serie de tiempo con patrón estacionario.....	21
<b>Figura 3</b> Serie de tiempo con patrón de tendencia.....	22
<b>Figura 4</b> Serie de tiempo con patrón cíclico .....	23
<b>Figura 5</b> Serie de tiempo con patrón estacional .....	24
<b>Figura 6</b> Serie de tiempo con variación irregular .....	25
<b>Figura 7</b> Ejemplo de una red neuronal totalmente conectada.....	35
<b>Figura 8</b> Esquema de funcionamiento de un proceso de aprendizaje supervisado .....	37
<b>Figura 9</b> Esquema del coeficiente de correlación .....	40
<b>Figura 10</b> Estacionalidad SARIMA.....	43
<b>Figura 11</b> Ubicación de la empresa (EPAA-AA). .....	49
<b>Figura 12</b> Organigrama de la EPAA-AA.....	52
<b>Figura 13</b> Autocorrelación de la demanda de agua potable.....	60
<b>Figura 14</b> Prueba Dickey-Fuller de la demanda mensual de agua potable .....	60
<b>Figura 15</b> Autocorrelación de los clientes mensuales.....	61
<b>Figura 16</b> Prueba de Dickey-Fuller los clientes mensuales .....	62
<b>Figura 17</b> Análisis de estacionalidad de la demanda de agua potable .....	63
<b>Figura 18</b> Análisis de estacionalidad de los clientes mensuales.....	63
<b>Figura 19</b> Análisis de la serie temporal de la demanda de agua potable. ....	66
<b>Figura 20</b> Análisis de tendencia de la serie temporal de la demanda de agua potable. ....	67
<b>Figura 21</b> Análisis de estacionalidad de la serie temporal de la demanda de agua potable.....	68
<b>Figura 22</b> Codificación de la red neuronal automática.....	69

<b>Figura 23</b> Pronóstico de la red MLP.....	69
<b>Figura 24</b> Codificación de la red neuronal modificada.....	70
<b>Figura 25</b> Estructura de las capas de la red.....	70
<b>Figura 26</b> Codificación de la mejora del entrenamiento de la red. ....	71
<b>Figura 27</b> Pronóstico de la red MLP mejorada.....	71
<b>Figura 28</b> Pronóstico modelo SARIMA (2,0,2) (1,0,1).....	72
<b>Figura 29</b> Pronóstico modelo regresión lineal.....	73
<b>Figura 30</b> Comportamiento de la demanda de agua potable.....	74
<b>Figura 31</b> Comparación de modelos de pronóstico. ....	75
<b>Figura 32</b> Comparación errores de los modelos de pronóstico.....	76
<b>Figura 33</b> Continuidad del servicio de agua potable en la provincia de Imbabura.....	78
<b>Figura 34</b> Índice de agua no contabilizada en la provincia de Imbabura. ....	79

## RESUMEN

El presente trabajo de grado tiene como objetivo principal pronosticar la demanda de agua potable de los años 2023 y 2024 con los datos de la Empresa Pública de Agua Potable y Alcantarillado de Antonio Ante. Se ha utilizado redes neuronales artificiales en busca de mejorar la distribución del recurso hídrico dentro del cantón.

La investigación documental relacionada con redes neuronales artificiales y su funcionamiento permitió establecer las bases teóricas para un correcto desarrollo de la investigación. Con el análisis de la estacionalidad y autocorrelación, se pudo identificar el comportamiento y la tendencia que adopta la demanda de agua potable. Sin dejar de lado los usuarios que emplean a diario este recurso.

Con la comparación de modelos de pronósticos de Regresión Lineal y SARIMA (2,0,2) (1,0,1), se pudo probar el comportamiento y el error de cada uno. La métrica de comparación fue el RMSE con un 148,12 para RNA, en el SARIMA arrojó un resultado de 12459,1 y el de Regresión Lineal un valor de 22560,39. Dejando en evidencia que el mejor modelo para la demanda de agua potable es el de Redes Neuronales Artificiales.

Con los resultados obtenidos de la demanda de agua potable para los dos siguientes años, la empresa logrará cubrir este requerimiento, sin embargo, esta debe centrarse en reducir el índice de agua no contabilizada y aumentar el porcentaje de continuidad del servicio para evitar desabastecimiento y brindar un servicio de calidad.

**Palabras clave:** Redes neuronales artificiales, pronóstico, demanda de agua, autocorrelación, estacionalidad.

## ABSTRACT

The main objective of this degree work is to forecast the demand for drinking water for the years 2023 and 2024 with data from the Drinking Water and Sewerage Public Company of Antonio Ante Canton. Artificial neural networks have been used in order to improve the distribution of water resources within the canton.

The documentary research related to artificial neural networks and their operation allowed establishing the theoretical basis for a correct development of this research. With the analysis of seasonality and autocorrelation, it was possible to identify the behavior and trend adopted by the demand for drinking water, without neglecting the consumers who daily use this resource.

With the comparison of Linear Regression and SARIMA (2,0,2) (1,0,1) forecasting models, it was possible to test the behavior and error of each one. The comparison metric was the RMSE with a value of 148.12 for ANN, SARIMA yielded a result of 12459.1 and Linear Regression yielded a value of 22560.39, showing that the best model for drinking water demand is that of Artificial Neural Networks.

With the results obtained for the demand of drinking water for the next two years, the company will be able to cover this requirement. However, it should focus on reducing the rate of unaccounted water and increase the percentage of continuity of service to avoid shortages and provide a quality service.

**Keywords:** artificial neural webs, forecasting, water demand, autocorrelation, seasonality.

## **Capítulo I**

### **GENERALIDADES**

#### **1.1. Tema**

Modelo para la predicción y evaluación de la demanda de agua potable mediante redes neuronales artificiales de EPAA-AA.

#### **1.2. Problema**

En el cantón Antonio Ante desde hace muchos años se ha denotado el desabastecimiento de agua potable en el sector urbano y rural debido al crecimiento poblacional y a la proliferación de emprendimientos y negocios que demandan el consumo racional del líquido vital.

En tal virtud, la Empresa Pública de Agua Potable y Alcantarillado del cantón Antonio Ante es una entidad que, a través de sus administraciones, presta servicios de este líquido vital y alcantarillado a la población del cantón, proyectándose siempre a la satisfacción del cliente, para un desarrollo sostenible y bienestar de la población en general. El crecimiento poblacional en los próximos años demandará del incremento de agua potable para atender de manera eficaz el suministro de este servicio.

En consecuencia, la empresa ha tomado acciones para la dotación permanente, sin embargo, existen ciertas zonas en la que la capacidad de respuesta frente a las necesidades de consumo se ha visto de forma inconsistente, tomando como referencia el número de habitantes y su ubicación geográfica. El trabajo de planificación es fundamental, ya que, implica una inversión importante para la empresa, al ser un gran proceso de gestión y coordinación de estrategias que se traducen en identificar trabajo perdido durante el proceso de inversión. La falta de planificación adecuada se ve reflejada en el nivel de servicio dirigido hacia los clientes, debido a que no se toma como referencia los tiempos de desabastecimiento y densidad poblacional.



### **1.3. Objetivos**

#### ***1.3.1. Objetivo general***

Diseñar un modelo para el pronóstico de la demanda de agua potable de la empresa EPAA-AA mediante redes neuronales artificiales que a futuro garantice la distribución eficiente del recurso hídrico.

#### ***1.3.2. Objetivos específicos***

- Referenciar el marco teórico de la investigación a través de los estudios, artículos científicos, tesis, técnicas aplicadas y bibliografía especializada, para la proyección demandante en la provisión de agua potable.
- Diagnosticar la situación actual del consumo de agua potable de la empresa mediante el análisis de datos históricos para suministrar el recurso hídrico de manera eficiente.
- Desarrollar la predicción a través del software R Studio para estimar la cantidad del recurso hídrico requerida por la población de Antonio Ante.

### **1.4. Alcance**

La relevancia del estudio se centra en la necesidad de hacer predicciones de la demanda de agua potable de EPAA-AA, mediante el uso de redes neuronales artificiales, soportada por el software R Studio, herramienta útil para las proyecciones esperadas que dependen del crecimiento de la población y la demanda adquirida de este recurso.

Para garantizar la correcta modelización de las previsiones, se tendrá en cuenta el crecimiento poblacional del cantón Antonio Ante se recopilarán datos históricos de la demanda de los consumidores de 36 meses, en el que se establecerá el tiempo de la proyección esperada, la tendencia del consumo del recurso hídrico de la población, las estacionalidades que presentan en ciertas épocas del año y los errores de la proyección del modelo de la demanda.

Este modelo de pronóstico brindará apoyo al mejoramiento de la planificación de este recurso hídrico para los dos siguientes años y contribuirá a la correcta toma de decisiones y proyectos a futuro de las diferentes áreas que conforma la empresa.

### **1.5. Justificación**

El acceso al líquido vital lo deberíamos tener de manera ininterrumpida con base en el artículo 326 numeral 15 de la (*Constitución de la República del Ecuador, 2008*) manifiesta que; Se prohíbe la paralización de los servicios públicos de salud y saneamiento ambiental, educación, justicia, bomberos, seguridad social, energía eléctrica, agua potable y alcantarillado, producción hidrocarburífera, procesamiento, transporte y distribución de combustibles, transportación pública, correos y telecomunicaciones. La ley establecerá límites que aseguren el funcionamiento de dichos servicios.

La empresa debe realizar un pronóstico consistente en predecir y evaluar la demanda de agua potable en el contexto cantonal, mediante redes neuronales artificiales, porque, estas serían la visión futurista para mejorar el servicio, cantidad y calidad del recurso hídrico. Al realizar estos estudios de factibilidad frente al crecimiento poblacional y demanda de la dotación de este servicio básico, se tendrá como respuesta datos estadísticos que posibiliten la distribución equitativa de agua, manteniendo a la ciudadanía sin descompensación del elemento indispensable para la vida de los seres vivos.

La aplicación de redes neuronales artificiales consideradas como un sistema de procesamiento de información distribuida en paralelo que consta de elementos de procesamiento simples y adaptables, interconectados entre sí, es la herramienta fundamental para realizar la predicción de la demanda de agua potable en los próximos dos años en la Empresa Pública de Agua del cantón Antonio Ante.

Con este proceso se justifica el trabajo investigativo, ya que, todavía se aplican técnicas tradicionales de predicción, sin obtener resultados positivos referentes a la demanda recurrente del líquido vital.

## **1.6. Metodología**

El tipo de investigación al aplicar procesos sistemáticos de pronóstico y análisis se enfoca a lo cuantitativo, ya que los datos que se obtendrán se encaminarán a una predicción; la misma que, pretenderá tener una visión exacta de la demanda de los usuarios respecto al consumo de agua potable en el cantón Antonio Ante.

### ***1.6.1. Métodos de investigación***

#### **➤ Metodología bibliográfica**

Esta metodología ofrece la posibilidad a través de un proceso sistemático de compilar, seleccionar, analizar y evaluar las referencias físicas o digitales que serán utilizadas como fuente de teoría para el trabajo investigativo.

#### **➤ Método deductivo**

Mediante este método se pretende analizar un modelo y predecir los resultados que, en este caso, con la aplicación de Redes Neuronales Artificiales se pronosticará la demanda y proyección estimada para la distribución del recurso hídrico.

#### **➤ Método descriptivo**

Con este método se registra el análisis de la situación actual de la empresa de Agua Potable y Alcantarillado de Antonio Ante, considerando la observación eficaz en el registro de las actividades desarrolladas por la entidad mencionada.

### ***1.6.2. Técnica de investigación***

- **Recolección de datos:** se recolectará datos históricos del consumo de agua potable y la cantidad de líquido vital suministrada a la población.
- **Revisión de documentos:** se accederá a base de datos del SNI para conocer el crecimiento poblacional del cantón.
- **Redes Neuronales Artificiales.**

### ***1.6.3. Instrumentos***

- Máquina electrónica de procesamiento de datos
- Software R Studio

## Capítulo II FUNDAMENTACIÓN TEÓRICA

### 2.1. Pronósticos

La mayoría de las empresas, tanto grandes como pequeñas, del sector privado como del público, utilizan los pronósticos de manera directa o indirecta, ya que dentro de su planificación es fundamental contar con herramientas precisas y eficientes para prever de manera adecuada las necesidades futuras de los productos (Arroyo Gallardo, 2008). Los modelos de pronóstico de la demanda se utilizan para analizar datos históricos y generar estimaciones de la demanda futura. Estos modelos pueden basarse en diversos enfoques, como técnicas estadísticas, métodos de series temporales o incluso modelos de aprendizaje automático (Babel et al., 2006).

La planificación óptima y la gestión eficiente de los recursos es vital para la supervivencia y crecimiento de cualquier tipo de organización (Wettschereck et al., 1997). Según Amadowski (2011) los modelos de pronóstico de la demanda desempeñan un papel crucial en este proceso, ya que permiten anticipar la demanda de los productos, identificar patrones estacionales o tendencias, y tomar decisiones informadas sobre la programación de la producción, el inventario y la cadena de suministro.

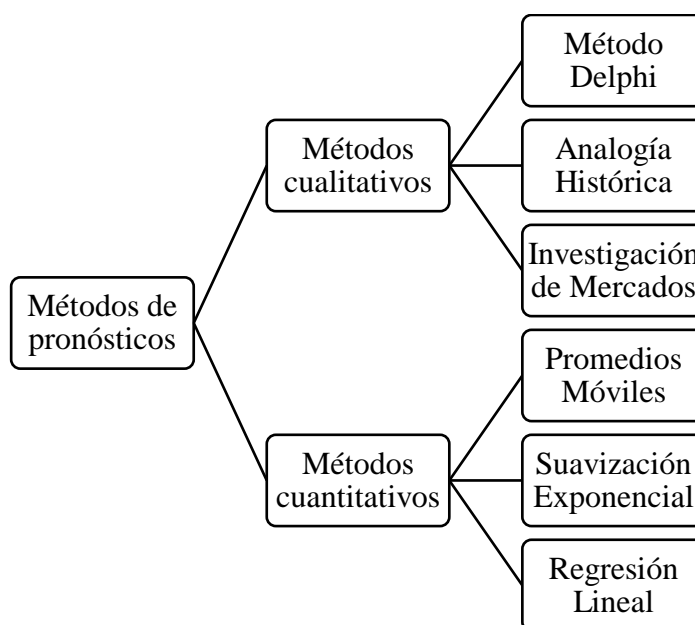
Además, es importante destacar que la elección y la implementación de un modelo de pronóstico adecuado dependen de varios factores, como la disponibilidad de datos históricos confiables, la naturaleza de los productos o servicios, y la complejidad de los patrones de demanda (Hanke & Wichern, 2010; Schroeder et al., 2005). Para lograrlo se suelen utilizar software especializado y técnicas avanzadas para desarrollar y evaluar estos modelos, considerando también la capacidad de adaptación y la mejora continua de los mismos (Hanke & Wichern, 2010).

### 2.1.1. Clasificación de los pronósticos

Con el propósito de lidiar con la incertidumbre que a menudo surge en el proceso de toma de decisiones en las organizaciones, es esencial tener conocimiento de los distintos métodos de pronóstico para asegurar que las decisiones se basen en evidencia concreta en lugar de depender únicamente de la intuición. Esto permitirá justificar los resultados en términos de costo-beneficio, y determinar cuál método es el más adecuado para atender una situación específica de la empresa (Paredes et al., 2018).

#### Figura 1

*Clasificación de los pronósticos*



*Nota:* Adaptado de *Importancia de los pronósticos en la toma de decisiones en las MIPYMES* (p. 102) por (Paredes et al., 2018), Revista GEON (Gestión, Organizaciones Y Negocios).

### 2.1.2. Patrones de tiempo

La serie temporal de datos se compone de diversos patrones o comportamientos que pueden ser desglosados en cuatro componentes distintos: tendencia, cíclico, estacional e irregular. Por lo


general, se asume que estos componentes trabajan en conjunto para producir los valores específicos de la serie temporal (J. E. Montemayor Gallegos, 2013).

### 2.1.2.1. Patrón horizontal (estacionario).

Cuando los valores de una variable se mantienen relativamente constantes en el tiempo y no muestran cambios significativos, se puede identificar un patrón estacionario horizontal (Krajewski et al., 2013). Un ejemplo de esto sería el caso de las ventas de sal, donde el nivel de ventas se mantiene estable sin experimentar aumentos o disminuciones notables a lo largo del tiempo, como puede verse en la figura 2. Este comportamiento estacionario horizontal indica una falta de tendencia, ciclo o estacionalidad significativa en los datos (E. J. Montemayor Gallegos, 2013).

## Figura 2

*Serie de tiempo con patrón estacionario*



*Nota:* Adaptado de *Métodos de pronósticos para negocios (p. 1)* por Montemayor Gallegos, 2013, Editorial Digital Tecnológico de Monterrey


### 2.1.2.2. Patrón de tendencia.

Se puede observar otro tipo de patrón denominado "tendencia", el cual se caracteriza por un aumento o disminución constante en una serie de datos a lo largo de un período de tiempo

prolongado (Toro Ocampo et al., 2004). Las series que muestran una tendencia están influenciadas por la actividad económica, y un ejemplo representativo de ello es el Producto Interno Bruto (PIB), el cual mide la producción de bienes y servicios de un país, ver figura 3 (E. J. Montemayor Gallegos, 2013).

### Figura 3

*Serie de tiempo con patrón de tendencia*



*Nota:* Adaptado de *Métodos de pronósticos para negocios (p. 1)* por Montemayor Gallegos, 2013, Editorial Digital Tecnológico de Monterrey


#### 2.1.2.3. Patrón cíclico

Cuando una serie de datos muestra una tendencia, es posible que también exhiba otro patrón llamado "comportamiento cíclico". Este comportamiento implica un aumento o disminución regular en intervalos de tiempo específicos, como cada tres años o más (Zavala Hepp, 2015). Montemayor (2013) indica en sus investigación que en el caso de México como se muestra en la figura 4, se puede observar este patrón en el comportamiento del Producto Interno Bruto (PIB), especialmente cada seis años durante los cambios de sexenio, donde se observa una disminución en la producción económica del país.



**Figura 4**

*Serie de tiempo con patrón cíclico*




*Nota:* Adaptado de *Métodos de pronósticos para negocios (p. 1)* por Montemayor Gallegos, 2013, Editorial Digital Tecnológico de Monterrey

#### **2.1.2.4. Patrón estacional**

Según Taha (2012), Mora (2001) y Vapnik (1999) cuando una serie de datos es influenciada por factores recurrentes que se repiten en la misma temporada cada año, se dice que presenta un patrón estacional. Algunos ejemplos de variables que muestran este patrón de acuerdo con Zavala (2015) son las ventas de trajes de baño, las cuales experimentan un aumento significativo durante el verano, las ventas de artículos navideños, que muestran un incremento notable en diciembre, y la cantidad de dinero en efectivo en manos del público, entre otros ejemplos, gráficamente se puede ver en la figura 5. Es importante destacar que el patrón estacional solo se puede observar en series de datos que se registran a lo largo del tiempo (E. J. Montemayor Gallegos, 2013).

**Figura 5**

*Serie de tiempo con patrón estacional*




*Nota:* Adaptado de *Métodos de pronósticos para negocios (p. 1)* por Montemayor Gallegos, 2013, Editorial Digital Tecnológico de Monterrey

#### **2.1.2.5. Variación irregular**

La variación irregular o aleatoria puede manifestarse en los patrones horizontales, de tendencia y estacionalidad. Estos cambios a corto plazo son difíciles de modelar matemáticamente debido a su naturaleza impredecible, y, por lo tanto, no se pueden prever con el fin de realizar pronósticos futuros (Tashman, 2000). Un ejemplo de esta variación se puede observar en el tipo de cambio (pesos por dólar) en la serie histórica, ver figura 6, la cual está sujeta a especulaciones generadas por diversos factores, como movimientos sociales, eventos políticos, desastres naturales, entre otros (Nyman & Ormerod, 2017). Estos factores influyen en las decisiones de los inversionistas y contribuyen a la variabilidad impredecible del tipo de cambio (Gutiérrez, 2013).

**Figura 6**

*Serie de tiempo con variación irregular*



*Nota:* Adaptado de *Métodos de pronósticos para negocios (p. 1)* por Montemayor Gallegos, 2013, Editorial Digital Tecnológico de Monterrey

### **2.1.3. Precisión de los pronósticos**

Krajewski (2013), Liu & Hung (2010), Tashman (2000) y Zhou (2002) concuerdan en que es posible evaluar la precisión global de cualquier modelo de predicción mediante la comparación entre los valores pronosticados y los valores observados o reales. En la práctica, se emplean diversas medidas para calcular el error global de la predicción, lo que permite comparar diferentes modelos de predicción y supervisar su desempeño para asegurar su correcto funcionamiento. Estas medidas de evaluación proporcionan una visión objetiva de qué tan cerca o lejos están los valores pronosticados de los valores reales, lo que es fundamental para evaluar la calidad y la confiabilidad de los modelos de predicción (Render & Heizer, 2007).

#### **2.1.3.1. Errores de los pronósticos**

Las medidas de error de predicción más comunes son las que se detallan a continuación:

### **2.1.3.1.1. Desviación absoluta media**

Villareal (2016) menciona que su valor se obtiene sumando los valores absolutos de errores individuales del pronóstico y dividiendo ese resultado entre la cantidad de períodos evaluados (n);

$$MAD = \frac{\Sigma |Real - Pronóstico|}{n} \quad (1)$$

### **2.1.3.1.2. Error cuadrático medio**

Para Chapman (2006) es una medida de dispersión del error del pronóstico comúnmente utilizada. Sin embargo, es importante tener en cuenta que esta medida tiene la particularidad de maximizar el error al elevarlo al cuadrado, lo que implica que aquellos períodos en los que la diferencia entre el pronóstico y los valores reales fue más alta en comparación con otros períodos, reflejará un mayor error. Esta característica de la medida puede influir en la interpretación de los resultados, ya que los errores más grandes tendrán un impacto desproporcionado en el cálculo de la medida de dispersión.

$$MSE = \frac{\Sigma Error\ de\ pronóstico^2}{n} \quad (2)$$

### **2.1.3.1.3. Error absoluto medio**

Esta métrica se calcula como el promedio de las diferencias absolutas entre los valores de la serie de tiempo en la base histórica y los valores obtenidos a través del pronóstico. En otras palabras, el MAE representa la diferencia promedio entre los datos reales y los valores pronosticados. Para la interpretación, cuanto más pequeño sea el valor del MAE, mejor se ajustará el modelo al comportamiento de los datos históricos. En resumen, el MAE es una medida utilizada para evaluar el grado de precisión de un modelo de pronóstico, donde un valor más bajo indica un mejor ajuste del modelo a los datos observados (Heizer & Render, 2007).

$$MAE = \frac{1}{n} \sum_{t=1}^T |x_t - \hat{x}| \quad (3)$$

#### 2.1.3.1.4. *Error porcentual medio absoluto*

A diferencia de las medidas anteriores, según D' Alessio (2002) el MAPE proporciona una desviación en términos porcentuales en lugar de unidades absolutas. Se calcula como la diferencia promedio entre los pronósticos y los valores reales, teniendo en cuenta la magnitud relativa de la demanda. Esta medida permite evaluar la precisión del modelo en relación con los valores reales de una manera más relativa y comparable. En resumen, el MAPE es una métrica utilizada para evaluar la precisión relativa de un modelo de pronóstico, expresando el error promedio como un porcentaje de los valores reales.

$$MAPE = \frac{\sum_{i=1}^n 100|Real_i - Pronóstico_i|}{n \cdot Real_i} \quad (4)$$

Durante el análisis de pronósticos o modelos, es importante considerar diferentes errores que pueden surgir y cada uno de ellos proporciona información valiosa. Algunos errores, como el error medio (ME) y el error porcentual promedio (MPE), permiten determinar si el pronóstico se encuentra en la dirección esperada, al evaluar si el promedio del pronóstico está por encima o por debajo del valor esperado (Velasco Sánchez & Campins Masriera, 2013).

Por otro lado, los errores que nos ayudan a entender el tamaño del error en el pronóstico son el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE). Estos errores se enfocan exclusivamente en la magnitud del error (valor absoluto), lo que nos brinda una idea de la precisión del pronóstico (Robert Jacobs & Chase, 2018). Son especialmente útiles para comparar los resultados obtenidos de diferentes métodos de estimación y determinar cuál ofrece una mayor precisión.

El error cuadrático medio (MSE) es ampliamente utilizado para comparar resultados, ya que nos ayuda a determinar cuál valor es el más pequeño, lo que implica un pronóstico más preciso.

Debido a su similitud con la varianza y la desviación estándar, el MSE se utiliza como una referencia para evaluar la calidad del pronóstico (Render & Heizer, 2007).

Cada uno de estos errores proporciona información específica y puede ser utilizado para diferentes propósitos en el análisis de pronósticos, desde evaluar la dirección del pronóstico hasta determinar la precisión y la calidad de este.

### **2.1.3.2. Selección de un método de pronóstico**

Existen numerosos métodos disponibles para realizar pronósticos, y no se puede afirmar que uno sea inherentemente mejor que los demás en todas las situaciones. La elección del mejor método de pronóstico generalmente depende de una variedad de factores que deben ser considerados (Farrera Gutiérrez, 2013), algunos de estos factores se mencionan a continuación:

- **Disponibilidad de datos:** La disponibilidad y calidad de los datos históricos pueden influir en la elección del método de pronóstico (Lindner, 2017). Algunos métodos requieren una cantidad mínima de datos para generar resultados confiables. Este es un factor que conducirá a la elección de un método cualitativo o cuantitativo.
- **Precisión deseada:** Es importante definir qué grado (Gutiérrez, 2013) de precisión se desea. Algunos enfoques pueden ser más precisos en situaciones de pronóstico a corto plazo, mientras que otros pueden funcionar mejor para pronósticos a largo plazo. Esto implica una evaluación de diversos modelos de pronóstico lo que se puede traducir en una gran cantidad de recursos necesarios.
- **Uso:** Es necesario saber para qué se utilizará el pronóstico, por ejemplo, para determinar el grado de exactitud adecuado (Herrera et al., 2010).

- **Disponibilidad de recursos:** La elección del método también puede depender de los recursos y conocimientos disponibles en la organización (Tashman, 2000). Algunos métodos pueden requerir un software o herramientas específicas, así como experiencia técnica para implementarlos correctamente.
- **Importancia del pasado para estimar el futuro:** Es fundamental considerar la relevancia del patrón de comportamiento histórico de la variable para identificar si puede tomarse en cuenta para el futuro. Para ello se utilizan herramientas estadísticas con las que se puede identificar esos patrones (Sahoo et al., 2009).
- **Persona que va a realizar el pronóstico:** La experiencia y el conocimiento del pronosticador también juegan un papel importante. De acuerdo con Herrera y demás colaboradores (2010) algunos métodos pueden requerir un mayor nivel de experiencia y comprensión de los datos y su contexto.

En resumen, no existe un método que sea mejor que otro; la elección del mejor método de pronóstico dependerá de una cuidadosa consideración de estos factores y de una evaluación detallada de las necesidades y características específicas del problema de pronóstico en cuestión. No existe una solución única que se aplique universalmente, y es importante adaptar el enfoque de pronóstico a las circunstancias particulares de cada situación.

## **2.2. Redes neuronales**

Las redes neuronales artificiales (RNA) son modelos computacionales que se basan en la estructura y funcionamiento de las neuronas en el cerebro humano. Estas redes imitan el comportamiento lógico y racional del cerebro al conectarse entre sí de manera similar a las neuronas biológicas (Villada et al., 2012). Las RNA realizan funciones de aprendizaje, abstracción y generalización, lo que les permite realizar tareas como reconocimiento de patrones, clasificación,

predicción y toma de decisiones. Son utilizadas en campos como la inteligencia artificial, el aprendizaje automático y la visión por computadora (Sarmiento Maldonado & Villa Acevedo, 2008). Las RNA continúan siendo objeto de investigación y desarrollo, contribuyendo al avance de sistemas más inteligentes y eficientes (Nacelle & Mizraji, 2009; Restrepo Leal et al., 2021).

### **2.2.1. Historia de las redes neuronales**

#### **2.2.1.1. Concepto de neurona**

Santiago Ramón y Cajal, un científico español, hizo un avance crucial a finales del siglo XIX al describir los diferentes tipos de neuronas de forma individual. Su teoría de la neurona afirmaba que el sistema nervioso está compuesto por unidades neuronales individuales que se comunican mediante sinapsis, lo cual contrastaba con las ideas previas de una red continua de fibras nerviosas (Yao, 1999). El minucioso trabajo de Ramón y Cajal reveló la verdadera naturaleza y organización de las neuronas, sentando las bases para comprender la interacción y transmisión de información entre ellas en el cerebro y el sistema nervioso en general (Hyndman, 2014). En la actualidad, la teoría de la neurona es ampliamente aceptada y considerada fundamental en la neurociencia, y el legado de Ramón y Cajal sigue siendo relevante en el estudio de la estructura y función del cerebro humano (Bravo, 2009).

#### **2.2.1.2. Primeros intentos**

En 1943, Warren McCulloch y Walter Pitts realizaron un importante avance en el campo de las redes neuronales al desarrollar modelos que se inspiraban en los principios de la neurología (Liu & Hung, 2010). Estos modelos se basaban en el concepto de neuronas simples, que se consideraban dispositivos binarios con umbrales fijos (Bravo, 2009).



### **2.2.1.3. Tecnología emergente y promisoría**

El Perceptrón, desarrollado por Frank Rosenblatt en 1958, fue un avance importante en el campo de las redes neuronales. Consiste en un modelo de dos niveles, con una capa de entrada que recibe información y una capa de salida que procesa los datos para generar la salida de la red neuronal. Este modelo revitalizó el interés y la actividad en el campo de las redes neuronales (Bravo, 2009; López & Fernández, 2008).

### **2.2.1.4. Período de frustración y desprestigio**

En 1969, Minsky y Papert publicaron un trabajo que destacó las limitaciones del Perceptrón para resolver problemas complejos, especialmente aquellos que no son linealmente separables. Esto provocó un período de menor interés en la simulación de redes neuronales y una disminución en la propuesta de nuevas ideas en el campo (Hanke & Wichern, 2010). Sin embargo, con el tiempo, la investigación en redes neuronales se reactivó gracias a avances tecnológicos y enfoques de aprendizaje más sofisticados, lo que llevó a un renacimiento en el campo y a su aplicación en diversos problemas complejos (Bravo, 2009).

### **2.2.1.5. Innovación**

Durante un periodo en el que el interés por las redes neuronales era bajo, hubo investigadores que continuaron trabajando en el desarrollo de métodos computacionales basados en principios neurobiológicos para abordar problemas de identificación y clasificación de patrones. En este periodo se generaron varios paradigmas importantes (Hilera Gonzáles & Martínez Hernando, 1995). Por ejemplo, Steve Grossberg y Gail Carpenter desarrollaron la teoría de la resonancia adaptativa (ART) en 1976, mientras que Anderson y Kohonen en 1982 desarrollaron técnicas para el aprendizaje asociativo. Hopfield, en 1984, propuso una red neuronal que empleaba una analogía energética. Paul Werbos, por su parte, desarrolló y utilizó el método de aprendizaje

conocido como Backpropagation en 1982 (García & Osella Massa, 2003; Hilerá Gonzáles & Martínez Hernando, 1995; Restrepo Leal et al., 2021). Aunque pasaron varios años antes de que este método se popularizara, actualmente es ampliamente utilizado en arquitecturas multicapa y ha demostrado ser altamente efectivo en aplicaciones prácticas. En esencia, una red de Backpropagation es similar a un perceptrón con múltiples capas, con diferentes funciones de activación en las neuronas artificiales y una regla de aprendizaje más sólida y confiable (Bravo, 2009).

#### **2.2.1.6. Resurgimiento**

En la década de 1970 y principios de 1980, se produjo un resurgimiento significativo del interés en el campo de las redes neuronales (García & Osella Massa, 2003). Varios factores contribuyeron a este movimiento, incluyendo la publicación de libros y la celebración de conferencias que difundieron las ventajas de esta técnica a diferentes audiencias (Isasi Viñuela & Galván León, 2004). Además, se incorporaron cursos sobre redes neuronales en los programas académicos de las principales universidades en Europa y América. Para Restrepo y colaboradores (2012) el respaldo financiero a proyectos de investigación en redes neuronales en Europa, Estados Unidos y Japón también desempeñó un papel importante, lo que resultó en una amplia gama de aplicaciones comerciales e industriales en este campo.

#### **2.2.1.7. Actualidad**

En el campo de las redes neuronales artificiales (RNA), se han logrado avances significativos que han generado un gran interés y atención, dando lugar al desarrollo de nuevos campos de aplicación (Isasi Viñuela & Galván León, 2004). Actualmente, existen circuitos integrados basados en RNA disponibles comercialmente, y las aplicaciones desarrolladas son capaces de resolver problemas cada vez más complejos. Además, se ha observado la aparición de

un nuevo tipo de máquinas de aprendizaje, como las máquinas con vectores de soporte, que tienen una gran capacidad para el procesamiento de datos (Matich, 2001). Aunque estas máquinas no están directamente inspiradas en la biología neuronal, ya que su aprendizaje se basa en métodos estadísticos, han tenido un fuerte impacto en diversos campos del conocimiento (Bravo, 2009).

### ***2.2.2. Principios de las redes neuronales***

Después de recibir un entrenamiento adecuado, las redes neuronales tienen la capacidad de abordar y resolver problemas específicos. Estos problemas se basan en cinco principios fundamentales, los cuales se describen en detalle en la tabla 1 según Acevedo y colaboradores (2017).

Las redes neuronales son especialmente efectivas en la resolución de ciertos tipos de problemas que comparten características comunes y distintivas. Estos problemas están asociados a aplicaciones empresariales e industriales que presentan ciertas características particulares, tal como lo menciona Díez y colaboradores (2001). Estas características incluyen: (Acevedo et al., 2017)

- La ausencia de soluciones adecuadas utilizando tecnologías tradicionales para abordar el problema en cuestión.
- La presencia de datos de entrada que pueden ser incompletos, variables o estar sujetos a ruido no deseado.
- La disponibilidad de una gran cantidad de datos que se pueden utilizar para entrenar la red y verificar los resultados obtenidos durante la etapa de aprendizaje.

**Tabla 1***Principios de las redes neuronales artificiales.*

<b>Definición</b>	<b>Principio</b>
Las redes neuronales se comportan en función de un entrenamiento.	Aprendizaje Adaptativo
Después de haber aprendido una serie de patrones, les podría reconocer otros patrones similares, aunque no se le hubiesen presentado en el entrenamiento.	Autoorganización
El ruido en los patrones de información no los afecta y pueden seguir trabajando, aunque se destruya parte de la red. Esto se debe a que le información en las redes neuronales se hacen de forma distribuida y con redundancia.	Tolerancia a fallos
Las redes neuronales artificiales realizan reconocimiento de patrones en tiempo real, debido a que trabajan en paralelo actualizando todas sus instancias simultáneamente.	Operación en tiempo real
Es fácil obtener hardware para trabajar con redes neuronales y es fácil realizar integración de forma modular en tecnologías existente.	Fácil inserción en la tecnología existente

*Nota:* Adaptado de Principios y características de las redes neuronales artificiales (p. 175) por (Acevedo et al., 2017), Revista Desarrollo e innovación en ingeniería.

### **2.2.3. Modelo de una red neuronal**

Nacelle y Mizraji (2009) dicen que las neuronas biológicas son conocidas por su capacidad de comunicación. Reciben señales de entrada excitatorias e inhibitorias a través de sus dendritas y cuerpo celular provenientes de neuronas cercanas, las cuales son combinadas e integradas en el cuerpo celular para emitir señales de salida.

Yao (1999) propone una clasificación de los modelos de redes neuronales basada en su similitud con el comportamiento biológico de las neuronas. Estos modelos se pueden dividir en dos categorías principales:


- Modelos de tipo biológico: Estos modelos tienen como objetivo simular los sistemas neuronales biológicos, enfocándose especialmente en las funciones básicas relacionadas con la audición y la visión. Buscan replicar de manera precisa el comportamiento de las neuronas biológicas para comprender y estudiar su funcionamiento (Villada et al., 2012).
- Modelos dirigidos a aplicaciones: Estos modelos se enfocan en el diseño de sistemas neuronales que sean aplicables en la resolución de problemas de inteligencia artificial y simulación de la realidad. Se busca utilizar las redes neuronales como herramientas para abordar y resolver problemas específicos en diversas áreas, adaptando su estructura y funcionamiento de acuerdo con las necesidades y requisitos de las aplicaciones deseadas (Rodríguez Aedo, 2016).

### 2.2.3.1. Elementos básicos de componen una red

En la figura 7 se muestra una red neuronal:

**Figura 7**

*Ejemplo de una red neuronal totalmente conectada*



*Nota.* Adaptado de *Ejemplo de una red neuronal totalmente conectada*, por (Matich, 2001)

Según Martí (2009) y Bonilla (2015), una red neuronal está compuesta por neuronas interconectadas distribuidas en capas, siendo la cantidad de capas variable. La información ingresa a través de la capa de entrada, pasa a través de una o varias capas ocultas y los resultados se obtienen en la capa de salida.

Las neuronas artificiales, también conocidas como unidades de proceso, reciben información de las neuronas vecinas y calculan un valor de salida, el cual es enviado a las demás neuronas restantes (Hilera Gonzáles & Martínez Hernando, 1995). García, Osella (2003), Sipper y Bulfin (1998) describen en detalle los diferentes tipos de neuronas que componen una red neuronal:


- **Neuronas de entrada:** Reciben señales o información del entorno, siendo estas las entradas de la red neuronal. Por lo general, estas entradas provienen de una serie de tiempo, como una base de datos histórica, que se utiliza para hacer predicciones (López & Fernández, 2008).
- **Neuronas ocultas:** Estas neuronas se encuentran en el interior de la red y no tienen contacto directo con el exterior. Sus entradas y salidas se encuentran dentro del sistema (Adamowski & Chan, 2011). Las redes neuronales aprenden de las interacciones entre las entradas y salidas de cada neurona oculta, lo que les permite aprender de experiencias pasadas y prepararse para generar la salida correcta en nuevas situaciones. Estas interacciones son fundamentales para el aprendizaje de la red neuronal (Acevedo et al., 2017).
- **Neuronas de salida:** Envían impulsos o señales fuera de la red. En la práctica, esto corresponde a la predicción o al valor futuro estimado que la red neuronal genera (Restrepo Leal et al., 2021).

### 2.2.3.2. Fase de entrenamiento

Según Vrontos y demás investigadores (2021), el proceso de aprendizaje o entrenamiento de la red neuronal tiene como objetivo determinar los pasos necesarios para que la red resuelva adecuadamente una situación específica. Durante la fase de aprendizaje, se desarrolla de manera iterativa la solución, refinándola hasta alcanzar el nivel operativo correcto, como se ilustra en la figura 8 (Martí Pérez, 2009).

#### Figura 8

*Esquema de funcionamiento de un proceso de aprendizaje supervisado*



*Nota.* Adaptado de *Esquema de funcionamiento de un proceso de aprendizaje supervisado*, por Martí Pérez, 2009

### 2.3. Regresión Lineal

La regresión lineal es un análisis utilizado para predecir el valor de una variable en función de otra (Bravo Sanzana et al., 2015). En este análisis, la variable que se desea predecir se conoce como variable dependiente, mientras que la variable utilizada para realizar la predicción se denomina variable independiente (Lindner, 2017).

El objetivo de la regresión lineal es encontrar los coeficientes de una ecuación lineal que mejor se ajuste a los datos, utilizando una o más variables independientes que sean buenos predictores del valor de la variable dependiente (AlShafeey & Csáki, 2021). El método de "mínimos cuadrados" se utiliza comúnmente para estimar los coeficientes y encontrar la línea recta

o superficie que minimiza las discrepancias entre los valores predichos y los valores reales (Fritz, 2022).

El modelo de regresión lineal se utiliza para pronosticar el valor esperado de una variable cuando se toma un valor específico para otra variable (Lindner, 2017). Sin embargo, es importante realizar un análisis de regresión previo para determinar la linealidad de la relación entre las variables que componen el modelo (Sigauke & Chikobvu, 2011).

El pronóstico de regresión lineal simple es especialmente adecuado para patrones de demanda con tendencia (creciente o decreciente), donde existe una relación lineal entre la demanda y el tiempo (Vanegas & Vásquez, 2017). Para determinar cuándo es apropiado utilizar la regresión lineal, se deben considerar medidas de la intensidad de la relación entre las variables (Dudek, 2016).

En resumen, la regresión lineal es un método de pronóstico que busca predecir el valor de una variable en función de otra utilizando una ecuación lineal. Es especialmente útil para patrones de demanda con tendencia y requiere un análisis previo de la relación entre las variables para determinar su idoneidad.

### ***2.3.1. Análisis de regresión***

En un análisis de regresión, el objetivo principal es establecer la relación entre una variable dependiente y una o más variables independientes (Choi et al., 2011). Para lograr esto, se propone una forma funcional que describe cómo las variables independientes están relacionadas con la variable dependiente (Ottaviani & Marco, 2022).

En muchos casos, se asume una relación lineal entre las variables, lo que implica que los cambios en las variables independientes se reflejan de manera proporcional en la variable



dependiente. Esta forma funcional lineal es ampliamente utilizada en la práctica debido a su simplicidad e interpretación intuitiva (Spencer et al., 2019).

El análisis de regresión permite estimar los coeficientes de regresión, que representan la intensidad y la dirección de la relación entre las variables. Los coeficientes de correlación y determinación también se utilizan para evaluar la fuerza y la calidad de la relación entre las variables (Bas et al., 2017).

El coeficiente de correlación indica la magnitud y la dirección de la relación lineal entre las variables, mientras que el coeficiente de determinación proporciona una medida de la proporción de la variabilidad de la variable dependiente que se explica por las variables independientes (Fang & Lahdelma, 2016).

En resumen, el análisis de regresión busca establecer la relación entre las variables mediante la propuesta de una forma funcional, con énfasis en la relación lineal en muchos casos. Los coeficientes de correlación y determinación se utilizan para medir la intensidad y la calidad de la relación entre las variables.

#### **2.3.1.1. Coeficiente de correlación [r]**

Según Ottaviani & Marco (2022), Sahoo (2009), Sigauke & Chikobvu (2011), Spencer (2019) el coeficiente de correlación, representado por  $r$  o  $R$ , es una medida que evalúa la relación entre dos variables aleatorias,  $X$  e  $Y$ . Su valor varía entre  $-1$  y  $+1$ , y proporciona información sobre la asociación lineal entre las variables.


- Si  $r$  es  $+1$ , indica una correlación positiva perfecta, lo que implica una relación lineal positiva constante entre las variables.
- Si  $r$  es  $-1$ , indica una correlación negativa perfecta, lo que implica una relación lineal negativa constante entre las variables.

- Si  $r$  es 0, no hay una correlación lineal entre las variables.

Es importante tener en cuenta que el coeficiente de correlación solo mide la asociación lineal y no considera otras formas de relación no lineal (Hu et al., 2007). Además, su interpretación debe realizarse considerando el contexto de los datos y la naturaleza de las variables analizadas, como se muestra en la figura 9.

## Figura 9

*Esquema del coeficiente de correlación*



*Nota.* Adaptado de *Coefficiente de correlación*, por (Kazemi et al., 2012)

El cálculo del coeficiente de correlación se efectúa de la siguiente manera:

$$r = \frac{n \sum_{i=1}^n X_i t_i - \sum_{i=1}^n X_i \sum_{i=1}^n t_i}{\sqrt{[n \sum_{i=1}^n t_i^2 - (\sum_{i=1}^n t_i)^2][n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2]}} \quad (5)$$

Dónde  $t$  hace referencia a la variable tiempo y  $x$  a la variable demanda.

### 2.3.2. Modelo de Regresión Lineal Simple

#### 2.3.2.1. Fórmulas

$$\hat{X}_t = a + bt \quad (6)$$

$\hat{X}_t$  Pronóstico del período  $t$

$a$	Intersección de la línea con el eje
$b$	Pendiente (positiva o negativa)
$t$	Período de tiempo

Donde:

$$a = \bar{X} - b\bar{t} \quad (7)$$

$\bar{X}$  Promedio de la variable dependiente (ventas o demanda)

$\bar{t}$  Promedio de la variable independiente (tiempo)

$$b = \frac{n \sum_{i=1}^n X_i t_i - \sum_{i=1}^n X_i \sum_{i=1}^n t_i}{n \sum_{i=1}^n t_i^2 - (\sum_{i=1}^n t_i)^2} \quad (8)$$

### 2.3.3. Hipótesis de la regresión lineal

Las hipótesis que se deben considerar para lograr un análisis exitoso de regresión lineal son las siguientes:

- **Variables:** Se deben tener en cuenta el número de casos válidos, la media y la desviación estándar de cada variable (AlShafeey & Csáki, 2021).
- **Modelo:** Se deben analizar los coeficientes de regresión, la matriz de correlación, las correlaciones parciales y semiparciales, el valor de R, R<sup>2</sup>, R<sup>2</sup> ajustado, el cambio en R<sup>2</sup>, el error estándar de la estimación, la tabla de análisis de varianza, los valores previstos y residuales. También es importante considerar los intervalos de confianza del 95% para cada coeficiente de regresión, la matriz de varianza-covarianza, el factor de inflación de la varianza, la tolerancia, la prueba de Durbin-Watson, las medidas de distancia (Mahalanobis, Cook y valores de apalancamiento), DfBeta, DfFit, los intervalos de predicción y la información de diagnóstico para cada caso (Tashman, 2000).

- **Gráficos:** Es útil examinar los diagramas de dispersión, los gráficos parciales y de probabilidad normal, así como los histogramas (Jeong et al., 2014).
- **Datos:** Las variables dependientes e independientes deben ser cuantitativas. En el caso de variables categóricas, como la religión, el campo principal de estudio o la región de residencia, se deben recodificar como variables binarias (ficticias) u otros tipos de variables de contraste (Ibujés Villacís & Benavides Pazmiño, 2018).
- **Otras hipótesis:** Es importante que la distribución de la variable dependiente sea normal para cada valor de la variable independiente. La varianza de la variable dependiente debe ser constante para todos los valores de la variable independiente. La relación entre la variable dependiente y cada variable independiente debe ser lineal, y todas las observaciones deben ser independientes (Lindner, 2017).

Al tener en cuenta estas hipótesis, se pueden realizar inferencias adecuadas y obtener conclusiones válidas a partir del análisis de regresión lineal (Tashman, 2000).

#### **2.4. Modelo SARIMA**

ARIMA (Autoregressive Integrated Moving Average) y SARIMA (Seasonal ARIMA) son dos algoritmos utilizados para el pronóstico de series temporales (Nwokike et al., 2020). Ambos modelos se basan en el análisis de los valores pasados de una serie temporal para predecir los valores futuros. Sin embargo, SARIMA va un paso más allá al considerar la presencia de patrones estacionales en los datos (Sigauke & Chikobvu, 2011).


ARIMA se basa en la combinación de tres componentes: el componente autoregresivo (AR), el componente de media móvil (MA) y el componente de integración (I). Estos componentes capturan la dependencia de los valores pasados y las tendencias presentes en los datos (Choi et al., 2011).

Por otro lado, SARIMA es una extensión de ARIMA que incorpora la estacionalidad como un parámetro adicional. Esto significa que SARIMA es capaz de modelar y predecir patrones estacionales en los datos, lo que lo hace más adecuado para series temporales que exhiben ciclos y fluctuaciones estacionales (Jeong et al., 2014).

En resumen, mientras que ARIMA se enfoca en capturar la dependencia temporal y las tendencias generales de una serie temporal, SARIMA tiene la capacidad adicional de modelar y pronosticar patrones estacionales (Dudek, 2016). Esto hace que SARIMA sea más poderoso y robusto en la predicción de datos complejos con ciclos y estacionalidad. Ver figura 10.

### Figura 10

#### *Estacionalidad SARIMA*



*Nota.* Adaptado de *Estacionalidad ARIMA*, por (Dudek, 2016)

En el modelo SARIMA, donde  $m$  representa el número de observaciones por año, utilizamos una notación en mayúsculas para las partes estacionales del modelo y en minúsculas para las partes no estacionales (Hanke & Wichern, 2010). La estacionalidad en una serie de tiempo se refiere a un patrón regular de cambios que se repiten cada  $S$  períodos de tiempo, donde  $S$  define la duración del ciclo estacional (Babel et al., 2006).

Para Chan (2011) dice que por ejemplo, en datos mensuales, podemos observar estacionalidad cuando ciertos meses tienen consistentemente valores altos o bajos. En este caso,  $S$  sería igual a 12 (meses por año). En datos trimestrales,  $S$  sería igual a 4 (trimestres por año).

En un modelo SARIMA, los términos autorregresivos (AR) y de media móvil (MA) estacionales se utilizan para predecir valores utilizando datos y errores con rezagos que son múltiplos de  $S$  (el intervalo de estacionalidad) (Hu et al., 2007).

Según Jeong y sus colaboradores (2014) para datos mensuales (con  $S = 12$ ), se podría utilizar un modelo autorregresivo estacional de primer orden para predecir.

- Por ejemplo, si analizamos las ventas de ventiladores de refrigeración, podríamos predecir las ventas de agosto utilizando las ventas de agosto del año anterior. Esta relación de predicción basada en datos del año anterior se mantiene para cualquier mes del año.
- Un modelo autorregresivo estacional de segundo orden utilizaría los valores de agosto de los dos años anteriores (es decir,  $x_{t-12}$  y  $x_{t-24}$ ) para predecir el valor actual  $x_t$ .
- En cuanto a los términos de media móvil (MA), un modelo  $MA(1)$  estacional de primer orden (con  $S = 12$ ) utilizaría el error de agosto del año anterior ( $w_{t-12}$ ) como predictor. Un modelo  $MA(2)$  estacional de segundo orden utilizaría los errores de agosto de los dos años anteriores ( $w_{t-12}$  y  $w_{t-24}$ ).

Estos son algunos ejemplos de cómo los términos estacionales en un modelo SARIMA se utilizan para pronosticar valores basados en patrones estacionales en los datos.

#### **2.4.1. Diferenciación**

En el pronóstico de series de tiempo con estacionalidad, es común que debamos considerar datos diferenciados. La estacionalidad introduce variaciones en los valores promedio dentro del intervalo estacional, lo que provoca que la serie no sea estacionaria (Jere et al., 2017). Por ejemplo, las ventas de ventiladores de refrigeración son consistentemente más altas durante los meses de

verano. Para abordar esta estacionalidad, es necesario examinar técnicas de diferenciación y utilizar modelos SARIMA en el pronóstico (Fang & Lahdelma, 2016).

#### **2.4.1.1. Diferenciación estacional**

La diferenciación estacional es una técnica utilizada en el análisis de series de tiempo para eliminar la estacionalidad y lograr una serie estacionaria (Box et al., 2015). De acuerdo con Habadi (2017) se realiza mediante la diferencia entre un valor actual y un valor rezagado que está separado por un múltiplo de  $S$ , donde  $S$  representa el intervalo de estacionalidad.

- Cuando  $S$  es igual a 12, típicamente utilizado para datos mensuales, la diferenciación estacional se expresa como  $(1 - B^{12})x_t = x_t - x_{t-12}$ . Esto implica restar el valor del mes actual ( $x_t$ ) con el valor del mismo mes del año anterior ( $x_{t-12}$ ).
- Del mismo modo, cuando  $S$  es igual a 4, que se aplica a datos trimestrales, la diferenciación estacional se calcula como  $(1 - B^4)x_t = x_t - x_{t-4}$ , donde se resta el valor del trimestre actual ( $x_t$ ) con el valor del mismo trimestre del año anterior ( $x_{t-4}$ ).

Estas diferencias estacionales ayudan a eliminar los efectos de la estacionalidad en los datos y permiten analizar la serie de tiempo de manera más precisa. Al aplicar esta técnica, las diferencias entre los valores en cada mes o trimestre del año tienden a ser aproximadamente las mismas, lo que conduce a una serie estacionaria (Choi et al., 2011).

#### **2.4.1.2. Diferenciación no estacional**

Si los datos presentan una tendencia, es posible que sea necesario aplicar una diferenciación adicional que no esté relacionada con la estacionalidad (Taha, 2012). En muchos casos, una primera diferencia no estacional puede ayudar a eliminar la tendencia de los datos. Esta diferencia

se obtiene restando el valor actual ( $x_t$ ) con el valor anterior ( $x_{t-1}$ ), y se expresa como  $(1 - B)x_t = x_t - x_{t-1}$ .

Al aplicar esta diferencia no estacional en presencia de tendencia, se busca desviar o eliminar la tendencia de los datos. Sin embargo, es importante tener en cuenta que esta técnica no siempre será efectiva, ya que existen casos en los que se requieren diferenciaciones más complejas para tratar con tendencias más complicadas (Zavala Hepp, 2015).

La diferenciación no estacional se utiliza en conjunto con la diferenciación estacional para lograr una serie de tiempo estacionaria y facilitar el análisis y la modelización de los datos.

#### **2.4.1.3. Diferenciación para tendencia y estacionalidad**

Cuando se presentan tanto la tendencia como la estacionalidad en los datos, puede ser necesario aplicar tanto una primera diferencia no estacional como una diferencia estacional (Gorgas García et al., 2011). Para ello, es importante examinar las funciones de autocorrelación (*ACF*) y autocorrelación parcial (*PACF*) de la serie resultante (Walpole et al., 2012).

La diferencia no estacional se aplica utilizando  $(1 - B)$ , donde  $B$  representa el rezago, y consiste en restar el valor actual ( $x_t$ ) del valor anterior ( $x_{t-1}$ ). La diferencia estacional se aplica utilizando  $(1 - B^S)$ , donde  $S = 12$  representa el número de períodos de tiempo en el ciclo estacional, y consiste en restar el valor actual del valor correspondiente al mismo período en el ciclo estacional anterior (Nwokike et al., 2020).

Es importante tener en cuenta que, al eliminar la tendencia, no se elimina necesariamente la dependencia entre los datos. La diferenciación puede dividir la dependencia en componentes de corto plazo y componentes de largo plazo. La parte no estacional del comportamiento seguirá siendo relevante en el modelo (Liu et al., 2020).



En el caso de datos estacionales, es probable que los componentes no estacionales a corto plazo sigan siendo importantes (Carmona-Benítez & Nieto, 2020). Por ejemplo, en el caso de las ventas mensuales de ventiladores de refrigeración mencionadas anteriormente, las ventas del mes anterior o de los dos últimos meses, junto con las ventas del mismo mes del año anterior, pueden contribuir a la predicción de las ventas del mes actual.

Para determinar qué términos no estacionales podrían ser relevantes en el modelo, se deben analizar las *ACF* y *PACF* durante los primeros rezagos (menos de  $S$ ). Esto ayudará a identificar qué componentes no estacionales pueden ser incluidos en el modelo para un pronóstico preciso (Bas et al., 2017).

#### 2.4.2. El modelo

El modelo ARIMA estacional (*SARIMA*) es una combinación de factores estacionales y no estacionales en un modelo multiplicativo (Bas et al., 2017). Utilizamos una notación abreviada para representar este modelo, que es:

$$ARIMA(p, d, q) \times (P, D, Q)_S \quad (9)$$

con

- $p$  = orden AR no estacional,
- $d$  =orden de diferencias no estacional,
- $q$  =orden MA no estacional,
- $P$  =orden AR estacional,
- $D$  =orden de diferencia estacional,
- $Q$  =orden MA estacional y
- $S$  =ventana de tiempo del patrón estacional.

Sin operaciones de diferenciación, el modelo podría escribirse más formalmente como

$$\Phi(B^S)\phi(B)(x_t - \mu) = \Theta(B^S)\theta(B)w_t \quad (10)$$

Los componentes no estacionales son:

- AR:  $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ .
- MA:  $\theta(B) = 1 + \theta_1 B + \dots + \theta_p B^p$ .

Los componentes estacionales son:

- AR estacional:  $\Phi(B^S) = 1 - \Phi_1 B^S - \dots - \Phi_p B^{pS}$ .
- MA estacional:  $\Theta(B^S) = 1 + \Theta_1 B^S + \dots + \Theta_Q B^{QS}$ .

## Capítulo III SITUACIÓN ACTUAL

### 3.1. Descripción de la organización


EPAA-AA es una empresa, que brinda servicios de agua potable y alcantarillado a la población del cantón Antonio Ante, proyectándose siempre a la satisfacción del cliente. La empresa dota del servicio de agua potable al 85% de la población del cantón, el alcantarillado en la ciudad supera el 80% y el 70% en las parroquias. Cuyo objetivo es disponer de un sistema de agua potable que garantice cantidad y calidad 24 horas de servicio y 100% de cobertura a todo el cantón. Además, es una empresa empeñada en lograr que la administración de los recursos económicos y financieros de los realice con el 100 por el ciento de agilidad y transparencia, para renovar nuestro compromiso de servicio y calidad a la ciudadanía.

### 3.2. Localización de la empresa

La empresa pública de agua potable y alcantarillado de Antonio Ante se encuentra ubicada en Atuntaqui en la calle Bolívar y Gonzáles Suárez.

#### Figura 11

*Ubicación de la empresa (EPAA-AA).*



*Nota:* Adaptado de EPAA-AA.

### 3.3. Misión

Entregar servicios de calidad en agua potable y alcantarillado en los hogares del Cantón Antonio Ante, comunicar mediante los medios de radio y televisión los sucesos importantes en el Cantón enmarcados en la normativa vigente, aportando al mejoramiento de la calidad de vida de los habitantes del cantón.

### 3.4. Visión

Ser en el 2023 la empresa referente a nivel Cantonal, provincial y nacional, en la optimización del modelo de gestión del recurso hídrico y alcantarillado, a través de la prestación de servicios oportunos, continuos y de calidad en beneficio de todos los habitantes del Cantón Antonio Ante.

### 3.5. Valores

**Eficiencia:** Brindar servicios de calidad en cada una de las funciones a su cargo, procurando obtener una capacitación sólida y permanente, que permita una actuación oportuna, efectiva y confiable;

**Universalidad:** Ofrecer a los sectores rurales y urbanos los servicios públicos de la Empresa;

**Accesibilidad:** Cubrir de manera eficiente la demanda de los servicios básicos del cantón Antonio Ante;

**Regularidad:** Ofrecer de manera permanente nuestros servicios públicos a la ciudadanía, manteniendo el servicio las 24 horas del día, los 365 días del año;

**Calidad:** Brindar los servicios públicos a la ciudadanía con las garantías técnicas que requieren los diferentes productos de la Empresa, para dar confianza al usuario;

**Continuidad:** Compromiso con la ciudadanía de brindar nuestros servicios las 24 horas del día y los 365 días del año al cantón Antonio Ante;

**Trabajo en equipo:** Potenciar las iniciativas, los conocimientos y recursos individuales, para impulsar una gestión eficiente en la Empresa; y,

**Transparencia:** Difundir la información sobre las acciones institucionales entregando información efectiva a la población y a las entidades de control.

### **3.6. Objetivos estratégicos**

Asegurar la continuidad, cobertura y calidad de la prestación de los servicios públicos operados por la empresa, teniendo en cuenta la sostenibilidad ambiental y el desarrollo del cantón Antonio Ante.

### **3.7. Productos**


- Implementar proyectos de tratamiento de aguas residuales para reducir la contaminación en el medio ambiente.
- Aumentar la cobertura de servicio de agua potable y alcantarillado en el cantón Antonio Ante.
- Incrementar las horas de servicio de agua potable en la población.

### **3.8. Estructura organizacional**

La estructura organizacional de la EPAA-AA se divide en cuatro procesos a través de sus diferentes en los que están los gobernantes que suministran planes estratégicos para el correcto funcionamiento institucional. Los de asesoría en los que brindan control y supervisión de la actividad diaria de las diferentes áreas. El proceso de apoyo es aquellos que brindan los recursos necesarios para una operatividad eficaz y eficiente. Finalmente se encuentra el proceso sustantivo que trabajan diariamente para cumplir con la misión planteada por la empresa. Al que servirá de apoyo el pronóstico de la demanda de agua potable del cantón. Ver figura 12

Figura 12

Organigrama de la EPAA-AA.



Nota: Adaptado de EPAA

### 3.9. Descripción del proceso productivo

#### 3.9.1. Captación

Para la captación de agua cruda existen diferentes fuentes de abastecimiento que la empresa tiene para su posterior tratamiento. Estas se encuentran detalladas en la tabla 2 a continuación.

**Tabla 2**

*Captaciones de agua cruda*

<b>Captación</b>	<b>Producción (l/s)</b>	<b>Tipo</b>	<b>Ubicación</b>
Perafán	40,00	Superficial – gravedad	Imantag – Comunidad de Perafán - Piavachupa
25 de Marzo	33,70	Subterráneo – bombeo	Andrade Marín – Eduardo Soasti y Panamericana
Chamanal	5,00	Superficial – gravedad	San Roque – Calle Sin Nombre
Imbaya	5,00	Subterráneo – bombeo	Imbaya – Vía a Urcuquí y Calle B
El Rancho	5,76	Superficial – gravedad	Atuntaqui – Vía a Imantag
General Enríquez	22,30	Subterráneo – bombeo	Andrade Marín – Calle Atahualpa y General Enríquez
San Juan Poglio	17,15	Superficial – gravedad	Panamericana E35 sector Pinsaquí.
Santa Bertha (El Guabo)	4,46	Superficial – gravedad	San Roque – Calle Santa Berta y Panamericana
Santa Martha (Santa Bertha)	3,58	Superficial – gravedad	San Roque – Calle Sin Nombre, Vertiente Santa Martha
Santa Martha	31,26	Superficial – gravedad	San Roque – Calle Sin Nombre, Vertiente Santa Martha
Poglyo (Imbaya)	1,50	Superficial – gravedad	Imbaya – Vía a Urcuquí

Nota: Adaptado de EPAA-AA

#### 3.9.2. Estación de bombeo

Una vez captada el agua cruda con un total de 169,70 l/s, es conducida hacia un tanque donde se encuentran equipos electro sumergibles (bomba y motor) los mismos que se encargan de

impulsar el agua por medio de tuberías hacia la planta de tratamiento para su posterior almacenamiento. Dichas bombas presentan las siguientes características descritas en la tabla 3, estas tienen un funcionamiento de las 24 horas del día, no usan variador de frecuencia y no funcionan en paralelo. La representación gráfica de los sistemas de bombeo se encuentra en el Anexo A.

**Tabla 3**

*Características de los sistemas de bombeo*

Nombre	Nro. Bombas	Marca	Potencia Motor (HP)
25 de Marzo	1	Grundfos 125-4	100
General Enríquez	1	Grundfos 125-4	75
Perafan – Piavachupa	2	Grundfos 160-8	200
Santa Isabel	1	Grundfos 30-22	40
El Rancho	2	Grundfos 30-19	40
Imbaya	1	Grundfos 30-16	40
Santa Martha	2	Grundfos 77-11	100
Santa Berta	1	Grundfos 60-14	50
El Chamanal	1	Grundfos 30-11	20
Yanaloma	2	Grundfos 30-22	40

Nota: Adaptado de EPAA-AA

### 3.9.3. *Planta de tratamiento*

#### 3.9.3.1. Aireación

La aireación consiste en la eliminación de olores y sabores producidos por gases disueltos en el agua, se utiliza la aireación cascada (torre de aireación) donde por medio de constantes saltos se logra su objetivo.

#### 3.9.3.2. Oxidación

El sistema consiste en una bomba pequeña que coloca un químico oxidante dentro del agua. El químico debe estar en el agua por lo menos durante veinte minutos para que se lleve a cabo la oxidación, o aún por más tiempo si el agua contiene hierro/manganeso coloidal. Este sirve para desinfectar el agua y eliminar organismos patógenos como bacterias. Elimina contaminantes



orgánicos y mejora la calidad del agua, desapareciendo sustancias que afectan su aspecto, sabor y olor. Finalmente reduce la formación de productos de desinfección como el cloro, que a largo plazo pueden generar enfermedades en la población.

### **3.9.3.3. Coagulación**

La coagulación, consiste en la neutralización de partículas, mediante el agregado de cargas de signo positivo, a través de un producto llamado “coagulante”. Este proceso dura unos pocos segundos y es necesario se produzca una agitación violenta para que el “coagulante” se mezcle completamente con el agua, en un tiempo lo más corto posible. Ese punto de máxima agitación, en donde se inyecta el coagulante, se llama “Mezcla rápida”

### **3.9.3.4. Flocculación**

Luego de coagulada el agua, las partículas no presentan cargas en su superficie y no existen impedimentos para que se unan entre sí.

Para lograr esto, el agua se debe agitar lentamente, de modo que las partículas coaguladas, al chocar, se vayan uniendo para dar lugar a otras de mayor tamaño llamadas “FLÓCS”

Este proceso se debe hacer bajo condiciones muy bien controladas, pues una agitación muy violenta en esta etapa puede producir rotura de óculos ya formados, en cambio una agitación muy lenta puede formar óculos esponjosos y débiles y difíciles de sedimentar.

### **3.9.3.5. Sedimentación**

La sedimentación, es la primera etapa efectiva de separación de partículas de agua, donde se logra una reducción de turbiedad y color con respecto al agua cruda.

En el sedimentador al reducirse la velocidad de circulación del agua, se produce la separación del fluido claro, y partículas de materias sólidas.

Estas se depositan en el fondo del sedimentador por efecto gravitacional y por la diferencia de densidad.

### 3.9.3.6. Filtración

El agua clarificada es llevada a los filtros descendentes, en donde a través de un medio filtrante (material filtrante), actúan una serie de mecanismos de remoción, la eficiencia de este proceso depende de las características de la suspensión (agua + partículas) y del medio poroso.

Las características para el transporte de agua potable se encuentran en el Anexo B.

## 3.10. Producción de la empresa y consumo anual

La empresa EPAA-AA con el fin de monitorear y controlar adecuadamente la información, mensualmente registran el consumo de agua potable y de sus clientes, lo que permite identificar el comportamiento del consumo anualmente de este recurso. A continuación, en la tabla 4 se presenta el consumo mensual de agua potable en metros cúbicos ( $m^3$ ) de los tres últimos años.

**Tabla 4**

*Producción y consumo ( $m^3$ ) mensual del cantón Antonio Ante.*

Año	2020		2021		2022	
	Producción	Consumo	Producción	Consumo	Producción	Consumo
Enero	377136	259520	440212	244815	440212	263473
Febrero	377136	240545	440212	230113	440212	232479
Marzo	377136	203647	440212	210460	440212	233916
Abril	377136	199417	440212	231803	440212	240445
Mayo	377136	175041	440212	194723	440212	255738
Junio	377136	297106	440212	254916	388372	227049
Julio	377136	230506	440212	240564	388372	222420
Agosto	377136	260690	440212	267023	388372	249198
Septiembre	440212	243245	440212	248179	388372	248547

Octubre	440212	260208	440212	255196	440212	253136
Noviembre	440212	245666	440212	239083	440212	248323
Diciembre	440212	219268	440212	218105	440212	234969

*Nota:* Adaptado de EPAA-AA.

### 3.11. Datos de la población

La población a nivel cantonal ha ido incrementando con el paso de los años, tanto en zonas urbanas como rurales, la proyección esperada según el (*Sistema Nacional de Información, 2021*), para el año 2023 Antonio Ante tendrá una población estimada de 57.096 habitantes, en la tabla 5, se presenta la proyección de habitantes según su rango de edad desde el año 2020.

**Tabla 5**

*Proyección poblacional del cantón Antonio Ante.*

Cantón	Grupo de edad	2020	2021	2022	2023
Antonio Ante	menores de 1 año	973	991	1.007	1.023
	1 a 4 años	4.338	4.413	4.487	4.560
	5 a 9 años	5.852	5.953	6.052	6.152
	10 a 14 años	5.814	5.914	6.014	6.113
	15 a 19 años	5.434	5.527	5.620	5.713
	20 a 24 años	4.743	4.823	4.905	4.986
	25 a 29 años	4.307	4.381	4.454	4.528
	30 a 34 años	3.811	3.877	3.942	4.007
	35 a 39 años	3.292	3.349	3.405	3.461
	40 a 44 años	3.019	3.070	3.123	3.174
	45 a 49 años	2.727	2.773	2.821	2.867
	50 a 54 años	2.109	2.145	2.181	2.217
	55 a 59 años	1.865	1.897	1.929	1.960
	60 a 64 años	1.522	1.548	1.574	1.600
	65 a 69 años	1.472	1.498	1.523	1.548
70 a 74 años	1.074	1.093	1.111	1.129	
75 a 79 años	849	863	878	893	
80 y más	1.109	1.127	1.146	1.165	
Total		54.310	55.242	56.172	57.096

*Nota:* Adaptado de *Proyecciones y Estudios Demográficos, por SNI, 2021*

### 3.12. Volumen de almacenamiento

El recurso hídrico ingresado por todos los procesos obligatorios para su potabilización es llevado a la zona de almacenaje, la Empresa Pública de Agua Potable y Alcantarillado de Antonio Ante cuenta con un total de 17 tanques de almacenamiento de agua como se detalla a continuación en la tabla 6.

**Tabla 6**

*Volumen de almacenamiento de los tanques de reserva*

<b>Nro</b>	<b>Tanques</b>	<b>Capacidad</b>
1	Santa Rosa de Peaje	70 m <sup>3</sup>
2	Cerotal	200 m <sup>3</sup>
3	Pucara Alto	200 m <sup>3</sup>
4	Yanaloma	200 m <sup>3</sup> 1000 m <sup>3</sup>
5	Pucara Bajo FIE	200 m <sup>3</sup>
6	Santa Isabel	200 m <sup>3</sup>
7	Óvalos Altos	100 m <sup>3</sup> 800 m <sup>3</sup>
8	General Enríquez	500 m <sup>3</sup> 500 m <sup>3</sup> 1000 m <sup>3</sup>
9	20 de julio	1000 m <sup>3</sup>
10	Santa Martha	70 m <sup>3</sup>
11	El Rancho	200 m <sup>3</sup> 100 m <sup>3</sup> 70 m <sup>3</sup>
12	Natabuela	100 m <sup>3</sup> 200 m <sup>3</sup>
13	Óvalos Bajos	100 m <sup>3</sup>
14	Planta de Imbaya	200 m <sup>3</sup>
15	Guayllabamba	70 m <sup>3</sup>
16	La Dolorosa	100 m <sup>3</sup>
17	El Poglyo Imbaya	50 m <sup>3</sup>

*Nota:* Adaptado de EPAA-AA

### 3.13. Capacidad de las plantas de tratamiento

La Empresa Pública de Agua Potable y Alcantarillado de Antonio Ante cuenta con seis plantas de tratamiento de agua ubicadas en puntos estratégicos para la dotación de agua potable. Esto con la finalidad de tener un mayor control en el proceso productivo. En la tabla 7 se puede identificar la capacidad de estas y su nombre respectivo.

**Tabla 7**

*Capacidad de las plantas de tratamiento*

<b>Planta de tratamiento</b>	<b>Capacidad</b>
General Enríquez	25 l/s
20 de Julio	40 l/s
Imbaya	10 l/s
El Rancho	10 l/s
Yanloma	25 l/s
Andrade Marín	40 l/s

*Nota:* Adaptado de EPAA-AA

### 3.14. Análisis de autocorrelación

Se realizó un análisis del comportamiento de los habitantes del cantón centrados en dos variables, la demanda y el número de clientes de la empresa por mes, con el objetivo de determinar si el consumo de agua de la población se incrementa o disminuye con el tiempo. El análisis de autocorrelación permite definir qué tipo de tendencia tiene cada variable. Este análisis junto a la prueba de Dickey Fuller permite evaluar si una serie temporal es estacionaria o no, basándose en el estadístico de prueba y el valor p obtenidos al realizar la prueba.

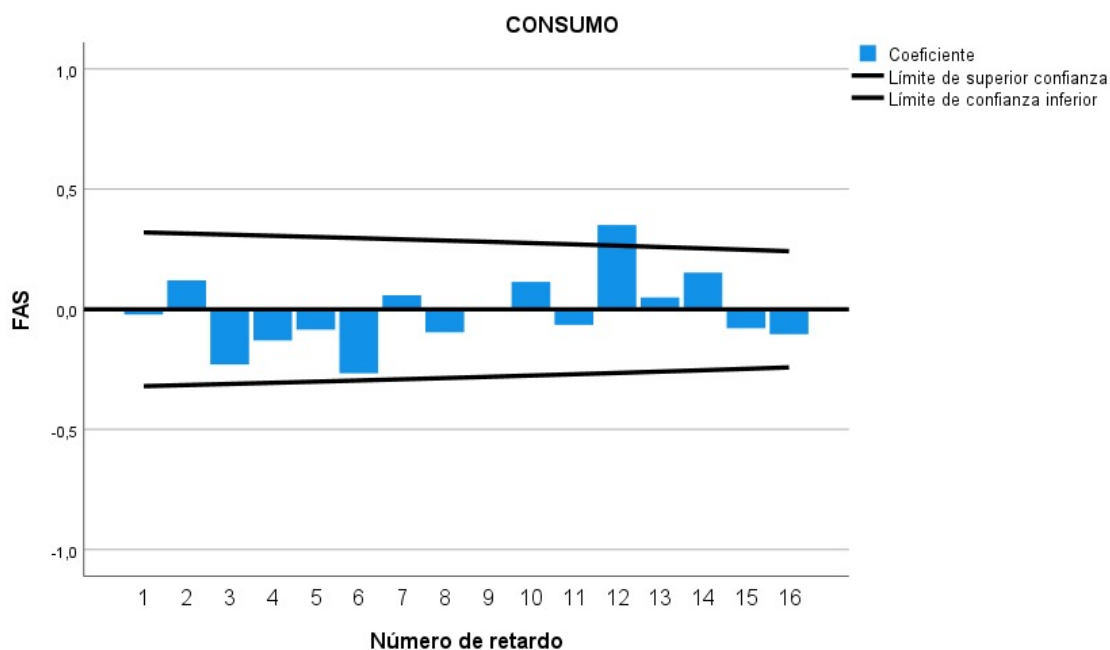
#### *3.14.1. Análisis de autocorrelación de la demanda mensual de agua potable*

En el análisis de la demanda mensual de agua potable se utilizó el software SPSS v27, para realizar su respectivo estudio. Es posible identificar que la serie de tiempo muestra una orientación creciente, sin embargo, en los retardos finales cambia esta tendencia debido al comportamiento

que tiene en los últimos meses del año la población de Antonio Ante. Evidenciando que la demanda de agua potable es de tipo estacionaria. Esto se puede identificar en la figura 13.

**Figura 13**

*Autocorrelación de la demanda de agua potable*



Para corroborar el análisis anterior se realizó la prueba de Dickey-Fuller aumentada con la ayuda del Software R Studio, en el que arrojó los resultados que se pueden observar en la figura 14. El que el resultado comprueba una vez más que la serie es estacionaria.

**Figura 14**

*Prueba Dickey-Fuller de la demanda mensual de agua potable*

```

Augmented Dickey-Fuller Test

data: serie
Dickey-Fuller = -3.69, Lag order = 3, p-value = 0.04015
alternative hypothesis: stationary

>
> # Interpretar el resultado de la prueba
> if (adf.test(serie, alternative = "stationary")$p.value < 0.05) {
+   print("La serie temporal es estacionaria.")
+ } else {
+   print("La serie temporal no es estacionaria.")
+ }
[1] "La serie temporal es estacionaria."

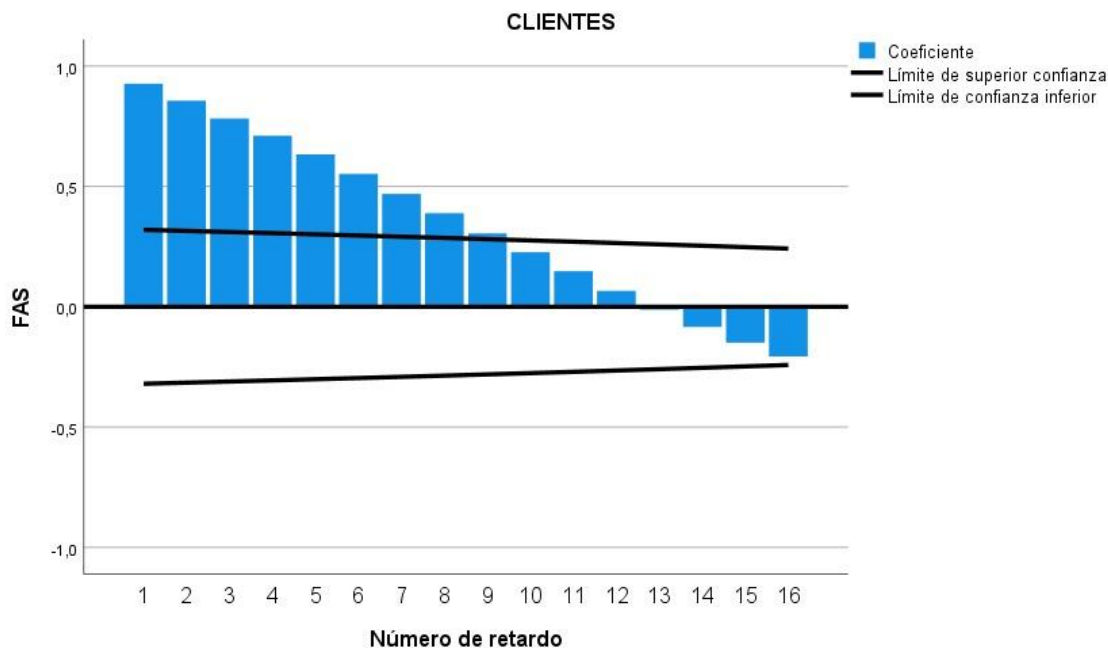
```

### 3.14.2. Análisis de autocorrelación de los clientes

Con los datos históricos de los clientes de manera mensual durante los últimos 3 años. Se realiza el análisis de autocorrelación, como se puede ver en la figura 15 los retardos son lejanos a cero. Dejando en evidencia que el número de consumidores que utilizan agua potable aumenta año tras año, es decir posee tendencia positiva.

**Figura 15**

*Autocorrelación de los clientes mensuales*



Para un análisis más detallado se realizó la prueba de Dickey-Fuller aumentada, misma que se realizó con la demanda de agua potable. Los resultados obtenidos se pueden observar en la figura 16. En el que su resultado es que los clientes mensuales no son de tipo estacionaria, es decir no presentan patrones similares en ciertas épocas del año a diferencia de la demanda de agua potable que, en ciertos meses del año presenta similitud por parte del consumo de este recurso hídrico.

## Figura 16

### *Prueba de Dickey-Fuller los clientes mensuales*

```

Augmented Dickey-Fuller Test

data: serie
Dickey-Fuller = -2.8407, Lag order = 3, p-value = 0.246
alternative hypothesis: stationary

>
> # Interpretar el resultado de la prueba
> if (adf.test(serie, alternative = "stationary")$p.value < 0.05) {
+   print("La serie temporal es estacionaria.")
+ } else {
+   print("La serie temporal no es estacionaria.")
+ }
[1] "La serie temporal no es estacionaria."

```

### 3.15. Análisis de estacionalidad de la serie de tiempo

El análisis estacional se desarrolló empezando por los datos recopilados entre 2020 y 2022 a partir del consumo mes a mes de agua potable y clientes mensuales, lo que le permite observar su comportamiento a lo largo del tiempo e identificar sus patrones utilizando el software R Studio.


#### *3.15.1. Análisis de estacionalidad de la demanda mensual de agua potable*

El análisis de estacionalidad se desarrolla con base en los datos recopilados sobre el consumo de agua potable de 2020 a 2022. Como se puede observar en la figura 17, los meses en general presentan mayor similitud dejando de lado el mes de mayo y junio. Es importante señalar que a partir del mes de octubre la demanda comienza a descender debido al mantenimiento anual realizado por la empresa en las plantas de tratamiento.



**Figura 17**

*Análisis de estacionalidad de la demanda de agua potable*




### 3.15.2. Análisis de estacionalidad de los clientes mensuales

Para el análisis estacional de los clientes mensuales de la empresa, no es posible identificar patrones adoptados durante los 3 años, debido a que estos van aumentando año a año. Como puede verse en la Figura 18, no asume ningún patrón en el tiempo.

**Figura 18**

*Análisis de estacionalidad de los clientes mensuales.*



## Capítulo IV MODELO DE PRONÓSTICO

Para elegir el modelo de pronóstico adecuado, se recopilan los datos de una serie temporal para alimentar y entrenar los modelos de predicción necesarios. En este caso, los datos corresponden al consumo mensual de agua desde el año 2020 hasta el 2022. Antes de ejecutar los modelos de pronóstico, se analiza la autocorrelación y estacionalidad de la serie de tiempo.

Con la finalidad de lograr un pronóstico cercano a la realidad y con un error mínimo, se entrena la red neuronal y se ajusta el número de entrenamientos en función de la rapidez con la que disminuye el error, lo que permite obtener una predicción más precisa.

### 4.1. Selección de variable

Se tomaron datos históricos sobre la demanda de agua potable para garantizar que el modelo funcione correctamente y realice predicciones precisas. Estos valores se utilizan como entrada a varios modelos para generar pronósticos apropiados.

- Variable que pronosticar: Demanda de agua potable de EPAA-AA
- Tipo de variable: Numérica o cuantitativa
- Unidad de medida: Miles de metros cúbicos

### 4.2. Obtención de datos

EPAA-AA registra el número de clientes que utilizan el servicio básico y la cantidad de metros cúbicos que generan, la cual se toma de la base de datos interna de la empresa.

La Tabla 8 indica el número de clientes que requieren este recurso por mes, y la [Tabla 1](#) muestra el consumo por parte de la población.

**Tabla 8**

*Clientes mensuales del año 2020 al 2022.*

Mes	2020	2021	2022
-----	------	------	------

Enero	13229	13536	14150
Febrero	13251	13602	14176
Marzo	13276	13646	14196
Abril	13284	13701	14255
Mayo	13290	13741	14262
Junio	13310	13772	14297
Julio	13326	13823	14333
Agosto	13385	13882	14342
Septiembre	13415	13918	14350
Octubre	13460	13991	14434
Noviembre	13491	14052	14450
Diciembre	13502	14105	14517
<b>Total</b>	<b>160219</b>	<b>165769</b>	<b>171762</b>

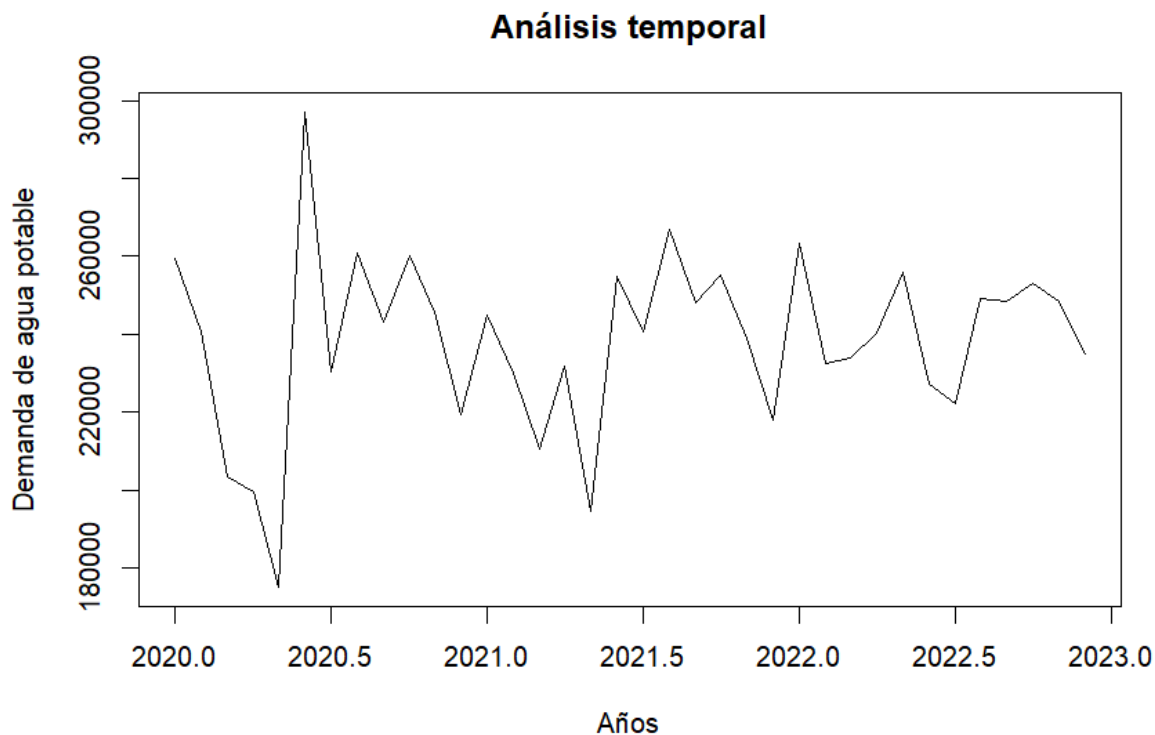
*Nota:* Elaboración propia.

### 4.3. Estructura de los modelos

Las series temporales se utilizan para estudiar la evolución de una o más variables a lo largo del tiempo. En este caso, corresponde a la demanda mensual de agua potable en metros cúbicos del 2020 al 2022. En la figura 19 podemos observar la evolución que ha tenido la demanda de agua potable en el cantón de Antonio Ante. Se describen claramente los altos y bajos que tienen debido al consumo diferenciado que ha tenido por parte de la población.

**Figura 19**

*Análisis de la serie temporal de la demanda de agua potable.*




#### 4.4. Análisis de tendencia y estacionalidad

Los datos históricos de demanda de agua potable muestran un incremento a lo largo del año, pero una tendencia anual negativa hacia el final del año debido al mantenimiento del sistema de distribución utilizado por la empresa para brindar el servicio. Es decir, el consumo no es constante, sino que cambia según la temporada, a pesar de eso se puede ver claramente que aumenta con el transcurso del tiempo. Este comportamiento se puede observar en la figura 20 correspondiente al análisis de tendencia de la serie temporal.

**Figura 20**


*Análisis de tendencia de la serie temporal de la demanda de agua potable.*



Dividiendo la serie temporal, se puede observar que, en los tres años analizados, el consumo de agua potable de los habitantes del cantón en determinadas épocas del año sigue un patrón similar, lo que indica evidentes cambios estacionales. Este patrón se puede identificar en la figura 21 del análisis de estacionalidad.

**Figura 21**

*Análisis de estacionalidad de la serie temporal de la demanda de agua potable.*



#### 4.5. Pronóstico de la red neuronal

El objetivo de esta investigación es pronosticar la demanda de agua potable con una base de datos de consumo histórico en miles de metros cúbicos de 2020 a 2022. Las variables de entrada corresponden a los 12 meses del año. El modelo comienza con la mejor red neuronal y determina la cantidad de iteraciones necesarias para minimizar el MSE (error cuadrático medio). El número de redes a entrenar dependerá del tamaño del error, es decir, si el error es grande, es necesario realizarlo repetidas veces para reducirlo. Por lo tanto, aumentar el número de repeticiones en el entrenamiento conduce a una disminución del MSE y, como resultado de esto, mejora la precisión de la predicción.

El proceso comienza con la primera iteración (fit1), donde se identifican las predicciones generadas por la red neuronal, se calcula el error MSE y genera una gráfica del pronóstico resultante de la red MLP. Además, la estructura de capas y nodos de la red neuronal utilizada en el modelo se muestra en las figuras 22 y 23.


## Figura 22

*Codificación de la red neuronal automática.*

```
#Entrenamiento automático
Fit1<- mlp(y*2, reps = 200, lags =NULL,difforder = NULL,hd.max = NULL)
plot(Fit1)
forecast(Fit1)
print(Fit1)
plot(forecast(Fit1))
```

## Figura 23

*Pronóstico de la red MLP.*



Sin embargo, es necesario realizar modificaciones en el número de capas y neuronas dentro de la red neuronal para minimizar el error obtenido por el entrenamiento automático. Por lo que,

se definió un número de 3 capas ocultas, con 26, 28 y 24 nodos respectivamente. Con dicha configuración se obtuvo una disminución del error significativo lo que hace que el pronóstico tome el camino correcto. Este cambio se describe en la figura 24.

### Figura 24

*Codificación de la red neuronal modificada.*


```
#Entrenamiento modificado
Fit01_1<- mlp(y*2, reps = 200, hd=c(26,28,24), sel.lag =FALSE, lags = 1:12)
plot(Fit01_1)
forecast(Fit01_1)
print(Fit01_1)
plot(forecast(Fit01_1))
```

### 4.6. Estructura de la red neuronal MLP

El modelo utilizado en este modelo es un perceptrón multicapa que contiene una capa de entrada, tres ocultas y una de salida, todas entrelazadas. La capa de entrada consta de 12 nodos circulares, la capa oculta consta de 26, 28 y 24 nodos y la capa de salida consta de un nodo. La estructura se muestra en la figura 25.

### Figura 25

*Estructura de las capas de la red.*





Cada nodo circular de la red neuronal simboliza una neurona artificial, mientras que las líneas que los conectan representan las conexiones entre ellos. De esta forma, la información procesada por cada neurona pasa a través de estas conexiones a la siguiente, y el resultado final es una predicción de demanda de agua potable.

#### 4.7. Pronóstico con la mejora del entrenamiento de la red

A medida que mejore el entrenamiento de la red, se espera que las predicciones de la demanda de agua potable sean más precisas y menos propensas a errores que las obtenidas durante la etapa inicial. Esto se logra a través de múltiples iteraciones, donde los pesos y sesgos de las neuronas de la red neuronal se ajustan para minimizar el error cuadrático medio (MSE).

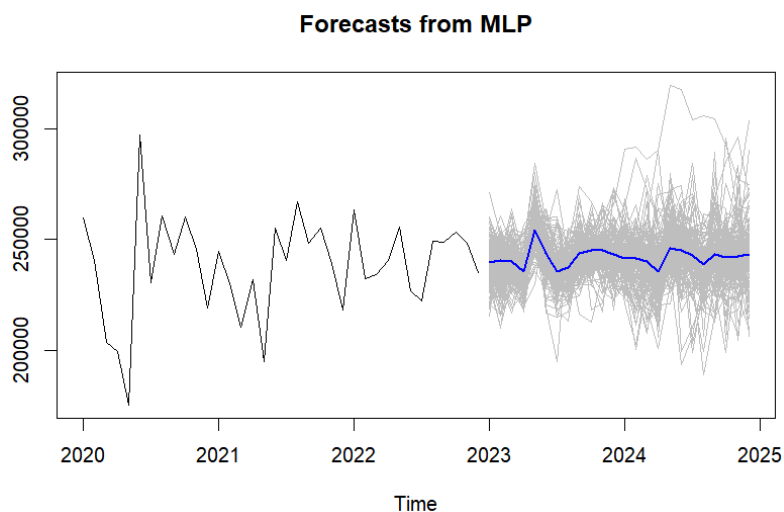
#### Figura 26

*Codificación de la mejora del entrenamiento de la red.*

```
##Mejora de entrenamiento
Fit2<-mlp(y, model=Fit01_1,retrain=20)
print(Fit2)
plot(Fit2)
plot(forecast(Fit2,h=24))
summary(forecast(Fit2,h=24))
```

#### Figura 27

*Pronóstico de la red MLP mejorada.*




Una vez que se completa el entrenamiento de la red neuronal, figura 26, se puede generar un pronóstico de la demanda de agua potable para los dos siguientes años utilizando los datos de entrada proporcionados, visualizado en la figura 27.

#### 4.8. Modelo SARIMA (2,0,2) (1,0,1)

Utilizando la función de predictor en el software Crystall Ball se realizó la configuración respectiva para realizar el pronóstico de la demanda usando el modelo SARIMA. Luego de ingresar todos los elementos necesarios para llevar a cabo la predicción, se obtuvo el siguiente gráfico de resultados representados en la figura 28.

**Figura 28**

*Pronóstico modelo SARIMA (2,0,2) (1,0,1).*



Este programa detecta entre varias técnicas de predicción, el mejor resultado, basándose en diferentes medidas de error, determinado así que la mejor técnica para la base de datos proporcionada por la empresa es el SARIMA (2,0,2) (1,0,1), utilizando como métrica el RMSE.


#### 4.9. Regresión lineal

Con regresión lineal, un método de pronóstico clásico, se utilizó el lenguaje de programación R, en el cual se evaluó de igual manera la base de datos de la demanda de agua

potable, en la que se obtuvo una tendencia positiva. Sin embargo, no identifica ningún patrón de comportamiento de la demanda como podemos ver en la figura 29.

**Figura 29**

*Pronóstico modelo regresión lineal.*



#### 4.10. Resultados de los modelos de pronóstico

Se está evaluando la aplicación de Redes Neuronales Artificiales para generar una predicción cercana a la realidad del cantón.

Utilizando el error cuadrático medio (MSE) como métrica de desempeño. El MSE calcula la diferencia cuadrática promedio entre los valores pronosticados y los reales, y mientras menor sea este parámetro, la predicción tendrá más veracidad.

Se comparó el modelo de RNA con SARIMA (2,0,2) (1,0,1), que también identifica la estacionalidad y tendencia de la serie de tiempo, empleando Crystal Ball.

De mismo modo, se realizó la comparación con la técnica de regresión lineal, un modelo clásico el cual no identifica estacionalidad.


La predicción resultante se refiere a la demanda de agua potable para el período 2023-2024, expresada en metros cúbicos.

#### 4.11. Comportamiento de la demanda

La figura 30 muestra claramente la evolución de la demanda de agua potable en Antonio Ante en los años 2020, 2021 y 2022. La comparación de las predicciones generadas por la red neuronal artificial con los datos de temporadas anteriores mostró que siguió el mismo comportamiento, lo que indica que este modelo es el más adecuado para predecir la demanda futura de agua potable en el cantón.

**Figura 30**

*Comportamiento de la demanda de agua potable.*

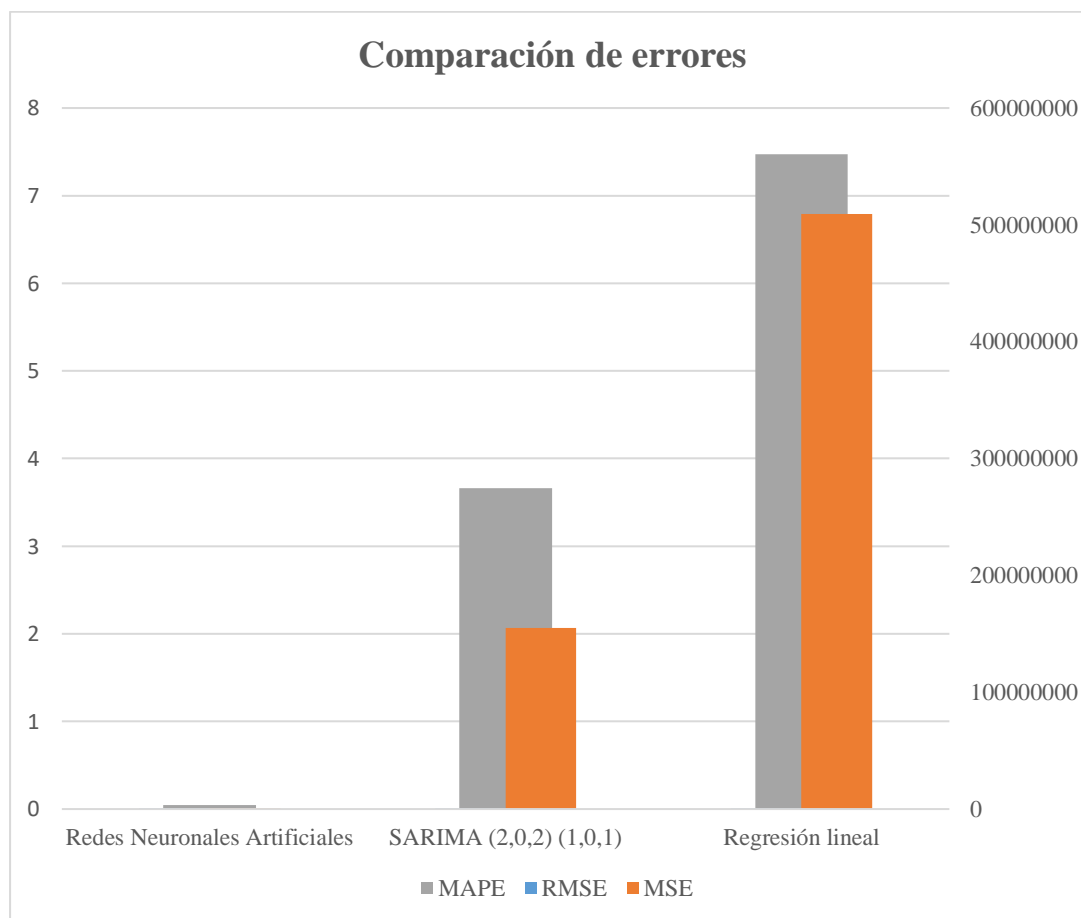




La predicción generada por la Red Neuronal Artificial resulto ser el mejor comparado con la evaluación de otros modelos. Con un RMSE de 148,12, le fue mejor que el SARIMA (2,0,2) (1,0,1), que creó el software Crystal Ball, con un RMSE de 12459,1. Además, el modelo de Regresión Lineal tuvo un valor RMSE de 22570,39. En particular, la evaluación incluyó un modelo que distingue patrones estacionales y de tendencias (SARIMA) y uno que carece de esa capacidad (regresión lineal), para demostrar la importancia de este análisis para la predicción de series temporales, específicamente en lo que respecta al uso de agua potable. Los resultados de cada modelo se pueden encontrar en la Tabla 9, describiendo su demanda pronosticada y los errores correspondientes en la figura 32.

### Figura 32

*Comparación errores de los modelos de pronóstico.*



**Tabla 9***Pronóstico de la demanda de agua potable de los diferentes modelos.*

<b>Año</b>	<b>Mes</b>	<b>Red Neuronal Artificial</b>	<b>SARIMA (2,0,2) (1,0,1)</b>	<b>Regresión lineal</b>
2023	Enero	239799	264529	244437
	Febrero	240343	232406	244768
	Marzo	240078	239233	245099
	Abril	235370	232525	245429
	Mayo	254265	270143	245760
	Junio	243514	225077	246091
	Julio	235397	213946	246421
	Agosto	237463	235714	246752
	Septiembre	243856	243661	247082
	Octubre	245211	248696	247413
	Noviembre	245125	250493	247744
	Diciembre	243431	242068	248074
2024	Enero	241286	252662	248405
	Febrero	241483	230036	248736
	Marzo	240214	235381	249066
	Abril	235657	231221	249397
	Mayo	245886	257885	249728
	Junio	245195	226848	250058
	Julio	242642	219412	250389
	Agosto	238581	234863	250720
	Septiembre	243127	240640	251050
	Octubre	241846	244352	251381
	Noviembre	242315	245778	251711
	Diciembre	243285	240053	252042

*Nota:* Elaboración propia.

## CONCLUSIONES


Una vez revisado el marco teórico, se pudo denotar las características y ventajas que presentan las redes neuronales artificiales frente a los pronósticos con series de tiempo, sus diferentes capacidades de aprendizaje y la adaptabilidad que presentan a la hora de analizar series de tiempo extensas e irregulares.

Las redes neuronales artificiales han logrado tener un menor error frente a las técnicas de pronóstico de Regresión Lineal y SARIMA (2,0,2) (1,0,1), acercándose a la realidad de la empresa con base a los datos históricos de consumo.

La producción mensual de agua que tiene la empresa lograría cubrir la demanda pronosticada con el método de redes neuronales artificiales. Sin embargo, es importante señalar que el porcentaje de continuidad del servicio es el más bajo de la provincia de Imbabura, como podemos ver en la figura 33. Esto implica que la distribución de agua es irregular en el cantón Antonio Ante, provocando desabastecimiento en ciertas épocas del año.

**Figura 33**

*Continuidad del servicio de agua potable en la provincia de Imbabura.*






Nota: Fuente Elaboración propia con datos extraídos de (*BENCHMARKING DE PRESTADORES PÚBLICOS DE LOS SERVICIOS DE AGUA POTABLE Y SANEAMIENTO EN EL ECUADOR.*, 2020-2021)

Debido al desabastecimiento que se produce en Antonio Ante, la empresa debe centrar sus actividades en aumentar su porcentaje de continuidad del servicio juntamente con la reducción de su índice de agua no contabilizada, que es de los más altos que presenta a nivel provincial, representado en la figura 34. Este índice de agua no contabilizada se debe a distintos factores, destacando desvío del recurso hídrico no autorizado en zonas rurales, manipulación de medidores de agua, entre otros.

### Figura 34

*Índice de agua no contabilizada en la provincia de Imbabura.*



Nota: Fuente Elaboración propia con datos extraídos de (*BENCHMARKING DE PRESTADORES PÚBLICOS DE LOS SERVICIOS DE AGUA POTABLE Y SANEAMIENTO EN EL ECUADOR.*, 2020-2021)

La demanda pronosticada de agua en el cantón Antonio Ante tiene tendencia positiva en base a los indicadores analizados, crecimiento poblacional, es decir, se prevé un mayor consumo de agua potable. Por lo tanto, la Empresa Pública de Agua Potable y Alcantarillado de Antonio Ante debe generar soluciones y planes de acción para brindar un servicio de calidad, mantener una continuidad del servicio a lo largo de tiempo y capacidad para cubrir la demanda pronosticada para los dos siguientes años.

## RECOMENDACIONES

Los resultados del modelo de pronóstico pueden servir de apoyo y guía para la ejecución del plan maestro de producción que está diseñando la empresa, este PMP permitiría tener un mayor control de la producción de agua potable y lograr reducir el índice de agua no contabilizada.

La identificación correcta de variables acompañado de una codificación ordenada permite que la red neuronal se entrene de mejor manera, arrojando resultados fiables y acordes con la realidad de la empresa. Se pudo denotar que entre mayor capas y nodos tenga la red neuronal el error será menor.

Para un mejor control interno la empresa debería realizar de manera periódica pronósticos de demanda de agua potable, esto permitirá tomar acciones inmediatas frente a cualquier adversidad.

Para futuras investigaciones sería apropiado que se añadan más variables de estudio para el pronóstico, ya que esto permitirá obtener resultados en base a diferentes características que presente la empresa en ese momento.

## BIBLIOGRAFÍA

- Acevedo, E., Serna, A., & Serna, E. (2017). Principios y características de las redes neuronales artificiales. *Desarrollo e innovación en ingeniería*, 173.
- Adamowski, J., & Chan, H. F. (2011). A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407(1-4), 28-40.  
<https://doi.org/10.1016/J.JHYDROL.2011.06.013>
- AlShafeey, M., & Csáki, C. (2021). Evaluating neural network and linear regression photovoltaic power forecasting models based on different input methods. *Energy Reports*, 7, 7601-7614. <https://doi.org/https://doi.org/10.1016/j.egy.2021.10.125>
- Arroyo Gallardo, J. (2008). Métodos de Predicción para Series Temporales de Intervalos e Histogramas. In. Madrid.
- Babel, M., Das Gupta, A., & Pradhan, P. (2006). A multivariate econometric approach for domestic water demand modeling: An application to Kathmandu, Nepal. *Water Resources Management*, 21, 573-589.
- Bas, M. d. C., Ortiz, J., Ballesteros, L., & Martorell, S. (2017). Evaluation of a multiple linear regression model and SARIMA model in forecasting 7Be air concentrations. *Chemosphere*, 177, 326-333.  
<https://doi.org/https://doi.org/10.1016/j.chemosphere.2017.03.029>
- BENCHMARKING DE PRESTADORES PÚBLICOS DE LOS SERVICIOS DE AGUA POTABLE Y SANEAMIENTO EN EL ECUADOR.* (2020-2021). Agencia de Regulación y Control

de Agua. <http://www.regulacionagua.gob.ec/boletin-estadistico-agua-potable-y-saneamiento/>

Bonilla Pastor, E. (2015). La gestión de la calidad y su relación con los costos de desechos y desperdicios en las mypes de la confección textil. *Ingeniería Industrial*, 33, 37-50.

Box, G., Jenkins, G., Reinsel, G., & Ljung, G. (2015). *Time Series Analysis: Forecasting and Control*, 5th Edition (5 ed.).

Bravo, E. F. C. (2009). *Una aproximación práctica a las redes neuronales artificiales*. Universidad del Valle.

Bravo Sanzana, M., Salvo Garrido, S., & Muñoz Poblete, C. (2015). Profiles of Chilean students according to academic performance in mathematics: An exploratory study using classification trees and random forests. *Studies in Educational Evaluation*, 44, 50-59. <https://doi.org/10.1016/J.STUEDUC.2015.01.002>

Carmona-Benítez, R. B., & Nieto, M. R. (2020). SARIMA damp trend grey forecasting model for airline industry. *Journal of Air Transport Management*, 82, 101736. <https://doi.org/https://doi.org/10.1016/j.jairtraman.2019.101736>

Chapman, S. N. (2006). *Planificación y control de la producción* (1 ed.). Pearson Educación.

Choi, T.-M., Yu, Y., & Au, K.-F. (2011). A hybrid SARIMA wavelet transform method for sales forecasting. *Decision Support Systems*, 51(1), 130-140. <https://doi.org/https://doi.org/10.1016/j.dss.2010.12.002>

- Constitución de la República del Ecuador*. (2008). Ministerio de Defensa del Ecuador Retrieved from [https://www.defensa.gob.ec/wp-content/uploads/downloads/2021/02/Constitucion-de-la-Republica-del-Ecuador\\_act\\_ene-2021.pdf](https://www.defensa.gob.ec/wp-content/uploads/downloads/2021/02/Constitucion-de-la-Republica-del-Ecuador_act_ene-2021.pdf)
- D' Alessio Ipinza, F. (2002). *Administracion y Direccion de la Produccion: enfoque estratégico y de calidad* (2 ed.). Pearson Prentice Hall.
- Dudek, G. (2016). Pattern-based local linear regression models for short-term load forecasting. *Electric Power Systems Research*, 130, 139-147.  
<https://doi.org/https://doi.org/10.1016/j.epsr.2015.09.001>
- Díez, R. P., Gómez, A. G., & de Abajo Martínez, N. (2001). *Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*. Universidad de Oviedo.
- Fang, T., & Lahdelma, R. (2016). Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system. *Applied Energy*, 179, 544-552. <https://doi.org/https://doi.org/10.1016/j.apenergy.2016.06.133>
- Farrera Gutiérrez, A. (2013). *Manual de pronósticos para la toma de decisiones*. Editorial Digital Tecnológico de Monterrey.
- Fritz, M. (2022). Improved output gap estimates and forecasts using a local linear regression. *International Economics*, 172, 157-167.  
<https://doi.org/https://doi.org/10.1016/j.inteco.2022.09.007>

Gaither, N., & Frazier, G. *Administración de producción y operaciones* (8 ed.). Soluciones Empresariales.

García, E. A., & Osella Massa, G. L. (2003). Evolución de Redes Neuronales mediante Sistemas de Reescritura. In.

Gorgas García, J., Cardiel López, N., & Zamorano Calvo, J. (2011). *Estadística básica para estudiantes de ciencias*.

Gutiérrez, A. F. (2013). *Manual de pronósticos para la toma de decisiones*. Editorial Digital del Tecnológico de Monterrey.

Habadi, M., & Tsokos, C. (2017). Statistical Forecasting Models of Atmospheric Carbon Dioxide and Temperature in the Middle East. *Journal of Geoscience and Environment Protection*, 5(10).

Hanke, J. E., & Wichern, D. W. (2010). *Pronósticos en los negocios* (9 ed.). Pearson Educación.

Heizer, J., & Render, B. (2007). *Dirección de la producción y de operaciones. Decisiones estratégicas* (8 ed.). Pearson.

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 Gonzáles, J. R., & Martínez Hernando, V. J. (1995). *Redes Neuronales Artificiales: Fundamentos, modelos y aplicaciones* (1 ed.).

Hu, W., Tong, S., Mengersen, K., & Connell, D. (2007). Weather Variability and the Incidence of Cryptosporidiosis: Comparison of Time Series Poisson Regression and SARIMA Models. *Annals of Epidemiology*, *17*(9), 679-688.

<https://doi.org/https://doi.org/10.1016/j.annepidem.2007.03.020>

Hyndman, R. J. (2014). *Forecasting: Principles & Practice*.

Ibujés Villacís, J. M., & Benavides Pazmiño, M. A. (2018). Contribución de la tecnología a la productividad de las pymes de la industria textil en Ecuador. *Cuadernos de Economía*, *41*(115), 140-150. <https://doi.org/https://doi.org/10.1016/j.cesjef.2017.05.002>

Isasi Viñuela, P., & Galván León, I. (2004). *Redes Neuronales Artificiales: Un enfoque práctico*.

Jeong, K., Koo, C., & Hong, T. (2014). An estimation model for determining the annual energy cost budget in educational facilities using SARIMA (seasonal autoregressive integrated moving average) and ANN (artificial neural network). *Energy*, *71*, 71-79.

<https://doi.org/https://doi.org/10.1016/j.energy.2014.04.027>

Jere, S., Kasense, B., & Chilyabanyama, O. (2017). Forecasting Foreign Direct Investment to Zambia: A Time Series Analysis. *Open Journal of Statistics*, *4*(8).

Kazemi, A., A, A. F., & Hosseinzadeh, M. (2012). A Multi-Level Fuzzy Linear Regression Model for Forecasting Industry Energy Demand of Iran. *Procedia - Social and Behavioral Sciences*, *41*, 342-348.

<https://doi.org/https://doi.org/10.1016/j.sbspro.2012.04.039>



- Krajewski, L. J., Ritzman, L. P., & Malhotra, M. K. (2013). *Operations management. Processes and supply chains* (10 ed.). Pearson.
- Lindner, C. (2017). Automated Image Interpretation Using Statistical Shape Models. *Statistical Shape and Deformation Analysis: Methods, Implementation and Applications*, 3-32.  
<https://doi.org/10.1016/B978-0-12-810493-4.00002-X>
- Liu, H., Li, C., Shao, Y., Zhang, X., Zhai, Z., Wang, X., . . . Jiao, M. (2020). Forecast of the trend in incidence of acute hemorrhagic conjunctivitis in China from 2011–2019 using the Seasonal Autoregressive Integrated Moving Average (SARIMA) and Exponential Smoothing (ETS) models. *Journal of Infection and Public Health*, 13(2), 287-294.  
<https://doi.org/https://doi.org/10.1016/j.jiph.2019.12.008>
- Liu, H.-C., & Hung, J.-C. (2010). Forecasting S&P-100 stock index volatility: The role of volatility asymmetry and distributional assumption in GARCH models. *Expert Systems with Applications: An International Journal*, 37(7), 4928-4934.
- López, R. F., & Fernández, J. M. F. (2008). *Las redes neuronales artificiales*. Netbiblo.
- Martí Pérez, P. C. (2009). Aplicación de redes neuronales artificiales para predicción de variables en ingeniería del riego: evapotranspiración de referencia y pérdidas de carga localizadas en emisores integrados. In.
- Matich, D. J. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. In.
- Montemayor Gallegos, E. J. (2013). *Métodos de pronósticos para negocios*. Editorial Digital Tecnológico de Monterrey.

Montemayor Gallegos, J. E. (2013). Métodos de pronósticos para negocios.

Mora Escobar, H. M. (2001). *OPTIMIZACION NO LINEAL Y DINAMICA* (2 ed.).

Nacelle, A., & Mizraji, E. (2009). Redes neuronales artificiales. *Núcleo de ingeniería biomédica–Universidad de la Republica Uruguay*.

Nwokike, C. C., Offorha, B. C., Obubu, M., Ugoala, C. B., & Ukomah, H. I. (2020). Comparing SANN and SARIMA for forecasting frequency of monthly rainfall in Umuahia. *Scientific African*, 10, e00621. <https://doi.org/https://doi.org/10.1016/j.sciaf.2020.e00621>

Nyman, R., & Ormerod, P. (2017). Predicting Economic Recessions Using Machine Learning Algorithms.

Ottaviani, F. M., & Marco, A. D. (2022). Multiple Linear Regression Model for Improved Project Cost Forecasting. *Procedia Computer Science*, 196, 808-815. <https://doi.org/https://doi.org/10.1016/j.procs.2021.12.079>

Paredes, A. P., de los Ángeles, J. A. C., Villalobos, A. M. G., & Fonseca, V. J. (2018). Importancia de los pronósticos en la toma de decisiones en las MIPYMES. *Revista GEON (Gestión, Organizaciones Y Negocios)*, 5(1), 97-114.

Render, B., & Heizer, J. (2007). Administración de la producción. *Mexico: Person Educacion*, 263.

Restrepo Leal, D. A., Vilorio Porto, J. P., & Robles Algarín, C. A. (2021). *El camino a las redes neuronales artificiales* (Vol. 0). Editorial Unimagdalena.

Robert Jacobs, F., & Chase, R. B. (2018). *Administración de operaciones: producción y cadena de suministros* (15 ed.). Mc Graw Hill Education.

Rodríguez Aedo, N. C. (2016). PRONÓSTICO DE DEMANDA DE AGUA POTABLE MEDIANTE REDES NEURONALES. In.

Sahoo, G. B., Schladow, S. G., & Reuter, J. E. (2009). Forecasting stream water temperature using regression analysis, artificial neural network, and chaotic non-linear dynamic models. *Journal of Hydrology*, 378(3-4), 325-342.

<https://doi.org/10.1016/J.JHYDROL.2009.09.037>

Sarmiento Maldonado, H. O., & Villa Acevedo, W. M. (2008). INTELIGENCIA ARTIFICIAL EN PRONOSTICO DE DEMANDA DE ENERGIA ELECTRICA: UNA APLICACION EN OPTIMIZACION DE RECURSOS ENERGETICOS. *Revista Colombiana de Tecnologías de Avanzada*, 2(12), 94-100.

Schroeder, R., Meyer Goldstein, S., & Rungtusanatham, J. (2005). *Administración de operaciones: conceptos y casos contemporáneos* (5 ed.). Mc Graw Hill.

Sigauke, C., & Chikobvu, D. (2011). Prediction of daily peak electricity demand in South Africa using volatility forecasting models. *Energy Economics*, 33(5), 882-888.

<https://doi.org/https://doi.org/10.1016/j.eneco.2011.02.013>

Sipper, D., & Bulfin, R. (1998). *Planeación y control de la producción* (1 ed.). Mc Graw Hill.

*Sistema Nacional de Información*. (2021). <https://sni.gob.ec/proyecciones-y-estudios-demograficos>

Spencer, B., Alfandi, O., & Al-Obeidat, F. (2019). Forecasting Temperature in a Smart Home with Segmented Linear Regression. *Procedia Computer Science*, 155, 511-518.

<https://doi.org/https://doi.org/10.1016/j.procs.2019.08.071>

Taha, H. A. (2012). *Investigación de operaciones* (9 ed.). Pearson Educación.

Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: an analysis and review.

*International Journal of Forecasting*, 16(4), 437-450. [https://doi.org/10.1016/S0169-2070\(00\)00065-0](https://doi.org/10.1016/S0169-2070(00)00065-0)

Toro Ocampo, E. M., Mejía Giraldo, D. A., & Salazar Isaza, H. (2004). PRONÓSTICO DE VENTAS USANDO REDES NEURONALES. *Scientia Et Technica*, X(26), 25-30.

Vanegas, J., & Vásquez, F. (2017). Multivariate Adaptive Regression Splines, una alternativa para el análisis de series de tiempo [10.1016/j.gaceta.2016.10.003]. *Gaceta Sanitaria*, 31(3), 235-237. <https://doi.org/10.1016/j.gaceta.2016.10.003>

Vapnik, V. (1999). An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 10(5), 988-999.

Velasco Sánchez, J., & Campins Masriera, J. A. (2013). *Gestión de la producción en la empresa: planificación, programación y control* (1 ed.). Pirámide.

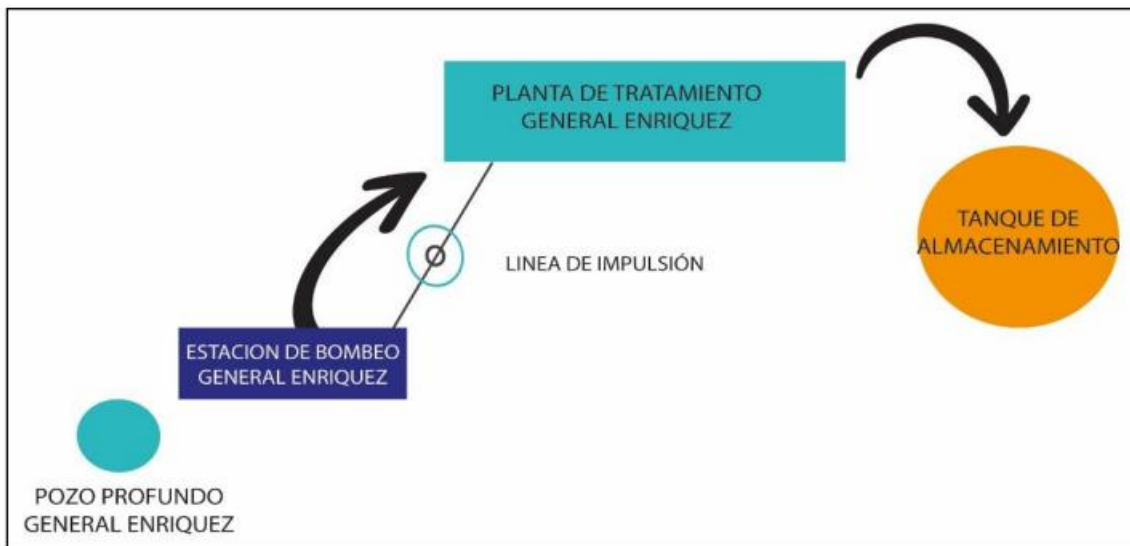

Villada, F., Muñoz, N., & García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. *Información Tecnológica*, 23(4), 11-20.

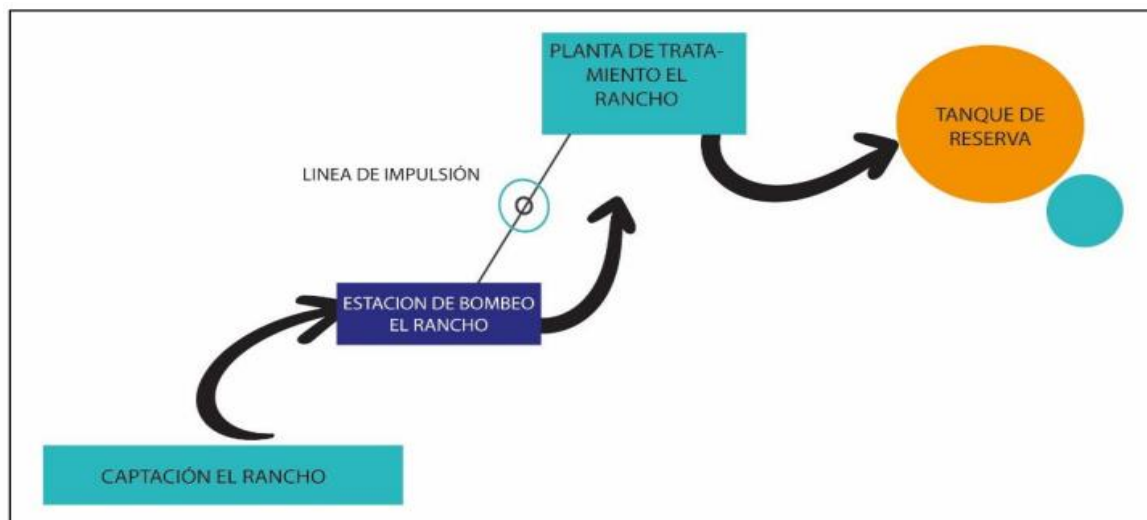
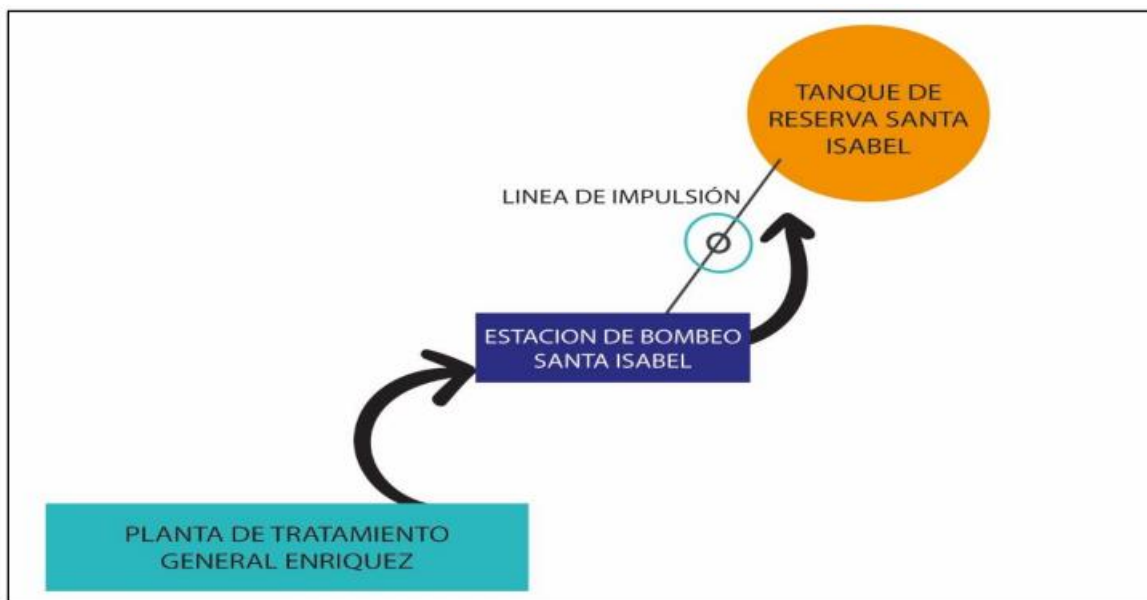
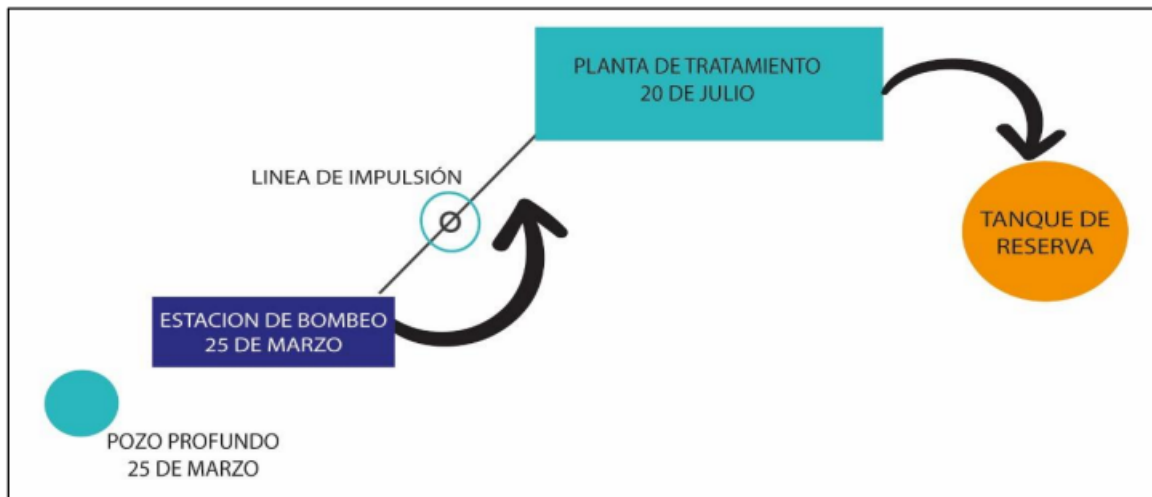
Villarreal, F. (2016). Introducción a los Modelos de Pronósticos. *Univ. Nac. del Sur*, 1-121.

- Vrontos, S. D., Galakis, J., & Vrontos, I. D. (2021). Modeling and predicting U.S. recessions using machine learning techniques. *International Journal of Forecasting*, 37(2), 647-671.  
<https://doi.org/10.1016/J.IJFORECAST.2020.08.005>
- Walpole, R. E., Myers, R. H., Myers, S. L., & Ye, K. (2012). *Probabilidad y estadística para ingeniería y ciencias* (9 ed.). Pearson Educación.
- Wettschereck, D., Aha, D., & Mohri, T. (1997). A Review and Empirical Evaluation of Feature Weighting Methods for a Class of Lazy Learning Algorithms. *Artificial Intelligence Review*, 11(1-5), 273-314.
- Yao, X. (1999). Evolving artificial neural networks. *Proceedings of the IEEE*, 87(9), 1423-1447.
- Zavala Hepp, B. I. (2015). Pronóstico de demanda desagregada para una empresa de productos de consumo masivo. In.
- Zhou, S. L., McMahon, T. A., Walton, A., & Lewis, J. (2002). Forecasting operational demand for an urban water supply zone. *Journal of Hydrology*, 259(1-4), 189-202.  
[https://doi.org/10.1016/S0022-1694\(01\)00582-0](https://doi.org/10.1016/S0022-1694(01)00582-0)

## ANEXOS

## ANEXO A. Sistemas de bombeo de la Empresa Pública de Agua Potable y Alcantarillado.





## ANEXO B. Características de la tubería de las redes.

PARROQUIA	MATERIAL	LONGITUD (m)
ANDRADE MARÍN	PVC	41043.75
	PVC (blanca )	9009.60
	ASBESTO CEMENTO	0.00
	<b>TOTAL</b>	<b>50053.35</b>
ATUNTAQUI	PVC	54110.37
	PVC (blanca )	25463.71
	ASBESTO CEMENTO	3723.67
	<b>TOTAL</b>	<b>83297.75</b>
SAN ROQUE	PVC	72434.05
	PVC (blanca )	11791.59
	ASBESTO CEMENTO	1184.54
	<b>TOTAL</b>	<b>85410.18</b>
NATABUELA	PVC	44055.09
	PVC (blanca )	6582.94
	ASBESTO CEMENTO	2833.52
	<b>TOTAL</b>	<b>53471.55</b>
CHALTURA	PVC	29329.05
	PVC (blanca )	2550.35
	ASBESTO CEMENTO	0.00
	<b>TOTAL</b>	<b>31879.40</b>
IMBAYA	PVC	10984.52
	PVC (blanca)	6732.45
	ASBESTO CEMENTO	0.00
	(*) TUBERÍA POLIETILENO	12213.50
	<b>TOTAL</b>	<b>17716.97</b>
<b>TOTAL PVC</b>		<b>251956.83</b>
<b>TOTAL PVC (blanca )</b>		<b>62130.64</b>
<b>TOTAL ASB. CEMENTO</b>		<b>7741.73</b>
<b>TOTAL TUBERÍA POLIETILENO</b>		<b>12213.50</b>
<b>TOTAL</b>		<b>321829.20</b>



## ANEXO C. Tabla de autocorrelación de la demanda mensual de agua potable.

**Autocorrelaciones**

Serie: CONSUMO

Retardo	Autocorrelación	Error estándar <sup>a</sup>	Estadístico de Box-Ljung		
			Valor	gl	Sig. <sup>b</sup>
1	-,022	,160	,018	1	,892
2	,121	,158	,605	2	,739
3	-,230	,155	2,795	3	,424
4	-,129	,153	3,510	4	,476
5	-,085	,151	3,826	5	,575
6	-,266	,148	7,052	6	,316
7	,058	,146	7,211	7	,407
8	-,096	,143	7,661	8	,467
9	-,003	,140	7,662	9	,569
10	,114	,138	8,350	10	,595
11	-,065	,135	8,578	11	,661
12	,351	,132	15,594	12	,211
13	,049	,130	15,737	13	,264
14	,153	,127	17,192	14	,246
15	-,079	,124	17,601	15	,284
16	-,104	,121	18,335	16	,305

a. El proceso subyacente asumido es independencia (ruido blanco).

b. Se basa en la aproximación de chi-cuadrado asintótica.

## ANEXO D. Tabla de autocorrelación de los clientes mensuales.

**Autocorrelaciones**

Serie: CLIENTES

Retardo	Autocorrelación	Error estándar <sup>a</sup>	Estadístico de Box-Ljung		
			Valor	gl	Sig. <sup>b</sup>
1	,927	,160	33,601	1	<,001
2	,857	,158	63,120	2	<,001
3	,782	,155	88,480	3	<,001
4	,711	,153	110,065	4	<,001
5	,633	,151	127,774	5	<,001
6	,552	,148	141,684	6	<,001
7	,469	,146	152,052	7	<,001
8	,389	,143	159,434	8	<,001
9	,305	,140	164,155	9	<,001
10	,227	,138	166,857	10	<,001
11	,148	,135	168,049	11	<,001
12	,066	,132	168,301	12	<,001
13	-,012	,130	168,310	13	<,001
14	-,084	,127	168,746	14	<,001
15	-,150	,124	170,203	15	<,001
16	-,206	,121	173,113	16	<,001

a. El proceso subyacente asumido es independencia (ruido blanco).

b. Se basa en la aproximación de chi-cuadrado asintótica.

## ANEXO E. Codificación prueba Dickey-Fuller aumentada.

```

# Instalar y cargar el paquete "urca"
library(urca)
library(readxl)
Datos<- read_excel("Datos.xlsx")

# Cargar tus datos en un objeto "serie_temporal"
serie_temporal <- c(Datos$CONSUMO)
serie_temporal

# Realizar la prueba de Dickey-Fuller aumentada
resultado_adf <- ur.df(serie_temporal, type = "drift", selectlags =
"AIC")

# Imprimir los resultados
print(summary(resultado_adf))

# Cargar la biblioteca
library(tseries)

# Crear una serie temporal de ejemplo (reemplaza con tus propios
datos)
serie <- c(Datos$CONSUMO)

# Realizar la prueba de Dickey-Fuller aumentada
adf.test(serie, alternative = "stationary")

# Interpretar el resultado de la prueba
if (adf.test(serie, alternative = "stationary")$p.value < 0.05) {
  print("La serie temporal es estacionaria.")
} else {
  print("La serie temporal no es estacionaria.")
}

```

## ANEXO F. Codificación modelo de pronóstico.

```

library(nnfor)
library(ggplot2)
library(TSstudio)
library(forecast)
library(readxl)
library(tseries)
Datos <- read_excel("Datos.xlsx")
Datos

#convertir la base de datos en serie temporal(ts)
Datosts=ts(Datos$CONSUMO,freq=12,start=c(2020,1))
Datosts

```

```

plot(Datosts, main="Análisis temporal", xlab="Años", ylab="Demanda de
agua potable")
boxplot(Datosts)

adf.test(Datosts)

#Grafico
seasonplot(Datosts, col = rainbow(3), main = "Análisis de
estacionalidad",xlab = "Meses", ylab = "Demanda de agua potable")

#Modelo aditivo
modeloaditivo=decompose(Datosts)
plot(modeloaditivo$trend, main="Análisis de tendencia",
xlab="Años",ylab="Demanda de agua potable")
plot(modeloaditivo$seasonal,main="Análisis estacional", xlab="Años")
#calculando la estacionalidad
ts_seasonal(Datosts,type="all")

#Autocorrelación
acf(Datosts)

#pronosticar la serie
y <- Datosts
y

#las variables de entrada son 12 meses
h <- 1*frequency(y)
frequency(y)

#Entrenamiento automático
Fit1<- mlp(y*2, reps = 200, lags =NULL,difforder = NULL,hd.max = NULL)
plot(Fit1)
forecast(Fit1)
print(Fit1)
plot(forecast(Fit1))

#Entrenamiento modificado
Fit01_1<- mlp(y*2, reps = 200, hd=c(26,28,24), sel.lag =FALSE,lags =
1:12)
plot(Fit01_1)
forecast(Fit01_1)
print(Fit01_1)
plot(forecast(Fit01_1))

##Mejora de entrenamiento
Fit2<-mlp(y, model=Fit01_1,retrain=20)
print(Fit2)
plot(Fit2)
plot(forecast(Fit2,h=24))

```

```
summary(forecast(Fit2,h=24))
```

```
Fit3<-mlp(y, model=Fit2,retrain=20)  
print(Fit3)  
plot(Fit3)  
plot(forecast(Fit3,h=24))  
summary(forecast(Fit3,h=24))
```

```
Fit4<-mlp(y, model=Fit3,retrain=20)  
print(Fit4)  
plot(Fit4)  
plot(forecast(Fit4,h=24))  
summary(forecast(Fit4,h=24))
```